

EVERTON CASTELÃO TETILA

Vencedor do Prêmio
MERCOSUL



**DETECÇÃO E CLASSIFICAÇÃO DE DOENÇAS
E PRAGAS DA SOJA USANDO IMAGENS
DE VEÍCULO AÉREOS NÃO TRIPULADOS E
TÉCNICAS DE VISÃO COMPUTACIONAL**

Atena
Editora
Ano 2023

EVERTON CASTELÃO TETILA

Vencedor do Prêmio
MERCOSUL



**DETECÇÃO E CLASSIFICAÇÃO DE DOENÇAS
E PRAGAS DA SOJA USANDO IMAGENS
DE VEÍCULO AÉREOS NÃO TRIPULADOS E
TÉCNICAS DE VISÃO COMPUTACIONAL**

Atena
Editora
Ano 2023

Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Bruno Oliveira

Camila Alves de Cremona

Luiza Alves Batista

Imagens da capa

Imagem do autor

Edição de arte

Luiza Alves Batista

2023 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2023 Os autores

Copyright da edição © 2023 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo do texto e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva do autor, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos ao autor, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto

Profª Drª Alana Maria Cerqueira de Oliveira – Instituto Federal do Acre

Profª Drª Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie

Profª Drª Ana Paula Florêncio Aires – Universidade de Trás-os-Montes e Alto Douro

Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás

Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná

Prof. Dr. Cleiseano Emanuel da Silva Paniagua – Instituto Federal de Educação, Ciência e Tecnologia de Goiás

Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia
 Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
 Prof^o Dr^a Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro
 Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
 Prof^o Dr^a Glécilla Colombelli de Souza Nunes – Universidade Estadual de Maringá
 Prof^o Dr^a Iara Margolis Ribeiro – Universidade Federal de Pernambuco
 Prof^o Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho
 Prof. Dr. Juliano Bitencourt Campos – Universidade do Extremo Sul Catarinense
 Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
 Prof^o Dr^a Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
 Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá
 Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora
 Prof^o Dr^a Maria José de Holanda Leite – Universidade Federal de Alagoas
 Prof. Dr. Miguel Adriano Inácio – Instituto Nacional de Pesquisas Espaciais
 Prof. Dr. Milson dos Santos Barbosa – Universidade Tiradentes
 Prof^o Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
 Prof^o Dr^a Neiva Maria de Almeida – Universidade Federal da Paraíba
 Prof. Dr. Nilzo Ivo Ladwig – Universidade do Extremo Sul Catarinense
 Prof^o Dr^a Priscila Tessmer Scaglioni – Universidade Federal de Pelotas
 Prof^o Dr Ramiro Picoli Nippes – Universidade Estadual de Maringá
 Prof^o Dr^a Regina Célia da Silva Barros Allil – Universidade Federal do Rio de Janeiro
 Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí
 Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Detecção e classificação de doenças e pragas da soja usando imagens de veículos aéreos não tripulados e técnicas de visão computacional

Diagramação: Camila Alves de Cremo
Correção: Soellen de Britto
Indexação: Amanda Kelly da Costa Veiga
Revisão: O autor
Autor: Everton Castelão Tetila

Dados Internacionais de Catalogação na Publicação (CIP)	
T347	<p>Tetila, Everton Castelão</p> <p>Detecção e classificação de doenças e pragas da soja usando imagens de veículos aéreos não tripulados e técnicas de visão computacional / Everton Castelão Tetila. – Ponta Grossa - PR: Atena, 2023.</p> <p>Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-65-258-0905-2 DOI: https://doi.org/10.22533/at.ed.052232601</p> <p>1. Soja - Doenças e pragas. I. Tetila, Everton Castelão. II. Título.</p> <p style="text-align: right;">CDD 633.34</p>
Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166	

Atena Editora
Ponta Grossa – Paraná – Brasil
Telefone: +55 (42) 3323-5493
www.atenaeditora.com.br
contato@atenaeditora.com.br

DECLARAÇÃO DO AUTOR

O autor desta obra: 1. Atesta não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao conteúdo publicado; 2. Declara que participou ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certifica que o texto publicado está completamente isento de dados e/ou resultados fraudulentos; 4. Confirma a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhece ter informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autoriza a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.

DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.

Este livro é dedicado à minha esposa Juliana e aos meus filhos Caetano e Alice pela paciência e compreensão durante as minhas ausências nesses últimos três anos.

Agradeço ao comitê editorial e a equipe de profissionais da Atena Editora que fizeram sugestões e contribuições indispensáveis para a publicação desta obra.

Ao meu orientador, Prof. Dr. Hemerson Pistori, pela paciência, dedicação e incentivo durante toda a orientação. Agradeço os momentos que passamos juntos, as nossas conversas, críticas construtivas, discussões e reflexões que foram fundamentais para o meu crescimento como pesquisador.

Ao meu coorientador, Prof. Dr. Bruno Brandoli Machado, cuja sábia orientação deu forma ao meu conhecimento dos problemas computacionais. Aos membros da banca examinadora: Dr. Michel Angelo Constantino de Oliveira, Dra. Rúbia Renata Marques, Dr. Jefersson Alex dos Santos e Dr. José Marcato Junior - que fizeram comentários e recomendações importantes.

Aos integrantes do Grupo de Pesquisa e Desenvolvimento INOVISAO¹ da Universidade Católica Dom Bosco (UCDB) que compartilharam suas experiências, dirimindo dúvidas e construindo novos saberes.

Ao Centro Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível superior (CAPES) pela bolsa de Doutorado, à NVIDIA Corporation pela doação da placa de vídeo GPU TITAN V, à Universidade Federal da Grande Dourados (UFGD) pela aquisição do DJI Phantom 4 Advanced, e à Fundação de Apoio ao Desenvolvimento do Ensino Ciência e Tecnologia do estado de Mato Grosso do Sul (FUNDECT) pelo financiamento do projeto que originou este trabalho.

¹ <<http://inovisao.weebly.com/>>

"Não vos conformeis com este mundo, mas transformai-vos pela renovação do vosso espírito, para que possais discernir qual é a vontade de Deus, o que é bom, o que lhe agrada e o que é perfeito".

(Bíblia Sagrada, Romanos 12, 2)

Olá, seja muito bem-vindo!

O texto deste livro é originário de uma tese de doutorado, organizada em uma coletânea de cinco artigos científicos publicados em revistas nacionais e internacionais de alto impacto, disponível no endereço eletrônico: <http://repositorio.ufgd.edu.br/jspui/handle/prefix/2385>. O artigo apresentado no Capítulo 6 foi vencedor do Prêmio Mercosul de Ciência e Tecnologia, Edição 2018, na categoria pesquisador sênior.

Neste livro, estudaremos os conceitos fundamentais necessários para criar uma abordagem de visão computacional que seja capaz de identificar doenças e pragas da soja em um ambiente de campo real, sob diferentes condições de iluminação, tamanho de objeto e variações de fundo. Para tal propósito, serão implementadas e avaliadas diferentes técnicas rasas (SVM, k-NN, Naive Bayes, J48, AdaBoost e Random Forest) e profundas (Inception-V3, Resnet-50, VGG-16, VGG-19, Xception, Inception-Resnet-v2 e DenseNet-201) de aprendizagem de máquina. As imagens capturadas pelo VANT serão submetidas à tarefa de classificação de doenças foliares e espécies de insetos encontrados na soja. Diferentes métricas, como taxa de classificação correta (TCC), medida-F, área sob a curva ROC e tempo para criar o modelo de classificação serão usadas para avaliar o desempenho dos classificadores e verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho.

Este livro está organizado em sete capítulos com os seguintes objetivos:

- Determinar os parâmetros tecnológicos de voo do VANT, como a altura ideal recomendada para a identificação de doenças da soja e o limite de altura mais baixo;
- Verificar se ao catalogar novas doenças da soja e aumentar a quantidade de classes ao dobro existe evidência de diferença significativa da taxa de classificação correta em relação aos classificadores comparados;
- Definir o melhor classificador para o reconhecimento de doenças e quais atributos visuais levam a maiores taxas de classificação correta;
- Avaliar modelos de aprendizagem profunda reconhecidos da literatura, usando imagens capturadas pelo VANT com a altura ideal recomendada para a identificação de doenças. Em seguida, comparar os resultados de desempenho dos modelos de aprendizagem profunda com outras técnicas tradicionais da área;
- Avaliar diferentes estratégias de treinamento para os modelos de aprendizagem profunda, como ajuste fino, transferência de aprendizagem e inicialização de pesos aleatórios, apropriadas para os pro-

blemas abordados;

- Avaliar modelos de aprendizagem profunda reconhecidos da literatura, treinados com diferentes parâmetros de ajuste fino e transferência de aprendizagem, para as tarefas de classificação e contagem de insetos-praga da soja.

Para mais detalhes, vocês podem consultar o meu currículo na plataforma Lattes do CNPq disponível em: <http://lattes.cnpq.br/4761324267689856>

Boa leitura!

Prof. Dr. Everton Castelão Tetila

LISTA DE ABREVIATURAS E SIGLAS	1
RESUMO	2
ABSTRACT	4
CAPÍTULO 1 - INTRODUÇÃO	6
CAPÍTULO 2 - IDENTIFICAÇÃO DE DOENÇAS FOLIARES DA SOJA USANDO IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO	29
Everton Castelão Tetila Bruno Brandoli Machado Nicolas Alessandro de Souza Belete David Augusto Guimarães Hemerson Pistori	
CAPÍTULO 3 - UM SISTEMA DE VISÃO COMPUTACIONAL PARA RECONHECIMENTO DE DOENÇAS DA SOJA USANDO VANTS: RESULTADOS PRELIMINARES.....	43
Everton Castelão Tetila Bruno Brandoli Machado Gercina Gonçalves da Silva Hemerson Pistori	
CAPÍTULO 4 - RECONHECIMENTO AUTOMÁTICO DE DOENÇAS FOLIARES DA SOJA USANDO IMAGENS DE VANT E REDES NEURAIS CONVOLUCIONAIS PROFUNDAS	58
Everton Castelão Tetila Bruno Brandoli Machado Gabriel Kirsten Menezes Adair da Silva Oliveira Júnior Marco Alvarez Willian Paraguassu Amorim Nicolas Alessandro de Souza Belete Gercina Gonçalves da Silva Hemerson Pistori	
CAPÍTULO 5 - DETECÇÃO E CLASSIFICAÇÃO DE PRAGAS DA SOJA USANDO APRENDIZAGEM PROFUNDA COM IMAGENS DE VANT.....	72
Everton Castelão Tetila Bruno Brandoli Machado Gilberto Astolfi Nicolas Alessandro de Souza Belete Willian Paraguassu Amorim Antonia Railda Roel Hemerson Pistori	
CAPÍTULO 6 - UMA ABORDAGEM DE APRENDIZAGEM PROFUNDA PARA CONTAGEM AUTOMÁTICA DE INSETOS-PRAGA NA SOJA.....	99

Everton Castelão Tetila
Bruno Brandoli Machado
Geazy Vilharva Menezes
Nícolas Alessandro de Souza Belete
Gilberto Astolfi
Hemerson Pistori

CAPÍTULO 7 - CONCLUSÕES E TRABALHOS FUTUROS113

REFERÊNCIAS117

ANEXOS..... 122

SOBRE O AUTOR 125

LISTA DE ABREVIATURAS E SIGLAS

ANN	Artificial Neural Network
CCR	Correct Classification Rate
CNN	Convolutional Neural Network
DNG	Digital negative
FT	Fine-Tuning
GSD	Ground Sample Distance
k-NN	k-Nearest Neighbors
MIP	Manejo Integrado de Pragas
NIR	Near Infrared Spectroscopy
RNA	Rede Neural Artificial
RNC	Rede Neural Convolucional
SLIC	Simple Linear Iterative Clustering
SMO	Sequential Minimal Optimization
SVM	Support Vector Machine
TCC	Taxa de Classificação Correta
TL	Transfer Learning
UAV	Unmanned Aerial Vehicle
VANT	Veículo Aéreo Não Tripulado
VIS	Visible Spectroscopy

RESUMO

A soja (*Glycine max*) é uma oleaginosa com bom perfil nutricional e importante respaldo econômico para a indústria alimentícia ao redor do mundo. Desde a semeadura até a colheita, a cultura da soja está sujeita a ataques bióticos de pragas e doenças, podendo ocasionar a depreciação do produto final. Neste trabalho propomos criar um sistema de visão computacional para identificar doenças e pragas na cultura da soja que seja capaz de apresentar ao produtor o nível de infestação de cada região da lavoura para um manejo mais eficiente de suas populações. O sistema proposto baseia-se no método Simple Linear Iterative Clustering (SLIC) para segmentar as folhas das plantas nas imagens da plantação, capturadas por veículos aéreos não tripulados (VANT) de uma linha bastante popular do mercado de VANT, denominada DJI Phantom. Em seguida, técnicas rasas e profundas da aprendizagem de máquina são usadas na classificação de doenças e pragas agrícolas. Na tarefa de classificação de doenças, o desempenho das técnicas de aprendizagem de máquina supervisionada foi avaliado para cinco alturas de voo diferentes: 1, 2, 4, 8 e 16 metros. Com técnicas rasas (SVM, k-NN, Naive Bayes, J48, AdaBoost e Random Forest) e atributos visuais das folhas (cor, gradiente, textura e forma), os experimentos sustentaram a hipótese de que as alturas de voo mais próximas entre o VANT e a planta apresentam maiores taxas de classificação correta (TCC). Para aprendizagem rasa, especificamente usando o classificador SVM, os experimentos alcançaram 98,34% na identificação da doença foliar usando alturas de voo entre 1 e 2 metros, com decaimento de 2% a cada metro, uma vez que a resolução da planta na imagem diminui para uma altura de voo mais alta. Os experimentos também confirmaram que mesmo catalogando novas doenças e aumentando o número de 3 para 6 classes, não houve evidência de diferença estatística significativa das métricas de desempenho para os dados coletados pelo VANT a 2 metros de altura da plantação. Com técnicas de aprendizagem profunda, quatro modelos reconhecidos pela concorrência no ImageNet foram avaliados para o reconhecimento automático de doenças foliares da soja, usando diferentes estratégias de fine-tuning (ajuste fino) e transfer learning (transferência de aprendizagem), sobre um conjunto de 3.000 imagens capturadas em condições reais de campo. Aumento de dados (data augmentation) e função de abandono dropout foram usados durante o treinamento da rede para aumentar a quantidade de dados e eliminar aleatoriamente alguns dos neurônios ocultos na rede, evitando o sobreajuste (overfitting). Os resultados mostraram que os modelos Inception-V3, Resnet-50, VGG-19 e Xception alcançaram taxas de classificação mais altas usando a estratégia de ajuste fino, atingindo 99,04% de amostras classificadas corretamente. Do mesmo modo, os modelos de aprendizagem profunda foram avaliados para a tarefa de classificação de insetos da soja, usando diferentes estratégias de fine-tuning e transfer learning, sobre um conjunto de 5.000 imagens coletadas diretamente do campo com a câmera de um smartphone. Os resultados mostraram que os modelos de aprendizagem profunda treinados com um ajuste fino atingiram maiores taxas de classificação em comparação a outras abordagens, alcançando uma acurácia de até 93,82%. Além disso, os modelos de aprendizagem profunda superaram nos experimentos os métodos de extração de atributos tradicionais, como SIFT e SURF com a abordagem histograma de palavras visuais, o método de aprendizagem semi supervisionada OPFSEImst e os métodos de aprendizagem supervisionada usados para classificar imagens, como SVM, k-NN, Naive

Bayes, J48, AdaBoost e Random Forest. Na tarefa de contagem de insetos-praga, três modelos de aprendizagem profunda foram avaliados. Os pesos da rede neural convolucional (RNC) DenseNet-201 FT - que obteve o maior valor para a acurácia (94,89%) na tarefa de classificação - foram usados em nosso sistema de visão computacional para a contagem dos insetos na imagem, obtida pela adição dos superpixels de cada classe. Deste modo, demonstramos como um modelo de aprendizagem profunda pode ser implementado em um sistema de visão computacional de ponta a ponta para operar em um ambiente de campo real, sob diferentes condições de iluminação, tamanho de objeto e variações de fundo. Na etapa de pós-processamento um mapa colorido é gerado, fornecendo uma classe de cada problema (doença ou praga) por segmento e a soma dos superpixels apresenta ao produtor o nível de infestação de uma região da lavoura, ao classificar os segmentos de uma imagem da plantação. Os resultados indicam que os modelos de aprendizagem profunda podem ser usados com sucesso para apoiar especialistas e agricultores no monitoramento de patógenos e pragas nos campos de soja.

PALAVRAS-CHAVE: Sensoriamento remoto baseado em VANT. doenças foliares da soja. insetos-praga da soja. agricultura de precisão. aprendizagem profunda. visão computacional.

ABSTRACT

Soybean (*Glycine max*) is an oleaginosa with good nutritional profile and important economic support for the food industry around the world. From sowing to harvesting, soybean cultivation can be affected by biotic pest and disease attacks, which may lead to depreciation of the final product. This thesis proposes to create a new system of computational vision to identify diseases and pests in the soybean crop that is able to present to the producer the level of infestation of each region of the field for a more efficient management of its populations. The proposed system is based on the Simple Linear Iterative Clustering (SLIC) method to segment plant leaves in the planting images captured by Unmanned Aerial Vehicles (UAVs) from a very popular UAV market line, called DJI Phantom. Then, shallow and deep techniques of machine learning are used in the classification of diseases and agricultural pests. In the task of disease classification, the performance of supervised machine learning techniques was evaluated for five different flight heights: 1, 2, 4, 8 and 16 meters. With shallow techniques (SVM, k-NN, Naïve Bayes, J48, AdaBoost and Random Forest) and visual attributes of the leaves (color, gradient, texture and shape), the experiments supported the hypothesis that the closest flight heights between the UAV and the plant show higher correct classification rates (CCR). For shallow learning, specifically using the SVM classifier, the experiments reached 98.34% in the identification of foliar disease using flight heights between 1 and 2 meters, with decay of 2% to each meter, since the resolution of the plant in the image decreases to a higher flight height. The experiments also confirmed that even cataloging new diseases and increasing the number of 3 to 6 classes, there was no evidence of significant statistical difference of the performance metrics for the data collected by UAV at 2 meters height of the plantation. With deep learning techniques, four models recognized by the competition in ImageNet were evaluated for the automatic recognition of soybean leaf diseases using different strategies of fine-tuning and transfer learning on a set of 3,000 images captured under real field conditions. Data augmentation and dropout were used during network training to increase the amount of data and randomly eliminate some of the hidden neurons in the network, avoiding overfitting. The results showed that the Inception-V3, Resnet-50, VGG-19 and Xception models achieved higher classification rates using the fine-tuning strategy, achieving 99.04% of correctly classified samples. Likewise, the deep learning models were evaluated for the classification task of soybean insects using different strategies of fine-tuning and transfer learning on a set of 5,000 images collected directly from the field with the camera of a smartphone. The results showed that deep learning models trained with a fine-tuning achieved the highest classification rates compared to other approaches, reaching an accuracy of up to 93.82%. In addition, deep learning models have outperformed traditional features extraction methods such as SIFT and SURF with the bag of visual words approach, the OPFSEMIst semi-supervised learning method, and the supervised learning methods used to classify images, such as SVM, k-NN, Naive Bayes, J48, AdaBoost and Random Forest. In the pest insect counting task, three deep learning models were evaluated. The weights of the DenseNet-201 FT convolutional neural network (CNN) - which obtained the highest value for accuracy (94.89%) in the classification task - were used in our computer vision system for counting insects in the image obtained by adding the superpixels of each class. In this way, we demonstrate how a deep learning model can be implemented in an end-to-end computer vision system to operate in a real

field setting, under different lighting conditions, object size and background variations. In the post-processing stage a color map is generated, providing a class of each problem (disease or pest) per segment and the sum of the superpixels presents to the producer the level of infestation of a crop region by classifying the segments of an image of the plantation. The results indicate that the deep learning models can be successfully used to support specialists and farmers in the monitoring of pathogens and pests in soybean fields.

KEYWORDS: UAV-based remote sensing. soybean leaf diseases. soybean insect pests. precision agriculture. deep learning. computer vision.

CAPÍTULO 1 - INTRODUÇÃO

1.1 MOTIVAÇÃO E RELEVÂNCIA DO PROBLEMA

O estado de Mato Grosso do Sul localiza-se na região Centro-Oeste do Brasil. O cerrado recobre a maior parte do estado que apresenta grande potencial de produção agrícola (soja, celulose, milho, cana-de-açúcar, etc) e pecuária (bovinos, suínos, aves, etc). Essa região caracteriza-se pelos elevados índices de produção agropecuária decorrente de seus solos férteis, com extensas superfícies planas (topografia regular), e condições climáticas favoráveis (na maior parte do território predomina o clima do tipo tropical ou tropical de altitude, com chuvas de verão e inverno seco), aliados a grandes investimentos na moderna tecnologia agropecuária. Além de abastecer a indústria alimentícia, o setor agropecuário também contribui para o abastecimento de outras indústrias, tais como, farmacêutica, cosmética, têxtil e sucroenergética, tornando uma das principais bases da economia brasileira.


A soja (*Glycine max*) é uma oleaginosa com bom perfil nutricional e importante respaldo econômico. “A qualidade nutricional da soja é determinada pelo seu conteúdo de proteínas, ácido graxo insaturado, minerais, vitaminas, isoflavonas e outros oligoelementos encontrados nas sementes frescas” (XING, 2011). Do ponto de vista econômico, a soja é um produto com forte liquidez que tem proporcionado um quadro de suporte dos preços no âmbito interno, reforçando a aposta anual dos produtores no incremento de área plantada. As expectativas para a temporada 2018/19 mantêm a tendência de crescimento, atingindo 1,9% de expansão em relação à safra passada. A estimativa da produção brasileira para a safra 2018/19 é de 114,8 milhões de toneladas do grão, em um plantio de 35,822 milhões de hectares e produtividade média de 3.206 kg/ha. A estimativa da produção de soja corresponde a quase metade da estimativa da safra brasileira de grãos que é de 238,9 milhões de toneladas. No que se refere à produção mundial de soja, Estados Unidos e Brasil, nesta ordem, são os maiores produtores mundiais. Mato Grosso é o estado brasileiro com a maior produção de soja, seguido por Paraná, Rio Grande do Sul, Goiás e Mato Grosso do Sul (CONAB, 2019).

Desde a semeadura até a colheita, a cultura da soja está sujeita a ataques bióticos de patógenos e pragas agrícolas. O conhecimento do dano causado por esses agentes na lavoura é importante para otimizar as aplicações de defensivos agrícolas e, conseqüentemente, reduzir o alto custo do controle químico e o impacto ecológico decorrente da contaminação do ambiente. A aplicação sistemática de defensivos agrícolas caracteriza-se por um considerável desperdício de produtos químicos, mão de obra e energia. Estima-se que a maior parte do montante dos custos diretos para a produção de soja estejam concentrados nos fertilizantes (27,82%), seguidos pelos defensivos agrícolas (18,24%), operações com máquinas (9,10%), sementes (7,35%) e depreciação de máquinas e implementos (6,76%) (CONAB, 2016).

Agentes patógenos e pragas agrícolas estão presentes em diversas regiões produtoras do mundo, causando perda de produtividade em várias cultivares, como milho, soja, trigo e feijão. O monitoramento de doenças e pragas em fases iniciais de epidemias são aspectos fundamentais para a proteção da lavoura (HILLNHUETTER; MAHLEIN, 2008). Antes da adoção de qualquer medida de controle de uma praga agrícola, há necessidade de sua correta identificação. Espécies semelhantes podem apresentar suscetibilidades diferentes a um mesmo produto químico, assim como comportamentos diferentes. No Brasil, já foram identificadas mais de 30 espécies de doenças (EMBRAPA, 2014a) e 40 espécies de insetos causadores de danos na soja (EMBRAPA, 2014b). No entanto, há um grupo menor de doenças foliares causadas por fungos com grande potencial de injúria na soja, tais como, Ferrugem asiática (Figura 1a), Mancha-alvo (Figura 1b), Oídio (Figura 1c), Crestamento foliar de *Cercóspora* (Figura 1d) e Mildio (Figura 1e). Da mesma maneira, Percevejo-marrom (Figura 2a), Percevejo-verde-pequeno (Figura 2b), Percevejo-verde (Figura 2c), Lagarta-da-soja (Figura 2d), Falsa-medideira (Figura 2e) e Heliotines (Figura 2f) são pragas classificadas como de importância primária.

O complexo de lagartas que se alimenta de folhas e os percevejos que sugam os grãos estão entre as principais pragas causadoras de dano econômico, em conformidade com a espécie presente no local, bem como o seu nível populacional. Portanto, o reconhecimento dessas espécies, associado às técnicas de manejo, é fundamental para o controle de doenças e pragas no campo. Além disso, o histórico da área conforme a população de doenças e pragas é uma informação importante para o planejamento de ações preventivas da safra seguinte. A Tabela 1 apresenta as pragas da soja, categorizadas em “principais”, “regionalmente importantes” e “secundárias”, em função da frequência, abrangência e danos provocados na cultura (EMBRAPA, 2013).

Em um adequado programa de controle de doenças e pragas não se recomenda a operação de aplicações de defensivos agrícolas em toda a plantação utilizando uma taxa uniforme (fixa). Essas aplicações geralmente são feitas sem base em critérios de manejo, prevalecendo datas pré-estabelecidas ou calendarizadas. A aplicação de defensivos na área total aumenta os custos de produção e contribui para o desequilíbrio ecológico. Recomenda-se utilizar a quantidade mínima requerida do produto em cada área com o problema identificado, tratando-a de maneira única e diferenciada. Quando se utiliza um produto químico sem que a praga ou doença esteja em nível de dano econômico, aumenta-se a resistência ao princípio ativo por seleção, agravando o problema em médio e longo prazo (TETILA et al., 2017).



(a) Ferrugem asiática (*Phakopsora pachyrhizi*)

(b) Mancha-alvo (*Corynespora cassiicola*)



(c) Oídio (*Microspheera diffusa*)



(d) Crestamento foliar de cercospora (*Cercospora kikuchii*)



(e) Míldio (*Peronospora manshurica*)

Figura 1 – Doenças foliares causadas por fungos com grande potencial de injúria na soja.


Fonte: EMBRAPA (2014a).

O uso abusivo de defensivos agrícolas na lavoura pode provocar diversas perturbações ao meio ambiente como: seleção de pragas e patógenos resistentes, redução de compostos orgânicos e microrganismos, ressurgimento de espécies controladas, surto de pragas de importância secundária, diminuição da população de insetos polinizadores, efeitos deletérios em animais, acúmulo de resíduos tóxicos no solo e nos alimentos, contaminação da água e da fauna aquática, falhas em programas de erradicação química e problemas de ordem econômica e social (PEDIGO; RICE, 2014).




(a) Percevejo marrom (*Euschistus heros*)

(b) Percevejo-verde-pequeno (*Piezodorus guildinii*)



(c) Percevejo verde (*Nezara viridula*)

(d) Lagarta-da-soja (*Anticarsia gemmatilis*)



(e) Falsa-medideira (*Chrysodeixis includens*)

(f) Heliotines (*Helicoverpa armigera*, *H. zea*, *Heliothis virescens*)

Figura 2 – Pragas da soja classificadas como de importância primária.

Fonte: EMBRAPA (2014b).

No campo, a simples observação visual não expressa a população real das pragas presente no plantio. O monitoramento de pragas por via de regra é realizado com base nos princípios do Manejo Integrado de Pragas (MIP) (HOFFMANN-CAMPO, 2000), (CORRÊA-FERREIRA, 2012) que indica o nível de ação de controle conforme a quantidade de insetos identificados no monitoramento. O MIP é um sistema de manejo de pragas que associa o estágio fenológico da planta e a densidade populacional dos insetos para uma tomada de decisão com relação ao controle, mantendo a população dos insetos em níveis abaixo daqueles capazes de causar dano econômico. Essas informações são obtidas em inspeções regulares por amostragem para a verificação do número de insetos encontrados por área e os sintomas de ataque. Assim, deverá ser realizado o controle químico ou biológico somente quando o nível de ação for atingido.

Nome científico	Nome comum	Parte da planta atacada	Observações
Principais			
<i>Anticarsia gemmatalis</i>	Lagarta-da-soja	Fo	
<i>Chrysodeixis includens</i>	Falsa-medideira	Fo	
<i>Helicoverpa armigera</i> , <i>Helicoverpa zea</i> e <i>Heliothis virescens</i>	Heliotines	Fo, Va	Identificação difícil em condições de campo
<i>Euschistus heros</i>	Percevejo marrom	Va, Se	
<i>Piezodorus guildinii</i>	Percevejo verde pequeno	Va, Se	
<i>Nezara viridula</i>	Percevejo verde	Va, Se	
Regionalmente importantes			
<i>Sternechus subsignatus</i>	Tamanduá-da-soja	Ha	Tem alto potencial de dano
<i>Scaptocoris castanea</i> , <i>S. carvalhoi</i> e <i>S. buckupi</i>	Percevejos-castanhos-da-raiz	Ra	Importante na região do cerrado. Tem alto potencial de dano
<i>Phyllophaga cuyabana</i> , <i>Liogenys</i> spp. e <i>Plectris pexa</i>	Corós	Ra	
Secundárias			
<i>Elasmopalpus ligno-sellus</i>	Broca-do-colo	Ha	Importante se ocorrer período seco na fase inicial da cultura
<i>Chalcodermus</i> sp.	Bicudinho	Fo	
<i>Colaspis</i> sp.	Vaquinha	Fo	
<i>Megascelis</i> sp.	Vaquinha	Fo	
<i>Diabrotica speciosa</i>	Patriota	Fo(A), Ra(L)	Mais comum após milho “safrinha”
<i>Cerotoma arcuata</i>	Vaquinha	Fo, Va(A), No(L)	
<i>Diphaulaca viridipennis</i>	Vaquinha azul	Fo	
<i>Aracanthus mourei</i>	Torrãozinho	Co, Fo, Pe	Ocorre no início do desenvolvimento da soja
<i>Spodoptera cosmio-ides</i> , <i>S. eridiana</i> , <i>S. albula</i>	Lagarta-das-vagens	Fo, Va	Insetos com importância crescente
<i>Maruca vitrata</i>	Lagarta maruca	Va	
<i>Etiella zinckenella</i>	Broca das vagens	Va	
<i>Dichelops melacanthus</i> , <i>D. furcatus</i>	Barriga verde	Va, Se	
<i>Edessa meditabunda</i>	Percevejo edessa	Va, Se	

<i>Thyanta perditor</i>	Percevejo faixa-vermelha	Va, Se	
<i>Chinavia</i> spp.	Percevejo acrosterno	Va, Se	
<i>Crocidosema aporema</i>	Broca-das-axilas	Fo, Br, Va	Importância em áreas restritas
<i>Bemisia tabaci</i> Biotipo B	Mosca branca	Fo	Tem alto potencial de dano
<i>Caliothrips braziliensis</i> e <i>Frankliniella schultzei</i>	Tripes	Fj	Vetores de vírus da “queima do broto”; ocorrem em áreas restritas
<i>Ceresa brunnicornis</i> , <i>C. fasciathorax</i>	Búfalo da soja	Pl, Pe	Ocorrem em áreas restritas
	Piolho-de-cobra	Pl, Se, Co	Importante em semeadura direta
	Caracóis e lesmas	Pl, Co, Fj	Importantes em semeadura direta
<i>Dysmicoccus</i> sp. E <i>Pseudococcus</i> sp.	Cochonilhas-da-raiz	Ra	Importantes em semeadura direta
<i>Omiodes indicata</i>	Lagarta-enroladeira	Fo	Pode ocorrer no período reprodu-tivo e causar pequena desfolha
<i>Mononychellus planki</i>	Ácaro verde	Fo	Causa clorose e queda das folhas
<i>Polyphagotarsonemus latus</i>	Ácaro branco	Fo, Pe	Causa bronzeamento das folhas e pecíolos
<i>Tetranychus urticae</i>	Ácaro rajado	Fo	Causa clorose e queda das folhas
<i>Tetranychus gigas</i> , <i>T. ludeni</i> , <i>T. desertorum</i>	Ácaro vermelho	Fo	Causa clorose e queda das folhas

Br = brotos; Co = cotilédones; Fj = folhas jovens; Fo = folhas; Ha = hastes; No =nódulos; Pe = pecíolos;

Pl = plântulas; Pp = plantas pequenas; Ra = raízes; Se = sementes; Va = vagens.

(A) = adulto, (L) = larva.

Tabela 1 – Pragas da soja e a parte da planta que atacam.

Fonte: Embrapa (2013).

O controle biológico é o uso de inimigos naturais geralmente usados para combater pragas e doenças na lavoura, podendo ser aplicados de forma mecanizada ou por Veículos Aéreos Não Tripulados (VANT). Existem dois tipos de biodefensivos: os macrobiológicos, que consistem no uso de macroorganismos, como insetos, ácaros e outros inimigos naturais das pragas; ou microbiológicos, que se baseiam em bactérias, fungos e vírus. A produção de produtos biológicos cresceu mais de 70% em 2018 no Brasil, movimentando R\$ 464,5 milhões ante R\$ 262,4 milhões em 2017. Os produtos biológicos são utilizados em cerca de 10 milhões de hectares, em uma área total plantada de 77,4 milhões de hectares no país. Para 2020, a expectativa é que o setor de biodefensivos fature no mundo US\$ 5 bilhões e US\$ 11 bilhões em 2025 (MAPA, 2019).

O crescimento do mercado brasileiro segue a mesma tendência mundial porque

a demanda do mercado internacional tem colocado cada vez mais restrições ao uso de defensivos químicos para combater pragas e doenças nas lavouras. Apesar do forte crescimento apresentado no último balanço do setor, a produção de produtos biológicos responde por apenas 2% do faturamento total do mercado de controle de pragas e a taxa de adoção em algumas regiões e culturas, como a soja, não chega a 5%. A baixa adesão aos produtos biológicos deve-se a fatores como: disponibilidade do inimigo natural das pragas; amostragem de pragas para determinar o momento certo do controle biológico; déficit de mão de obra especializada para realizar o controle; tempo de armazenamento dos organismos que determina a duração que o produto pode ficar armazenado (MAPA, 2019).


Para avaliar o impacto da utilização do Manejo Integrado de Pragas na cultura da soja, a Embrapa e o Instituto Emater (PR) conduziram na safra 2013/2014 46 Unidades de Referência (URs) em propriedades agrícolas paranaenses. O monitoramento realizado mostrou que o número médio de aplicações de inseticidas nas URs que utilizaram o MIP foi de 2,3 aplicações, enquanto a média estadual foi de 5 aplicações entre os produtores que não utilizaram o MIP. Os resultados indicam que o MIP pode reduzir os custos de produção ao diminuir o número médio de aplicações por pulverização, contribuindo com o equilíbrio ecológico e a preservação do meio ambiente (EMBRAPA, 2015). Por outro lado, inspeções regulares no campo são difíceis de serem realizadas com o MIP quando se tem grandes áreas de cultivo.

Métodos de amostragem, como pano-de-batida, rede-de-varredura, exame visual de plantas e exame de amostras de solo tem sido utilizados no monitoramento de pragas e seus danos na cultura da soja. Outros métodos como o uso de armadilhas atrativas (feromônios, urina bovina, iscas, etc) vem sendo estudados, mas ainda necessitam de pesquisas que viabilizem sua utilização pelo sojicultor (CORRÊA-FERREIRA, 2012). O monitoramento de pragas desde o início do desenvolvimento da soja é muito importante e permite uma aplicação mais eficiente de defensivos agrícolas, visto que os insumos podem ser aplicados na medida e locais corretos, reduzindo-se assim os custos de produção e o impacto ambiental decorrente do uso excedente de controle químico, além de contribuir com a saúde humana e a segurança alimentar (TETILA et al., 2017).

Independentemente do método de amostragem adotado, para se avaliar a infestação de pragas na lavoura, sugere-se que o número de insetos seja anotado em cada ponto de amostragem para que a média de todos os pontos amostrados seja calculada. Quanto maior o número de amostragens realizadas na área, maior a segurança de uma previsão correta da infestação de insetos-praga. Recomenda-se, no mínimo, seis amostragens para lavouras de até 10 hectares; ou oito para lavouras de até 30 hectares; e 10 para lavouras de até 100 hectares. Para propriedades maiores, recomenda-se a divisão por talhões de 100 hectares (EMBRAPA, S.d.).

O método de amostragem mais utilizado para o monitoramento das lagartas

desfolhadoras, dos percevejos sugadores de sementes e insetos de um modo geral é o pano-de-batida. Na época crítica para as pragas, de preferência semanalmente, o pano-de-batida nas medidas de 1,50 metro de comprimento por 1 m de largura é introduzido enrolado entre as fileiras de soja, de forma cuidadosa para não perturbar os insetos presentes na área a ser amostrada, ajustando-se um lado na base das plantas, e o outro estendido sobre as plantas de soja da fileira adjacente (Figura 3a). As plantas presentes em 1 m de fileira são inclinadas sobre o pano e sacudidas vigorosamente (Figura 3b), deslocando-se os insetos para o pano (Figura 3c), os quais são contados e registrados em fichas de monitoramento (Figura 3d). Esse procedimento deve ser repetido em vários pontos da lavoura. O exame de plantas, principalmente das hastes, dos pecíolos, dos ponteiros e das vagens, complementa a amostragem com o pano-de-batida. Detalhes da ficha nas Figuras 4 e 5 (CORRÊA-FERREIRA, 2012). O controle deve ser realizado somente quando forem atingidos os níveis de danos mencionados na Tabela 2 (EMBRAPA, 2013).














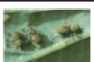
Autor: J. J. da Silva

Figura 3 – Sequência utilizada no uso do pano-de-batida em 1 m de fileira de soja.

Fonte: Corrêa-Ferreira (2012).

MONITORAMENTO DE PRAGAS NA CULTURA DA SOJA - MIP SOJA

Data: _____	Monitor: _____	<input type="checkbox"/> Vegetativo
Propriedade/Município: _____		<input type="checkbox"/> Floração
Cultivar: _____		<input type="checkbox"/> Desenvolvimento de vagens
Data da Semeadura: _____		<input type="checkbox"/> Enchimento de grãos
Lote/Talhão: _____		<input type="checkbox"/> Maturação






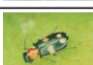
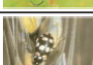






PRAGAS			PONTOS DE AMOSTRAGEM												Nível de controle
Lagartas: Pequenas = menores do que 1,5 cm Grandes = maiores do que 1,5 cm			1	2	3	4	5	6	7	8	9	10	Total	Média	
	Lagarta-da-soja (<i>Anticarsia</i>)	Pequena													20 lagartas > 1,5 cm/m
		Grande													
	Lagarta-falsa-medideira (<i>Chrysodeixis</i>)	Pequena													
		Grande													
	Lagarta-das-vagens (<i>Spodoptera</i> spp.)	Pequena													10 lagartas/m ou 10% de vagens danificadas
		Grande													
	Lagartas do grupo Heliothinae	Pequena													4 lagartas/m - vegetativo
		Grande													2 lagartas/m - reprodutivo
Desfolhamento															30 % até o florescim., ou 15 % após
	Percevejo-verde (<i>Nezara</i>)	Ninfa (3º ao 5º instar)													Lavoura Grão: 2 perc. /m
		Adulto													
	Percevejo-pequeno (<i>Piezodorus</i>)	Ninfa (3º ao 5º instar)													
		Adulto													
	Percevejo-marrom (<i>Euschistus</i>)	Ninfa (3º ao 5º instar)													Lavoura Semente: 1perc. /m
		Adulto													
	Percevejo-barriga-verde (<i>Dichelops</i>)	Ninfa (3º ao 5º instar)													
		Adulto													
Outros Percevejos		Ninfa (3º ao 5º instar)													25 a 30% das plantas c/ ponteiros atacados
		Adulto													
	Broca-dos-ponteiros (<i>Crociosema</i>)	Ponteiros Atacados													
		Nº de Plantas													
	Tamanduá-da-soja (<i>Stemechus</i>)	Adulto													até V3 1 adulto/m V4-V6 2 adultos/m
	Vaquinhas (<i>Diabrotica</i>) (<i>Cerotoma</i>) (<i>Colaspis</i>)	Adulto													Desfolha: 30% até o florescim. ou 15% após
	Torrãozinho (<i>Aracanthus</i>)	Adulto													
Outros Insetos															

Autores: Beatriz S. Corrêa-Ferreira, bscferreira@gmail.com, Daniel R. Sosa-Gómez, Clara Beatriz Hoffman-Campo, Samuel Roggia, Edson Hirose, Adeney de Freitas Bueno, Embrapa Soja.

Figura 4 – Ficha (frente) utilizada no monitoramento dos principais insetos-praga amostrados em soja, para programas de manejo integrado de pragas.

Fonte: Corrêa-Ferreira et al. (2013).

MONITORAMENTO DOS INIMIGOS NATURAIS NA CULTURA DA SOJA

DOENÇAS		PONTOS DE AMOSTRAGEM											
		1	2	3	4	5	6	7	8	9	10	Total	Média
	Lagarta com <i>Nomuraea</i> (doença branca)												
	Lagarta com <i>Baculovirus</i> (doença preta)												
PREDADORES													
	<i>Calosoma granulatum</i>												
	<i>Callida</i> sp.												
	<i>Callida scutellaris</i>												
	<i>Lebia concinna</i>												
	<i>Eriopsis connexa</i>												
	<i>Cycloneda sanguinea</i>												
	<i>Podisus</i> sp.												
	<i>Tropiconabis</i> sp.												
	<i>Geocoris</i> sp.												
	<i>Doru</i> sp. (tesourinha)												
	Aranhas												
	Outros												

Autores: Beatriz S. Corrêa-Ferreira, bscferreira@gmail.com, Daniel R. Sosa-Gómez, Clara Beatriz Hoffman-Campo, Samuel Roggia, Edson Hirose, Adeney de Freitas Bueno, Embrapa Soja.

Figura 5 – Ficha (verso) utilizada no monitoramento dos principais inimigos naturais amostrados em soja, para programas de manejo integrado de pragas.

Fonte: Corrêa-Ferreira et al. (2013).

Emergência	Período vegetativo	Floração	Formação de vagens	Enchimento de vagens	Maturação
30% de desfolha ou 20 lagartas/m*		15% de desfolha ou 20 lagartas/m*			
Lavouras para consumo			2 percevejos/m**		
Lavouras para semente			1 percevejos/m**		
Broca-das-axilas: a partir de 25% - 30% de plantas com ponteiros atacados					
Tamanduá-da-soja: até V3: 1 adulto/m linear de V4 a V6: 2 adultos/m linear					
			Lagartas-das-vagens: a partir de 10% de vagens atacadas		
* Maiores de 1,5cm e considerando a batida de apenas uma fileira de soja sobre o pano.					
** Maiores de 0.5cm e considerando a batida de apenas uma fileira de soja sobre o pano.					

Tabela 2 – Níveis de ação de controle para as principais pragas da soja.

Fonte: Embrapa (2013).

De acordo com a Tabela 2, as lagartas desfolhadoras devem ser controladas quando forem encontradas, em média, 20 lagartas grandes (>1,5 cm) por pano-de-batida (uma fileira de plantas); ou se a desfolha atingir 30% antes da floração; ou, ainda, 15% tão logo apareçam as primeiras flores. Para os percevejos, o controle deve ser iniciado quando forem encontrados dois percevejos adultos ou ninfas com mais de 0,5 cm por metro. Em campos de produção de sementes, o nível deve ser reduzido para 1 percevejo por metro.

No caso das doenças, a disseminação do fungo pode ocorrer pela ação dos ventos, solo contaminado, restos de cultura, chuva, além de outros hospedeiros; a distribuição na lavoura geralmente é observada na forma de reboleiras ou manchas ao acaso. A análise de folhas deve ser considerada como uma prática complementar à análise de solo ou mesmo a outros critérios de avaliação, como a diagnose visual de deficiências ou excesso de nutrientes (avaliação do equilíbrio nutricional). Para a correta utilização da análise foliar, um aspecto importante é a época de amostragem e a escolha do tecido a ser colhido. A época recomendada é quando 50% das plantas do talhão se apresentar em início do florescimento (fase de desenvolvimento R1), que ocorre com o aparecimento de uma flor aberta em qualquer nó da haste principal, até a fase R6 (período de maior ocorrência de doenças na soja), mas podendo se estender até a fase R8 em conformidade com cada doença. A Figura 6 mostra os períodos de ocorrência das doenças da soja. Deve-se colher por talhão em torno de 35 folhas trifolioladas recém-maduras sem pecíolo que, de modo geral, correspondem à terceira ou quarta folha a partir do ápice da haste principal (Figura 7) (CASTRO et al., S.d.).

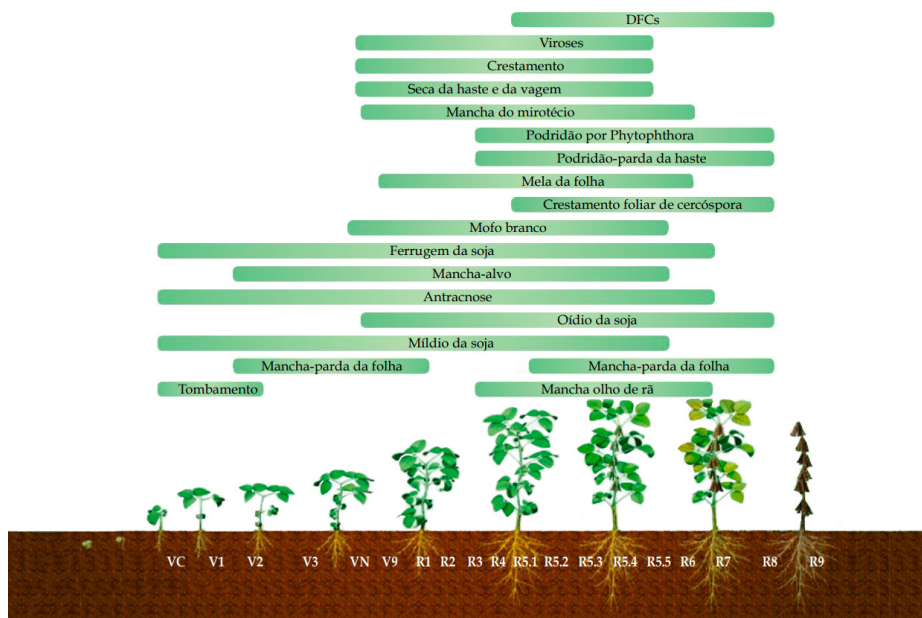


Figura 6 – Períodos de ocorrência das doenças da soja.

Fonte: Adaptado de Saran (2013).




Figura 7 – Terceira ou quarta folhas de soja, que podem ser colhidas para a análise de tecido, na fase de desenvolvimento R1 (início de florescimento).

Fonte: Adaptado de Castro et al. (S.d.).

O sucesso no controle das doenças está intimamente ligado ao período da interferência realizada, seja ela por meio de medidas legislativas e tratos culturais que visam prevenir ou retardar a ocorrência de doenças para a safra seguinte, ou por meio de intervenções químicas aplicadas de forma preventiva ou curativa durante a safra. Nas intervenções químicas, independentemente do método de controle ou dos produtos optados, antes do uso é preciso diagnosticar a verdadeira causa dos sintomas existentes ou antecipar a sua ocorrência, tendo como base alguns procedimentos como a sanidade das sementes, o conhecimento das características das variedades optadas, o histórico de ocorrência nas lavouras e as condições favoráveis para a evolução das doenças (SARAN, 2013).

O vazio sanitário é uma medida fitossanitária de extrema importância para controlar o inóculo da ferrugem asiática durante a entressafra e assim atrasar a ocorrência da doença na safra. O vazio sanitário é o período mínimo de 60 dias sem a cultura e plantas voluntárias no campo. No Brasil, treze estados e o Distrito Federal adotaram essa medida estabelecida por meio de normativas. O fungo que causa a ferrugem-asiática é biotrófico, o que significa que precisa de hospedeiro vivo para se desenvolver e multiplicar. Ao eliminar-se as plantas de soja na entressafra, o ciclo do fungo é quebrado, reduzindo assim a quantidade de esporos presentes no ambiente (EMBRAPA, 2017b).

O vazio sanitário varia de acordo com a janela de cultivo da soja, por isso, há um calendário específico definido pela legislação de cada estado produtor (Figura 8). A calendarização da semeadura da soja é a determinação de data-limite para semear a soja na safra. Essa medida foi estabelecida também por normativas estaduais de sete estados produtores de soja, até o momento: Goiás, Mato Grosso, Paraná, Santa Catarina, Tocantins, Bahia e Mato Grosso do Sul. O objetivo da calendarização é reduzir o número de aplicações de fungicidas ao longo da safra e com isso reduzir a pressão de seleção por resistência do fungo aos fungicidas. Semeaduras tardias de soja podem receber inóculo já nos estádios vegetativos, exigindo a antecipação da aplicação de fungicida e demandando maior número de aplicações. Quanto maior o número de aplicações, maior a exposição dos fungicidas e maior a chance de acelerar o processo de seleção de populações resistentes à esses fungicidas (EMBRAPA, 2017b).




Figura 8 – Calendarização da semeadura da soja.

Fonte: Embrapa (2017b).

O arranjo espacial de plantas de soja, ou seja, a forma como as plantas são dispostas na área, também pode influenciar diretamente nos resultados de produtividade e na incidência de doenças e pragas. Esse arranjo é definido pela densidade de semeadura (plantas por hectare), pelo espaçamento entre as fileiras e pela uniformidade de distribuição de plantas dentro dessas fileiras. O uso de cultivares de soja com crescimento indeterminado e arquitetura compacta de plantas tem aumentado nos últimos anos, estimulando a avaliação de arranjos alternativos, como a semeadura cruzada, a semeadura em covas com sementes agrupadas, a fileira dupla (duas linhas espaçadas de 20 cm, seguido de um espaçamento de 60 cm, retomando com duas linhas de 20 cm) e o espaçamento reduzido (20 a 30 cm entre fileiras). Estudos indicam que o arranjo com melhor resultado para soja

de crescimento indeterminado é o de espaçamento entre 40 e 50 cm de distância entre as linhas, com taxa de semeadura variável, dependendo da cultivar selecionada e da época de semeadura. O arranjo pode alterar o crescimento da cultura, a incidência de estresses bióticos (plantas invasoras, pragas e doenças) e abióticos (déficit hídrico, por exemplo), a qualidade das pulverizações, o acamamento e, conseqüentemente, a produtividade e qualidade dos grãos (EMBRAPA, 2017a).

Embora o ajuste do espaçamento possa conferir ganhos expressivos de produtividade, sem grandes alterações nos custos de produção e nos impactos ambientais, geralmente há maior dificuldade de manejo de algumas doenças e pragas com a redução do espaçamento. Isso ocorre em razão do fechamento rápido das entrelinhas e da menor penetração da radiação solar e dos defensivos agrícolas em lavouras com espaçamento reduzido. Além disso, a redução do espaçamento na soja impossibilita o uso da mesma semeadora para o plantio do milho sem que haja necessidade de reposicionamento das linhas. Por outro lado, em alguns experimentos, ocorreram ganhos de produtividade com o uso do espaçamento reduzido. Esses resultados foram obtidos com o uso de cultivares com plantas compacta (altura inferior a 80 cm), com pouca ramificação e ciclo precoce (inferior a 110 dias entre a semeadura e a colheita) (EMBRAPA, 2017a).

Os ganhos de produtividade agrícola também são suscetíveis à influência de fatores naturais, como clima, solo, pluviosidade, hidrografia, vegetação e relevo. O avanço das tecnologias nas últimas décadas tem diminuído a influência desses fatores naturais com a adoção de técnicas agrícolas como: plantio direto, rotação de culturas, cultivares resistentes, controle químico e biológico, tratamento de sementes, irrigação e fertilização do solo, possibilitando aumentar a produtividade e a lucratividade nas últimas safras (CONAB, 2019).

Um novo paradigma que vem sendo utilizado nos campos de cultivo para aumentar a produção de alimentos e reduzir o impacto ambiental é a Agricultura de Precisão “um sistema de gerenciamento agrícola baseado na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (MAPA, 2012). As tecnologias de Agricultura de Precisão estão difundindo progressivamente o conhecimento da variabilidade espacial das unidades produtivas em todos os seus aspectos, devido às variações de produtividade, solo, relevo, vegetação e também do histórico de uso. Estas diferenças fazem com que produtores e técnicos tratem cada região da lavoura de modo diferenciado, realocando insumos para que sejam diminuídos os desequilíbrios de acordo com as necessidades e potencialidades de cada área. Técnicas de sensoriamento remoto, onde as informações da lavoura são obtidas de forma não-destrutiva, rápida e por vezes à distância (satélite, avião ou VANT), têm sido fundamentais na obtenção e tratamento dos dados de campo. A radiometria espectral é capaz de identificar a intensidade com que cada material, seja um tipo de solo, de rocha ou de vegetação, reflete a radiação eletromagnética em diferentes comprimentos

de onda do espectro. Assim, dados da refletância tem sido associados às características das plantas, como o índice da área foliar, biomassa, porcentagem de cobertura do solo, atividade fotossintética e estresse hídrico (BERNARDI et al., 2014).

Na agricultura, as propriedades da refletância em cada faixa do espectro eletromagnético podem ser melhor avaliadas através de combinações matemáticas de diferentes bandas espectrais. Essas transformações são medidas da atividade da vegetação, especialmente na região do visível e do infravermelho próximo (NIR - *Near Infrared*), e são denominadas de índices de vegetação. A escolha do índice de vegetação mais adequado está relacionada às características que se deseja avaliar. Com base nos índices de vegetação, os insumos (corretivos, fertilizantes e defensivos) podem ser aplicados em taxas variáveis nos pontos localizados com problemas, com o uso de arquivos de dados geoespaciais construídos na forma de mapas de recomendação de aplicação (p. ex. *shapefile*¹), exportados para o maquinário agrícola que utiliza automação baseada em um sistema de posicionamento global (GPS). As tecnologias disponíveis indicam que há potencial para gerar sistemas de recomendação de aplicação de insumos de forma mais eficiente, com alta probabilidade de retorno econômico e baixo impacto ambiental (BERNARDI et al., 2014).

Inovações tecnológicas como Veículos Aéreos não Tripulados (VANT) têm revolucionado a produção de alimentos no campo. Na agricultura de precisão, o uso de VANT tem ajudado no mapeamento/monitoramento do cultivo/colheita de propriedades agrícolas de todos os tamanhos, o que tem contribuído com o aumento da produção de alimentos e a redução dos custos de produção. VANT equipados com câmeras de alta resolução espacial são capazes de sobrevoar uma plantação a poucos metros de distância e capturar imagens RGB em alta resolução. Imagem RGB é a abreviatura de um sistema de cores aditivas em que o Vermelho (Red), o Verde (Green) e o Azul (Blue) são combinados para reproduzir um largo espectro cromático. Esse sistema de cores possui a vantagem de ser reproduzido em vários dispositivos eletrônicos como, monitores de TV e computador, celulares e câmeras digitais, assim como na fotografia tradicional. Sensores RGB geralmente são mais baratos do que os sensores multi-hiperespectrais, podendo ser empregados em larga escala no mercado eletrônico. Além disso, sensores multi-hiperespectrais tem sido propostos para capturar imagens do campo em regiões espectrais específicas que podem variar de acordo com as características espectrais dos alvos e do ambiente. Já as imagens RGB oferecem uma imagem colorida com melhor resolução espacial.

Os VANT também podem ser programados para executar operações de plano de voo automático, com autonomia superior a 1 hora dependendo do modelo, cobrindo áreas médias que podem ultrapassar 1.000 hectares por voo, possibilitando realizar inspeções regulares em grandes áreas e operações com maior periodicidade no acompanhamento

¹ *Shapefile* são arquivos de dados geoespaciais em forma de vetor utilizados para descrever geometrias, como pontos, linhas e polígonos.

de toda a safra. Inspeções regulares com o VANT são imunes à presença de nuvens, o que pode encobrir, total ou parcialmente, características visuais importantes dos alvos. O trabalho realizado com o levantamento aéreo viabiliza a construção de um banco de dados da propriedade (p. ex. histórico de produção, falhas de plantio, fertilidade do terreno, análise de biomassa, identificação de plantas infestantes, doenças e pragas, etc) que auxilia na execução de estratégias futuras. Desse modo, o uso de VANT em campos de cultivo tem sido considerado um importante instrumento para identificar manchas de doenças foliares e pragas na soja, permitindo que agricultores e especialistas tomem melhores decisões de manejo.

Abordagens de aprendizagem de máquina tem sido cada vez mais usadas para extrair padrões e conhecimento de dados geoespaciais. Essas abordagens permitem construir um modelo capaz de generalizar novos exemplos depois de ter experimentado um conjunto de dados de aprendizado considerado representativo dentro do espaço de ocorrência. Abordagens de aprendizagem de máquina, como árvores de decisão, máquinas de vetores de suporte, redes bayesianas e aprendizagem profunda, têm sido estudadas para modelar diferentes tarefas relacionadas à classificação, regressão, agrupamento, entre outras.

As tarefas de aprendizagem de máquina são tipicamente classificadas em três categorias, de acordo com a natureza da aprendizagem: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço. Na aprendizagem supervisionada, um algoritmo aprende a relação de entrada-para-saída após fornecer as entradas e as respectivas saídas. Por exemplo, a entrada pode ser um conjunto de imagens e a saída pode ser um conjunto de rótulos correspondentes. Na aprendizagem não supervisionada, o algoritmo não tem acesso à saída, portanto, o objetivo é inferir a estrutura subjacente dos dados. Por exemplo, o algoritmo poderia separar automaticamente imagens com diferentes propriedades estatísticas ou semânticas. Na aprendizagem por reforço, um algoritmo interage com um ambiente dinâmico em que deve desempenhar determinado objetivo, sendo fornecido ao algoritmo uma realimentação dos acertos e erros na medida em que é navegado o espaço do problema. Entre a aprendizagem supervisionada e a não supervisionada, está a aprendizagem semi supervisionada, quando uma quantidade de exemplos não rotulados é fornecida junto com um conjunto de exemplos rotulados (REICHSTEIN et al., 2019).

Aprendizagem profunda, do inglês *deep learning*, refere-se a modelos computacionais compostos por múltiplas camadas de processamento que aprendem representações de dados com múltiplos níveis de abstração. Esses métodos melhoraram consideravelmente o estado da arte no reconhecimento da fala (HINTON et al., 2012), reconhecimento de objetos visuais (WANG; YEUNG, 2013), detecção de objetos (GIRSHICK et al., 2014), segmentação (LONG; SHELHAMER; DARRELL, 2014), classificação de vídeo (KARPATHY et al., 2014) e muitos outros domínios. A aprendizagem profunda é capaz de descobrir a

estrutura complexa em grandes conjuntos de dados usando o algoritmo *backpropagation* para indicar como uma máquina deve mudar seus parâmetros internos que são usados para calcular a representação em cada camada da representação na camada anterior (LECUN; BENGIO; HINTON, 2015). Diversas arquiteturas de aprendizagem profunda foram propostas na última década para a classificação de imagens em conjunto de dados públicos, como PASCAL VOC, Caffe e ImageNet (IMAGENET, 2016). Essas arquiteturas geralmente são avaliadas e comparadas em cima desses conjuntos de dados e concentram-se em encontrar redes neurais convolucionais de maior desempenho. As melhorias na qualidade da arquitetura da rede geralmente transferem os ganhos de desempenho significativos para uma ampla variedade de domínios de aplicação que dependem cada vez mais de recursos visuais aprendidos de alta qualidade. Particularmente, estamos interessados em arquiteturas do estado da arte que sejam capazes em reconhecer diferentes espécies de doenças e pragas presentes na cultura da soja.

Na literatura, existem vários trabalhos comparando sensores de imagem e métodos de aprendizagem de máquina para identificar doenças em plantas e o ataque de pragas em diferentes culturas. No entanto, poucos deles abordam o uso de imagens coletadas por VANT para identificação de doenças e pragas na soja. A Tabela 3 resume os artigos pesquisados em revisão sistemática para identificação de doenças e pragas em diferentes culturas, relacionando: autor, grupo, cultura, local, dispositivo de aquisição de imagem e método de aprendizagem de máquina.

Autor	Grupo	Cultura	Local	Dispositivo	Método
Tetila et al. (2019)	Doenças	Soja	Brasil	VANT	RNA
Adhikari et al. (2018)	Doenças	Tomate	Nepal	Câmera	RNA
Lu et al. (2018)	Doenças	Tomate	EUA	Câmera	Índices de vegetação
Ferentinos (2018)	Doenças	Diversas	Grécia	Câmera	RNA
Fuentes et al. (2017)	Doenças, Pragas	Tomate	Korea	Câmera	RNA
Tetila et al. (2017)	Doenças	Soja	Brasil	VANT	SVM, k-NN
Bajwa et al. (2017)	Doenças	Soja	EUA	Espectroscópico	Índices de vegetação
Brodbeck et al. (2017)	Doenças	Soja	EUA	VANT	Índices de vegetação
Pires et al. (2016)	Doenças	Soja	Brasil	Scanner	Descritores locais
Mohanty et al. (2016)	Doenças	Diversas	Suíça	Smartphone	RNA
Sladojevic et al. (2016)	Doenças	Diversas	Sérvia	Câmera	RNA
Gui et al. (2015)	Doenças	Soja	China	Câmera	k-means
Pujari et al. (2014)	Doenças	Diversas	Índia	Câmera	RNA
Shrivastava e Hooda (2014)	Doenças	Soja	Índia	Smartphone	k-NN

Tan et al. (2014)	Doenças	Soja	China	Câmera CCD	RNA
Garcia-Ruiz et al. (2013)	Doenças	Citros	EUA	VANT	SVM
Rumpf et al. (2010)	Doenças	Beterraba	Alemanha	Clorofila	SVM
Akintayo et al. (2018)	Pragas	Soja	EUA	Microscópio	RNA
Chen et al. (2018)	Pragas	Soja	China	Câmera	RNA
Maharlooei et al. (2017)	Pragas	Soja	Iran	Câmera	Limiarização
Gedeon et al. (2017)	Pragas	Diversas	Hungria	Sensor opto-eletr.	Infravermelho
Yang, Bao e Liu (2017)	Pragas	Campos de chá	China	Câmera	RNA
Leow et al. (2015)	Pragas	Cadeia marinha	Japão	Microscópio	RNA
Wen et al. (2015)	Pragas	Laboratório	EUA	Câmera	RNA
Ma et al. (2014)	Pragas	Soja	China	Hiperespectral	Fuzzy, SVM
Chelladurai et al. (2014)	Pragas	Soja	Canadá	Fluoroscopia	Índices de vegetação
Barbedo (2014)	Pragas	Soja	Brasil	Câmera	Limiarização
Vakilian e Massah (2013)	Pragas	Soja	Iran	Câmera CCD	RNA
Wang et al. (2012)	Pragas	Diversas	China	Câmera	RNA, SVM
Yaakob e Jain (2012)	Pragas	Cana, algodão	Malásia	Câmera	RNA
Al-Saqer e Hassan (2011)	Pragas	Palmeiras	Arábia	Câmera	RNA

Tabela 3 – Resumo dos artigos pesquisados em revisão sistemática.

Fonte: Produzido pelo autor.

As demandas atuais de eficiência econômica e ambiental da agricultura moderna indicam a necessidade de incorporar novos sistemas inteligentes de automação e manejo capazes de processar os dados coletados em campo para o monitoramento preciso das lavouras. O monitoramento viabiliza a aplicação de insumos em taxas variadas, orientando a gestão dos sistemas agrícolas, em harmonia com as questões ambientais. Além disso, possibilita aumentar a produção de alimentos no campo para atender o crescimento da população mundial. Espera-se que a adoção desses sistemas inteligentes se torne mais comum, eficiente e sustentável do que os sistemas atuais usados em gerenciamento de lavouras.

Neste trabalho propomos criar uma abordagem de visão computacional que seja capaz de identificar doenças e pragas da soja em um ambiente de campo real, sob diferentes condições de iluminação, tamanho de objeto e variações de fundo, usando imagens RGB de alta resolução. Queremos entregar para o produtor uma solução computacional que seja capaz de indicar quais as áreas da plantação sofreram ataques de patógenos (doenças) e pragas em níveis de ação de controle. Por consequência, este trabalho trará contribuições para o setor agropecuário e para o desenvolvimento

local, uma vez que a região será beneficiada com o desenvolvimento de uma importante solução computacional que poderá (1) impulsionar um dos principais setores econômicos, reduzindo a quantidade de aplicações de defensivos agrícolas nos campos de soja; (2) contribuir com o desenvolvimento social, gerando novas vagas de trabalhos de mão de obra especializada com a adoção de novas tecnologias; (3) reduzir o impacto ambiental causado pelo uso excedente de defensivos agrícolas utilizado em toda a plantação a uma taxa uniforme; (4) auxiliar na questão da segurança alimentar e bem-estar social por meio de uma abordagem baseada em alternativas ecologicamente corretas; (5) e contribuir com as políticas nacionais de ciência, tecnologia e inovação com base no Registro do Programa de Computador PYNOVISÃO, protocolado pelo Instituto Nacional da Propriedade Industrial (INPI), Processo N.: BR512019000427-2, disponível em (PYNOVISÃO, 2019).

2 | OBJETIVOS

2.1 Objetivo Geral

Criar uma abordagem de visão computacional que seja capaz de identificar doenças e pragas da soja em um ambiente de campo real, sob diferentes condições de iluminação, tamanho de objeto e variações de fundo. Para tal propósito, serão implementadas e avaliadas diferentes técnicas rasas (SVM, k-NN, Naive Bayes, J48, AdaBoost e Random Forest) e profundas (Inception-V3, Resnet-50, VGG-16, VGG-19, Xception, Inception-Resnet-v2 e DenseNet-201) de aprendizagem de máquina. As imagens capturadas pelo VANT serão submetidas à tarefa de classificação de doenças foliares e espécies de insetos encontrados na soja. Diferentes métricas, como taxa de classificação correta (TCC), medida-F, área sob a curva ROC e tempo para criar o modelo de classificação serão usadas para avaliar o desempenho dos classificadores e verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho. Na etapa de pós-processamento, o sistema de visão computacional deverá gerar um mapa colorido fornecendo uma classe de cada problema (doença ou inseto-praga) por segmento; a soma dos segmentos das categorias de cada problema, ao classificar os segmentos de uma imagem da plantação, deverá apresentar ao produtor o nível de infestação de cada região do campo para um manejo mais eficiente de defensivos agrícolas.

2.2 Objetivos Específicos

Para atingir o objetivo geral, são propostos os seguintes objetivos específicos:

- Determinar os parâmetros tecnológicos de voo do VANT, como a altura ideal recomendada para a identificação de doenças da soja e o limite de altura mais baixo;
- Verificar se ao catalogar novas doenças da soja e aumentar a quantidade de classes ao dobro existe evidência de diferença significativa da taxa de classifi-

cação correta em relação aos classificadores comparados;

- Definir o melhor classificador para o reconhecimento de doenças e quais atributos visuais levam a maiores taxas de classificação correta;
- Avaliar modelos de aprendizagem profunda reconhecidos da literatura, usando imagens capturadas pelo VANT com a altura ideal recomendada para a identificação de doenças. Em seguida, comparar os resultados de desempenho dos modelos de aprendizagem profunda com outras técnicas tradicionais da área;
- Avaliar diferentes estratégias de treinamento para os modelos de aprendizagem profunda, como ajuste fino, transferência de aprendizagem e inicialização de pesos aleatórios, apropriadas para os problemas abordados;
- Avaliar modelos de aprendizagem profunda reconhecidos da literatura, treinados com diferentes parâmetros de ajuste fino e transferência de aprendizagem, para as tarefas de classificação e contagem de insetos-praga da soja.

3 | METODOLOGIA

Na tarefa de classificação de doenças da soja, diversos testes foram realizados para encontrar o melhor desempenho das abordagens propostas, de acordo com as alturas de voo estipuladas para o VANT, variando de 1 a 16 metros. As imagens da plantação foram coletadas em dias, locais e condições climáticas diferentes, entre os estádios fenológicos R1 e R6, considerados de grande ocorrência de doenças e pragas na soja. Para identificar as manchas de doenças foliares e os insetos na soja, cada imagem capturada pelo VANT foi segmentada usando o método de segmentação SLIC Superpixels, e assim, as folhas das plantas foram usadas como amostras de imagens para diferentes classes de doenças e insetos, tais como, Ferrugem asiática, Mancha-alvo e Percevejo marrom, Lagarta-da-soja.

Com apoio de um engenheiro agrônomo responsável técnico, cada imagem foi anotada para construir o conjunto de dados de imagem. Depois, o modelo de aprendizagem de máquina foi treinado para a tarefa de classificação de imagens de doenças e pragas da soja. Diferentes métodos de extração de atributos visuais foram testados para descrever as características de propriedades físicas da folha, como cor, gradiente, textura e forma. Igualmente, diversas técnicas de classificação conhecidas da literatura especializada tiveram os desempenhos avaliados experimentalmente para revelar quais técnicas obtém o melhor desempenho para o reconhecimento automático de doenças e pragas na soja.

Para o treinamento e teste dos classificadores foi usada uma validação cruzada de 10 dobras estratificada. Neste esquema, as imagens do conjunto de dados são particionadas em 10 dobras, garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para teste, enquanto as dobras restantes são usadas para treinar o classificador. O processo é repetido 10 vezes usando cada dobra exatamente uma vez para o teste. Finalmente, o desempenho da métrica é dado pela média das 10 rodadas.

Para cada modelo de aprendizagem de máquina, nós calculamos os desempenhos médios das métricas: taxa de classificação correta, tempo de processamento, medida-F e área sob a curva ROC.

Os algoritmos usados nos experimentos foram avaliados estatisticamente em relação ao desempenho com o teste de hipóteses ANOVA, considerando-se cada uma das métricas avaliadas e o conjunto de dados de imagem. ANOVA, ou análise de variância, é uma técnica estatística que permite verificar se existe uma diferença significativa entre as médias de populações. A análise de variância é utilizada quando se quer decidir se as diferenças amostrais observadas são reais (causadas por diferenças significativas nas populações observadas) ou casuais (decorrentes da mera variabilidade amostral). Portanto, essa análise parte do pressuposto que o acaso só produz pequenos desvios, sendo as grandes diferenças geradas por causas reais (MILONE, 2003). Nos experimentos, relatamos os valores-*p* encontrados para cada métrica e usamos um nível de significância de 5% para descartar a hipótese nula. Os valores-*p* foram analisados com o pós-teste de *Tukey* para comparação das variáveis entre os grupos.

Também usamos o diagrama de caixa (*boxplot*) para analisar e comparar a dispersão das variáveis observadas por meio de quartis entre os diferentes grupos de dados. Os espaços entre as diferentes partes da caixa (onde estão localizados 50% dos valores mais prováveis) indicam o grau de dispersão com a mediana em destaque, a obliquidade (medida da assimetria de uma distribuição) nos dados e os *outliers* (valores extremos). O teste de hipóteses ANOVA e o diagrama de caixa (*boxplot*) foram analisados no software estatístico *RStudio*, versão 1.0.136.

As Seções Materiais e Métodos dos Capítulos 2, 3, 4, 5 e 6 descrevem com maiores detalhes o objeto de estudo, o delineamento da pesquisa, os procedimentos utilizados (coleta de dados, variáveis analisadas, avaliações realizadas, etc) e os testes estatísticos utilizados na análise dos dados.

4 | ESTRUTURA DO TRABALHO

Este trabalho está organizado em formato de múltiplos artigos, dividido em sete capítulos.

O Capítulo 2 apresenta um artigo publicado na revista *IEEE Geoscience and Remote Sensing Letters* (Fator de Impacto: 3.534) com uma abordagem proposta baseada no método de segmentação SLIC para identificar doenças foliares da soja usando VANT. Os experimentos sustentaram a hipótese de nossa abordagem que as alturas mais próximas entre o VANT e a planta apresentam maiores taxas de classificação, alcançando 98,34% na identificação da doença foliar utilizando alturas entre 1 e 2 m, com decaimento de aproximadamente 2% a cada metro.

O Capítulo 3 mostra um artigo publicado no Workshop de Visão Computacional e

introduz a mesma proposta baseada no método SLIC, no entanto, novas doenças foram catalogadas aumentando o número de 3 para 6 classes, no intuito de avaliar o potencial da abordagem proposta para múltiplas classes – artigo este que foi premiado como o melhor artigo do evento (*best paper award* – ANEXO A). Resultados experimentais mostraram que não existe evidência de diferença significativa da taxa de classificação correta, em relação aos classificadores comparados, ao catalogar novas doenças da soja e aumentar a quantidade de classes ao dobro.

O Capítulo 4 é um artigo publicado na revista *IEEE Geoscience and Remote Sensing Letters* que compara o desempenho de quatro modelos de aprendizagem profunda para a tarefa de reconhecimento de doenças foliares da soja. Resultados experimentais mostraram que os modelos de aprendizagem profunda levam a altas taxas de classificação, atingindo uma acurácia de até 99,04%. Também demonstramos como um modelo de aprendizagem profunda pode ser implementado em um sistema de visão computacional para operar em um ambiente de campo real, sob diferentes condições de iluminação, tamanho do objeto e variações de fundo.

O Capítulo 5 compara o desempenho de cinco arquiteturas de aprendizagem profunda com outras técnicas de aprendizagem de máquina para a tarefa de detecção e classificação de pragas da soja. Recentemente, este artigo foi publicado na revista *Computer and Electronics in Agriculture* (Fator de Impacto: 3.171).

O Capítulo 6 propõe uma nova abordagem para contagem automática de pragas da soja no campo. Neste artigo foi demonstrado como um modelo de aprendizagem profunda pode ser implementado no sistema de visão computacional PYNOVISÃO (ANEXO B) para a contagem de insetos-praga e calcular o nível de infestação de uma área de cultivo. Este artigo foi publicado na revista *IEEE Geoscience and Remote Sensing Letters* e também foi o vencedor do Prêmio Mercosul de Ciência e Tecnologia 2018 na categoria Pesquisador Sênior (ANEXO C).

No Capítulo 7 são descritas as conclusões e os trabalhos futuros, articulando os resultados mostrados em cada um dos cinco artigos apresentados. Desta maneira, a partir dos aportes teóricos e dos experimentos realizados, os resultados de desempenho das técnicas rasas e profundas são apresentados para os problemas abordados e finalizamos com apontamentos para estudos futuros.

CAPÍTULO 2 - IDENTIFICAÇÃO DE DOENÇAS FOLIARES DA SOJA USANDO IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO

Everton Castelão Tetila

Bruno Brandoli Machado

Nícolas Alessandro de Souza Belete

David Augusto Guimarães

Hemerson Pistori

RESUMO: A soja tem sido a principal *commodity* agrícola brasileira, contribuindo substancialmente para a balança comercial do país. Apesar disso, doenças foliares são fatores-chave que podem prejudicar a produção de soja, geralmente causadas por fungos, bactérias, vírus e nematoides. Este artigo propõe um sistema de visão computacional para monitorar as doenças foliares da soja no campo, usando imagens capturadas por um VANT de baixo custo, modelo DJI Phantom 3. O sistema proposto baseia-se no método de segmentação *Simple Linear Iterative Clustering* para detectar as folhas de plantas nas imagens e atributos visuais para descrever as características de propriedades físicas da folha, como cor, gradiente, textura e forma. O desempenho de seis classificadores foi avaliado para diferentes alturas, incluindo 1, 2, 4, 8 e 16 metros. Os resultados experimentais mostraram que os atributos de cor e textura levam a taxas de classificação mais altas, atingindo a precisão de 98,34% para alturas entre 1 e 2 metros, com um decaimento médio de 2% a cada metro. Os resultados indicam que a abordagem proposta pode apoiar especialistas e agricultores no monitoramento de doenças nos campos de soja.

PALAVRAS-CHAVE: Imagens aéreas, proteção de culturas de precisão, doenças foliares da soja, sensoriamento remoto baseado em veículo aéreo não tripulado (VANT).

1 | INTRODUÇÃO

A soja (*Glycine max*) tem sido a principal *commodity* agrícola brasileira, com importante participação econômica na balança comercial do país. Apesar dos resultados satisfatórios, muitas doenças – causadas por fungos, bactérias, vírus e nematoides – têm atacado consideravelmente as culturas de soja em diferentes estados. O diagnóstico precoce de doenças é bastante importante para o manejo de pesticidas na cultura e, consequentemente, pode reduzir o impacto ambiental de agroquímicos e os prejuízos econômicos.

O controle de pragas geralmente consiste em tomar decisões com base no nível

de infestação e no estágio de desenvolvimento da planta de soja. No entanto, essas informações são obtidas com inspeções regulares por amostragem de diferentes regiões da lavoura e a inspeção é realizada visualmente a partir do solo [1]. Além disso, o alto custo de produtos químicos associados a ações de baixo impacto ecológico levam a melhores práticas da agricultura de precisão. Assim, o uso de VANTs em campos de cultivo tem sido considerado um importante instrumento para identificar manchas de doenças, permitindo que especialistas e agricultores tomem melhores decisões de manejo.

Neste artigo, um sistema de visão computacional foi proposto para identificar automaticamente doenças foliares da soja, a partir de imagens aéreas capturadas por um modelo de VANT de baixo custo bastante conhecido no mercado, denominado DJI Phantom 3. Inicialmente, considerou-se um passo de segmentação de imagem para detectar as folhas das plantas nas imagens obtidas durante a inspeção de voo. Em seguida, as folhas foram descritas usando características visuais, incluindo cor, gradiente, textura e forma. Depois, seis classificadores bem conhecidos da literatura foram avaliados para cinco alturas diferentes. A abordagem proposta foi testada usando um conjunto de dados com 3.624 imagens divididas em três classes: mancha-alvo, oídio e sem doença. Por fim, os resultados experimentais foram comparados com descritores locais usando as imagens de VANT.

Este artigo está organizado da seguinte forma. A Seção II apresenta os trabalhos relacionados. A abordagem proposta para identificar as doenças foliares da soja está descrita na Seção III. A Seção IV relata os materiais e métodos adotados nesta pesquisa. A Seção V mostra os resultados experimentais, seguido por uma breve discussão. Conclusões e trabalhos futuros são apresentados na Seção VI.

2 | TRABALHOS RELACIONADOS

A aplicação de sensoriamento remoto baseado em VANT aumentou as oportunidades de proteção das culturas de precisão, incluindo detecção, monitoramento e identificação de ervas daninhas e doenças de plantas. A visão computacional e os métodos de aprendizagem de máquina desempenham um papel importante na medição automática e classificação das imagens remotas. Na literatura, existem várias revisões que comparam diferentes sensores de imagem [2] e algoritmos de aprendizagem de máquina [3], [4] para identificar doenças de plantas em diferentes culturas. No entanto, poucos deles abordam o uso de imagens coletadas de VANTs para identificação de doenças de soja.

Neste contexto, usando imagens digitalizadas individuais, Pires et al. [5] propuseram um método para identificar doenças foliares de soja com base em descritores locais e histograma de palavras visuais. [6] relataram um método para a detecção de folhas de soja com base em regiões salientes e agrupamento *k-means*. [7] propuseram um método para detectar mancha marrom e olho-de-rã, duas doenças foliares de soja comuns, usando

características de forma e classificação de k -vizinhos mais próximos; as imagens foram registradas com *smartphones*.

Estudos recentes sobre proteção de culturas, usando imagens obtidas a partir de sensoriamento remoto baseado em VANT e algoritmos de aprendizagem de máquina foram propostos para identificar doenças em cítricos [8], detectar ervas daninhas em trigo [9] e também em milho [10]. Da mesma forma, Sanchez et al. [11] propuseram um método baseado em imagens de VANT para a identificação de ervas daninhas, e [12] apresentaram uma estratégia de aprendizagem de máquinas para o monitoramento de ervas daninhas. Em [13], os autores usaram uma detecção remota com imagens do espectro visível e infravermelho próximo (NIR) para detectar duas doenças de soja, incluindo o nemátodo de cisto e a síndrome da morte súbita. Yuan et al. [14] utilizou recentemente VANTs para medir o índice da área foliar da soja.

3 | ABORDAGEM PROPOSTA

Nesta seção, introduzimos uma abordagem de visão computacional para identificar doenças foliares da soja através de imagens de VANT. A abordagem proposta adota o algoritmo SLIC Superpixels, proposto por Achanta et al. [15], para detectar as folhas das plantas nas imagens. O algoritmo SLIC foi escolhido porque é mais rápido com complexidade linear, mais eficiente em termos de memória que outros métodos baseados em superpixels e produz adesão do estado da arte aos limites da imagem, o que supera os métodos existentes quando usados para a segmentação de imagens.

O método SLIC emprega o algoritmo k -means para a geração de regiões, chamadas superpixels. O parâmetro k do algoritmo refere-se ao número de superpixels na imagem e permite controlar a forma e o tamanho dos superpixels. Aqui, ajustamos o parâmetro k para melhor segmentar as folhas das plantas de soja.

O algoritmo SLIC superpixel agrupa pixels de acordo com a cor dos pixels usando os componentes CIELAB, L , a , b , bem como as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões retangulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os centros dos agrupamentos de superpixel $C_k = [l_k; a_k; b_k; x_k; y_k]$ com $k = [1; k]$ são escolhidos, espaçados em uma matriz regular para formar os agrupamentos de tamanho aproximado S^2 . Os centros são movidos para o valor de menor gradiente sobre uma vizinhança de 3×3 pixels, evitando a alocação de centroides nas regiões de borda que tenham pixels ruidosos. Em vez de usar uma norma euclidiana simples no espaço 5D, uma medida de distância D_s é definida da seguinte forma:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D_s = d_{lab} + \frac{m}{s} * d_{xy} \quad (3)$$

onde D_s é a soma da distância d_{lab} (Equação 1) e a distância d_{xy} (Equação 2), normalizada pelo intervalo S . O parâmetro m corresponde ao controle de compactação de superpixel; quanto maior o seu valor, mais compacto é o agrupamento em termos de proximidade espacial. Cada pixel da imagem é associado ao centroide mais próximo e, depois de todos os pixels estarem associados a um centroide, um novo centro é calculado com o vector Lab_{xy} de todos os superpixels pertencentes ao grupo. No final do processo, alguns pixels podem estar conectados a um grupo incorretamente, então o algoritmo reforça a conectividade na última etapa, atribuindo os pixels sozinhos aos maiores grupos vizinhos [15].

Um diagrama esquemático do sistema proposto é mostrado na Figura 2.1. Ela ilustra a metodologia que consiste de cinco etapas: (a) aquisição de imagem, (b) segmentação SLIC, (c) conjunto de dados de imagem, (d) extração de atributos e, finalmente, (e) classificação de doenças foliares. Inicialmente, a inspeção de voo foi conduzida com o VANT nos campos de soja para capturar imagens da plantação em diferentes alturas (ver passo (a) na Figura 2.1). Essas imagens foram segmentadas usando o método SLIC superpixels. Cada segmento de superpixel foi classificado visualmente em uma classe específica: mancha-alvo, oídio ou amostras de folhas saudáveis.

Após a segmentação da imagem com o método SLIC, os segmentos de folhas pertencentes a uma determinada classe foram analisados visualmente por um agrônomo para construir um conjunto de dados de imagem para treinamento e teste do sistema, ver etapa (c) da Figura 2.1. Neste caso, o agrônomo foi responsável por avaliar a representatividade das amostras para a análise estatística. Posteriormente, as imagens foram descritas como características baseadas na cor, gradiente, textura e forma (ver passo (d) da Figura 2.1). O passo final mostra uma imagem de teste avaliada pelo nosso sistema de visão computacional. O resultado da porcentagem de cada classe é mostrado na captura de tela do sistema proposto.

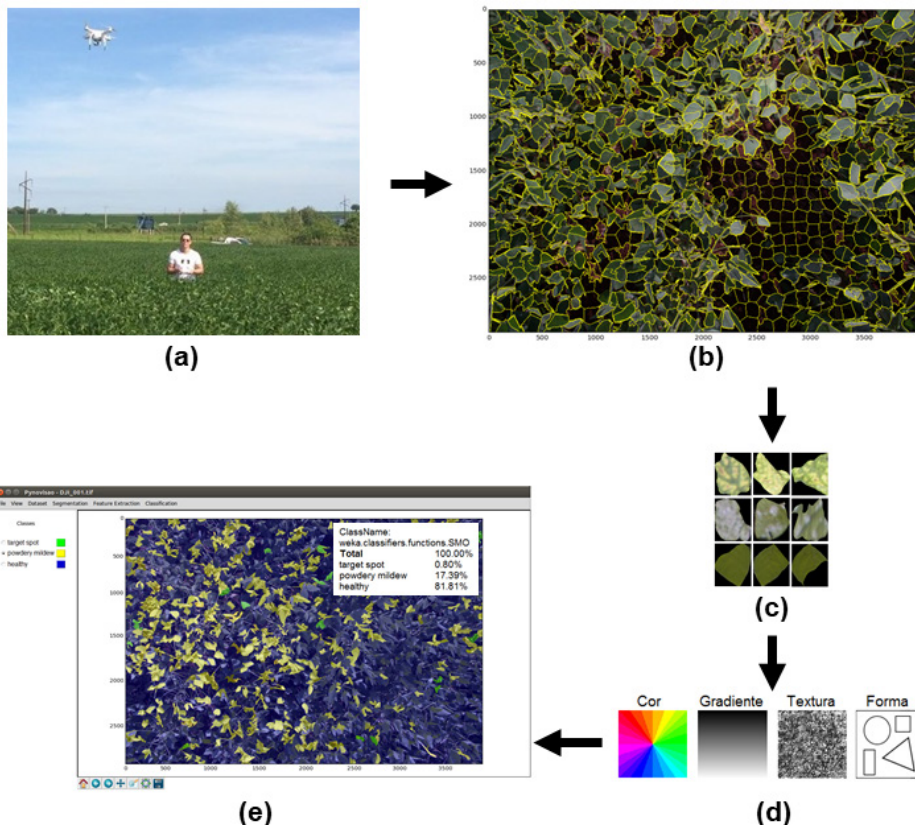


Figura 2.1 – Sistema de visão computacional proposto para identificar doenças foliares da soja com imagens de VANT. (a) Aquisição de imagem. (b) segmentação SLIC. (c) Conjunto de dados de imagem. (d) Extração de atributos. (e) Classificação de imagem de doenças.

4 | MATERIAIS E MÉTODOS

A. Delineamento Experimental

Para os experimentos, vários testes foram realizados para encontrar a taxa de classificação de doença foliar mais alta, de acordo com as alturas especificadas no VANT, incluindo 1, 2, 4, 8 e 16 metros. Para este fim, as imagens foram capturadas a partir de um campo experimental de soja, mostrado na Figura 2.2(a). As imagens foram coletadas em dias e condições climáticas diferentes. Uma quantidade total de 300 imagens aéreas foi tomada na safra Setembro/2016-Fevereiro/2017. Para identificar as doenças das plantas nas imagens, cada imagem foi segmentada usando o método baseado em superpixels, de acordo com o parâmetro k que melhor ajusta a detecção das folhas da planta. O valor de k foi configurado para dividir as imagens da planta em k segmentos de folha. Consequentemente, o parâmetro k foi definido pela aderência do limite do algoritmo SLIC.

Cada imagem tem uma dimensão de 4.000×3.000 pixels, totalizando 12.000.000

pixels. Uma folha individual de soja para 1 metro de altura possui cerca de 12.000 pixels. Assim, o parâmetro de segmentação k foi ajustado para 1.000 regiões; dividindo 12.000.000 pixels por 1.000 regiões, obteve-se 12.000 pixels para cada folha. A mesma ideia foi considerada para o dobro da altura, isto é, tomando 2 metros de altura, o número k de regiões foi 2.000, e assim por diante. Após a segmentação SLIC das imagens, foram geradas 3,624 imagens de superpixels, ou seja, imagens de folhas divididas em três classes de doenças da soja: mancha-alvo, oídio e folhas sem doença.




Figura 2.2 – (a) Área experimental usada para o plantio da cultura de soja a partir da vista de cima (imagem criada com o Google Earth). (b) e (c) são imagens obtidas pelo VANT com alturas de 4m e 16m, respectivamente.

Com apoio de um agrônomo, cada imagem foi anotada para construir o conjunto de dados de imagem e o modelo de aprendizagem de máquina. As imagens foram capturadas no formato *digital negative* (DNG), com diferentes alturas usando o DJI Phantom 3 Professional, equipado com um sensor Sony EXMOR de 1/2,3 polegadas e 12,3 megapixels de resolução. Na Tabela 2.1, o GSD (*Ground Sample Distance*) foi obtido com uma distância focal real de 3,57 mm para diferentes alturas de voo, mostrando a área de cobertura com seu respectivo GSD. As imagens foram capturadas nos campos de cultivo, usando um ângulo de 0° da câmera em relação ao solo. Assim, foi possível calcular quantos pixels tem uma folha nas imagens tomadas em diferentes alturas.

Altura de Voo (m)	GSD (mm)	Comprimento da imagem (m)	Altura da imagem (m)	Área (m ²)	Pixels por Folha
1	0,43	1,72	1,29	2,24	12.000
2	0,86	3,45	2,59	8,96	6.000
4	1,72	6,91	5,18	35,84	3.000
8	3,45	13,82	10,37	143,37	1.500
16	6,91	27,65	20,73	573,50	750

Tabela 2.1 - Valores de GSD calculados para diferentes alturas do Phantom 3.

B. Extração de Atributos e Classificação

Existem vários atributos visuais para descrever as propriedades físicas das imagens e que dependem principalmente da cor, gradiente, textura e forma. Os atributos de cor focam as propriedades físicas das superfícies dos objetos, ou seja, como refletem os diferentes valores de comprimento de onda. Os atributos de textura se concentram em descrever imagens como padrões repetitivos que podem variar de acordo com o tamanho, o que produz diferentes sensações táteis associadas à rugosidade, grosseria e regularidade. Forma descreve imagens de acordo com o contorno dos objetos, enquanto os recursos de gradiente são baseados nas derivadas em diferentes direções da imagem. O sistema de classificação de imagens utiliza como características os seguintes métodos:

- Cor: estatísticas de cores [16],
- Gradiente: histograma de gradientes orientados [17],
- Textura: matriz de coocorrência de níveis de cinza [18] e padrões binários locais [19]
- Forma: Momento de Hu e momentos centrais [20]

Para a classificação de imagens, os algoritmos de aprendizagem de máquina usam as imagens descritas para identificar e classificar de acordo com os padrões visuais. Aqui, modelos de aprendizagem supervisionados foram empregados com conjuntos de treinamento e teste divididos de acordo com a validação cruzada de dez dobras. Classificadores bem conhecidos da literatura foram comparados, incluindo SVM [21], *Adaboost* [22], árvores de decisão usando o algoritmo J48 [23], *k*-vizinhos mais próximos (*k*-NN) [24], *Random Forest* [25] e *Naive Bayes* [26], a fim de avaliar estatisticamente o potencial da proposta de reconhecimento foliar nos campos de soja, comparando diferentes alturas.

5 | RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Nesta seção são descritos os experimentos e os resultados obtidos pela abordagem proposta. Na tarefa de classificação, as imagens capturas em diferentes alturas foram

submetidas aos modelos de aprendizagem de máquina. Para avaliar o desempenho dos classificadores, foi usada a taxa de classificação correta (TCC). Para treinamento e teste dos classificadores, foi usada a validação cruzada de 10 dobras estratificada. Neste esquema, as imagens do conjunto de dados são divididas em 10 dobras garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para testar, enquanto as dobras restantes são usadas para treinar o classificador SVM. O processo é repetido 10 vezes usando cada dobra exatamente uma única vez para o teste. Finalmente, a taxa de classificação correta (TCC) é dada pela média das 10 rodadas. Para cada algoritmo testado, foram calculados os desempenhos médios das métricas TCC e medida- F .

Para verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho e altura, utilizou-se o teste de hipóteses ANOVA no *RStudio*, com cada bloco correspondendo uma classe do problema. Os valores- p encontrados para cada métrica e o nível de significância requerido foram relatados para descartar a hipótese nula. Depois, os dados foram analisados a partir de uma linha estatística descritiva no diagrama *boxplot*.

A. Classificação e Avaliação de Altura

A Figura 2.3 mostra os resultados obtidos por seis classificadores bem-conceituados na aprendizagem de máquina e inteligência artificial, conforme descrito na Seção IV. O melhor desempenho de TCC foi obtido pelo classificador SVM, seguido pelo *Random Forest*.




Figura 2.3 – TCC obtido em diferentes alturas usando extratores de atributos combinados baseados em cor, gradiente, textura e forma.

A Figura 2.4 apresenta o desempenho de cada classificador, com o valor da mediana em destaque no diagrama *boxplot*. O diagrama também mostra o intervalo da variação de desempenho obtido por cada classificador. De acordo com a figura, o classificador SVM apresentou a melhor TCC, possuindo maior valor para a mediana e dispersão de dados na melhor faixa de valores para TCC.




Figura 2.4 – Diagrama *boxplot* comparando o desempenho entre os classificadores para a métrica TCC.

Na Figura 2.5, observa-se que os valores das medianas e das dispersões de dados resultaram em uma melhor faixa de TCC entre alturas de 1 metro e 2 metros. Essas alturas não apresentaram variações significativas nos experimentos realizados, possuindo forte evidência estatística de similaridade.




Figura 2.5 – Diagrama *boxplot* comparando o desempenho entre os classificadores para diferentes alturas.

B. Avaliação de Extratores de Atributos

Outro objetivo dos experimentos foi avaliar o desempenho individual dos atributos extraídos para o reconhecimento de doenças foliares da soja. Para este propósito, os atributos baseados em cor, gradiente, textura e forma foram comparados em termos de TCC calculados pelos classificadores para diferentes alturas, como mostra a Figura 2.6. Os resultados deste experimento demonstram que a cor é o atributo mais importante em termos de discriminação quando comparada aos atributos de textura, gradiente e forma na tarefa de reconhecimento de doenças foliares da soja.

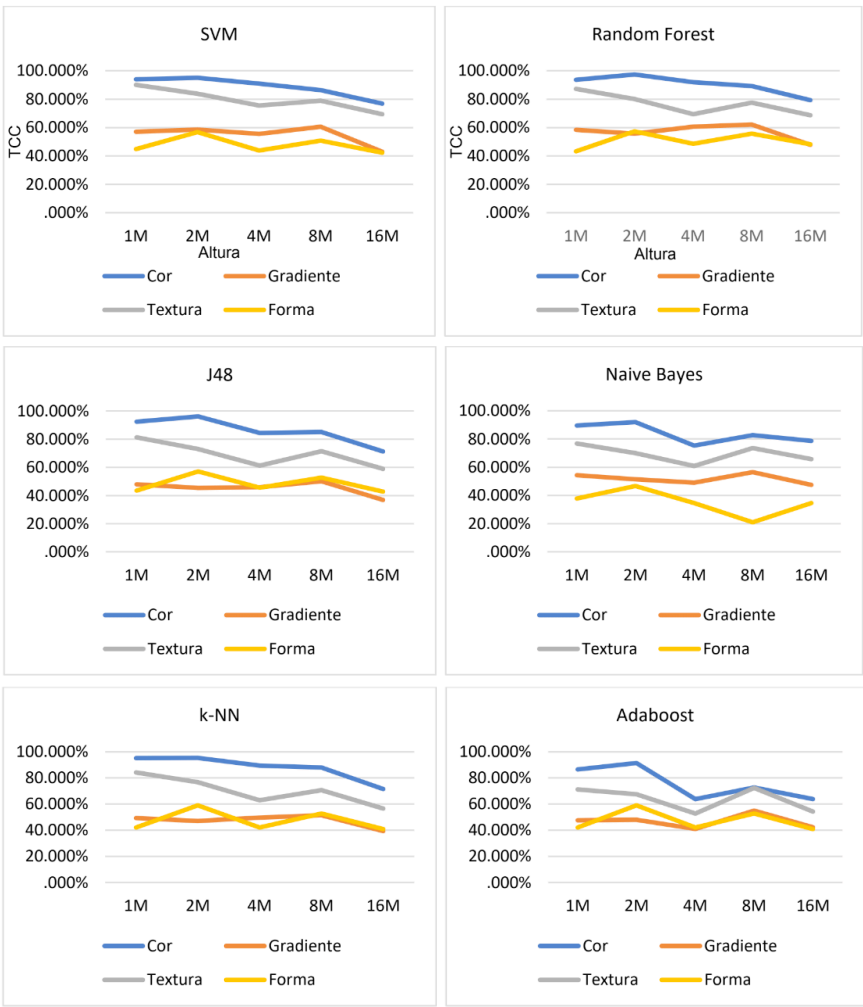


Figura 2.6 – TCCs obtidos pelos classificadores em diferentes alturas utilizando extratores de atributos baseados em cor, gradiente, textura e forma.

C. Comparação com Descritores Locais

Neste experimento, a abordagem proposta foi comparada com descritores locais que foram utilizados para identificar doenças foliares da soja através de um *scanner* de mesa, proposto em [5]. Para este fim, a mesma implementação dos autores foi utilizada aplicando as melhores alturas, 1 e 2 metros. Também foram empregados os melhores parâmetros k para cada descritor local testado em [5], a fim de definir o número de palavras visuais usadas no dicionário da abordagem de histograma de palavras visuais.

A Tabela 2.2 mostra a TCC para cada descritor local e dois classificadores, SVM e k-NN. Como pode ser visto, a abordagem proposta superou os métodos de descritores locais para todos os valores de k . A abordagem proposta alcançou o melhor resultado com o classificador SVM. Os métodos de descritores locais PHOW, DSIFT e HOG forneceram 69,72%, 63,05% e 62,77% para 3.500, 2.000 e 1.000 palavras visuais, respectivamente. Para descritores locais esparsos, o SIFT e o SURF alcançaram 46,94% e 56,38% com imagens tomadas sob a altura de 1 metro.

Descritor Local	SVM (%)			k-NN (%)	
	k	1m	2m	1m	2m
SURF	500	56,38	38,05	55,56	35,56
HOG	1000	61,66	62,77	45,00	36,11
DSIFT	2.000	63,05	56,38	44,44	35,56
SIFT	3.500	46,94	34,44	39,17	34,44
PHOW	3.500	69,72	58,61	45,28	36,44
Abordagem Proposta	-	98,34	98,09	93,14	93,05

Tabela 2.2 - Comparação da abordagem proposta com descritores locais para identificação de doenças foliares da soja sob duas alturas diferentes.

O modelo SVM exibiu a mais alta TCC, usando recursos baseados em cor, gradiente, textura e forma. Os métodos baseados em descritores locais não alcançaram a mesma precisão conforme relatado em [5] devido à distância entre a câmera e a folha, se comparado com qualquer *scanner* de mesa. Portanto, o SVM foi o modelo mais adequado para a classificação de doenças da soja usando imagens do VANT Phantom 3, e a altura mais adequada foi entre 1 e 2 metros.

6 | CONCLUSÃO E TRABALHOS FUTUROS

Neste artigo uma nova abordagem baseada no método de segmentação SLIC foi proposta para identificar doenças foliares da soja utilizando VANTs. Um passo de segmentação de imagem foi considerado para detectar as folhas da planta nas imagens tomadas com voos de um VANT modelo Phantom. Posteriormente, as folhas foram

descritas usando características visuais, incluindo cor, gradiente, textura e forma. Na etapa de classificação da abordagem, seis classificadores bem conhecidos na literatura foram comparados. Os experimentos sustentaram a hipótese da abordagem proposta de que as alturas mais próximas entre o VANT e a planta apresentam maiores taxas de classificação. A taxa de classificação correta (TCC) confirmou que a abordagem obteve 98,34% de acerto na identificação da doença foliar usando alturas entre 1 e 2 metros, com decaimento de 2% a cada metro, uma vez que a resolução da imagem da planta muda para alturas mais altas.

Os resultados experimentais também indicaram que os atributos de cor e textura levam a maiores taxas de classificação. Além disso, os experimentos foram capazes de determinar o limite de altura mais baixo da abordagem proposta. Embora seja possível tirar fotos em diferentes alturas, ao usar lentes diferentes, recomenda-se que os especialistas considerem alturas superiores a 1m, visto que as pás dos rotores do VANT podem agitar consideravelmente as folhas das plantas. Como parte do trabalho futuro, pretende-se testar redes neurais convolucionais, aumentando a quantidade de doenças. Também considera-se avaliar a abordagem proposta com câmeras de maior resolução e multiespectrais.

AGRADECIMENTOS

Os autores prestam os seus agradecimentos ao centro nacional de desenvolvimento científico e tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível superior (CAPES) pela bolsa de Doutorado concedida aos autores e à Fundação de apoio ao desenvolvimento do ensino, ciência e tecnologia do estado de Mato Grosso do Sul (FUNDECT) pelo financiamento do projeto que originou este trabalho.

REFERÊNCIAS

- [1] C. Bock, G. Poole, P. Parker, and T. Gottwald, "Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging," *Critical Reviews in Plant Sciences*, vol. 29, no. 2, pp. 59–107, 2010.
- [2] A.-K. Mahlein, E.-C. Oerke, U. Steiner, and H.-W. Dehne, "Recent advances in sensing plant diseases for precision crop protection," *European Journal of Plant Pathology*, vol. 133, no. 1, pp. 197–209, 2012.
- [3] S. Sankaran, A. Mishra, R. Ehsani, and C. Davis, "A review of advanced techniques for detecting plant diseases," *Computers and Electronics in Agriculture*, vol. 72, no. 1, pp. 1–13, 2010.
- [4] A. Singh, B. Ganapathysubramanian, A. K. Singh, and S. Sarkar, "Machine learning for high-throughput stress phenotyping in plants," *Trends in Plant Science*, vol. 21, no. 2, pp. 110 – 124, 2016.
- [5] R. D. L. Pires, D. N. Gonçalves, J. P. M. Oruê, W. E. S. Kanashiro, J. F. Rodrigues, B. B. Machado, and W. N. Gonçalves, "Local descriptors for soybean disease recognition," *Computers and Electronics in Agriculture*, vol. 125, no. 1, pp. 48–55, 2016.

- [6] J. Gui, L. Hao, Q. Zhang, and X. Bao, "A new method for soybean leaf disease detection based on modified salient regions," *International Journal of Multimedia and Ubiquitous Engineering*, vol. 10, no. 6, pp. 45–52, 2015.
- [7] S. Shrivastava and D. S. Hooda, "Automatic brown spot and frog eye detection from the image captured in the field," *American Journal of Intelligent Systems*, vol. 4, no. 4, pp. 131–134, 2014.
- [8] F. Garcia-Ruiz, S. Sankaran, J. M. Maja, W. S. Lee, J. Rasmussen, and R. Ehsani, "Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees," *Comput. Electron. Agric.*, vol. 91, pp. 106–115, 2013.
- [9] J. Torres-Sánchez, J. Peña, A. de Castro, and F. López-Granados, "Multitemporal mapping of the vegetation fraction in early-season wheat fields using images UAV," *Computers and Electronics in Agriculture*, vol. 103, pp. 104–113, 2014.
- [10] J. M. Peña, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, and F. López-Granados, "Quantifying efficacy and limits of unmanned aerial vehicle (uav) technology for weed seedling detection as affected by sensor resolution," *Sensors*, vol. 15, no. 3, pp. 5609–5626, 2015.
- [11] J. Torres-Sánchez, F. López-Granados, A. I. De Castro, and J. M. Peña-Barragán, "Configuration and specifications of an unmanned aerial vehicle (uav) for early site specific weed management," *PLOS ONE*, vol. 8, pp. 1–15, 2013.
- [12] M. Pérez-Ortiz, P. A. Gutiérrez, J. M. Peña, J. Torres-Sánchez, F. López-Granados, and C. Hervás-Martínez, "Machine learning paradigms for weed mapping via unmanned aerial vehicles," in *2016 IEEE Symposium Series on Computational Intelligence*, 2016, pp. 1–8.
- [13] S. G. Bajwa, J. C. Rupe, and J. Mason, "Soybean disease monitoring with leaf reflectance," *Remote Sensing*, vol. 9, no. 2, pp. 127–133, 2017.
- [14] H. Yuan, G. Yang, C. Li, Y. Wang, J. Liu, H. Yu, H. Feng, B. Xu, X. Zhao, and X. Yang, "Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of rf, ann, and svm regression models," *Remote Sensing*, vol. 9, no. 4, pp. 309–315, 2017.
- [15] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, "Slic superpixels compared to state-of-the-art superpixel methods," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 11, pp. 2274–2282, 2012.
- [16] M. J. Swain and D. H. Ballard, "Color indexing," *International Journal of Computer Vision*, vol. 7, no. 1, pp. 11–32, 1991.
- [17] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 1. IEEE, 2005, pp. 886–893.
- [18] R. M. Haralick, "Statistical and structural approaches to texture," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [19] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, 2002.

- [20] M. K. Hu, "Visual Pattern Recognition by Moment Invariants," *IRE Transactions on Information Theory*, vol. 8, pp. 179–187, 1962.
- [21] J. C. Platt, "Advances in kernel methods," 1999, ch. Fast Training of Support Vector Machines Using Sequential Minimal Optimization, pp. 185–208.
- [22] B. Kégl, "The return of adaboost.mh: multi-class hamming trees," *CoRR*, vol. abs/1312.6086, 2013.
- [23] J. R. Quinlan, "Induction of decision trees," *Mach. Learn.*, vol. 1, no. 1, pp. 81–106, Mar. 1986.
- [24] N. S. Altman, "An introduction to kernel and nearest-neighbor nonparametric regression," *The American Statistician*, vol. 46, no. 3, pp. 175–185, 1992.
- [25] T. K. Ho, "Random decision forests," in *Proceedings of the Third International Conference on Document Analysis and Recognition*, ser. ICDAR '95, 1995, pp. 278–285.
- [26] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 2nd ed. Pearson Education, 2003.

CAPÍTULO 3 - UM SISTEMA DE VISÃO COMPUTACIONAL PARA RECONHECIMENTO DE DOENÇAS DA SOJA USANDO VANTS: RESULTADOS PRELIMINARES

Everton Castelão Tetila

Universidade Federal da Grande Dourados, UFGD, Dourados, MS, Brasil

Bruno Brandoli Machado

Universidade Federal de Mato Grosso do Sul, UFMS, Ponta Porã, MS, Brasil

Gercina Gonçalves da Silva

Universidade Católica Dom Bosco, UCDB, Campo Grande, MS, Brasil

Hemerson Pistori

Universidade Católica Dom Bosco, UCDB, Campo Grande, MS, Brasil

RESUMO: A soja tem sido a principal *commodity* agrícola brasileira, contribuindo substancialmente para a balança comercial do país. Entretanto, doenças foliares tem prejudicado o alto rendimento da produção de soja, ocasionando a depreciação do produto final. Este artigo propõe um sistema de visão computacional para monitorar as doenças foliares da soja no campo, utilizando imagens capturadas por um VANT de baixo custo, modelo DJI Phantom 3. O sistema proposto baseia-se no método de segmentação SLIC para detectar folhas de plantas nas imagens e atributos visuais para descrever as características de propriedades físicas da folha, tais como cor, gradiente, textura e forma. O desempenho de seis classificadores foi avaliado usando imagens capturadas a 2 metros de altura da plantação. Os resultados experimentais mostraram que os atributos de cor e textura levam a taxas de classificação mais altas, atingindo a TCC de 97,8%. Os resultados indicam que a abordagem proposta pode apoiar especialistas e agricultores no monitoramento de doenças da cultura de soja.

PALAVRAS-CHAVE: Doenças foliares da soja, VANTs, imagens aéreas.

1 | INTRODUÇÃO

A soja (*Glycine max*) tem sido a principal *commodity* agrícola brasileira, possuindo importante participação econômica na balança comercial do país. O Brasil é o segundo maior produtor mundial de soja, atrás apenas dos EUA. Na safra 2016/2017, o estado de Mato Grosso foi considerado o maior produtor brasileiro do grão (29.952,9 milhões de toneladas), seguido pelo estado do Paraná (18.249,8 milhões de toneladas) e Rio Grande do Sul (16.374,6 milhões de toneladas) [1].

Apesar dos resultados satisfatórios, algumas doenças provocadas por fungos, bactérias, vírus e nematoides tem prejudicado consideravelmente a produção de soja em

alguns estados. Na safra 2016/17, o Consórcio Antiferrugem registrou 415 ocorrências de focos da doença ferrugem asiática em diversos estados produtores do Brasil, como Rio Grande do Sul (115), Paraná (87), Mato Grosso do Sul (64), Tocantins (41), Mato Grosso (34), Bahia (32), entre outros [2]. Além disso, doenças como mancha alva, míldio e oídio também podem afetar severamente o rendimento da soja. O diagnóstico precoce de doenças é fundamental para a gestão de pesticidas na cultura e, conseqüentemente, pode reduzir os prejuízos econômicos e o impacto ambiental decorrente do uso excessivo de agroquímicos [3].

Embora o potencial de danos causados na cultura da soja sejam, em alguns casos, alarmantes, não se indica a aplicação preventiva de produtos químicos, pois a aplicação desnecessária eleva os custos de produção e contribui para o desequilíbrio populacional de insetos benéficos [4]. O controle das principais doenças da soja deve ser feito com base nos princípios do manejo de doenças da soja [5]. Consistem de tomadas de decisão de controle com base no nível de infestação e no estágio de desenvolvimento da soja – informações essas obtidas em inspeções regulares por amostragem em diferentes regiões da lavoura.

Normalmente a detecção da doença é realizada visualmente por um profissional do meio agrônomo, o que pode levar a um diagnóstico impreciso ou incorreto. Bock et al. [6] listam uma série dessas desvantagens. Algumas doenças não têm quaisquer sintomas visíveis associados, ou somente aparecem quando é muito tarde para agir. Nesses casos, algum tipo de análise sofisticada, por meio de microscópios modernos, é geralmente necessária. Em outros casos, os sinais só podem ser detectados em algumas faixas do espectro eletromagnético que não são visíveis aos seres humanos. Uma abordagem comum é o uso de sensores remotos que exploram a captura de imagens multiespectrais e hiperespectrais. A maioria das doenças, no entanto, geram algum tipo de manifestação no espectro visível.

Devido aos altos custos de controle químico e o seu impacto ecológico, um dos objetivos da agricultura de precisão é reduzir e otimizar as aplicações de pesticidas. A detecção e a classificação de várias doenças em fases iniciais de epidemias permitem uma aplicação mais eficiente de agroquímicos [3]. Contudo, o monitoramento visual de doenças em fases iniciais no campo é um processo que requer elevado conhecimento técnico, sendo suscetível a falha humana.

Para superar essas questões, há uma crescente motivação ao uso de Veículos Aéreos não Tripulados (VANTs¹) na agricultura. Neste contexto, eles são capazes de sobrevoar uma plantação a poucos metros de distância com câmeras de alta resolução espacial, a fim de capturar imagens ricas em detalhes, o que torna possível a criação de um sistema de visão computacional para identificar diferentes espécies de doenças da cultura

¹ Segundo a Força Aérea Brasileira (FAB), um VANT é toda aeronave projetada para operar sem piloto a bordo, com carga útil embarcada e não utilizada para fins recreativos.

de soja. Isso é essencial para tornar este tipo de aplicação viável, uma vez que uma grande quantidade de imagens é capturada e são necessárias analisá-las automaticamente. Além disso, o alto custo de produtos químicos associados a ações de baixo impacto ecológico levam a melhores práticas da agricultura de precisão. Assim, o uso de VANTs em campos de cultivo tem sido considerado um importante instrumento para identificar manchas de doenças, permitindo que especialistas e agricultores tomem melhores decisões gerenciais.

Diante do contexto exposto e da lacuna de pesquisa observada, este artigo propõe um sistema de visão computacional para identificar automaticamente doenças foliares da soja, a partir de imagens aéreas capturadas por um modelo de VANT de baixo custo bastante conhecido no mercado, denominado DJI Phantom 3. Inicialmente, considerou-se um passo de segmentação de imagem para detectar as folhas das plantas nas imagens obtidas durante a inspeção de voo. Em seguida, as folhas foram descritas usando características visuais, incluindo cor, gradiente, textura e forma. A metodologia avalia seis classificadores conhecidos da literatura, utilizando imagens capturadas a 2 metros de altura da plantação. A abordagem proposta utiliza um conjunto de 3.000 imagens, divididas em 6 classes: ferrugem asiática, mancha-alvo, míldio, oídio, solo (solo exposto e palha) e folhas saudáveis - para avaliar a taxa de classificação correta (TCC) do sistema. Os experimentos também compararam as TCC de cada característica visual separadamente para descobrir quais atributos são mais significativos em termos de discriminação na tarefa de reconhecimento de doenças foliares da soja.

Este artigo está organizado da seguinte forma. A Seção II oferece a revisão da literatura. A abordagem proposta para identificar as doenças foliares da soja está descrita na Seção III. A Seção IV relata os materiais e métodos adotados nesta pesquisa. A Seção V mostra os resultados experimentais, seguidos por uma discussão. Finalmente, conclusões e trabalhos futuros são apresentados na Seção VI.

2 I REVISÃO DA LITERATURA

Nas últimas décadas muitos sistemas têm sido propostos para a detecção automática de doenças em plantas. No entanto, poucos deles abordam o uso de imagens coletadas por VANTs para a identificação de doenças da soja. Neste contexto, Pires et al. [7] propuseram um método baseado em descritores locais e histogramas de palavras visuais para identificar doenças de soja usando imagens de folhas capturadas por um *scanner* de mesa.

Gui et al. [8] sugeriram um novo método adaptado do método *Itti* para detectar doenças da soja com base em regiões salientes. Este método utiliza recursos de baixo níveis de iluminação e cor, combinados com análise multi-escala para determinar mapas de saliência em imagens, utilizando o algoritmo *k-means* e limiar de experiência combinada.

Shrivastava Hooda [9] apresentaram uma aplicação na agricultura para detecção e classificação de duas doenças da soja: mancha marrom e olho de rã. O dispositivo

móvel captura a imagem no campo e depois um vetor de atributos de forma é extraído no processamento da imagem que ajuda um classificador k-NN na classificação da doença.

Mohanty et al. [10] descreveram uma arquitetura de rede neural convolucional para problemas de classificação de imagens com um grande número de classes. Usando um conjunto de dados públicos de 54.306 imagens de folhas de plantas doentes e saudáveis coletadas sob condições controladas, eles treinaram uma rede neural convolucional para identificar 14 espécies de culturas diferentes e 26 doenças.

Pujari et al. [11] analisaram a aparência da doença fúngica oídio em diferentes culturas: uva, manga, pimentão, trigo, feijão e girassol. Eles extraíram características de cor e textura das amostras de oídio e, depois, utilizaram essas características como entrada para dois classificadores: baseado-em-conhecimento e redes neurais artificiais (RNA).

Rumpf et al. [12] propuseram um sistema para detectar doenças de plantas utilizando máquina de vetores de suporte baseado em reflectância hiperespectral. A principal contribuição deste trabalho é um procedimento que detecta e classifica, de modo pré-sintomático, as doenças cercospora, ferrugem e oídio da beterraba-sacarina, baseando-se em índices espectrais da vegetação.

Estudos recentes sobre agricultura de precisão, utilizando imagens de sensoriamento remoto obtidas por VANTs e algoritmos de aprendizagem de máquina, foram propostos para identificar doenças em cítricos [13], detectar ervas daninhas em trigo [14] e também em milho [15]. Em [16], os autores utilizaram sensoriamento remoto com imagens no espectro do visível e do infravermelho próximo (NIR) para detectar duas doenças de soja, incluindo o nemátodo de cisto e a síndrome da morte súbita. Yuan et al. [17] recentemente usaram VANTs para medir o índice da área foliar da soja.

3 | ABORDAGEM PROPOSTA

Nesta seção, apresentamos uma abordagem de visão computacional para identificar doenças foliares da soja através de imagens coletadas pelo VANT Phantom 3. A abordagem proposta adota o algoritmo *Simple Linear Iterative Clustering* (SLIC) para detectar as folhas das plantas nas imagens. O método SLIC emprega o algoritmo *k-means* [18] para a geração de regiões semelhantes, chamadas superpixels. O parâmetro k do algoritmo refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels. Aqui, o parâmetro k foi ajustado para melhor segmentar as folhas das plantas de soja.

De acordo com Achanta et al. [19], o algoritmo SLIC agrupa regiões de pixels no espaço 5-D definido por L , a , b (valores da escala CIELAB de cor) e as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões retangulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os centros dos agrupamentos de superpixel $C_k = [l_k, a_k, b_k, x_k, y_k]$ com $k = [1, k]$ são escolhidos,

espaçados em uma matriz regular para formar os agrupamentos de tamanho aproximado S^2 . Os centros são movidos para o valor de menor gradiente sobre uma vizinhança de 3×3 pixels, evitando a alocação de centroides nas regiões de borda que tenham pixels ruidosos. Em vez de usar uma norma euclidiana simples no espaço 5D, uma medida de distância D_s é definida da seguinte forma:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D_s = d_{lab} + \frac{m}{S} * d_{xy} \quad (3)$$

onde D_s é a soma da distância d_{lab} (Equação 1) e a distância d_{xy} (Equação 2), normalizada pelo intervalo S . O parâmetro m corresponde ao controle de compactação de superpixel; quanto maior o seu valor, mais compacto é o agrupamento em termos de proximidade espacial. Cada pixel da imagem é associado ao centroide mais próximo de um grupo e, depois de todos os pixels estarem associados a um centroide, um novo centro é calculado com o vetor Lab_{xy} de todos os superpixels pertencentes ao grupo. No final do processo, alguns pixels podem estar conectados a um grupo incorretamente, então o algoritmo reforça a conectividade na última etapa, atribuindo os pixels sozinhos aos maiores grupos vizinhos [19].

Um diagrama esquemático do sistema proposto é mostrado na Figura 3.1. Ela ilustra a metodologia que consiste de cinco etapas: (a) aquisição de imagem, (b) segmentação SLIC, (c) conjunto de imagens, (d) extração de atributos e, finalmente, (e) classificação de doenças foliares. Inicialmente, a inspeção de voo foi conduzida com o VANT nos campos de soja para capturar imagens da plantação (ver passo (a) na Figura 3.1). Essas imagens foram segmentadas usando o método SLIC Superpixels. Cada segmento de superpixel foi classificado visualmente em uma classe específica: ferrugem asiática, mancha-alvo, míldio, oídio, solo ou amostras de folhas saudáveis. O valor de $k = 2.000$ foi ajustado para dividir a imagem em 2.000 segmentos de superpixels (Figura 3.1(b)). Este valor corresponde ao tamanho aproximado da segmentação de uma folha de soja.




Figura 3.1 – Proposta do sistema de visão computacional para identificar doenças foliares da soja com imagens de VANT.

Após a segmentação da imagem com o método de SLIC, os segmentos foliares pertencentes à classe foram visualmente analisados por um especialista para compor um banco de imagens de superpixels para treinamento e teste do sistema, ver etapa (c) da Figura 3.1. Neste caso, um engenheiro agrônomo foi responsável pela avaliação da representatividade da amostra para a análise estatística. Subsequentemente, as imagens foram descritas como características baseadas na cor, gradiente, textura e forma (ver passo (d) da Figura 3.1) através de vetores de atributos extraídos das imagens de superpixels. A etapa final mostra uma imagem de teste avaliada pelo sistema de visão computacional (ver passo (e) da Figura 3.1). O resultado da taxa de classificação calculada para cada uma das doenças é mostrado na captura de tela do sistema proposto.

4 | MATERIAIS E MÉTODOS

As próximas seções cobrem os materiais e métodos adotados neste artigo.

A. Delineamento Experimental

As imagens das plantas de soja foram capturadas a 2 metros de altura com o VANT Phantom 3. Neste caso, escolheu-se dois metros porque valores menores causam o deslocamento das folhas devido ao vento gerado pelas pás dos rotores. Em contrapartida, para valores mais altos o tamanho das folhas nas imagens é gradativamente reduzido e, consequentemente, a resolução da imagem diminui. A Figura 3.2 mostra diferentes alturas testadas, no caso, 1, 2, 4, 8 e 16 metros.




Figura 3.2 – Planta da soja com a presença da doença do oídio capturada pelo VANT em diferentes alturas.

Para tanto, as imagens foram capturadas a partir de um campo experimental de soja, mostrado na Figura 3.3. A área agrícola é situada na fazenda Bom Princípio, localizada no município de Dourados-MS, com coordenadas geográficas 22° 6' 22.77" latitude Sul e 54° 15' 20.05" longitude Oeste. As imagens foram obtidas durante a safra Set/2016–Fev/2017. A fim de identificar as folhas das plantas nas imagens, cada imagem foi segmentada por meio do método baseado em superpixel, de acordo com o parâmetro k que melhor ajusta a detecção das folhas na planta. Nos experimentos, os melhores parâmetros k foram encontrados empiricamente com o valor de 2.000 superpixels para segmentar as folhas

das plantas de soja. Como resultado, 3.000 imagens de superpixels, sendo 500 imagens para cada classe, foram distribuídas entre as seis classes de identificação de doenças da soja. As classes, neste caso, correspondem às doenças: ferrugem asiática, mancha-alvo, míldio, oídio, solo e folhas sem doença.



Figura 3.3 – Visão aérea da área experimental utilizada para o plantio da cultura de soja.

Com apoio de um especialista da área agrônômica, cada imagem foi anotada, construindo assim, uma coleção de referências de superpixels para o conjunto de imagens (veja a Figura 3.4). As imagens no formato .DNG foram capturadas utilizando o VANT modelo DJI Phantom 3 Professional, equipado com um sensor Sony EXMOR de 1/2,3 polegadas e 12,3 megapixels de resolução. As imagens foram capturadas a 2 metros de altura da plantação sobre os alvos de interesse, usando um ângulo de 0° da câmera em relação ao solo. Os alvos, neste caso, correspondem ao estrato superior da planta (folhas) que carregam as informações de doenças da soja.




Figura 3.4 – Exemplos de imagens de superpixels do nosso conjunto de imagens, divididos em doenças, solo e folha saudável.

B. Extração de Atributos e Classificação

Extração ou descrição de atributos é um passo importante nos sistemas de classificação, visto que esta etapa é capaz de reduzir a informação dos padrões de conteúdo visual e os representá-los em um vetor de características. Existem vários atributos visuais que descrevem as propriedades físicas das imagens, que dependem principalmente da cor, gradiente, textura e forma. Embora o sistema visual humano possa facilmente discriminar imagens, a descrição das características baseia-se nas propriedades físicas das superfícies dos objetos, ou seja, como elas refletem os diferentes valores de comprimento de onda.

Os atributos de textura se concentram em descrever imagens como padrões repetitivos que podem variar de acordo com o tamanho, o que produz diferentes sensações táteis associadas à aspereza, grosseria e regularidade. Forma descreve imagens dependendo do contorno dos objetos, enquanto as características de gradiente são baseadas nas derivadas em diferentes direções da imagem. No sistema de classificação de imagens foram implementados e usados como atributos os seguintes métodos: cor (estatísticas de cores [20]), gradiente (histograma de gradientes orientados [21]), textura (matriz de co-ocorrência de nível de cinza [22] e padrões binários locais [23]) e forma (momentos de Hu e momentos centrais [24]).

Para a classificação de imagens, os algoritmos de aprendizagem de máquina usam as imagens descritas para identificar e classificar de acordo com os padrões visuais. Aqui, empregou-se modelos de aprendizagem supervisionados com conjuntos de treinamento e

teste divididos de acordo com a validação cruzada de dez dobras. Seis classificadores bem conhecidos da literatura foram comparados, incluindo SVM [25], *Adaboost* [26], árvores de decisão usando o algoritmo J48 [27], *Random Forest* [28], *k*-vizinhos mais próximos (*k*-NN) [29] e *Naive Bayes* [30], a fim de avaliar estatisticamente o potencial da proposta de reconhecimento foliar nos campos de soja.

5 | RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Esta seção descreve os experimentos e os resultados obtidos pela abordagem proposta. Na tarefa de classificação, as imagens capturadas foram submetidas aos modelos de aprendizagem de máquina. Quatro métricas foram utilizadas para avaliar o desempenho dos classificadores: taxa de classificação correta (TCC), medida-*F*, área ROC e tempo médio para construir o modelo de classificação. Para treinamento e teste dos classificadores, foi utilizada a validação cruzada de 10 dobras estratificada. Neste esquema, as imagens do conjunto de dados são divididas em 10 dobras, garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para testar, enquanto as dobras restantes são usadas para treinar o classificador. O processo é repetido 10 vezes usando cada dobra exatamente uma única vez para o teste. Finalmente, a taxa de classificação correta é dada pela média das 10 rodadas. Para cada algoritmo testado, foram calculados os desempenhos médios das métricas ajustadas para problemas com mais de duas classes.

Para verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho, utilizou-se o teste de hipóteses ANOVA no *RStudio*, com cada bloco correspondendo uma classe do problema. Os valores-*p* encontrados para cada métrica e o nível de significância requerido foram relatados para descartar a hipótese nula. Em seguida, os dados foram analisados a partir de uma linha estatística descritiva no diagrama *boxplot*.

A. Avaliação de Classificação

A Figura 3.5 mostra os resultados de TCC obtidos por seis classificadores bem conhecidos da literatura, considerando os valores da Tabela 3.1. É possível observar que não existe diferença significativa de desempenho de TCC entre os classificadores SVM e *Random Forest*. Este resultado foi confirmado pelo teste de *Tukey* (*p*-valor > 0,05). Neste critério de desempenho, o classificador SVM obteve maior TCC, seguido pelos classificadores *Random Forest*, J48, *k*-NN, *Naive Bayes* e *Adaboost*. A Tabela 3.1 também mostra o tempo médio para construir o modelo de classificação. Conforme a tabela, o classificador *k*-NN obteve menor tempo de processamento, seguido pelos classificadores *Adaboost*, *Naive Bayes*, SVM, J48 e *Random Forest*.

Classificador	TCC (%)	Medida-F (%)	Área ROC (%)	Tempo (s)
SVM	97,80	97,80	99,50	0,62
RandomForest	97,76	97,80	99,90	4,47
J48	94,93	94,90	97,30	1,78
NaiveBayes	51,16	48,50	90,50	0,20
k-NN	88,03	88,00	92,80	0,00
AdaBoost	32,96	18,30	72,10	0,19

Tabela 3.1 - Métricas de desempenho utilizadas para avaliar o sistema de visão computacional proposto.




Figura 3.5 – TCC obtido por diferentes classificadores, utilizando extratores de atributos baseados em cor, gradiente, textura e forma.

A Figura 3.6 apresenta o desempenho de cada classificador para as métricas TCC, medida- F e área sobre a curva ROC, com o valor da mediana em destaque no diagrama *boxplot*. O diagrama apresenta ainda o intervalo da variação de desempenho obtido por cada classificador. De acordo com a figura, os classificadores SVM e *Random Forest* apresentaram melhor desempenho, possuindo maior valor para a mediana e dispersão de dados na melhor faixa de valores para as métricas avaliadas.




Figura 3.6 – Diagrama *boxplot* comparando o desempenho entre os classificadores para a métrica TCC.

A Figura 3.7 apresenta a matriz de confusão do classificador SVM – que obteve o melhor resultado para a TCC. De acordo com a figura, as classes oídio/mancha-alvo e mildio/folha saudável obtiveram maior número de instâncias classificadas incorretamente, devido ao grau de semelhança existente entre essas classes.

	ferrugem	saudável	fundo	mancha-alvo	mildio	oídio
ferrugem	495	0	3	2	0	0
saudável	0	489	0	0	10	1
fundo	2	0	496	0	0	2
mancha-alvo	3	1	0	488	0	8
mildio	0	12	0	1	483	4
oídio	0	0	2	11	4	483

Figura 3.7 – Matriz de confusão obtida pelo classificador SVM com a TCC para cada classe investigada.

B. Avaliação de Extratores de Atributos

Outro objetivo do experimento foi avaliar o desempenho de cada característica visual que descreve as propriedades físicas da folha. Para este propósito, os atributos

baseados em cor, gradiente, textura e forma foram comparados individualmente em termos de TCC calculados pelo classificador SVM, como mostra a Figura 3.8. Os resultados deste experimento demonstram que para o classificador avaliado, os atributos cor (97,53%) e textura (68,96%) são mais significativos em termos de discriminação quando comparados aos atributos de gradiente (46,16%) e forma (25,13%) na tarefa de reconhecimento de doenças foliares da soja.




Figura 3.8 – TCC obtido pelo classificador SVM, utilizando cada extrator de atributo separado, baseado em cor, gradiente, textura e forma.

O atributo cor é mais significativo que os demais atributos porque as manchas de doenças geralmente apresentam diferentes colorações na folha. Os primeiros sintomas da ferrugem asiática são caracterizados por pequenos pontos de coloração esverdeada a cinza-esverdeada, mais escuros do que o tecido sadio da folha. As lesões da mancha-alvo se iniciam por pontuações pardas, com halo amarelado, evoluindo para grandes manchas circulares de coloração castanho-clara a castanho-escuro. Os sintomas iniciais do míldio são manchas verde-claras que evoluem para a cor amarela na parte superior da folha. Já a doença oídio apresenta uma fina cobertura esbranquiçada nas folhas em decorrência da coloração branca do fungo [31].

6 | CONCLUSÃO

Neste artigo foi proposta uma nova abordagem baseada no método de segmentação SLIC para identificar as doenças foliares da soja utilizando VANTs. Consideramos um passo de segmentação de imagem para detectar as folhas das plantas nas imagens tomadas com voos de um VANT modelo Phantom. Em seguida, foi realizada a etapa de extração

de características usando descritores visuais, incluindo cor, gradiente, textura e forma. Na etapa de classificação da abordagem proposta, seis classificadores bem conhecidos na literatura foram comparados. A taxa de classificação correta confirmou que a abordagem obteve a TCC de 97,80% na identificação da doença foliar, utilizando o classificador SVM em imagens capturadas a 2 metros de altura. Os resultados experimentais também indicaram que os atributos de cor e textura levam a maiores taxas de classificação. Como parte de trabalhos futuros, pretende-se realizar novos experimentos com câmeras multiespectrais e de maior resolução. Também considera-se comparar a abordagem proposta com outras abordagens de aprendizagem.

REFERÊNCIAS

- [1] C. N. de Abastecimento (CONAB), “Acompanhamento da safra brasileira grãos, v.4 - safra 2016/17 - n.6 - sexto levantamento (in portuguese),” Brasília, DF, Brasil, 2017. pp. 1-176, 2017. [Online]. Available: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_03_14_15_28_33_boletim_graos_marco_2017bx.pdf
- [2] E. B. de Pesquisa Agropecuária (EMBRAPA), “Consórcio Antiferrugem (safra 2016/2017) (in portuguese),” Brasília, DF, Brasil, 2016. [Online]. Available: <https://www.embrapa.br/soja/ferrugem/consorcioantiferrugem>
- [3] C. Hillnhuetter and A.-K. Mahlein, “Early detection and localisation of sugar beet diseases: new approaches,” *Gesunde Pflanzen*, vol. 60, no. 4, pp. 143–149, 2008.
- [4] E. B. de Pesquisa Agropecuária (EMBRAPA), “Níveis de desfolha tolerados na cultura da soja sem a ocorrência de prejuízos à produtividade (in portuguese),” Londrina, PR, Brasil, 2010. [Online]. Available: <http://www.cnpso.embrapa.br/download/CT79VE.pdf>
- [5] A. A. Henning, “Manejo de doenças da soja (glycine max l. merrill) (in portuguese),” Informativo ABRATES, vol. 19, no. 3, p. 4, 2009. [Online]. Available: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/96109/1/Manejo-de-doencas-da-soja-Glycine-max-L.-Merrill.pdf>
- [6] C. Bock, G. Poole, P. Parker, and T. Gottwald, “Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging,” *Critical Reviews in Plant Sciences*, vol. 29, no. 2, pp. 59–107, 2010.
- [7] R. D. L. Pires, D. N. Gonçalves, J. P. M. Oruê, W. E. S. Kanashiro, J. F. Rodrigues, B. B. Machado, and W. N. Gonçalves, “Local descriptors for soybean disease recognition,” *Computers and Electronics in Agriculture*, vol. 125, pp. 48–55, 2016.
- [8] Q. Z. Jiangsheng Gui, Li Hao and X. Bao, “A new method for soybean leaf disease detection based on modified salient regions,” *International Journal of Multimedia and Ubiquitous Engineering*, vol. 10, pp. 45–52, 2015.
- [9] D. S. H. Sourabh Shrivastava, “Automatic brown spot and frog eye detection from the image captured in the field,” *American Journal of Intelligent Systems*, vol. 4, no. 4, pp. 131–134, 2014.
- [10] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *CoRR*, vol. abs/1604.03169, 2016. [Online]. Available: <http://arxiv.org/abs/1604.03169>

- [11] J. D. Pujari, *Recognition and classification of Produce affected by identically looking Powdery Mildew disease*, Y. Rajesh, Ed. De Gruyter Open, 2014. [Online]. Available: <https://doi.org/article/ef63bd9fffc34d42af2146c82c9127da>
- [12] T. Rumpf, A.-K. Mahlein, U. Steiner, E.-C. Oerke, H.-W. Dehne, and L. Plümer, “Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance,” *Computers and Electronics in Agriculture*, vol. 74, no. 1, pp. 91 – 99, 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0168169910001262>
- [13] F. Garcia-Ruiz, S. Sankaran, J. M. Maja, W. S. Lee, J. Rasmussen, and R. Ehsani, “Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees,” *Comput. Electron. Agric.*, vol. 91, pp. 106–115, 2013.
- [14] J. Torres-Sánchez, J. Peña, A. de Castro, and F. López-Granados, “Multitemporal mapping of the vegetation fraction in early-season wheat fields using images UAV,” *Computers and Electronics in Agriculture*, vol. 103, pp. 104–113, 2014.
- [15] J. M. Peña, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, and F. López-Granados, “Quantifying efficacy and limits of unmanned aerial vehicle (uav) technology for weed seedling detection as affected by sensor resolution,” *Sensors*, vol. 15, no. 3, pp. 5609–5626, 2015.
- [16] S. G. Bajwa, J. C. Rupe, and J. Mason, “Soybean disease monitoring with leaf reflectance,” *Remote Sensing*, vol. 9, no. 2, pp. 127–133, 2017.
- [17] H. Yuan, G. Yang, C. Li, Y. Wang, J. Liu, H. Yu, H. Feng, B. Xu, X. Zhao, and X. Yang, “Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of rf, ann, and svm regression models,” *Remote Sensing*, vol. 9, no. 4, pp. 309–315, 2017.
- [18] J. A. Hartigan and M. A. Wong, “A k-means clustering algorithm,” *JSTOR: Applied Statistics*, vol. 28, no. 1, pp. 100–108, 1979.
- [19] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, “Slic superpixels compared to state-of-the-art superpixel methods,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 11, pp. 2274–2282, 2012. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2012.120>
- [20] M. J. Swain and D. H. Ballard, “Color indexing,” *International Journal of Computer Vision*, vol. 7, no. 1, pp. 11–32, 1991. [Online]. Available: <http://dx.doi.org/10.1007/BF00130487>
- [21] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” in *Computer Vision and Pattern Recognition*, 2005. CVPR 2005. *IEEE Computer Society Conference on*, vol. 1. IEEE, 2005, pp. 886–893.
- [22] R. M. Haralick, “Statistical and structural approaches to texture,” *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [23] T. Ojala, M. Pietikäinen, and T. Mäenpää, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, 2002. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2002.1017623>
- [24] M. K. Hu, “Visual Pattern Recognition by Moment Invariants,” *IRE Transactions on Information Theory*, vol. 8, pp. 179–187, 1962.

- [25] J. C. Platt, "Advances in kernel methods," B. Schölkopf, C. J. C. Burges, and A. J. Smola, Eds. Cambridge, MA, USA: MIT Press, 1999, ch. Fast Training of Support Vector Machines Using Sequential Minimal Optimization, pp. 185–208. [Online]. Available: <http://dl.acm.org/citation.cfm?id=299094.299105>
- [26] B. Kégl, "The return of adaboost.mh: multi-class hamming trees," *CoRR*, vol. abs/1312.6086, 2013. [Online]. Available: <http://arxiv.org/abs/1312.6086>
- [27] J. R. Quinlan, "Induction of decision trees," *Mach. Learn.*, vol. 1, no. 1, pp. 81–106, Mar. 1986. [Online]. Available: <http://dx.doi.org/10.1023/A:1022643204877>
- [28] T. K. Ho, "Random decision forests," in *Proceedings of the Third International Conference on Document Analysis and Recognition*, ser. ICDAR '95. Washington, DC, USA: IEEE Computer Society, 1995, pp. 278–285. [Online]. Available: <http://dl.acm.org/citation.cfm?id=844379.844681>
- [29] N. S. Altman, "An introduction to kernel and nearest-neighbor nonparametric regression," *The American Statistician*, vol. 46, no. 3, pp. 175–185, 1992.
- [30] S. J. Russell and P. Norvig, "Artificial Intelligence: A Modern Approach," 2nd ed. Pearson Education, 2003.
- [31] E. B. de Pesquisa Agropecuária (EMBRAPA), "Manual de identificação de doenças de soja - 5ª edição (in portuguese)," 2014.

CAPÍTULO 4 - RECONHECIMENTO AUTOMÁTICO DE DOENÇAS FOLIARES DA SOJA USANDO IMAGENS DE VANT E REDES NEURAIIS CONVOLUCIONAIS PROFUNDAS

Everton Castelão Tetila

Universidade Federal da Grande Dourados, Dourados, Mato Grosso do Sul, Brasil

Bruno Brandoli Machado

Universidade Federal de Mato Grosso do Sul, Ponta Porã, Mato Grosso do Sul, Brasil

Gabriel Kirsten Menezes

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Adair da Silva Oliveira Júnior

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Marco Alvarez

Universidade de Rhode Island, Kingston, Rhode Island, Estados Unidos

Willian Paraguassu Amorim

Universidade Federal da Grande Dourados, Dourados, Mato Grosso do Sul, Brasil

Nícolas Alessandro de Souza Belete

Universidade de Rondônia, Cacoal, Rondônia, Brasil

Gercina Gonçalves da Silva

Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil

Hemerson Pistori

Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil

RESUMO: As doenças de plantas são uma questão crucial na agricultura. Uma identificação precisa e automática de doenças foliares poderia ajudar a desenvolver uma resposta precoce visando reduzir as perdas econômicas. Pesquisas recentes em doenças de plantas adotaram redes neurais profundas. No entanto, pesquisas usaram os modelos como uma caixa preta passando as imagens rotuladas pelas redes. Este artigo apresenta uma análise dos pesos de redes para o reconhecimento automático de doenças foliares da soja aplicadas a imagens obtidas diretamente de um VANT pequeno e barato. Para alcançar uma alta precisão, avaliamos quatro modelos de redes neurais profundas treinados com diferentes parâmetros para ajuste fino e transferência de aprendizagem. O aumento de dados e o *dropout* foram usados durante o treinamento da rede para evitar sobreajuste. Nossa metodologia consiste em usar o método SLIC (*Simple Linear Iterative Clustering*) para segmentar as folhas da planta nas imagens aéreas obtidas durante o voo. Testamos o nosso conjunto de dados criado a partir de inspeções reais de voo em uma abordagem de visão computacional de ponta a ponta. Os resultados sugerem fortemente que o ajuste fino dos parâmetros melhora substancialmente a acurácia da identificação.

PALAVRAS-CHAVE: Imagens aéreas, aprendizagem profunda, agricultura de precisão, doenças foliares de soja, sensoriamento remoto baseado em veículo aéreo não tripulado (VANT).

1 | INTRODUÇÃO

A visão computacional tem sido amplamente utilizada como ferramenta da agricultura de precisão para aumentar a produção de grãos. Estima-se que o crescimento da população mundial chegará a 9,7 bilhões em 2050 e a 11,2 bilhões em 2100 [1], o que significa que será necessário expandir substancialmente a quantidade de alimentos produzidos. Veículos aéreos não tripulados (VANT) tem ajudado a inovar na produção de grãos. Eles são equipados com câmeras espaciais de alta resolução e capazes de voar sobre uma plantação a poucos metros de altura, capturando imagens de alta definição. Isso permite que os sistemas automáticos monitorem o cultivo e a colheita de fazendas inteiras. Além disso, os VANT no campo de cultivo tem sido considerado um elemento vital para identificar as manchas de doenças foliares, permitindo que agricultores e especialistas tomem melhores decisões de gerenciamento.

O reconhecimento de doenças nos estágios iniciais da epidemia permite um manejo mais eficiente dos insumos, uma vez que as doenças podem apresentar diferentes suscetibilidades ao princípio ativo do mesmo agrotóxico. Além disso, a identificação de doenças no campo é importante para o planejamento da próxima safra de soja. Inspeções regulares de plantio também são difíceis de realizar quando se cultivam grandes áreas. Para superar esses problemas, há uma motivação crescente para usar VANTs na agricultura, pois eles são capazes de sobrevoar campos em missões de coleta de dados, tornando viável o uso de sistemas de visão computacional para identificar doenças que afetam plantações em diferentes cultivares.

Métodos de detecção remota usando diferentes tipos de tecnologias ópticas têm sido propostos para capturar imagens do campo em diversas faixas espectrais e aumentar a produtividade agrícola. Tecnologias de imagem incluem RGB [2], sensores de termografia [3], fluorescência de clorofila [4], LiDAR [5] e multi-hiperespectrais [6]. Para processar e analisar as imagens coletadas, métodos de aprendizagem de máquina [7] foram propostos para detectar doenças em plantas [8] [9] em várias culturas, usando imagens onde a iluminação de fundo e a reflexão podem ser bem controladas. No entanto, poucos estudos abordam o uso de imagens coletadas de VANTs para identificação de doenças da soja no campo. Neste contexto, imagens remotas baseadas em VANT e algoritmos de aprendizagem de máquina foram propostos para identificar doenças na soja [10], [11].

Nos últimos anos, modelos de redes neurais convolucionais (RNCs) popularizaram-se devido aos resultados impressionantes em problemas de classificação de imagens. Tan *et al.* [12] propuseram uma rede neural para identificar doenças em sementes de soja.

Mohanty *et al.* [9] e Sladojevic *et al.* [13] treinaram diferentes abordagens de RNCs para classificação de imagens de doenças em diferentes espécies de plantas, no entanto, as imagens foram coletadas em condições controladas. Similarmente, uma rede neural convolucional foi usada em [14] para classificar três espécies diferentes de leguminosas (feijão branco, feijão vermelho e soja) a partir dos padrões das veias foliares. Em todos os trabalhos citados, as imagens das folhas foram previamente cortadas no campo e capturadas por uma câmera em laboratório.

Redes neurais profundas e imagens capturadas em condições reais de campo sob diferentes condições de iluminação, tamanho de objetos e variações de fundo foram propostas em [15] para detectar 9 tipos diferentes de doenças e pragas em plantas de tomate e [16] para detectar doenças em 25 espécies de plantas, evitando assim o processo de coleta e análise de amostras no laboratório. Apesar disso, os autores utilizaram imagens coletadas por câmeras digitais, ao invés de imagens aéreas capturadas pelo VANT, o que dificulta a realização de inspeções regulares no campo quando as áreas de cultivo são grandes. Além disso, não foram encontrados estudos na literatura que abordem modelos de aprendizagem profunda utilizando imagens de VANT para detectar e classificar doenças da soja em condições reais de campo. Também não encontramos experimentos comparando diferentes parâmetros para ajuste fino e transferência de aprendizagem com modelos de aprendizagem profunda de última geração.

Este artigo avalia quatro modelos de aprendizagem profunda para o reconhecimento automático de doenças foliares da soja, utilizando imagens capturadas a 2 metros acima do plantio com um DJI Phantom 3 Professional. Inicialmente, consideramos uma etapa de segmentação de imagens usando o método SLIC superpixels [17] para segmentar as folhas da planta nas imagens obtidas durante a inspeção de voo. Em seguida, um engenheiro agrônomo identificou cada imagem da folha de soja em uma classe de doença específica para descrever exemplos de cada classe. A abordagem de avaliação proposta usa um conjunto de dados de imagens dividido em seis classes. Acurácia, tempo de treinamento e erro de aprendizado dos modelos de aprendizagem profunda são avaliados na tarefa de reconhecer as doenças foliares da soja. Essas doenças geralmente estão presentes em diversas regiões produtoras do mundo, causando perda de produtividade em diversas cultivares, como milho, soja, trigo e feijão.

2 | ABORDAGEM PROPOSTA

Nesta seção, apresentamos um sistema de visão computacional para identificar doenças da soja a partir de imagens coletadas pelo VANT. A abordagem proposta adota o método SLIC superpixels para segmentar folhas de plantas nas imagens capturadas. O algoritmo SLIC foi escolhido por ser mais rápido com complexidade linear, mais eficiente em termos de memória do que métodos baseados em superpixels, e permite aderência de

última geração aos limites das imagens, superando os métodos existentes quando usados para segmentação de imagens, comparação feita em [17].

SLIC superpixels emprega o algoritmo *k-means* [18] para a geração de regiões semelhantes, chamadas superpixels. O parâmetro k refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels. SLIC agrupa regiões de pixels no espaço 5-D definido por l , a , b (valores da escala de cor CIELAB) e as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões regulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os centros dos agrupamentos de superpixel $C_k = [l_k, a_k, b_k, x_k, y_k]$ com $k = [1, k]$ são amostrados em uma matriz regular espaçada em S pixels. Os centros são movidos para a posição de gradiente mais baixa em uma vizinhança de 3×3 , evitando a alocação de centroides em uma borda e reduzindo a chance de semear um superpixel com um pixel ruidoso. Cada pixel é associado ao centro do agrupamento mais próximo, uma etapa de atualização ajusta os centros dos agrupamentos para serem o vetor médio $labxy$ de todos os pixels pertencentes ao agrupamento [17].

Um diagrama esquemático da abordagem proposta é mostrado na Figura 4.1. Ele ilustra o sistema proposto que consiste em 4 etapas: (a) aquisição de imagem, (b) segmentação SLIC, (c) conjunto de dados de imagens e, finalmente (d) classificação de doenças foliares. Inicialmente, a inspeção de voo foi conduzida com o VANT nos campos de soja para capturar imagens da plantação (veja o passo (a) na Figura 4.1). Essas imagens foram segmentadas usando o método SLIC superpixels (Figura 4.1-b). Após a segmentação da imagem, os segmentos foliares foram visualmente analisados por um especialista para compor um banco de dados de imagens de superpixel para treinamento e teste do sistema, veja etapa (c) da Figura 4.1.

Neste caso, cada superpixel foi visualmente rotulado por um agrônomo em uma classe específica: ferrugem asiática, mancha-alvo, oídio, míldio, solo (exposto e palha) ou amostras de folhas saudáveis. Posteriormente, uma rede neural convolucional foi treinada para extrair os recursos visuais das imagens de superpixel e, finalmente, classificar as imagens de doenças da soja (ver passo (d) da Figura 4.1). Na etapa de pós-processamento, o sistema de visão computacional mostra os resultados visuais e quantitativos ao classificar os segmentos de uma imagem da plantação, o que possibilita calcular o nível de infestação de doenças de cada área da plantação, permitindo um manejo mais eficiente dos patógenos no campo.

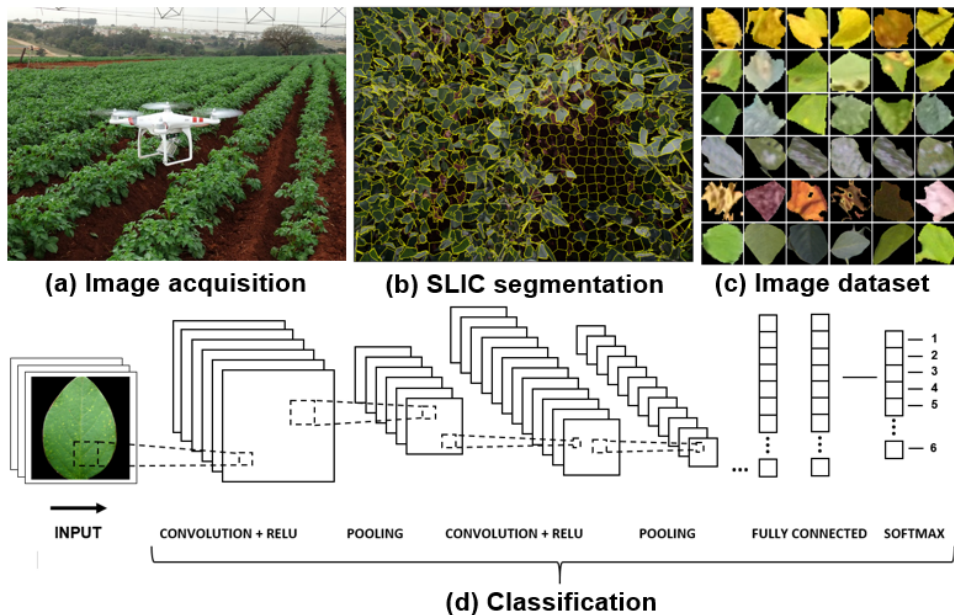


Figura 4.1 – Proposta do sistema de visão computacional para identificar doenças foliares da soja com imagens de VANT. (a) Aquisição de imagem. (b) Segmentação SLIC. (c) Conjunto de dados de imagem. (d) Classificação.

Após a segmentação da imagem com o método de SLIC, os segmentos das folhas foram analisados visualmente por um especialista para compor um banco de imagens de superpixels para treinamento e teste do sistema, ver etapa (c) da Figura 4.1. Nesse caso, cada superpixel foi visualmente rotulado por um engenheiro agrônomo em uma classe específica: ferrugem asiática, mancha-alvo, míldio, oídio, solo (exposto e palha) ou amostras de folhas saudáveis. Subsequentemente, uma rede neural convolucional foi treinada para aprender as características visuais das imagens de superpixels e, finalmente, classificar as imagens de doenças da soja (ver passo (d) da Figura 4.1). Na fase de pós-processamento, o sistema de visão computacional mostra os resultados visuais e quantitativos ao classificar os segmentos de uma imagem da plantação. Isso possibilita o cálculo do nível de infestação de doenças em cada área de plantio, permitindo um manejo mais eficiente dos patógenos no campo.

3 | MATERIAIS E MÉTODOS

3.1 Aquisição de Imagem

As imagens das plantas de soja foram capturadas com o VANT Phantom 3 Professional, equipado com um sensor Sony EXMOR de 1/2,3 polegadas e resolução de 12,3 megapixels. Imagens digitais negativas (DNG) foram capturadas sob os alvos de interesse a 2 metros da plantação, usando um ângulo de 90° da câmera em relação ao solo.

Os alvos de interesse correspondem ao estrato superior da planta (folhas) que transportam as informações de doenças da soja. Neste caso, escolhemos dois metros porque valores menores causam o deslocamento da planta devido ao vento gerado pelas pás dos rotores, o que modifica substancialmente a posição inicial das folhas. Por outro lado, em valores mais altos, o tamanho da folha na imagem é gradualmente reduzido e, conseqüentemente, a resolução da imagem diminui, como relatado em [10].

As imagens foram capturadas em condições reais de campo em uma área de soja agrícola localizada na cidade de Dourados-MS, Brasil, com coordenadas geográficas 22°6'22.77" de latitude sul e 54°15'20.05" de longitude oeste. Um total de 300 imagens aéreas foram coletadas em dias e condições climáticas diferentes, durante os estádios fenológicos R1 a R6 da fase reprodutiva da soja. Por esse motivo, as imagens capturadas pelo VANT contêm diversas variações indesejadas, como diferentes condições de iluminação e reflexão, tamanho e posição dos objetos, movimentação das folhas, oclusão, variações de fundo e estádios fenológicos da soja. Essas variações nas condições reais de campo contribuem para o sistema operar em um cenário real.

3.2 Altura do VANT e Segmentação Foliar

Para identificar as folhas das plantas nas imagens, cada imagem da plantação foi segmentada usando o método superpixel, de acordo com os parâmetros k e m que melhor ajustam a segmentação das folhas individuais. Para nossos experimentos, o valor de $k = 2.000$ foi ajustado para dividir uma imagem da plantação em 2.000 segmentos de superpixels. Este valor corresponde ao tamanho médio da segmentação de uma área foliar. O valor de $m = 10$ foi encontrado pela aderência aos limites de compactação dos segmentos de superpixel do algoritmo SLIC.

Cada imagem tem uma dimensão de 4.000×3.000 pixels, totalizando 12.000.000 pixels. Uma folha individual de soja a 2 metros de altura tem cerca de 6.000 pixels. Assim, o parâmetro de segmentação k foi definido para 2.000 regiões; dividindo 12.000.000 de pixels por 2.000 regiões, obtemos 6.000 pixels para cada folha. Além disso, entre os estádios fenológicos R1 e R6 que são fases reprodutivas de alta incidência de doenças na soja, não houve variação significativa no tamanho das folhas. Assim, mantivemos os mesmos valores dos parâmetros k e m encontrados no algoritmo SLIC. Como resultado, 3.000 imagens de superpixels, incluindo 500 imagens para cada classe, foram distribuídas entre as seis classes de doenças de soja, solo e folhas saudáveis. A Figura 4.1(c) descreve exemplos de cada classe.

3.3 Avaliação de Classificação

Para a classificação de imagens, os modelos de aprendizagem profunda [14] são treinados com imagens rotuladas para aprender como identificá-las e classificá-las de acordo com os padrões visuais. Usamos implementações de código aberto compreendendo redes neurais convolucionais, incluindo Inception-v3 [19], VGG-19 [20], ResNet-50 [21] e

Xception [22], fornecidas como parte do módulo Keras e reconhecido como validação no ImageNet. Os parâmetros de implementação do Keras não foram variados para comparar os modelos de aprendizagem profunda sem ajustes. Usamos modelos de aprendizado supervisionado com conjuntos de treinamento e teste divididos em 70 % para treinamento e 30% para teste. Três métricas foram utilizadas para avaliar o desempenho de cada modelo: acurácia, tempo de treinamento e erro de aprendizagem. Para analisar se os modelos diferem estatisticamente em relação ao seu desempenho, utilizamos o teste de hipótese de análise de variância (ANOVA). Relatamos os valores-*p* encontrados para cada métrica e o nível de significância necessário para descartar a hipótese nula.

Nos experimentos, usamos os seguintes parâmetros de entrada. A largura e a altura da imagem de entrada foram igualmente definidas em 256. O tamanho do lote foi definido 16 imagens para treinamento e o número de épocas foi usado 50, uma vez que a convergência estava em algumas iterações. Usamos o otimizador SGD com taxa de aprendizado de 0,0001 e *momentum* de 0,9 (acelera o SGD na direção relevante e amortece as oscilações). A abordagem proposta usa um conjunto de 500 imagens por classe, o que pode não ser suficiente para treinar um modelo de aprendizagem profunda. Assim, o conjunto de dados foi submetido à técnica de aumento de dados (*data augmentation*) para aumentar a quantidade de dados aplicando operações de rotação, redimensionamento, rolagem e zoom.

Esta técnica visa reforçar a invariância de rotação e invariância de escala na tarefa de classificação, uma vez que as imagens são capturadas pelo VANT em diferentes posições e escalas. A taxa de *dropout* usada nos experimentos foi fixada em 50%. Também mantivemos os mesmos parâmetros para o aumento de dados, isto é, reescalonamento de 1./255 significando o fator de multiplicação para cada pixel da imagem, com flip horizontal, modo de preenchimento mais próximo (pontos fora dos limites de entrada são preenchidos de acordo com a direção mais próxima); faixa de fator de zoom 0,3, faixa de deslocamento de largura de 0,3 para fator de deslocamento horizontal e vertical, faixa de rotação de 30.

Com o objetivo de avaliar estatisticamente o potencial dos modelos para identificação de doenças em campos de soja, definimos quatro diferentes estratégias de treinamento utilizando o *Fine-Tuning* (FT) com os pesos obtidos no *ImageNet* variando de 25% a 100%, com passo de 25%, para as camadas de rede. Também treinamos a rede completa com os pesos inicializados aleatoriamente (No TL), além da estratégia *Transfer Learning* (TL) [10] com os pesos obtidos no *ImageNet*.

Em todos os nossos experimentos usamos uma *workstation* com processador Intel Core i7-6800K 3.40GHz 15MB (6N, 12T), placa gráfica GeForce GTX 1070 8GB 1920 núcleos cuda, memória RAM 16GB Kingston DDR4 2400MHz, SSD de armazenamento 120GB de 2,5 "SATA III Kingston Ultra valor 400.

4 | RESULTADOS EXPERIMENTAIS

A Tabela 1 mostra os resultados da acurácia obtidos pelos modelos de aprendizagem profunda. O maior valor da acurácia obtido por cada modelo é destacado na tabela. A Tabela 1 também mostra o erro de aprendizado e o tempo total de treinamento, em segundos, para construir o modelo de classificação. Os resultados de tempo da Tabela 1 referem-se às especificações de hardware apresentadas na Seção 3.3. Execuções em diferentes configurações de máquinas podem interferir nos resultados apresentados.

Arquitetura	Estratégia	Tempo de treinamento (s)	Acurácia (%)	Erro de aprendizagem
Inception-V3	FT 100%	2558,91	98.87	0.0523
	FT 75%	2026,29	99.04	0.0490
	FT 50%	1812,23	97.22	0.1052
	FT 25%	1606,61	94.78	0.1645
	TL	1474,77	86.85	0.3869
	No TL	2558,97	95.75	0.1476
Resnet-50	FT 100%	3045,23	98.96	0.0414
	FT 75%	2392,65	99.02	0.0459
	FT 50%	2000,82	98.96	0.0421
	FT 25%	1759,21	98.79	0.0544
	TL	1493,96	96.95	0.1282
	No TL	3048,31	96.54	0.1106
VGG-19	FT 100%	3926,62	99.02	0.0476
	FT 75%	3302,91	98.33	0.0569
	FT 50%	2535,51	98.27	0.0703
	FT 25%	1945,43	96.37	0.1236
	TL	1736,97	77.53	0.6501
	No TL	3904,94	69.59	0.6855
Xception	FT 100%	4548,38	98.56	0.0549
	FT 75%	3009,02	97.98	0.0796
	FT 50%	2693,55	94.53	0.2356
	FT 25%	2352,87	92.63	0.2700
	TL	2000,16	86.69	0.3922
	No TL	4371,06	97.87	0.0796

Tabela 1 – Métricas de desempenho utilizadas para avaliar as arquiteturas de aprendizagem profunda.

Em nossos experimentos, o modelo *Inception-v3* FT 75% obteve o maior valor de acurácia (99,04%), seguido de *Resnet-50*, *VGG-19* (99,02%) e *Xception* (98,56%). O *Inception-v3* também obteve o menor tempo de treinamento, seguido pelo *Resnet-50*, *VGG-*

19 e Xception. Por meio do teste ANOVA, encontramos o valor- p de .412 e, portanto, não temos evidências de que haja uma diferença estatisticamente significativa no desempenho médio dos modelos testados em um nível de significância de 5%, usando a acurácia como métrica. Por outro lado, é importante destacar as implicações da escolha de um modelo de aprendizagem profunda e uma estratégia de treinamento. Por exemplo, na Tabela 1 o modelo VGG-19 treinado sem aprendizagem de transferência obteve acurácia de 69,59% versus 99,02% usando ajuste fino de 100%, resultando em uma diferença de 29,43%. Além disso, as estratégias de ajuste fino de 100% e 75% apresentaram taxas de classificação mais altas em comparação com outras estratégias de treinamento, mas obtiveram longos períodos de treinamento porque mais camadas são retreinadas usando essas estratégias.

A Figura 4.2 mostra o intervalo da variação de desempenho obtido por cada modelo com o valor da mediana em destaque no diagrama *boxplot*. Segundo a figura, o *Resnet-50* apresentou o maior valor para a mediana e a dispersão de dados na melhor faixa de valores para acurácia em comparação aos demais modelos.




Figura 4.2 – Diagrama boxplot comparando os resultados da acurácia de cada modelo de aprendizagem profunda.

A Figura 4.3 apresenta a matriz de confusão dos modelos de aprendizagem profunda. De acordo com a figura, as classes mancha-alvo/oídio e folha saudável/míldio obtiveram o maior número de ocorrências classificadas incorretamente, devido à maior similaridade dos padrões visuais existentes entre essas classes. Os sintomas iniciais do míldio são pontos verdes brilhantes de 3 a 5 mm no topo da folha que são difíceis de discriminar a partir de folhas saudáveis. As lesões da mancha-alvo começam com pontos marrons, com halo amarelado, evoluindo para grandes manchas circulares de marrom-claro a marrom-escuro, alcançando até dois centímetros de diâmetro. O oídio apresenta uma fina camada branca

nas folhas devido à cor branca do fungo, mas muda para uma cor marrom-acinzentada ao longo do tempo [23].

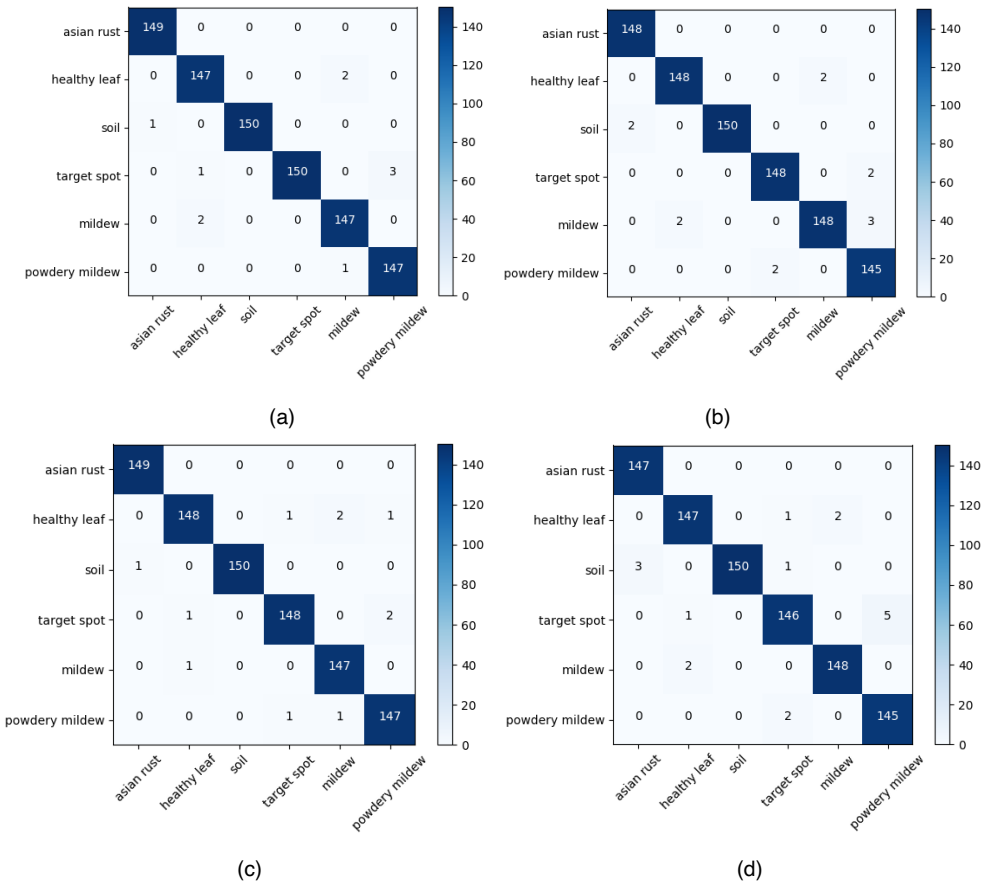



Figura 4.3 – Matriz de confusão dos modelos de aprendizagem profunda. (a) Inception-v3. (b) Resnet-50. (c) VGG-19. (d) Xception.

A Figura 4.4 mostra a etapa final do sistema de visão computacional classificando os segmentos de uma imagem da plantação capturada pelo VANT a 2 metros de altura. Aqui, usamos uma abordagem prática com o método SLIC para segmentação de imagens e o modelo *Inception-v3* FT 75% para classificação de segmentos. No estágio de pós-processamento, um mapa colorido é gerado fornecendo uma classe por segmento. O resultado visual de cada classe é destacado na imagem pela cor que ela representa e o resultado quantitativo mostra o nível de infestação por classe.



(a)



(b)

Figura 4.4 – Validação de nossa abordagem de visão computacional em um campo de cultivo de soja. A Figura (a) mostra uma imagem aérea tirada a dois metros de altura usando o pequeno VANT Phantom 3. No centro da imagem há uma mancha de oídio na cor acinzentada. A Figura (b) mostra a imagem do nosso sistema de visão computacional. O sistema apresenta o passo de segmentação da imagem da folha e a classificação dos superpixels usando o modelo *Inception-v3*. Os rótulos de cor representam as categorias do nosso problema.

A complexidade computacional do processo de segmentação, baseada no algoritmo SLIC, limita o espaço de busca a uma região proporcional ao tamanho do superpixel. Isso reduz a complexidade linear ao número de k superpixels, em vez do número de n pixels. No processo de classificação, o sistema percorre a imagem da esquerda para a direita, de cima para baixo, classificando cada superpixel individualmente, enquanto fornece a cor da classe simultaneamente. Nesse processo, a complexidade linear também é proporcional ao número de k superpixels k .

5 | CONCLUSÃO

Neste artigo, avaliamos quatro modelos de aprendizagem profunda para a tarefa de reconhecer as doenças foliares da soja, utilizando imagens de VANT capturadas a 2 metros acima do plantio. Consideramos uma etapa de segmentação de imagem com o algoritmo SLIC superpixels para detectar as folhas das plantas nas imagens. Na etapa de classificação, comparamos quatro modelos de aprendizagem profunda bem conhecidos na literatura: *Inception-v3*, *Resnet-50*, *VGG-19* e *Xception*. Resultados experimentais mostraram que modelos de aprendizagem profunda levam a altas taxas de classificação, alcançando uma acurácia de até 99,04%. Além disso, em nossos experimentos, as estratégias de ajuste fino de 100% e 75% mostraram taxas de classificação mais altas em comparação com outras estratégias de treinamento. Os resultados indicam que os modelos avaliados podem apoiar os agricultores no monitoramento das doenças da soja. Também demonstramos como um modelo de aprendizagem profunda pode ser implementado em um sistema de visão computacional para operar em um ambiente de campo real, sob diferentes condições de iluminação, tamanho de objetos e variações de fundo. Como parte do trabalho futuro, pretendemos avaliar nossa abordagem com câmeras de alta resolução e multi-hiperespectrais.

AGRADECIMENTOS

Agradecemos ao Centro Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à NVIDIA Corporation pela doação da placa gráfica e à Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do estado de Mato Grosso do Sul (FUNDECT).

REFERÊNCIAS

[1] United Nations “World Population Prospects: The 2017 Revision, Key Findings and Advance Tables” (PDF). United Nations Department of Economic and Social Affairs, Population Division. New York, NY, USA, Working Paper ESA/P/WP/248, 2017.

- [2] Rillian Diello Lucas Pires, Diogo Nunes Gonçalves, Jonatan Patrick Margarido Oruê, Wesley Eiji Sanches Kanashiro, Jose F. Rodrigues, Bruno Brandoli Machado, and Wesley Nunes Gonçalves. 2016. Local descriptors for soybean disease recognition. *Comput. Electron. Agric.* 125, C (July 2016), 48-55. DOI: <https://doi.org/10.1016/j.compag.2016.04.032>
- [3] Oerke, E. -C., Steiner, U., Dehne, H. -W., & Lindenthal, M. (2006). Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions. *Journal of Experimental Botany*, 57, 2121–2132.
- [4] A.-K. Mahlein, E.-C. Oerke, U. Steiner, and H.-W. Dehne, “Recent advances in sensing plant diseases for precision crop protection,” *European Journal of Plant Pathology*, vol. 133, no. 1, pp. 197–209, 2012.
- [5] U. Weiss, P. Biber, S. Laible, K. Bohlmann and A. Zell, “Plant Species Classification Using a 3D LIDAR Sensor and Machine Learning,” *2010 Ninth International Conference on Machine Learning and Applications*, Washington, DC, 2010, pp. 339-345. doi: 10.1109/ICMLA.2010.57
- [6] V. Chelladurai, K. Karupiah, D.S. Jayas, P.G. Fields, N.D.G. White, “Detection of *Callosobruchus maculatus* (F.) infestation in soybean using soft X-ray and NIR hyperspectral imaging techniques,” In *Journal of Stored Products Research*, Vol. 57, 2014, pp. 43-48.
- [7] S. Sankaran, A. Mishra, R. Ehsani, and C. Davis, “A review of advanced techniques for detecting plant diseases,” *Computers and Electronics in Agriculture*, vol. 72, no. 1, pp. 1–13, 2010.
- [8] S. Shrivastava and D. S. Hooda, “Automatic brown spot and frog eye detection from the image captured in the field,” *American Journal of Intelligent Systems*, vol. 4, no. 4, pp. 131 – 134, 2014.
- [9] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *CoRR*, vol. abs/1604.03169, 2016. [Online]. Available: <http://arxiv.org/abs/1604.03169>
- [10] Everton Castelhão Tetila, Bruno Brandoli Machado, Nicolas Alessandro de Souza Belete, David Augusto Guimarães, and Hemerson Pistori, “Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images,” *IEEE Geoscience and Remote Sensing Society*, vol. PP, no. 99, pp. 1–5, 2017. DOI: 10.1109/LGRS.2017.2743715
- [11] C. Brodbeck, E. Sikora, D. Delaney, G. Pate, and J. Johnson, “Using Unmanned Aircraft Systems for Early Detection of Soybean Diseases,” *Precision Agriculture*, vol. 8, no. 2, pp. 802-806, 2017.
- [12] T. Kezhu, C. Yuhua, S. Weixian, and C. Xiaoda, “Identification of diseases for soybean seeds by computer vision applying BP neural network,” *Int. J. Agricult. Biol. Eng.*, vol. 7, no. 3, pp. 43–50, Jun. 2014.
- [13] Sladojevic, Srdjan & Arsenovic, Marko & Anderla, Andras & Culibrk, Dubravko & Stefanovic, Darko. (2016). Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*. 2016. 1-11. 10.1155/2016/3289801.
- [14] L. Grinblat, Guillermo & C. Uzal, Lucas & Larese, Monica & Granitto, Pablo. (2016). Deep learning for plant identification using vein morphological patterns. *Computers and Electronics in Agriculture*. 127. 418-424. 10.1016/j.compag.2016.07.003.

- [15] Alvaro Fuentes and Sook Yoon and Sang Cheol Kim and Dong Sun Park. A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. *Sensors*, 17(9):2022, 2017}. doi: 10.3390/s17092022
- [16] Ferentinos, K.P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*. 145. 311-318. 10.1016/j.compag.2018.01.009. DOI: 10.1016/j.compag.2018.01.009
- [17] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, "Slic superpixels compared to state-of-the-art superpixel methods," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 11, pp. 2274–2282, 2012. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2012.120>.
- [18] R. M. Haralick, "Statistical and structural approaches to texture," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [19] Szegedy, Christian et al. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016. p. 2818-2826.
- [20] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [21] He K., Zhang X., Ren S., Sun J., 2016. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, 770-778. doi:10.1109/CVPR.2016.90
- [22] Chollet, François. Xception: Deep Learning with Depthwise Separable Convolutions. *arXiv preprint arXiv:1610.02357*, 2016.
- [23] EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. Manual de identificação de doenças de soja. 5ª edição, Londrina-PR, 2014.

CAPÍTULO 5 - DETECÇÃO E CLASSIFICAÇÃO DE PRAGAS DA SOJA USANDO APRENDIZAGEM PROFUNDA COM IMAGENS DE VANT

Everton Castelão Tetila

Universidade Federal da Grande Dourados, Dourados, Mato Grosso do Sul, Brasil
Universidade Federal de Rondônia, Cacoal, Rondônia, Brasil

Bruno Brandoli Machado

Universidade Federal de Mato Grosso do Sul, Ponta Porã, Mato Grosso do Sul, Brasil

Gilberto Astolfi

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Nícolas Alessandro de Souza Belete

Universidade Federal de Rondônia, Cacoal, Rondônia, Brasil
Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil

Willian Paraguassu Amorim

Universidade Federal da Grande Dourados, Dourados, Mato Grosso do Sul, Brasil

Antonia Railda Roel

Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil

Hemerson Pistori

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil
Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil

RESUMO: Este artigo apresenta os resultados da avaliação de cinco arquiteturas de aprendizagem profunda para a tarefa de classificação de imagens de pragas herbívoras da soja. O desempenho das arquiteturas Inception-V3, Resnet-50, VGG-16, VGG-19 e Xception foi avaliado para diferentes estratégias de *fine tuning* e *transfer learning* em um conjunto de 5.000 imagens capturadas em condições reais do campo. Os resultados experimentais mostraram que as arquiteturas de aprendizagem profunda treinadas com *fine tuning* levam a taxas de classificação mais altas em comparação a outras abordagens, atingindo a TCC de até 93.82%. Além disso, as arquiteturas de aprendizagem profunda superaram nos experimentos os métodos de extração de atributos tradicionais, como SIFT e SURF com a abordagem histograma de palavras visuais, o método de aprendizado semi-supervisionado OPFSEImst e os métodos de aprendizado supervisionados usados para classificar imagens, como SVM, *AdaBoost* e *Random Forest*. Os resultados indicam que as arquiteturas avaliadas podem apoiar especialistas e agricultores no monitoramento dos níveis de ação de controle de pragas nos campos de soja.

PALAVRAS-CHAVE: VANT, sensoriamento remoto, praga da soja, agricultura de precisão, aprendizagem profunda.

1 | INTRODUÇÃO

A soja vegetal (*Glycine max* [L.] Merrill) é uma oleaginosa com bom perfil nutricional e importante participação econômica mundial. A qualidade nutricional da soja é determinada pelo seu conteúdo de proteínas, ácido graxo insaturado, minerais, vitaminas, isoflavonas e outros oligoelementos encontrados nas sementes frescas (Hou et. al, 2011). Desde a semeadura até a colheita, a cultura da soja está sujeita ao ataque de herbívoros desfolhadores, como insetos, invertebrados e moluscos. Métodos de amostragem, como pano-de-batida, rede-de-varredura, exame visual de plantas, amostragem de solo e, mais recentemente, armadilha iscada com feromônio tem sido empregue para o monitoramento dos níveis de ação de controle de pragas nos campos de soja (Corrêa-Ferreira et. al, 2012). A detecção precoce permite uma aplicação mais eficiente de pesticidas, visto que os insumos podem ser aplicados na medida e locais corretos, reduzindo-se assim os custos de produção e o impacto ambiental decorrente do uso excessivo de pesticidas, além de contribuir com a saúde humana e a segurança alimentar (Tetila et. al, 2019b).

Como alternativa aos métodos de amostragens manuais, inovações tecnológicas têm ajudado a controlar pragas e aumentar a produção de alimentos no campo. VANTs equipados com câmeras de alta resolução espacial, em missões de coleta de dados, são capazes de sobrevoar uma plantação a poucos metros de distância e capturar imagens ricas em detalhes, o que tem ajudado a monitorar o cultivo e a colheita de propriedades agrícolas inteiras, com o auxílio da agricultura de precisão. Além disso, o alto custo de produtos químicos associados a ações de baixo impacto ecológico levam a melhores práticas da agricultura de precisão. Desse modo, o uso de VANTs em campos de cultivo tem sido considerado um importante instrumento para identificar pragas no campo, permitindo que especialistas e agricultores tomem melhores decisões de manejo.

Nos últimos anos, várias arquiteturas de redes neurais popularizaram-se devido aos resultados impressionantes em problemas de detecção e classificação de imagens. Keyvan and Jafar (2013) propuseram uma rede neural artificial (RNA) de três camadas para identificação do inseto lepidóptero *Spodoptera exigua* de outras espécies de pragas. Do mesmo modo, uma RNA foi treinada por Leow et. al (2015) para a classificação de espécies de Copepod – um grupo de crustáceos muito importante da cadeia marinha. Em (Yaakob and Jain, 2012) uma RNA foi combinada com seis diferentes técnicas de momentos invariantes para extrair características de forma das imagens usadas na tarefa de reconhecimento de insetos.

Redes neurais artificiais também foram projetadas em (Wang et. al, 2012) para identificação automática de espécies de insetos no nível de sua ordem. No trabalho de Wen et. al (2015) os autores treinaram uma rede neural convolucional para estimar a pose das mariposas coletadas no campo. Combinações de textura, cor, forma e características locais foram extraídas com base na pose específica da mariposa e utilizada como entrada

no modelo de aprendizagem profunda. Em (Al-Saqer and Hassan et. al, 2011) uma RNA foi usada para reconhecer a presença do inseto *Weevil Red Palm* e o distinguir de outros insetos encontrados no habitat das palmeiras. Recentemente, Guoguo et. al (2017) propuseram um sistema de reconhecimento de pestes baseado na análise de saliência da imagem e um modelo de aprendizagem profunda para a tarefa de classificação de espécies de insetos nos campos de chá da China.

Em todos os trabalhos citados, a aquisição de imagens não abrange as condições reais de campo, as quais fornecem várias condições de iluminação, como ângulos do sol, cobertura de nuvens e variações de fundo. Além disso, os autores não compararam os resultados com outras abordagens do estado da arte, como ResNet-50, VGG-19 e Inception-V3. Nesse contexto, uma abordagem baseada em aprendizagem profunda usando imagens capturadas em condições reais do campo, sob diferentes condições de iluminação, tamanho de objetos e variações de fundo foi proposta para detectar doenças e pragas em plantas de tomate (Fuentes et. al, 2017), na soja (Amorim W.P., 2019) e para a contagem automática de pragas da soja (Tetila E.C., 2019b). Machado et. al (2016) criaram um aplicativo móvel chamado *BioLeaf* baseado nas técnicas de segmentação de *otsu* e curvas de *bezier* para medir o dano das folhas de soja causado pela herbivoria de insetos. Uma revisão da literatura sobre classificação de insetos baseados em imagens, em que foram investigadas as questões que ainda podem permanecer não resolvidas foi apresentada em Martineau et. al (2017).

Métodos de detecção remota, utilizando diferentes tipos de tecnologias ópticas, como imagens RGB (Tetila et. al, 2017; Tetila et. al, 2019a), sensores acústicos (Liu and Lee, 2017a), software de raio-X (Chelladurai et. al, 2014), termografia (Calderón et. al, 2015; Oerke et. al, 2006; Mahlein et. al, 2012), ultravioleta (Liu et. al, 2017b; Peruca et. al, 2017), fluorescência de clorofila (Calderón et. al, 2015; Mahlein et. al, 2012), LiDAR (Weiss et. al, 2010) e multi-hiperespectrais (Calderón et. al, 2015; Yanan et. al, 2014; Mahlein et. al, 2012; Lu et. al, 2018) têm sido propostos para capturar imagens do campo em faixas espectrais específicas para aumentar a produtividade agrícola.

Em (Sirisomboon et. al, 2009) foi investigada a espectroscopia por refletância variando da luz visível (VIS) à região do infravermelho próximo (NIR) (600-1100nm) para a detecção de defeitos (externos e internos) nas vagens de soja verdes causados por insetos e doenças. Gedeon et. al (2017) descreveram o mecanismo de configuração e operação de um sensor optoeletrônico de raios infravermelho para detectar microartrópodes de solo na faixa de tamanho 0,4-10mm e estimar o comprimento corporal (tamanho) dos microartrópodes de solo em condições de campo. Em (Chelladurai et. al, 2014) foram usadas técnicas de imagem hiperespectral na região do infravermelho próximo (NIR) e software de raio-X para detectar a infestação de *Callosobruchus maculatus* na soja – uma praga de armazenamento que causa grandes perdas de armazenamento em leguminosas.

Algoritmos de aprendizagem de máquina também foram propostos para detectar

espécies de insetos, como abelhas (da Silva et. al, 2015), invertebrados comuns (p. ex. borboletas, gafanhotos) e moluscos (p. ex. caracóis e lesmas) (Liu and Lee, 2017a), além de contar moscas brancas (Barbedo, 2014) e pulgões (Maharlooei, 2017; Shajahan, 2016) em folhas de soja. Imagens remotas baseadas em VANT foram propostos para identificar doenças na soja (Tetila et. al, 2017; Tetila et. al, 2019a; Brodbeck et. al, 2017) e também em citros (Garcia-Ruiz et. al, 2013). Em (dos Santos et. al, 2017) os autores usaram imagens de VANT e uma rede neural convolucional para detectar ervas daninhas na soja, diferenciando-as entre folhas estreitas e folhas largas, de modo a orientar a aplicação de herbicidas. Pantazi et. al (2017) relataram a detecção e o mapeamento de ervas daninhas usando um mapa auto-organizado hierárquico e uma câmera multiespectral montada em um VANT de asa fixa. No entanto, não foi encontrado na literatura estudos que abordem o uso de imagens de VANTs para detecção de pragas da soja no campo.

Neste artigo foram comparadas cinco arquiteturas de aprendizagem profunda para a tarefa de detectar e classificar imagens de herbívoros desfolhadores da soja coletadas em condições reais do campo. Inicialmente, considerou-se um passo de segmentação de imagem usando o algoritmo SLIC superpixels (Achanta et. al, 2012) para identificar individualmente o herbívoro nas folhas das plantas, obtido durante a etapa de aquisição de imagens. Durante a fase de inspeção foram capturadas imagens aéreas usando um VANT de baixo custo bastante conhecido no mercado, modelo DJI Phantom 4 Advanced. Depois, um biólogo entomologista rotulou cada imagem de herbívoro para identificar a sua classe específica e descrever exemplos de cada classe.

A metodologia avalia cinco arquiteturas de aprendizagem profunda e as compara com outros algoritmos do estado da arte. A abordagem proposta utiliza um conjunto de 5.000 imagens, dividido em 13 classes: *Acrididae*, *Anticarsia gemmatilis*, *Coccinellidae*, *Diabrotica speciosa*, *Edessa meditabunda*, *Euschistus heros* (adulto), *Euschistus heros* (ninf), *Gastropoda*, *Lagria villosa*, *Nezara viridula* (adulto), *Nezara viridula* (ninf), *Spodoptera* spp. e sem presença de herbívoros – para medir a TCC, o tempo de treinamento e o erro de aprendizagem das arquiteturas de aprendizagem profunda na tarefa de classificação de herbívoros desfolhadores da soja. Essas espécies de herbívoros costumam estar presentes em várias regiões produtoras do mundo inteiro, frequentemente ocasionando perda de rendimento em cultivares, como soja, milho, trigo e feijão.

2 | SIMPLE LINEAR ITERATIVE CLUSTERING (SLIC)

O algoritmo *Simple Linear Iterative Clustering* (SLIC) agrupa regiões de pixels no espaço 5-D definido por L , a , b (valores da escala CIELAB de cor) e as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões retangulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os

centros dos agrupamentos de superpixel $C_k = [l_k, a_k, b_k, x_k, y_k]$ com $k = [1, k]$ são escolhidos, espaçados em uma matriz regular para formar os agrupamentos de tamanho aproximado S^2 . Os centros são movidos para o valor de menor gradiente sobre uma vizinhança de 3×3 pixels, evitando a alocação de centroides nas regiões de borda que tenham pixels ruidosos. Em vez de usar uma norma euclidiana simples no espaço 5D, uma medida de distância D_s é definida da seguinte forma:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D_s = d_{lab} + \frac{m}{S} * d_{xy} \quad (3)$$

onde D_s é a soma da distância d_{lab} (Equação 1) e a distância d_{xy} (Equação 2), normalizada pelo intervalo S . O parâmetro m corresponde ao controle de compactação de superpixel; quanto maior o seu valor, mais compacto é o agrupamento em termos de proximidade espacial. Cada pixel da imagem é associado ao centroide mais próximo de um grupo e, depois de todos os pixels estarem associados a um centroide, um novo centro é calculado com o vetor Lab_{xy} de todos os superpixels pertencentes ao grupo. No final do processo, alguns pixels podem estar conectados a um grupo incorretamente, então o algoritmo reforça a conectividade na última etapa, atribuindo os pixels sozinhos aos maiores grupos vizinhos (Achanta et. al, 2012).

3 | APRENDIZAGEM PROFUNDA

A aprendizagem profunda permite que modelos computacionais compostos por múltiplas camadas de processamento aprendam representações de dados com múltiplos níveis de abstração. Esses métodos melhoraram consideravelmente o estado da arte no reconhecimento da fala (Hinton et. al, 2012), reconhecimento de objetos visuais (Wang and Yeung, 2013), detecção de objetos (Girshick et. al, 2014), segmentação (Long et. al, 2015), classificação de vídeo (Karpathy et. al, 2014) e muitos outros domínios. A aprendizagem profunda é capaz de descobrir a estrutura complexa em grandes conjuntos de dados usando o algoritmo *backpropagation* para indicar como uma máquina deve mudar seus parâmetros internos que são usados para calcular a representação em cada camada da representação na camada anterior (LeCun et. al, 2015).

Diversas arquiteturas de aprendizagem profunda foram propostas na última década para a classificação de imagens em conjunto de dados públicos, como PASCAL VOC e ImageNet (ImageNet, 2016). Essas arquiteturas geralmente são avaliadas e comparadas em cima desses conjuntos de dados e concentram-se em encontrar redes neurais convolucionais de maior desempenho. As melhorias na qualidade da arquitetura da rede geralmente transferem os ganhos de desempenho significativos para uma ampla variedade

de domínios de aplicação que dependem cada vez mais de recursos visuais aprendidos de alta qualidade. A seguir são apresentadas cinco arquiteturas de aprendizagem profunda conhecidas da literatura e bastante utilizadas nas tarefas de visão computacional.

VGGNet (Simonyan and Zisserman, 2014) utiliza uma arquitetura com filtros de convolução muito pequenos (3×3), o que mostra que uma melhoria significativa sobre as configurações do estado da técnica pode ser alcançada empurrando a profundidade para 16-19 camadas de peso. Essas descobertas asseguraram o primeiro e o segundo lugar nas trilhas de localização e classificação, respectivamente, no conjunto de dados do ImageNet Challenge 2014 (Russakovsky et. al, 2015). Além disso, as representações VGG-16 e VGG-19 generalizam bem outros conjuntos de dados, obtendo bons resultados de desempenho em visão computacional.

ResNet-50 (He, 2016) apresenta uma estrutura de aprendizagem residual para facilitar o treinamento de redes que são substancialmente mais profundas do que as redes usadas anteriormente. A rede reformula explicitamente as camadas como funções residuais de aprendizagem com referência às entradas de camada, em vez de aprender funções não referenciadas. Essas redes residuais são mais fáceis de otimizar e podem ganhar precisão a partir do aumento considerável da profundidade. No conjunto de dados ImageNet, redes residuais com profundidade de até 152 camadas (8 vezes mais profundas que as redes VGG) foram avaliadas e, mesmo assim, apresentaram menor complexidade. Um conjunto destas redes residuais atingiu 3,57% de erro no conjunto de teste ImageNet. Este resultado ganhou o 1º lugar na tarefa de classificação ILSVRC 2015 (Russakovsky et. al, 2015).

Inception (Szegedy, 2016) explora maneiras de ampliar redes de forma que visem a utilização da computação adicional tão eficientemente quanto possível por meio de convoluções devidamente fatoradas e regularização agressiva. O custo computacional do Inception é muito menor do que outras arquiteturas, como VGGNet ou seus sucessores de maior desempenho (He et. al, 2015). A arquitetura Inception da GoogLeNet (Szegedy et. al, 2015) foi projetada para funcionar bem mesmo sob restrições rigorosas de memória e custo computacional. Por exemplo, a GoogLeNet emprega cerca de 7 milhões de parâmetros, o que representa uma redução de quase 9 vezes em relação ao seu antecessor AlexNet, que usa 60 milhões de parâmetros. Além disso, VGGNet emprega cerca de 3 vezes mais parâmetros do que AlexNet. Isso tornou viável a utilização das redes Inception em cenários de big data, onde uma grande quantidade de dados precisa ser processada a um custo razoável ou cenários em que a memória ou a capacidade computacional são inerentemente limitadas. No entanto, a complexidade da arquitetura Inception torna difícil fazer alterações na rede. Se a arquitetura é aumentada de maneira espontânea, grandes partes dos ganhos computacionais podem ser imediatamente perdidos. Isso torna muito mais difícil adaptá-lo a novos casos de uso, mantendo a sua eficiência.

Xception (Chollet, 2017) é uma arquitetura de rede neural convolucional que utiliza 36 camadas convolucionais para formar a base da extração de recursos da rede. As 36

camadas convolucionais são estruturadas em 14 módulos, todos com conexões residuais lineares em torno delas, com exceção do primeiro e último módulo. Primeiro, os dados passam pelo fluxo de entrada, depois pelo fluxo médio que é repetido oito vezes e, finalmente, pelo fluxo de saída. As camadas de convolução separáveis em profundidade com conexões residuais torna a arquitetura muito fácil de definir e modificar; leva apenas 30 a 40 linhas de código usando uma biblioteca de alto nível, como Keras (Chollet, 2015) ou TensorFlow-Slim (Guadarrama and Silberman, 2016), não muito diferente de uma arquitetura como o VGG-16 (Simonyan and Zisserman, 2014), mas sim de arquiteturas, como Inception V2 ou V3 que são muito mais complexas para definir. Xception tem o mesmo número de parâmetros que o Inception V3, mas o supera no conjunto de dados do ImageNet devido a utilização mais eficiente dos parâmetros do modelo.

4 | ABORDAGEM PROPOSTA

Esta seção apresenta uma abordagem de visão computacional para identificar imagens de pragas da soja coletadas em condições reais de campo. A abordagem proposta adota o método SLIC superpixels para segmentar as pragas nas imagens. O método SLIC emprega o algoritmo *k-means* (Hartigan and Wong, 2013) para a geração de regiões semelhantes, chamadas superpixels. O parâmetro *k* do algoritmo refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels. O parâmetro *m* corresponde ao controle de compactação das regiões geradas. Superpixels quadrados significa alto valor de compactação para o parâmetro *m*. Definimos os parâmetros $k = 200$ e $m = 50$ para segmentar as pragas nas imagens, definidas pela adesão aos limites de tamanho e compacidade do algoritmo SLIC. Esses parâmetros correspondem ao menor tamanho de superpixel encontrado para segmentar o maior objeto de interesse na imagem. Neste caso, os insetos-praga das espécies *Spodoptera* spp. e *Anticarsia gemmatilis*.

Um diagrama esquemático do sistema proposto é mostrado na Figura 5.1. Ela ilustra a metodologia que consiste de cinco etapas: (a) aquisição de imagens, (b) segmentação SLIC, (c) conjunto de imagens, (d) extração de atributos e, finalmente, (e) classificação de herbívoros-pragas. Inicialmente, uma inspeção de voo a 2 metros de altura foi conduzida com o VANT nos campos de soja para capturar imagens da plantação (ver passo (a) na Figura 5.1). Essas imagens foram segmentadas usando o método SLIC superpixels. Cada segmento de superpixel foi classificado visualmente em uma classe de herbívoro específica. O valor de *k* foi ajustado para dividir a imagem em *k* segmentos de superpixels de acordo com o tamanho aproximado da segmentação de um herbívoro na imagem (Figura 5.1(b)).

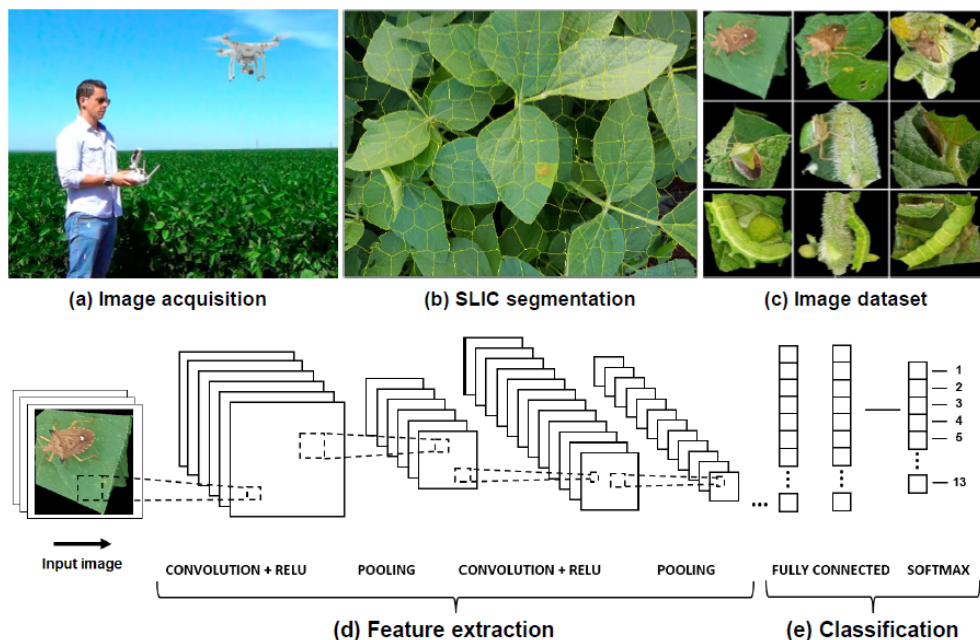


Figura 5.1 – Proposta do sistema de visão computacional para identificar pragas da soja usando aprendizagem profunda com imagens de VANT.

Após a segmentação da imagem com o método de SLIC, os segmentos pertencentes à classe de herbívoro foram visualmente analisados por um especialista para compor um banco de imagens de superpixels para treinamento e teste do sistema, ver etapa (c) da Figura 5.1. Neste caso, um biólogo entomologista foi responsável pela avaliação da representatividade da amostra para a análise estatística. Subsequentemente, uma rede neural convolucional foi treinada para aprender as características visuais das imagens de superpixels (ver passo (d) da Figura 5.1) e classificar as imagens de espécies de herbívoros da soja (ver passo (e) da Figura 5.1). A etapa final mostra o resultado de TCC, o erro de aprendizagem e o tempo de treinamento de cada arquitetura de aprendizagem de máquina avaliada pelo nosso sistema de visão computacional.

5 | MATERIAIS E MÉTODOS

Uma área experimental de 2 hectares foi semeada com cultivares de soja convencional e ausência de aplicação de pesticidas. A área agrícola mostrada na Figura 5.2 é situada na fazenda experimental da UFGD, localizada no município de Dourados-MS, Brasil, com coordenadas geográficas 22°13'57.52" latitude Sul e 54°59'17.93" longitude Oeste.



Figura 5.2 – Visão aérea da área experimental utilizada para o plantio de soja.

Duas abordagens diferentes foram utilizadas para coletar imagens de herbívoros presentes no campo experimental. Primeiro, utilizou-se uma câmera Sony equipada com o sensor IMX260 de 12 megapixels de resolução. Um total de 5.000 imagens no formato JPG foi coletado em dias e condições climáticas diferentes, entre 8h e 10h e 17h e 18h:30min, no decorrer dos estádios fenológicos R4 e R6 da fase reprodutiva da soja, durante a safra Set/2017–Fev/2018. No campo experimental, constatou-se que a exposição dos herbívoros no topo das plantas geralmente ocorre no início do dia ou no final da tarde, reforçando a recomendação de que amostragens de herbívoros da parte aérea sejam realizadas, preferencialmente, nos períodos mais frescos e úmidos do dia, conforme relatado em (Corrêa-Ferreira et. al, 2012). Essas imagens foram capturadas pelo pesquisador no local, usando a câmera a 50cm de distância sobre o alvo de interesse e um ângulo de 0° da câmera em relação ao solo. Os alvos, neste caso, correspondem aos herbívoros desfolhadores que ocasionam dano econômico quando encontrados em níveis elevados nos campos de soja. Em seguida, cada imagem foi anotada com apoio de um biólogo entomologista, construindo assim, uma coleção de referências de superpixels para o conjunto de imagens de treinamento e teste do sistema (veja a Figura 5.3), denominado INSECT5K13C e disponível em (Tetila E.C., 2018). O número desigual de amostras usadas no conjunto de imagens de treinamento e teste reflete o número de ocorrências de cada espécie de praga em condições reais de campo.

Na segunda abordagem, 300 imagens aéreas (JPG) foram capturadas a 2 metros de

altura da plantação, usando o VANT DJI Phantom 4 Advanced, equipado com uma câmera Sony CMOS de 1 polegada e 20 megapixels de resolução. Nesse caso, a altura de dois metros foi escolhida porque valores menores causam o deslocamento das plantas devido ao vento gerado pelos rotores, o que modifica substancialmente o posicionamento inicial das pragas. Por outro lado, para valores mais altos, o tamanho das pragas nas imagens é gradualmente reduzido e, conseqüentemente, a resolução da imagem das pragas diminui.

Embora não tenhamos avaliado a vibração do drone na qualidade das imagens aéreas neste trabalho, acreditamos que a influência é mínima porque a câmera do VANT geralmente possui um obturador com velocidade muito rápida para a captura de imagens (por exemplo, Phantom 4 - Velocidade do obturador eletrônico: 8s a 1/8000s). Publicamos um artigo em (Tetila et. al, 2017) que aborda a identificação de doenças da soja usando imagens de VANT. Os resultados indicam que há uma grande influência da resolução da imagem no sistema de identificação. Quanto maior a distância entre a câmera e os alvos de interesse, menor a acurácia do sistema de identificação.

As imagens aéreas capturadas pelo VANT são georreferenciadas. Cada imagem possui coordenadas geográficas de latitude sul, longitude oeste e altitude. A localização das pragas identificadas nas imagens deve ser incluída para fornecer informações úteis para aplicações específicas do local. As imagens de VANT não compreendem nossos conjuntos de treinamento e teste devido à limitação encontrada para identificar visualmente as pragas nas imagens. Apesar disso, discutimos na Seção 6.3 a detecção de pragas da soja com imagens de VANT para altitudes mais altas.

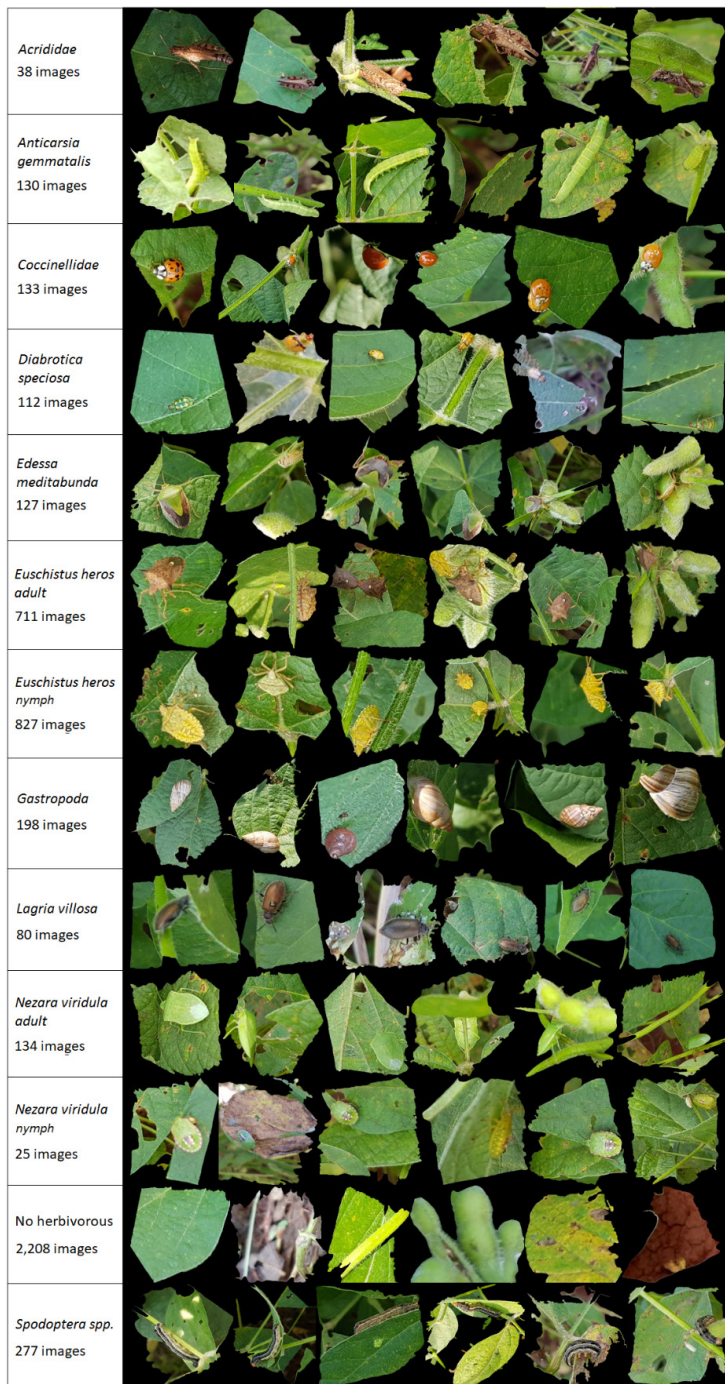


Figura 5.3 – Amostras de imagens de superpixels do nosso conjunto de imagens, dividido em espécies de pragas da soja e números de imagens por classe. As imagens foram coletadas em condições reais do campo, as quais fornecem várias condições de iluminação, como ângulos do sol e cobertura de nuvens, tamanho e posicionamento de objetos, oclusão, variações de fundo, fases de acasalamento e desenvolvimento.

Para a classificação de imagens, as arquiteturas de aprendizagem profunda usam as imagens rotuladas para identificar e classificar de acordo com os padrões visuais. Aqui, utilizou-se as implementações de código aberto das arquiteturas *Xception*, *Inception-V3*, *VGG-16*, *VGG-19* e *Resnet-50* que são fornecidas como parte do módulo de aplicativos do *Keras*, sob a licença MIT. Empregou-se modelos de aprendizagem supervisionados com conjuntos de treinamento e teste divididos em 70% para o treinamento e 30% para o teste. Nos experimentos, usamos os seguintes parâmetros de entrada. A largura e a altura da imagem de entrada foram igualmente definidas em 256. O tamanho do lote foi definido em 16 imagens para treinamento e o número de épocas foi usado 50. Utilizamos o otimizador SGD com taxa de aprendizado de 0,0001 e momento de 0,9 (acelera o SGD na direção relevante e amortece as oscilações).

Depois, o conjunto de dados foi submetido à técnica de aumento de dados (*data augmentation*) para aumentar a quantidade de dados aplicando as operações de rotação, reescala, deslocamento e zoom. Esta técnica tem o objetivo de reforçar a invariância à rotação e a invariância à escala da imagem na tarefa de classificação, uma vez que as imagens são capturadas pelo VANT em diferentes ângulos e escalas. Também foram mantidos os mesmos parâmetros para o *data augmentation*: *rescale*=1./255 (fator de multiplicação para cada pixel da imagem); *horizontal_flip*=True (alterna aleatoriamente as imagens horizontalmente); *fill_mode*="nearest" (pontos fora dos limites de entrada são preenchidos de acordo com o sentido mais próximo); *zoom_range*=0.3 (fator de ampliação de imagem); *width_shift_range*=0.3 (fator de deslocamento horizontal); *high_shift_range*=0.3 (fator de deslocamento vertical); *rotation_range*=30 (fator de rotação de imagem).

Utilizamos duas estratégias de taxas de fixação das redes neurais com os pesos obtidos no conjunto de dados ImageNet para avaliar cada arquitetura e seu comportamento durante o processo de treinamento.

- **Transfer Learning (transferência de aprendizagem):** dado um domínio de origem D_s e a tarefa de aprendizagem T_s , um domínio de destino D_t e tarefa de aprendizagem T_t , *transfer learning* visa ajudar a melhorar a aprendizagem da função preditiva de destino $f_t(\cdot)$ em D_t usando o conhecimento em D_s e T_s , onde $D_s \neq D_t$ ou $T_s \neq T_t$ (Pan and Yang, 2010). Nesta definição, o conhecimento adquirido em uma determinada tarefa, em um determinado domínio, pode ser aproveitado para melhorar a aprendizagem da função preditiva em uma outra tarefa, em um outro domínio.
- **Fine Tuning (ajuste fino):** refere-se à reutilização de valores de parâmetros estimados em conjuntos de dados potencialmente grandes como a inicialização em aplicações com acesso limitado a dados rotulados (Kading et. al, 2016). Esta estratégia não só substitui e retreina o classificador no conjunto de dados, mas também afina os pesos da rede neural pré-treinada por meio do algoritmo *backpropagation*. É possível afinar todas as camadas da rede neural ou manter algumas das camadas anteriores fixadas e apenas ajustar a parte de nível

superior da rede.

Com o objetivo de avaliar o potencial das arquiteturas para a classificação de imagens de herbívoros nos campos de soja, definiu-se quatro estratégias diferentes de treinamento utilizando a abordagem *fine-tuning* com os pesos obtidos do ImageNet, variando de 25% até 100%, com passo de 25%, para as camadas da rede. A rede completa também foi treinada com os pesos inicializados aleatoriamente, além da abordagem *transfer learning* com os pesos obtidos do ImageNet. Nos experimentos, utilizou-se para a tarefa de classificação cinco arquiteturas conhecidas em aprendizagem profunda e reconhecidas pela competição no ImageNet: Inception-V3 (Szegedy, 2016), VGG-19 (Simonyan and Zisserman, 2014), VGG-16 (Simonyan and Zisserman, 2014), ResNet-50 (He, 2016) e Xception (Chollet, 2017).

Na tarefa de classificação, submeteu-se às arquiteturas de aprendizagem profunda as imagens capturadas. Três métricas foram utilizadas para avaliar o desempenho das arquiteturas: TCC, tempo de treinamento e erro de aprendizagem. Para avaliar se as arquiteturas treinadas diferem estatisticamente em relação ao desempenho, considerando-se cada uma das métricas avaliadas e o conjunto de dados de imagem, utilizou-se o teste de hipóteses ANOVA e o diagrama de caixa (*boxplot*) no *software* estatístico *RStudio*, versão 1.0.136. Os valores-*p* encontrados para cada métrica e o nível de significância necessário para descartar a hipótese nula também foram relatados. Por fim, os valores-*p* foram analisados com o teste de *Tukey*.

Em todos os experimentos, adotou-se uma estação de trabalho (*workstation*) com as configurações de hardware descritas na Tabela 5.1.

Componente	Especificação
Processador	Intel Core i7-6800K 3.40GHz 15MB (6N, 12T)
Placa de vídeo	Geforce GTX1070 8GB 1920 cuda cores
Memória RAM	16GB Kingston DDR4 2400MHz
Armazenamento	SSD 120GB 2.5"SATA III Kingston UV400

Tabela 5.1 - Especificações técnicas de hardware da estação de trabalho.

6 | RESULTADOS E DISCUSSÃO

Esta seção descreve os resultados obtidos pela abordagem proposta, seguidos por uma discussão.

6.1 Avaliação de Classificação

A Figura 5.4 mostra os resultados de TCC obtidos pelas arquiteturas de aprendizagem profunda no conjunto de teste, considerando os valores da Tabela 5.2. O maior valor absoluto de TCC obtido por cada arquitetura está em destaque na tabela. A

Tabela 5.2 também mostra o erro de aprendizagem e o tempo total de treinamento, em segundos, para construir o modelo de classificação. Os resultados de tempo da Tabela 5.2 são referentes às especificações de hardware apresentadas na Tabela 5.1. Execuções em diferentes configurações de máquina podem interferir nos resultados apresentados.




Figura 5.4 – Maior valor absoluto de TCC obtido por cada arquitetura.

Nos experimentos, a arquitetura Resnet-50 obteve o maior valor absoluto de TCC (93.82%), seguida pelas arquiteturas Inception-V3 (91.87%), VGG-16 (91.80%), VGG-19 (91.33%) e Xception (90.52%). A arquitetura VGG-16 obteve menor tempo de treinamento, seguida pelas arquiteturas VGG-19, Resnet-50, Inception-V3 e Xception. Os resultados indicam que não existe diferença estatisticamente significativa de TCC entre as arquiteturas investigadas. Esses resultados foram confirmados pelo teste de hipóteses ANOVA (valor- $p=0.0732$).

Arquitetura	Estratégia de treinamento	Tempo de treinamento (s)	TCC (%)	Erro de aprendizagem
Inception-V3	Fine tuning 100%	5,066.99	91.26	0.3195
	Fine tuning 75%	5,077.51	91.60	0.3297
	Fine tuning 50%	5,064.74	91.80	0.3136
	Fine tuning 25%	5,077.79	91.87	0.3064
	Transfer learning	4,504.44	61.49	1.2493
	No Transfer learning	4,633.00	55.91	1.4025
Resnet-50	Fine tuning 100%	4,977.64	93.55	0.2535
	Fine tuning 75%	4,981.61	93.48	0.2564
	Fine tuning 50%	4,968.79	93.82	0.2410
	Fine tuning 25%	4,975.51	92.88	0.2684
	Transfer learning	4,885.96	64.85	1.1051
	No Transfer learning	4,575.90	67.34	1.0690
VGG-16	Fine tuning 100%	4,884.36	91.80	0.3098
	Fine tuning 75%	4,891.02	90.86	0.3577
	Fine tuning 50%	4,895.05	90.59	0.3633
	Fine tuning 25%	4,887.41	91.26	0.3722
	Transfer learning	4,858.54	51.81	1.5225
	No Transfer learning	4,470.05	45.90	1.6980
VGG-19	Fine tuning 100%	4,904.61	90.19	0.3625
	Fine tuning 75%	4,904.16	91.26	0.3422
	Fine tuning 50%	4,909.60	91.33	0.3241
	Fine tuning 25%	4,910.54	90.66	0.3562
	Transfer learning	4,883.55	50.47	1.6162
	No Transfer learning	4,486.60	44.29	1.8172
Xception	Fine tuning 100%	5,347.77	89.65	0.3776
	Fine tuning 75%	5,330.41	90.52	0.3283
	Fine tuning 50%	5,364.83	89.92	0.3815
	Fine tuning 25%	5,357.58	90.46	0.3740
	Transfer learning	4,513.90	65.52	1.1209
	No Transfer learning	5,193.43	74.60	0.8430

Tabela 5.2 - Métricas de desempenho utilizadas para avaliar as arquiteturas de aprendizagem profunda.

A Figura 5.5 mostra os resultados de TCC de cada arquitetura de aprendizagem profunda com o valor da mediana em destaque no diagrama *boxplot*. O diagrama também mostra o intervalo da variação de desempenho obtido por cada arquitetura. A arquitetura Resnet-50 apresentou o maior valor absoluto para a mediana; Resnet-50 e Xception apresentaram dispersão de dados na melhor faixa de valores para a TCC em comparação às demais arquiteturas.




Figura 5.5 – Diagrama *boxplot* comparando os resultados de TCC de cada arquitetura de aprendizagem profunda.

De maneira análoga, a Figura 5.6 mostra os resultados de TCC e o intervalo da variação de desempenho de cada estratégia de treinamento. Conforme a Figura 5.6, as estratégias de *fine tuning* (FTuning25, FTuning50, FTuning75 e FTuning100) apresentaram maior valor absoluto para a mediana e dispersão de dados na melhor faixa de valores para a TCC em comparação às estratégias treinadas com ou sem *transfer learning* (TrLearning e NoTrLearning). Todas as comparações entre as estratégias de *fine tuning* e *transfer learning* resultaram em valores- $p \leq 0.0000002$. Logo é possível rejeitar a hipótese nula com o nível de significância de 0,05 e concluir que existe uma diferença estatisticamente significativa de TCC entre as estratégias treinadas com *fine tuning* e *transfer learning*. Por outro lado, não existe uma diferença significativa entre as estratégias de *fine tuning* (valores- $p \geq 0.9999997$) ou entre *transfer learning* e *no transfer learning* (valor- $p=0.9992375$).




Figura 5.6 – Diagrama *boxplot* comparando os resultados de TCC de cada estratégia de aprendizagem profunda.

Enfatizamos a importância de escolher corretamente a estratégia usada no treinamento de arquiteturas de aprendizado profundo. Por exemplo, na Tabela 2, a estratégia NoTrLearning treinada pela arquitetura VGG-16 obteve acurácia de 45,90% contra 91,80% usando a estratégia FTuning100%, resultando em uma diferença de 45,90%. O treinamento NoTrLearning considera o treinamento completo em rede com pesos inicializados aleatoriamente. Os resultados de não transferência de aprendizagem da Tabela 2 indicam que a acurácia dessa estratégia é menor porque ela não reutiliza os valores dos parâmetros pré-treinados em um conjunto de dados potencialmente grande (por exemplo, ImageNet) como inicialização em novas aplicações. No caso do ajuste fino, essa estratégia não apenas substitui e treina novamente o classificador no conjunto de dados, mas também ajusta os pesos da rede neural pré-treinados com o algoritmo de retropropagação. É possível ajustar todas as camadas da rede neural (FTuning100%) ou manter algumas das camadas anteriores fixas (por exemplo, FTuning50% ou FTuning25%) e ajustar apenas a parte de nível superior da rede. Isso é motivado pela observação de que as camadas anteriores de uma rede neural aprendem recursos mais genéricos (por exemplo, detectores de borda ou detectores de cores) que podem ser úteis em muitas tarefas, mas as últimas camadas da rede tornam-se progressivamente mais específicas aos detalhes das classes contidas no conjunto de dados original.

A Figura 5.7 apresenta a matriz de confusão da arquitetura de aprendizagem profunda Resnet-50, treinada com *fine tuning* 50%, uma vez que essa arquitetura forneceu o maior valor absoluto de TCC entre as arquiteturas treinadas. De acordo com a figura, as classes *Euschistus heros* adulto e *Euschistus heros* ninfa, representadas pelas letras

F e G, obtiveram maior número de instâncias classificadas incorretamente em virtude da dificuldade em discriminar as fases ninfas (de 1º ao 5º ínstar) da fase adulto do ciclo de desenvolvimento do inseto. Essas duas classes pertencem a mesma espécie do inseto *Euschistus heros*, o que contribui para a maior semelhança dos padrões visuais existente entre essas classes.

	A	B	C	D	E	F	G	H	I	J	K	L	M
A	10	0	0	0	0	0	0	0	0	0	0	0	0
B	0	39	0	0	0	0	1	0	0	1	0	0	0
C	0	0	39	0	0	0	0	1	0	0	0	0	0
D	0	0	1	32	0	1	3	0	0	0	0	0	0
E	0	0	0	0	36	3	1	0	1	0	1	1	1
F	0	0	0	0	0	198	3	0	0	0	0	2	0
G	0	0	0	0	0	6	234	0	0	0	0	3	0
H	0	0	0	0	0	0	0	58	0	0	0	1	0
I	0	0	0	0	0	0	0	0	23	0	0	0	1
J	0	0	0	0	0	0	1	0	0	39	1	1	0
K	0	0	0	0	0	0	0	0	0	0	6	0	0
L	1	0	0	2	2	5	5	1	0	0	0	652	0
M	0	0	0	0	0	0	0	0	0	0	0	2	81

A = *Acrididae*
B = *Anticarsia gemmatalis*
C = *Coccinellidae*
D = *Diabrotica speciosa*
E = *Edessa meditabunda*
F = *Euschistus heros* adulto
G = *Euschistus heros* ninfa

H = *Gastropoda*
I = *Lagria villosa*
J = *Nezara viridula* adulto
K = *Nezara viridula* ninfa
L = No herbivorous
M = *Spodoptera* spp.

Figura 5.7 – Matriz de confusão da arquitetura Resnet-50. A maior acurácia foi alcançada com a arquitetura Resnet-50, usando a estratégia de treinamento *fine tuning* 50%.

6.2 Comparação com outras abordagens do estado da arte

Neste experimento, a abordagem proposta é comparada com outras abordagens do estado da arte: descritores locais SIFT (Lowe D.G., 1999) e SURF (Bay et. al, 2008), algoritmos de classificação supervisionados (SVM, *Random Forest*, J48, *Naive Bayes*, k-NN e *Adaboost*) e semi-supervisionado OPFSEMIst (Amorim et. al, 2016). Para este propósito, utilizou-se a mesma implementação dos autores e submeteu-se o mesmo conjunto de imagens de herbívoros da soja apresentado na seção V, dividido em 70% para o treinamento e 30% para o teste. Também foi variado o parâmetro *k* com os valores 25, 50 e 100 para cada descritor local, a fim de definir o número de palavras visuais usadas no

dicionário da abordagem de histograma de palavras visuais. A Tabela 5.3 mostra a TCC e o tempo de treinamento para cada arquitetura de aprendizagem profunda e as compara com outras abordagens de algoritmos do estado da arte.

Abordagem	Estratégia de treinamento	Tempo de treinamento (s)	TCC (%)
Inception-v3	Fine tuning 25%	5,077.79	91.87
Resnet-50	Fine tuning 50%	4,968.79	93.82
VGG-16	Fine tuning 100%	4,884.36	91.80
VGG-19	Fine tuning 50%	4,909.60	91.33
Xception	Fine tuning 75%	5,330.41	90.52
SVM	Extratores de atributos combinados baseados em cor ¹ , gradiente ² , textura ³ e forma ⁴	43.93	60.46
Random Forest		9.83	56.42
J48		5.57	48.28
Naive Bayes		0.25	12.80
k-NN		0.00	42.04
AdaBoost		0.47	47.18
SIFT	SVM e k=25	7,730.66	48.80
SIFT	SVM e k=50	12,101.26	51.40
SIFT	SVM e k=100	18,710.90	52.13
SURF	SVM e k=25	7,391.27	48.73
SURF	SVM e k=50	13,238.70	49.53
SURF	SVM e k=100	23,487.67	50.73
OPFSEImst [26]	(Z1' = 10% e Z1'' = 90%)	1.78	51.28
	(Z1' = 20% e Z1'' = 80%)	1.79	52.29
	(Z1' = 30% e Z1'' = 70%)	1.80	52.34
	(Z1' = 40% e Z1'' = 60%)	1.80	52.72
	(Z1' = 50% e Z1'' = 50%)	1.81	52.63
	(Z1' = 60% e Z1'' = 40%)	2.32	52.95
	(Z1' = 70% e Z1'' = 30%)	2.33	53.61
	(Z1' = 80% e Z1'' = 20%)	2.39	53.19
	(Z1' = 90% e Z1'' = 10%)	2.41	53.52

Tabela 5.3 - Comparação das arquiteturas de aprendizagem profunda com outras abordagens do estado da arte.

Como pode ser visto na Tabela 5.3, as arquiteturas de aprendizagem profunda superaram todos os métodos de descritores locais (para todos os valores de *k*) e todos

1 (Swain and Ballard, 1991)
2 (Dalal and Triggs, 2005)
3 (Haralick, 1979; Ojala et al., 2002)
4 (Hu, 1962)

os algoritmos de classificação supervisionados. Os métodos de descritores locais SIFT e SURF forneceram 52.13% e 50.73% para 100 palavras visuais, respectivamente. Para os algoritmos de classificação supervisionados, SVM e *Random Forest* alcançaram 60.46% e 56.42%.

O sistema semi-supervisionado OPFSEImst de Amorim et. al (2016) também foi treinado usando a mesma implementação dos autores e o mesmo conjunto de imagens apresentado na seção V, dividido em 70% para o treinamento (Z_1) e 30% para o teste (Z_2). O conjunto de treinamento Z_1 foi dividido em Z_1' (conjunto rotulado ou supervisionado) e Z_1'' (conjunto não rotulado ou não supervisionado) para aplicação do processo semi-supervisionado. OPFSEImst usa o conjunto supervisionado para treinamento e propaga os rótulos mais fortemente conectados para o conjunto não supervisionado. Após a propagação, é gerado um classificador supervisionado que é avaliado sobre o conjunto de teste Z_2 . Entre as estratégias de propagação, o maior valor absoluto de TCC forneceu 53.61% treinando 70% do conjunto supervisionado ($Z_1' = 70\%$) e 30% do conjunto não supervisionado ($Z_1'' = 30\%$).

6.3 Detecção de Insetos da Soja com imagens de VANT

Esta seção apresenta a abordagem proposta na seção III para detecção de herbívoros da soja com imagens de VANT. A Figura 5.8 mostra a etapa final do nosso sistema de visão computacional ao classificar os segmentos de uma imagem da plantação capturada pelo VANT a 2 metros de altura. Aqui, o parâmetro $k=2.000$ foi ajustado para melhor segmentar as pragas na imagem.



Figura 5.8 – Sistema de visão computacional para detectar pragas herbívoras da soja usando imagens de VANT.

De acordo com a Figura 5.8, os herbívoros podem ser detectados na imagem pela cor do segmento que corresponde a sua respectiva classe. Na imagem, pode-se observar a existência de quatro segmentos destacados dos demais, isto é, daqueles segmentos que não possuem herbívoros: 2 segmentos cianos, 1 segmento magenta e 1 segmento branco, os quais correspondem às classes *Euschistus heros* adulto, Gastropoda e *Spodoptera* spp., respectivamente. Entretanto, os herbívoros pertencentes às classes *Euschistus heros* ninfa e *Lagria villosa* não foram detectados na imagem pelo nosso software, mesmo sendo confirmada a presença deles pelo biólogo entomologista.

O conjunto de imagens de treinamento e teste do sistema apresentado na seção V e avaliado estatisticamente em relação ao desempenho na seção VI foi construído com imagens coletadas por uma câmera de smartphone a 50cm de distância do alvo de interesse (pragas). Nesta seção, testamos uma imagem de VANT capturada a 2 metros de altura da plantação, mas não obtivemos bons resultados para a acurácia na tarefa de classificação, assumindo que, para alturas mais elevadas o tamanho das pragas na imagem reduz gradativamente e, conseqüentemente, a resolução das pragas na imagem diminui, impactando no desempenho do sistema de visão computacional. Não avaliamos estatisticamente o desempenho das imagens capturadas pelo VANT porque elas não correspondem à mesma distância de captura do nosso conjunto de imagens de treinamento e teste coletadas pela câmera do smartphone. Como alternativa, sensores de alta resolução espacial (p. ex. 100 ou 200 megapixels) podem ser embarcados em um VANT para capturar imagens em alta definição de pragas para alturas mais elevadas, isso demonstra o potencial da abordagem proposta, embora o investimento desses equipamentos ainda seja alto.

7 | CONCLUSÃO

Neste artigo, avaliou-se o desempenho das arquiteturas de aprendizagem profunda Inception-V3, Resnet-50, VGG-16, VGG-19 e Xception para a tarefa de classificação de imagens de herbívoros da cultura da soja. Considerou-se um passo de segmentação de imagem com o algoritmo SLIC superpixels para detectar os herbívoros nas imagens coletadas em condições reais do campo. Na etapa de classificação, o desempenho das arquiteturas de aprendizagem profunda para diferentes estratégias de *fine tuning* e *transfer learning* foi comparado com outras abordagens tradicionais de aprendizagem e extração de atributos. Os resultados experimentais mostraram que as arquiteturas de aprendizagem profunda treinadas com *fine tuning* levam a taxas de classificação mais altas em comparação a outras abordagens do estado da arte, atingindo a TCC de até 93,82% com a arquitetura Resnet-50. Os resultados indicam que as arquiteturas avaliadas podem apoiar especialistas e agricultores no monitoramento dos níveis de ação de controle de pragas nos campos de soja. Como parte do trabalho futuro, pretende-se embarcar câmeras de maior resolução no VANT e avaliar o desempenho da abordagem proposta para imagens

coletadas em diferentes alturas. Também considera-se avaliar a contagem dos herbívoros nas imagens capturadas pelo VANT.

AGRADECIMENTOS

Os autores prestam os seus agradecimentos ao centro nacional de desenvolvimento científico e tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível superior (CAPES) pela bolsa de Doutorado e Mestrado concedida aos autores e à Fundação de apoio ao desenvolvimento do ensino, ciência e tecnologia do estado de Mato Grosso do Sul (FUNDECT) pelo financiamento do projeto que originou este trabalho.

REFERÊNCIAS

- Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Susstrunk S., 2012. Slic superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 34(11):2274–2282. doi:10.1109/TPAMI.2012.120
- Al-Saqer S., Hassan G.M., 2011. Artificial Neural Networks Based Red Palm Weevil (*Rynchophorus Ferrugineus*, Olivier) Recognition System. *American Journal of Agricultural and Biological Science*, 6:356-364. doi:10.3844/ajabssp.2011.356.364
- Amorim, W.P, Falcão, A.X., Papa, J.P., Carvalho, M.H., 2016. Improving semi-supervised learning through optimum connectivity. *Pattern Recognition* 60:72-85. doi:10.1016/j.patcog.2016.04.020
- Amorim W.P., Tetila E.C., Pistori H., Papa J.P., 2019. Semi-supervised learning with convolutional neural networks for UAV images automatic recognition. *Computers and Electronics in Agriculture*, 164(2019)104932. doi: 10.1016/j.compag.2019.104932
- Barbedo J.C.A., 2014. Using Digital Image Processing for Counting Whiteflies on Soybean Leaves. *Journal of Asia-Pacific Entomology*, 17(4):685-694. doi:10.1016/j.aspen.2014.06.014
- Bay H., Ess A., Tuytelaars T., Gool L.V., 2008. Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 110(3):346-359. doi:10.1016/j.cviu.2007.09.014
- Brodbeck C., Sikora E., Delaney D., Pate G., Johnson J., 2017. Using Unmanned Aircraft Systems for Early Detection of Soybean Diseases. *Precision Agriculture* 8(2):802-806. doi:10.1017/S2040470017001315
- Calderón R., Navas-Cortés J.A., Zarco-Tejada P.J., 2015. Early Detection and Quantification of Verticillium Wilt in Olive Using Hyperspectral and Thermal Imagery over Large Areas. *Remote Sensing*, 7(5):5584-5610. doi:10.3390/rs70505584
- Chelladurai V., Karuppiiah K., Jayas D.S., Fields P.G., White N.D.G., 2014. Detection of *Callosobruchus maculatus* (F.) infestation in soybean using soft X-ray and NIR hyperspectral imaging techniques. In *Journal of Stored Products Research* 57:43-48. doi:10.1016/j.jspr.2013.12.005
- Chollet F., 2015. Keras. [Online]. Available: <https://github.com/fchollet/keras>.

Chollet F., 2017. Xception: Deep Learning with Depthwise Separable Convolutions. 1800-1807. doi:10.1109/CVPR.2017.195

Corrêa-Ferreira B.S. AMOSTRAGEM DE PRAGAS DA SOJA In: Hoffmann-Campo C.B., Corrêa-Ferreira B.S., Moscardi F., 2012. Soja: manejo integrado de insetos e outros artrópodes-praga. Londrina: Embrapa Soja, cap 9, p. 631-672. ISBN 978-85-7035-139-5

Dalal, N., Triggs, B., 2005. Histograms of oriented gradients for human detection. In Computer Vision and Pattern Recognition (CVPR 2005). IEEE Computer Society Conference on 1:886–893. doi:10.1109/CVPR.2005.177

da Silva F.L., Sella M.L.G., Franco T.M., Costa A.H.R., 2015. Evaluating classification and feature selection techniques for honeybee subspecies identification using wing images. Computers and Electronics in Agriculture, 114:68-77. ISSN 0168-1699 doi:10.1016/j.compag.2015.03.012.

dos Santos A.F., Freitas D.M., Silva G., Pistori H., Folhes M.T., 2017. Weed detection in soybean crops using ConvNets. Computers and Electronics in Agriculture 143:314-324. doi:10.1016/j.compag.2017.10.027

Fuentes A., Yoon S., Kim S.C., Park D.S., 2017. A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. Sensors 2017, 17(9):2022 doi:10.3390/s17092022

Garcia-Ruiz F., Sankaran S., Maja J.M., Lee W.S., Rasmussen J., Ehsani R., 2013. Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees. Computers and Electronics in Agriculture 91:106–115. doi:10.1016/j.compag.2012.12.002

Gedeon C.I., Flórián N., Liszli P., Hambek-Oláh B., Bánszegi O., Schellenberger J., Dombos M., 2017. An Opto-Electronic Sensor for Detecting Soil Microarthropods and Estimating Their Size in Field Conditions. Sensors (Basel, Switzerland), 17(8):1757. doi:10.3390/s17081757.

Girshick R., Donahue J., Darrell T., Malik J., 2014. {Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR'14). IEEE Computer Society, Washington, DC, USA, 580-587. doi:10.1109/CVPR.2014.81

Guadarrama S., Silberman N., 2016. TF-Slim. [Online]. Available: <https://github.com/tensorflow/tensorflow/tree/master/tensorflow/contrib/slim>

Guoguo Y., Yidan B., Ziyi L., 2017. Localization and recognition of pests in tea plantation based on image saliency analysis and convolutional neural network. Editorial Office of Transactions of the Chinese Society of Agricultural Engineering, 33(6):156-162. doi:10.11975/j.issn.1002-6819.2017.06.020

Haralick, R.M., 1979. Statistical and structural approaches to texture. Proceedings of the IEEE 67(5):786–804. doi:10.1109/PROC.1979.11328

Hartigan, J.A., Wong, M.A., 2013. A k-means clustering algorithm. Applied Statistics 28:100–108. [Online]. Available: https://www.researchgate.net/publication/310403387_A_K-means_clustering_algorithm

He K., Zhang X., Ren S., Sun J., 2015. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: IEEE International Conference on Computer Vision (ICCV). IEEE Computer Society, Washington, DC, USA, 1026-1034. doi:10.1109/ICCV.2015.123

- He K., Zhang X., Ren S., Sun J., 2016. Deep residual learning for image recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 770-778. doi:10.1109/CVPR.2016.90
- Hinton G., Deng L., Yu D., Dahl G., Mohamed A-R., Jaitly N., Senior A., Vanhoucke V., Nguyen P., Sainath T., Kingsbury B., 2012. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The shared views of four research groups. IEEE Signal Processing Magazine 29(6):82–97. doi:10.1109/MSP.2012.2205597
- Hou J., Wang C., Hong X., Zhao C., Xue C., Guo N., Gai J., Xing H., 2011. Association analysis of vegetable soybean quality traits with SSR markers. Plant Breed, 130(4):444–449. doi:10.1111/j.1439-0523.2011.01852.x
- Hu, M-K., 1962. Visual Pattern Recognition by Moment Invariants. IRE Transaction of Information Theory IT-8. Information Theory, IRE Transactions on 8:179-187. doi:10.1109/TIT.1962.1057692
- ImageNet, 2016. About ImageNet. ImageNet, 2016. [Online]. Available: <http://www.image-net.org/about-overview>
- Kading, C., Rodner, E., Freytag, A., Denzler, J., 2017. Fine-tuning Deep Neural Networks in Continuous Learning Scenarios. Computer Vision - ACCV 2016 Workshops 588-605. doi:10.1007/978-3-319-54526-4_43
- Karpathy A., Toderici G., Shetty S., Leung T., Sukthankar R., Fei-Fei L., 2014. Large-scale video classification with convolutional neural networks. In Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Washington, DC, USA, 1725-1732. doi:10.1109/CVPR.2014.223
- Keyvan A.V., Jafar M., 2013. Performance evaluation of a machine vision system for insect pests identification of field crops using artificial neural networks. Archives of Phytopathology and Plant Protection, 46(11):1262-1269. doi:10.1080/03235408.2013.763620
- LeCun Y., Bengio Y., Hinton G., 2015. Deep learning. Nature 521: 436–444. doi:10.1038/nature14539
- Leow L.K., Chew L.L., Chong V.C., Dhillon S.K., 2015 Automated identification of copepods using digital image processing and artificial neural network. BMC Bioinformatics, 16(18):1471-2105. doi:10.1186/1471-2105-16-S18-S4
- Liu H., Lee S-H., Chahl J.S., 2016. A review of recent sensing technologies to detect invertebrates on crops. Precision Agriculture 18(4):635–666. doi:10.1007/s11119-016-9473-6
- Liu H., Lee S.H., Chahl J.S., 2017. An evaluation of the contribution of ultraviolet in fused multispectral images for invertebrate detection on green leaves. Precision Agriculture, 18(4):667-683. doi:10.1007/s11119-016-9472-7
- Lowe D.G., 1999. Object Recognition from Local Scale-Invariant Features. Proceedings of the International Conference on Computer Vision-Volume 2 - Volume 2, Washington, DC, USA. IEEE Computer Society 2:1150–1157. doi:10.1109/ICCV.1999.790410
- Long J., Shelhamer E., Darrell T., 2015. Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, 3431-3440. doi:10.1109/CVPR.2015.7298965

- Lu J., Ehsani R., Shi Y., de Castro A.I., Wang S., 2018. Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1):2793. doi:10.1038/s41598-018-21191-6.
- Machado B.B., Orue J.P.M., Arruda M.S., Santos C.V., Sarath D.S., Goncalves W.N., Silva G.G., Pistori H., Roel A.R., Rodrigues-Jr J.F., 2016. BioLeaf: A professional mobile application to measure foliar damage caused by insect herbivory. *Computers and Electronics in Agriculture*, 129:44-55. doi:10.1016/j.compag.2016.09.007
- Maharlooei M., Sivarajan S., Bajwa S., Harmon J., Nowatzki J., 2017. Detection of soybean aphids in a greenhouse using an image processing technique. *Computers and Electronics in Agriculture*, 132:63-70. doi: 10.1016/j.compag.2016.11.019.
- Mahlein A.-K., Oerke E.-C., Steiner U., Dehne H.-W., 2012. Recent advances in sensing plant diseases for precision crop protection. *European Journal of Plant Pathology* 133(1):197–209. doi:10.1007/s10658-011-9878-z
- Martineau M., Conte D., Raveaux R., Arnault I., Munier D., Venturini G., 2017. A survey on image-based insects classification. *Pattern Recognition*, 65:273-284. doi:10.1016/j.patcog.2016.12.020
- Oerke E.-C., Steiner U., Dehne H.-W., Lindenthal M., 2006. Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions. *Journal of Experimental Botany* 57(9):2121-2132. doi:10.1093/jxb/erj170
- Ojala, T., Pietikainen, M., Maenpaa, T., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24(7):971–987. doi:10.1109/TPAMI.2002.1017623
- Pan, S.J., Yang, Q., 2010. A survey on transfer learning. In *IEEE Transactions on knowledge and data engineering* 22(10):1345-1359. doi:10.1109/TKDE.2009.191
- Pantazi X.E., Tamouridou A.A., Alexandridis T.K., Lagopodi A.L., Kashefi J., Moshou D., 2017. Evaluation of hierarchical self-organising maps for weed mapping using UAS multispectral imagery. *Computers and Electronics in Agriculture*, 139(2017):224-230. doi:10.1016/j.compag.2017.05.026
- Peruca R.D., Coelho R.G., da Silva G.G., Pistori H., Ravaglia L.M., Roel A.R., Alcantara G.B., 2018. Impacts of soybean-induced defenses on *Spodoptera frugiperda* (Lepidoptera: Noctuidae) development. *Arthropod-Plant Interactions*, 12(2):257–266. doi:10.1007/s11829-017-9565-x
- Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A.C., Fei-Fei L., 2015. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)* 115(3):211–252. arXiv:1409.0575
- Shajahan S., Sivarajan S., Maharlooei M., Bajwa S., Harmon J., Nowatzki J., Igathinathane C., 2016. Identification and Counting of Soybean Aphids from Digital Images using Particle Separation and Shape Classification. Conference: ASABE Annual International Meeting, At Orlando, Florida. doi:10.13031/aim.20162462927
- Simonyan K., Zisserman A., 2014. Very deep convolutional networks for large-scale image recognition. In *International Conference on Learning Representations (ICLR2015)*. arXiv:1409.1556

- Sirisomboon P., Hashimoto Y., Tanaka M., 2009. Study on non-destructive evaluation methods for defect pods for green soybean processing by near-infrared spectroscopy. *Journal of Food Engineering*, 93(4):502-512. doi:10.1016/j.jfoodeng.2009.02.019
- Swain, M.J., Ballard, D.H., 1991. Color indexing. *International Journal of Computer Vision* 7(1):11–32. doi:10.1007/BF00130487
- Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., 2015. Going deeper with convolutions. In: *Computer Vision and Pattern Recognition (CVPR)*. doi:10.1109/CVPR.2015.7298594
- Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z., 2016. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* 2818-2826. arXiv:1512.00567
- Tetila E.C., 2018. INSECT5K13C - Image dataset of soybean pests. Available: <https://bit.ly/2SKp9jC>
- Tetila E.C, Machado B.B., Belete N.A.S., Guimarães D.A., Pistori H., 2017a. Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Society* 14(12):2190-2194. doi:10.1109/LGRS.2017.2743715
- Tetila E.C., Machado B.B., Menezes G.K., Oliveira-Jr A.S., Alvarez M., Amorim W.P., Belete N.A.S., Silva G.G., Pistori H., 2017b. Automatic Recognition of Soybean Leaf Diseases Using UAV Images and Deep Convolutional Neural Networks. *IEEE Geoscience and Remote Sensing Letters*. doi: 905 10.1109/LGRS.2019.2932385
- Tetila E.C., Machado B.B., Menezes G.V., Belete N.A.S., Astolfi G., Pistori H., 2019. A Deep-Learning Approach for Automatic Counting of Soybean Insect Pests. *IEEE Geoscience and Remote Sensing Letters*. doi: 10.1109/LGRS.2019.2954735
- Yaakob S.N., Jain L., 2012. An insect classification analysis based on shape features using quality threshold ARTMAP and moment invariant. *Applied Intelligence*, 37(1):12-30. doi:10.1007/s10489-011-0310-3
- Yanan M., Min H., Bao Y., Qibing Z., 2014. Automatic threshold method and optimal wavelength selection for insect-damaged vegetable soybean detection using hyperspectral images. *Computers and Electronics in Agriculture* 106:102-110. doi:10.1016/j.compag.2014.05.014
- Wang N., Yeung D.-Y., 2013. Learning a deep compact image representation for visual tracking. In *Proceedings of the 26th International Conference on Neural Information Processing Systems (NIPS)*, USA, 1:809–817. [Online]. Available: <http://dl.acm.org/citation.cfm?id=2999611.2999702>
- Wang J., Lin C., Ji L, Liang A., 2012. A new automatic identification system of insect images at the order level. *Know.-Based Syst.*, 33:102-110. doi:10.1016/j.knosys.2012.03.014
- Wang S., Fan K., Luo N., Cao Y., Wu F. Zhang C., Heller K.A., You L., 2019. Massive computational acceleration by using neural networks to emulate mechanism-based biological models. *Nat Commun* 10, 4354 (2019). doi: 10.1038/s41467-019-12342-y
- Weiss U., Biber P., Laible S., Bohlmann K., Zell A., 2010. Plant Species Classification Using a 3D LIDAR Sensor and Machine Learning. *Ninth International Conference on Machine Learning and Applications*, Washington, DC, 339-345. doi:10.1109/ICMLA.2010.57

Wen C., Wu D., Hu H., Pan W., 2015. Pose estimation-dependent identification method for field moth images using deep learning architecture. *Biosystems Engineering*, 136:117-128, doi:10.1016/j.biosystemseng.2015.06.002.

CAPÍTULO 6 - UMA ABORDAGEM DE APRENDIZAGEM PROFUNDA PARA CONTAGEM AUTOMÁTICA DE INSETOS-PRAGA NA SOJA

Everton Castelão Tetila

Universidade Federal da Grande Dourados, Dourados, Mato Grosso do Sul, Brasil

Bruno Brandoli Machado

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Geazy Vilharva Menezes

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Nícolas Alessandro de Souza Belete

Universidade de Rondônia, Cacoal, Rondônia, Brasil

Gilberto Astolfi

Universidade Federal de Mato Grosso do Sul, Campo Grande, Mato Grosso do Sul, Brasil

Hemerson Pistori

Universidade de Rondônia, Cacoal, Rondônia, Brasil

RESUMO: A ocorrência de ataques de insetos-pragas nos campos de soja tem preocupado agricultores ao redor do mundo. O diagnóstico precoce e automático da quantidade de insetos-praga poderia avaliar o nível de infestação de cada área da plantação para otimizar as aplicações de pesticidas na cultura e, consequentemente, reduzir os custos de produção e o impacto ambiental. Pesquisas recentes em contagem de insetos adotaram redes neurais profundas. No entanto, pesquisas empregaram modelos treinados para contar somente uma espécie de inseto, usando imagens capturadas em um ambiente controlado, bastante diferente de um cenário real. Para obter uma alta acurácia, avaliamos três modelos de redes neurais convolucionais com três estratégias de treinamento diferentes: 100% de ajuste fino (*fine-tuning*) com os pesos obtidos no ImageNet, rede completa com os pesos inicializados aleatoriamente e transferência de aprendizagem (*transfer learning*) com os pesos obtidos no ImageNet. O aumento (*data augmentation*) e a eliminação (*dropout*) de dados foram usados durante o treinamento da rede para reduzir o sobreajuste (*overfitting*) e aumentar a generalização do modelo. Nossa abordagem consiste em segmentar uma imagem da plantação com o método SLIC e classificar cada segmento de superpixel em uma classe de insetos-praga usando o modelo de classificação treinado pela rede neural profunda. A contagem de insetos-praga é obtida adicionando-se os insetos de cada classe de superpixels identificados pelo nosso sistema de visão computacional. Os resultados indicam que os modelos de aprendizagem profunda podem ser usados com sucesso para apoiar especialistas e agricultores no manejo de insetos-pragas nos campos de soja.

PALAVRAS-CHAVE: Aprendizagem profunda, agricultura de precisão, insetos-praga da soja.

1 | INTRODUÇÃO

Nos últimos anos, a ocorrência de pragas agrícolas nos campos de soja tem preocupado agricultores de diferentes regiões do mundo e o número de aplicações de pesticidas tem se intensificado por causa da resistência do princípio ativo por seleção. Estima-se que a maior parte do montante dos custos diretos para a produção de soja esteja concentrada nos fertilizantes (27,82%), seguidos pelos pesticidas (18,24%), operações com máquinas (9,10%), sementes (7,35%) e depreciação de máquinas e implementos (6,76%) [1].

O controle de insetos-praga consiste em tomadas de decisão de manejo baseadas no nível de infestação e no estágio de desenvolvimento das plantas. Essas informações são obtidas com inspeções regulares por amostragem em diferentes regiões da lavoura, usando métodos de amostragem como: pano-de-batida, rede-de-varredura, exame visual de plantas, amostragem de solo e armadilha iscada com feromônio; no entanto, as inspeções regulares são difíceis de realizar quando se cultivam grandes áreas. A detecção precoce de insetos-praga permite uma aplicação mais eficiente de pesticidas, visto que os insumos podem ser aplicados na medida e locais corretos, reduzindo-se assim, os custos de produção e o impacto ambiental decorrente da aplicação de pesticidas na área total, além de contribuir com a saúde humana e a segurança alimentar [2].

Como alternativa aos métodos de amostragens manuais, há uma motivação crescente para usar imagens digitais coletadas do campo, tornando possível a criação de um sistema de visão computacional para identificar e contar diferentes espécies de insetos-praga de uma região da lavoura. Isso é essencial para tornar este tipo de aplicação viável, uma vez que uma grande quantidade de imagens é capturada e são necessárias analisá-las automaticamente. Além disso, câmeras de alta resolução espacial podem ser embarcadas em Veículos Aéreos não Tripulados (VANTs) para capturar imagens da plantação em missões de coleta de dados, permitindo que especialistas e agricultores tomem melhores decisões de manejo de pragas.

Neste artigo, propusemos um sistema de visão computacional para identificar automaticamente insetos-praga na soja, a partir de imagens capturadas por uma câmera digital. Primeiro, consideramos uma etapa de segmentação de imagem com o método SLIC Superpixels para segmentar os insetos nas imagens coletadas durante a fase de inspeção no campo. A abordagem proposta foi testada usando um conjunto de dados com 10.000 imagens, dividido em 7 classes de insetos-praga, para medir a acurácia e o tempo de treinamento dos modelos de aprendizagem profunda na tarefa de classificação. Nossa metodologia avalia o desempenho de três redes neurais profundas bem conhecidas da literatura, treinadas com três estratégias de treinamento diferentes: 100% de ajuste fino (*fine-tuning*) das camadas de rede com os pesos obtidos no ImageNet, rede completa com os pesos inicializados aleatoriamente e transferência de aprendizagem (*transfer learning*)

com os pesos obtidos no ImageNet.

Nós usamos o modelo de classificação da rede neural profunda melhor avaliada para a acurácia em nosso sistema de visão computacional com o objetivo de classificar os superpixels na imagem e contar os insetos de cada classe, calculando assim, o nível de infestação de uma região da lavoura. Na tarefa de contagem, quatro métricas foram usadas para avaliar a abordagem proposta.

2 | TRABALHOS RELACIONADOS

Dentro do paradigma da aprendizagem profunda, [3] projetou um contador automático para discernir e contar ovos de nematódeos de cisto de soja (NCS) por meio de imagens microscópicas. Eles treinaram uma rede neural convolucional (RNC) com dados rotulados por especialistas para aprender a reconstruir um padrão de “ovo” reduzindo cada imagem rotulada em um conjunto de dimensões (16×16) contendo um único ovo ou nenhum ovo. O modelo então verifica as imagens de teste, *patch* por *patch* e, em seguida, identifica se cada *patch* contém um ovo. Os ovos detectados são então contados usando uma função de anotação da matriz. Os resultados indicam melhorias significativas no tempo de quantificação dos ovos, mantendo a precisão do nível humano, no entanto, onde ocorrem sobreposições ou oclusão dos ovos NCS, a ferramenta de contagem não foi tão eficiente.

Chen *et al.* [4] propôs um método para segmentação e contagem de ninfas de afídeos usando RNCs. Imagens digitais de folhas de *pakchoi* (repolho chinês) em diferentes estágios de infestação de afídeos foram obtidas e uma máscara binária no nível de pixel correspondente foi anotada manualmente para cada imagem, identificando cada pixel como um afídeo (branco) ou fundo (preto). Após a segmentação, eles simplesmente contaram o número de componentes brancos conectados como a quantidade de ninfas de afídeo para cada imagem. O resultado da contagem automática mostrou alta precisão (0,9563) e revocação (0,9650), porém o método falhou em alguns casos: lesões em folhas, exoesqueletos de pulgões velhos e áreas de condições de iluminação complexas. Outra limitação deste método é o tedioso procedimento de anotação, pixel por pixel, antes do treinamento.

Algoritmos de aprendizagem de máquina também foram propostos para detectar espécies de insetos, como abelhas [5], invertebrados comuns (p. ex. borboletas, gafanhotos) e moluscos (p. ex. caracóis e lesmas) [6], além de contar moscas brancas [7] e pulgões [8] em folhas de soja. No entanto, em todos os trabalhos citados, as imagens foram coletadas em condições onde a iluminação e a reflexão de fundo podem ser bem controladas, além disso, os autores não compararam os resultados com outras abordagens do estado da arte, como Inception-ResNet-v2 e DenseNet-201.

Uma abordagem baseada em aprendizagem profunda usando imagens capturadas em condições reais do campo, sob diferentes condições de iluminação, tamanho de objetos

e variações de fundo foi proposta em [9] para detectar doenças e pragas em plantas de tomate. Uma revisão da literatura sobre classificação de insetos baseada em imagens, em que foram investigadas as questões que ainda podem permanecer não resolvidas foi apresentada em [10].

3 | ABORDAGEM PROPOSTA

Esta seção apresenta uma abordagem de visão computacional para classificação e contagem de insetos-praga na soja, a partir de imagens coletadas em condições reais do campo. A abordagem proposta adota o método SLIC Superpixels para segmentar os insetos nas imagens. O método SLIC emprega o algoritmo *k-means* [11] para a geração de regiões semelhantes, chamadas superpixels. O parâmetro k do algoritmo refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels. O parâmetro m corresponde ao controle de compactação das regiões geradas. Nós fixamos os parâmetros $k=1.000$ e $m=50$ para segmentar os insetos nas imagens, definidos pela aderência aos limites de tamanho e compactação do algoritmo SLIC. Esses parâmetros correspondem ao menor tamanho de superpixel encontrado para segmentar o maior objeto de interesse na imagem, no caso, o inseto-praga da espécie *Spodoptera*.

O algoritmo SLIC Superpixels agrupa pixels de acordo com a cor dos pixels usando os componentes CIELAB¹, l , a , b , bem como as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões regulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os centros dos agrupamentos de superpixel $C_k = [l_k, a_k, b_k, x_k, y_k]$ com $k = [1, k]$ são amostrados em uma matriz regular espaçada em S pixels. Os centros são movidos para a posição de gradiente mais baixa em uma vizinhança de 3×3 , evitando a alocação de centroides em uma borda e reduzindo a chance de semear um superpixel com um pixel ruidoso. Cada pixel é associado ao centro do agrupamento mais próximo, uma etapa de atualização ajusta os centros dos agrupamentos para serem o vetor médio $labxy$ de todos os pixels pertencentes ao agrupamento [12].

Um diagrama esquemático do sistema proposto é mostrado na Figura 6.1. Ela ilustra a abordagem proposta que consiste em quatro etapas: (a) Aquisição de imagem, (b) Segmentação SLIC, (c) Anotação de imagem e, finalmente (e) Classificação e contagem de pragas. Inicialmente, foi realizada uma inspeção no campo para capturar imagens da plantação (veja o passo (a) na Figura 6.1). Estas imagens foram segmentadas usando o método SLIC Superpixels (veja o passo (b) da Figura 6.1). Após a segmentação da imagem, cada superpixel foi anotado por um especialista para compor um conjunto de dados de imagens de superpixel para treinamento e teste do sistema, veja o passo (c) da Figura 6.1. Depois, as imagens anotadas foram divididas em sete classes de insetos-

¹ O espaço de cores CIELAB é definido por três valores: L^* para a luminosidade de preto (0) para branco (100), a^* de verde (-) para vermelho (+) e b^* de azul (-) para amarelo (+).

praga: (1) *Diabrotica speciosa*, (2) *Euschistus heros* adult, (3) *Euschistus heros* nymph, (4) *Euschistus heros* mating, (5) *Gastropoda*, (6) *Spodoptera* spp. e (7) sem insetos-praga (fundo). Posteriormente, uma RNC foi treinada para aprender os recursos visuais dos superpixels e, finalmente, criar o modelo de classificação para classificar imagens de insetos-praga (veja o passo (d) da Figura 6.1).

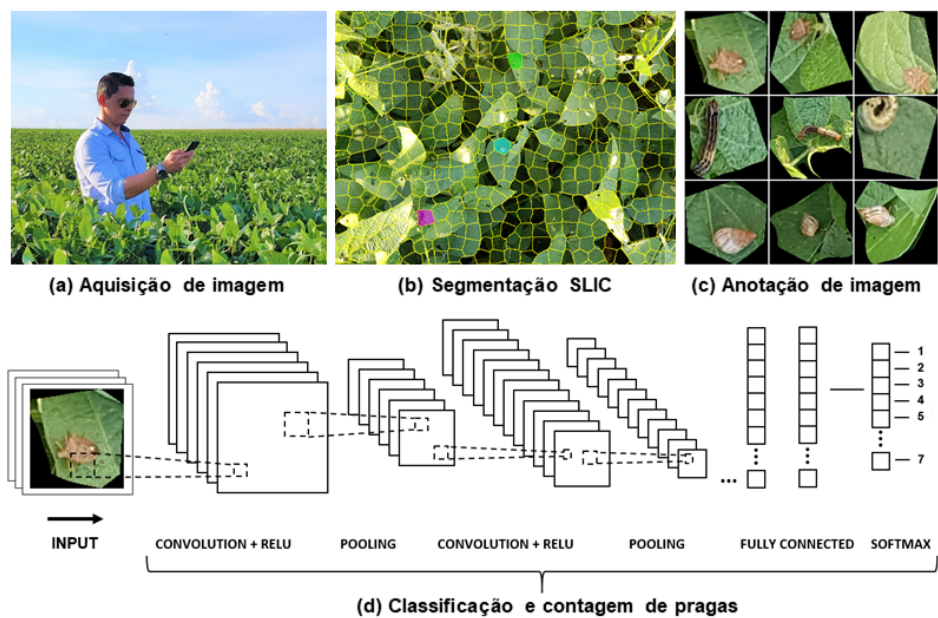


Figura 6.1 – Proposta de um sistema de visão computacional para classificar e contar insetos pragas da soja.

O estágio de pós-processamento consiste em segmentar uma imagem da plantação com o método SLIC e classificar cada segmento de superpixel em uma classe específica. O sistema percorre a imagem da esquerda para a direita de cima para baixo, classificando cada superpixel individualmente usando o modelo de classificação treinado pela RNC, enquanto fornece a cor da classe simultaneamente. Assim, um mapa colorido é gerado fornecendo uma classe por segmento. A contagem de insetos-praga é obtida pelo resultado da adição de cada classe de superpixels relatada pelo nosso sistema de visão computacional. A complexidade computacional do processo de segmentação limita o espaço de busca a uma região proporcional ao tamanho dos superpixels. Isso reduz a complexidade linear ao número de k superpixels, em vez do número de n pixels.

4 | MATERIAIS E MÉTODOS

4.1 Aquisição de imagem

As imagens da plantação foram coletadas em uma área agrícola de soja de 100ha localizada na cidade de Dourados-MS, Brasil, com coordenadas geográficas 22°14'15.83" de latitude sul e 55°0'1.75" de longitude oeste. Um total de 1.000 imagens foram coletadas em dias e condições climáticas diferentes, entre 18h e 19h:30min, durante os estádios fenológicos reprodutivos R1 a R6 da fase reprodutiva da soja na safra 2018/19. Duas pessoas participaram da coleta de imagens e anotação do conjunto de dados, sendo um especialista em domínio.

As imagens digitais com tamanho 4032 × 2268 pixels foram capturadas pelo pesquisador no local, usando uma câmera digital equipada com um sensor 1/2.5" Samsung SM-G930F de 12.2 megapixels de resolução. Essas imagens foram registradas sobre os alvos de interesse a 1 metro de altura da plantação, usando um ângulo de aproximadamente 45° da câmera em relação ao solo. Neste caso, escolhemos um metro porque valores mais baixos diminuem a quantidade de insetos na imagem; por outro lado, usando valores mais altos, o tamanho do inseto na imagem é gradualmente reduzido e, conseqüentemente, a resolução do inseto na imagem diminui. Também consideramos o uso de 1 metro de altura porque sua área de cobertura é semelhante a um pano de batida. Em seguida, cada imagem foi segmentada com o método SLIC Superpixels e anotada com apoio de um especialista, criando assim, um conjunto de dados de imagens de superpixel para treinamento e teste do sistema (veja a Figura 6.2), chamado INSECT10K7C e disponível em [13].

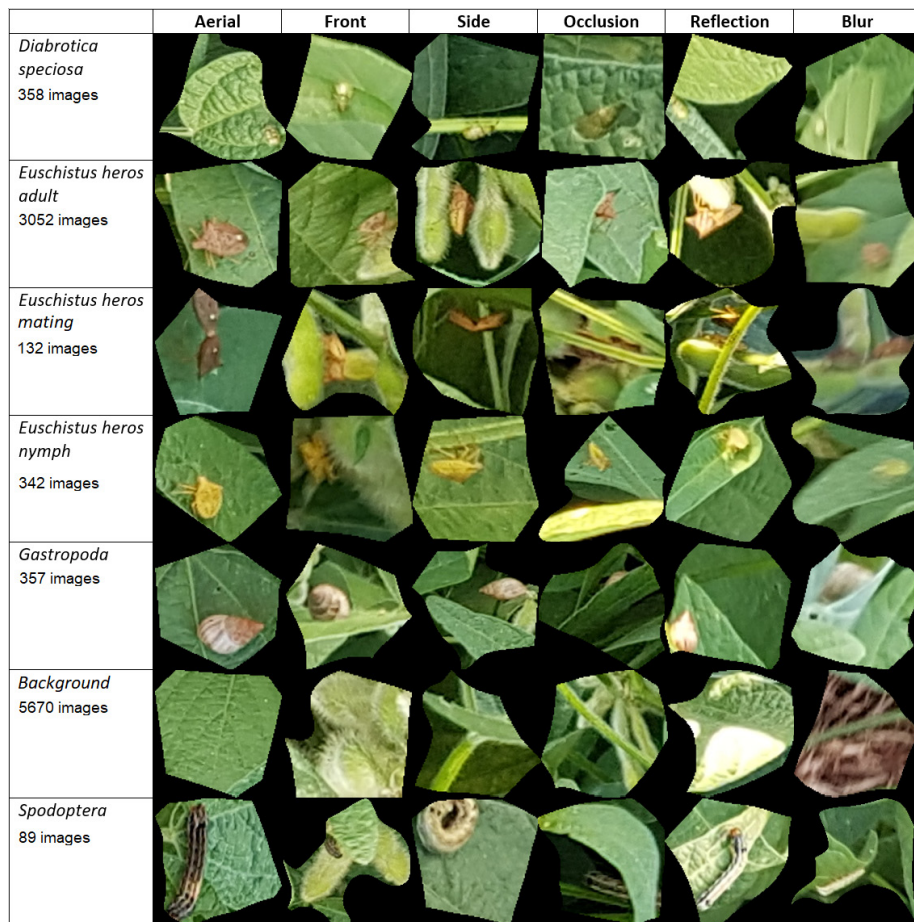


Figura 6.2 – Exemplos de imagens de superpixels do conjunto de imagens, divididos em espécies de insetos-praga da cultura da soja, fundo e números de imagens por classe.

Como mostra a Figura 6.2, as imagens foram coletadas em condições reais de campo com diversas variações não controladas, como condições de iluminação e reflexão distintas, tamanho e posicionamento de objetos, oclusão, movimento das folhas, variações de fundo, acasalamento e fases de desenvolvimento. Essas variações nas condições reais de campo contribuem para o sistema operar em um cenário real. No campo experimental, constatou-se que a exposição dos insetos na parte superior das plantas geralmente ocorre no início do dia ou no final da tarde, reforçando a recomendação de que amostragens de insetos da parte aérea sejam realizadas, preferencialmente, nos períodos com temperaturas mais amenas do dia ($\leq 30^{\circ}\text{C}$) e com maior umidade ($\geq 55\%$), conforme relatado em [14].

4.2 Desenho experimental

Na tarefa de contagem, nós dividimos um total de 1.000 imagens coletadas da área agrícola em 70% para o treinamento (Z_1) e 30% para o teste (Z_2). Quatro métricas foram

usadas para avaliar o desempenho da contagem no conjunto (Z_2): acurácia de detecção média, precisão média, medida-F e erro médio absoluto.

Na tarefa de classificação, duas métricas foram usadas para avaliar o desempenho dos classificadores: acurácia e tempo de treinamento para construir o modelo de classificação. Para o treinamento e teste dos classificadores, uma validação cruzada de 10 dobras estratificada foi usada no conjunto Z_1 que contém as imagens de superpixels. Neste esquema, as imagens do conjunto de dados são particionadas em 10 dobras, garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para teste, enquanto as dobras restantes são usadas para treinar o classificador. O processo é repetido 10 vezes usando cada dobra exatamente uma vez para o teste. Finalmente, a acurácia é dada pela média das 10 rodadas. Para cada modelo de RNC testado, nós calculamos os desempenhos médios para as métricas acurácia e tempo de treinamento.

Na etapa de segmentação, cada imagem do conjunto (Z_1) foi segmentada e todos os insetos-praga localizados nas imagens foram rotulados. O número de cada espécie na Figura 6.2 representa a ocorrência total dos insetos-praga nas imagens. Nesta etapa, constatou-se a baixa ocorrência de insetos que não causam dano econômico à soja: como *Musca domestica*, *Araneae*, *Coccinellidae*, *Lepidoptera* e *Formicidae*. Outras espécies causadoras de dano também foram encontradas em pequeno número, como *Edessa meditabunda*, *Nezara viridula*, *Dichelops melacanthus* e *Acrididae*. Essas espécies foram excluídas do conjunto de imagens porque o número de ocorrências (<.05%) não é representativo em relação ao tamanho da amostra, além de ser considerado limitado para treinar as redes neurais convolucionais. Nós também criamos uma classe chamada *Euschistus herus nymph* que corresponde a mesma espécie do inseto *Euschistus heros* em fases de ninfa porque esta distinção é importante na avaliação do nível de infestação de insetos-praga no campo. De modo semelhante, nós também criamos uma classe chamada *Euschistus herus mating* para representar o acasalamento desta espécie, ou ainda dois insetos desta espécie no mesmo segmento, porque este é um evento comum no campo e a segmentação de objetos sobrepostos ou muito próximos entre si tem sido um problema de difícil solução, conforme relatado em [3].

Para analisar se os modelos diferem estatisticamente em relação ao seu desempenho, utilizamos o teste de hipótese ANOVA. Relatamos os valores- p encontrados para cada métrica e o nível de significância foi definido para 5%.

4.3 Aumento de Dados e Análise de Treinamento

Para classificação de imagens, modelos de aprendizagem profunda são treinados com imagens rotuladas para aprender como identificá-las e classificá-las de acordo com os padrões visuais. Em nossos experimentos, usamos implementações de código aberto de três modelos de aprendizagem profunda reconhecidos pela concorrência no ImageNet:

Inception-Resnet-v2 [15], ResNet-50 [16] e DenseNet-201 [17].

Nos experimentos, usamos os seguintes parâmetros de entrada. A largura e a altura da imagem de entrada foram igualmente definidas em 256 pixels. O tamanho do lote foi definido com 16 imagens para treinamento e o número de épocas foi usado 50, uma vez que a convergência estava em poucas iterações. Usamos o otimizador SGD com taxa de aprendizagem de 0,0001 e momento de 0,9 (acelera o SGD na direção relevante e amortece as oscilações). A abordagem proposta usa um conjunto de 10.000 imagens de superpixels distribuído em 7 classes, o que pode não ser suficiente para treinar um modelo de aprendizagem profunda. Assim, o conjunto de dados foi submetido à técnica de aumento de dados para aumentar a quantidade de dados aplicando operações de rotação, reescala, rolagem e zoom. Esta técnica visa reforçar a invariância de rotação e invariância à escala na tarefa de classificação. A taxa de *dropout* utilizada nos experimentos foi fixada em 50%. Também mantivemos os mesmos parâmetros para o aumento de dados, isto é, reescala de 1./255 significando o fator de multiplicação para cada pixel da imagem, com rolagem horizontal (alterna aleatoriamente imagens horizontalmente), modo de preenchimento mais próximo (pontos fora do limites de entrada são preenchidos de acordo com a direção mais próxima); faixa de zoom com fator de ampliação de imagem 0.3, faixa de deslocamento de largura de 0.3 para fator de deslocamento horizontal e vertical, faixa de rotação de 30.

Com o objetivo de avaliar estatisticamente o potencial dos modelos para identificação de insetos-praga, definimos três diferentes estratégias de treinamento. Utilizamos um ajuste fino de 100% para as camadas de rede com os pesos obtidos do ImageNet. Também treinamos a rede completa com os pesos inicializados aleatoriamente, além de um aprendizado de transferência com os pesos obtidos do ImageNet. Em todos os nossos experimentos usamos uma workstation com Processor Intel Core i7-6800K 3.40GHz 15MB (6N, 12T), placa gráfica Nvidia Titan Xp 12GB 3840 cuda cores, memória RAM 16GB Kingston DDR4 2400MHz, SSD de armazenamento 120GB 2.5" SATA III Kingston Ultra-valor 400.

5 | RESULTADOS E DISCUSSÃO

A Tabela 1 mostra os resultados da acurácia obtidos pelos modelos de aprendizagem profunda. Nossa abordagem alcançou o melhor resultado com o DenseNet-201 (94,89%) usando um ajuste fino de 100% (FT). A tabela também mostra o tempo total de treinamento, em horas, para construir o modelo de classificação. Os resultados de tempo da Tabela 1 referem-se às especificações de hardware apresentadas na Seção 4.3. Os resultados do teste ANOVA indicam que não há evidência de diferença estatisticamente significativa no desempenho médio dos modelos testados em um nível de significância de 5% usando a acurácia (valor- $p = .382$) e o tempo de treinamento (valor- $p = .202$) como métricas. Além disso, a estratégia de ajuste fino (FT) apresentou taxas de classificação mais altas em

comparação com outras estratégias de treinamento, mas ela obteve longos períodos de treinamento porque mais camadas são retreinadas usando essa estratégia.

Modelo	Estratégia de Treinamento	Tempo de Treinamento (h)	Acurácia (%)
DenseNet-201	FT	24.47	94.89
DenseNet-201	TL	19.40	61.16
DenseNet-201	No TL	23.59	85.29
Inception-Resnet-v2	FT	31.48	93.40
Inception-Resnet-v2	TL	18.42	66.79
Inception-Resnet-v2	No TL	28.01	85.86
Resnet-50	FT	22.38	93.78
Resnet-50	TL	19.31	59.27
Resnet-50	No TL	22.16	84.32

Tabela 1. Métricas de desempenho usadas para avaliar os modelos de aprendizagem profunda.

A Figura 6.3 apresenta as matrizes de confusão dos modelos de aprendizagem profunda para as imagens do conjunto de testes. De acordo com esta figura, a classe *Euschistus heros acasalamento* e *Euschistus heros* obtiveram proporcionalmente o maior número de ocorrências mal classificadas, uma vez que ambas as classes se referem à mesma espécie de inseto em diferentes quantidades. No entanto, a classe *Euschistus heros* foi capaz de discriminar bem os insetos individuais nas imagens em relação à classe de acasalamento que contém dois insetos. Além disso, a matriz de confusão para a estratégia de treinamento de transferência de aprendizagem (TL) mostra que os modelos de aprendizagem profunda treinados com os pesos obtidos no ImageNet somente refinaram a detecção de fundo e não contribuíram significativamente para a detecção correta de classes de insetos. Por outro lado, o ajuste fino (FT) alcançou as maiores taxas de classificação em comparação com outras estratégias de treinamento.

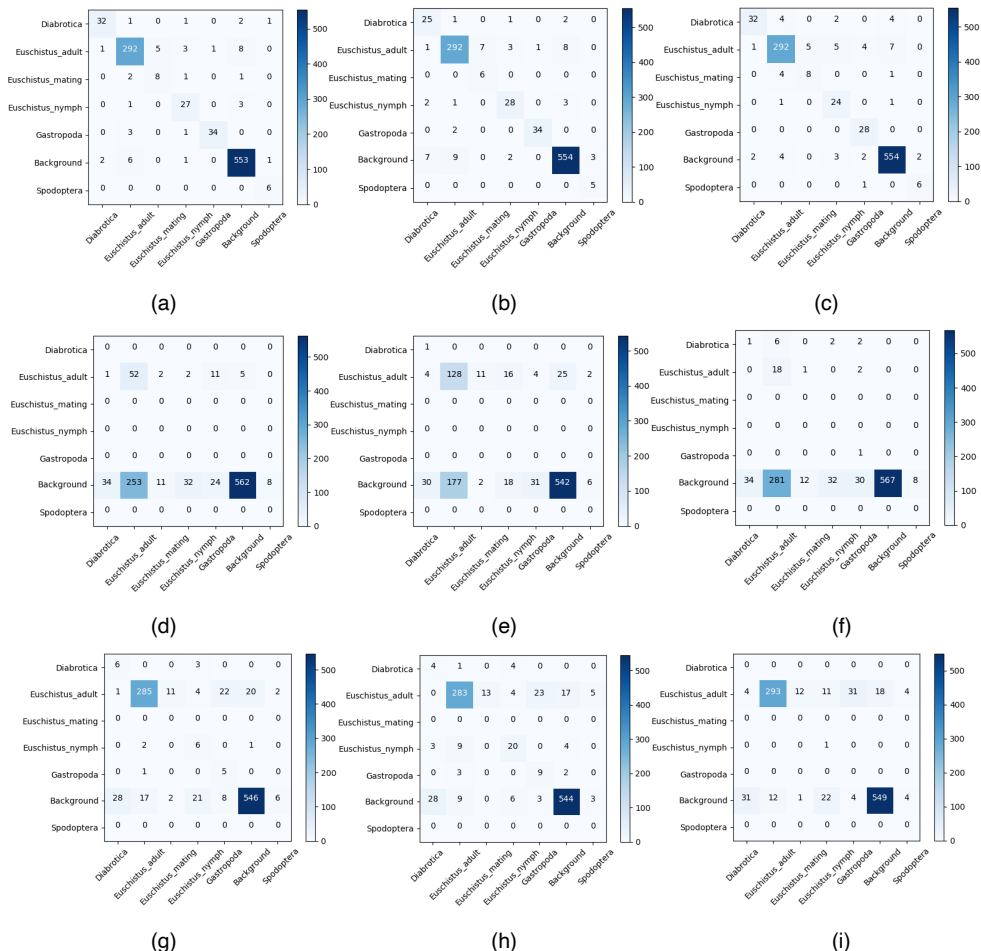


Figura 6.3 –Matrizes de confusão dos modelos de aprendizagem profunda. (a) DenseNet-201 FT. (b) Inception-Resnet-v2 FT. (c) Resnet-50 FT. (d) DenseNet-201 TL. (e) Inception-Resnet-v2 TL. (f) Resnet-50 TL. (g) DenseNet-201 No TL. (h) Inception-Resnet-v2 No TL. (i) Resnet-50 No TL.

A Tabela 2 apresenta quatro métricas propostas para avaliar o desempenho da contagem no conjunto de testes Z_2 . Usamos a RNC de melhor valor para a acurácia na tarefa de classificação empregando os pesos do modelo DenseNet-201 FT em nosso sistema de visão computacional. A contagem de insetos-praga é obtida pelo resultado da adição dos superpixels de cada classe, como mostra a Figura 6.4. A classe *Euschistus heros mating* é a única exceção. O resultado quantitativo dessa classe foi multiplicado por dois porque contém dois insetos em cada superpixel. Assim, o resultado quantitativo das pragas de insetos de cada imagem da plantação pode ser comparado entre a contagem humana e a contagem do nosso sistema de visão computacional para as quatro métricas propostas.

Métrica	Fórmula	Conjunto de Teste (Z_2)
Acurácia de detecção média (ADM)	$\frac{\sum CA}{\sum CH + ME}$	$\frac{2038}{2243} = 90,86\%$
Precisão Média (PM)	$\frac{\sum CA}{\sum CH + ME + \sum CE}$	$\frac{2038}{2285} = 89,19\%$
Medida-F	$\frac{2 \times PM \times ADM}{PM + ADM}$	0,90
Erro médio absoluto	$\frac{1}{N} \sum_{i=1}^N CH - CA $	0,61

onde CA é a contagem do algoritmo, CH é a contagem humana, ME é a margem de erro, CE é a contagem excedida e N é o número total de imagens de amostra testadas. A margem de erro é encontrada tomando 5% da contagem total humana para todas as imagens no conjunto de testes (Z_2).

Tabela 2. Métricas de desempenho usadas para avaliar a abordagem proposta na tarefa de contagem.



Figura 6.4 – Captura de tela do nosso sistema de visão computacional em um campo de cultivo de soja. O sistema denominado PYNOVISÃO apresenta a etapa de segmentação de insetos-praga e a classificação de superpixels utilizando o modelo DenseNet-201 FT. Os rótulos de cor representam as categorias do nosso problema. PYNOVISÃO foi registrado pelo INPI sob o número BR 51 2019 000427 2.

6 | CONCLUSÃO

Neste artigo, avaliamos três modelos de aprendizagem profunda para as tarefas de classificação e contagem de insetos-praga da soja. Consideramos um passo de segmentação de imagem com o algoritmo SLIC Superpixels para segmentar os insetos nas imagens. Na etapa de classificação, comparamos três modelos de aprendizagem profunda reconhecidos pela concorrência no ImageNet: Inception-Resnet-v2, ResNet-50 e DenseNet-201. O DenseNet-201, usando um ajuste fino (FT) de 100%, foi o modelo mais apropriado para a classificação de insetos-praga da soja a partir de imagens coletadas a

1 metro de altura. Os resultados experimentais também mostraram que os modelos de aprendizagem profunda treinados com um ajuste fino levam a taxas de classificação mais altas em comparação às outras estratégias de treinamento.

No experimento com contagem, nós usamos o modelo de classificação da rede neural profunda melhor avaliada para a acurácia em nosso sistema de visão computacional com o objetivo de classificar cada segmento de superpixel da imagem. A contagem dos insetos-pragas foi obtida somando os superpixels de cada classe, calculando assim, o nível de infestação de uma região da lavoura. Os resultados da contagem mostraram que a acurácia diminui quando um mesmo inseto é segmentado em dois superpixels diferentes. Este é um campo de pesquisa que tem sido explorado, mas ainda não está resolvido.

Também foi demonstrado como um modelo de aprendizagem profunda pode ser implementado em um sistema de visão computacional para operar em um cenário real do campo, sob diferentes condições de iluminação, tamanho de objetos e variações de fundo. Os resultados indicam que os modelos avaliados podem apoiar agricultores no monitoramento de insetos-praga da soja. Como parte do trabalho futuro, pretendemos avaliar novas abordagens de aprendizagem de máquina para detecção de múltiplos objetos com câmeras de maior resolução embarcadas no VANT.

AGRADECIMENTOS

Agradecemos ao Centro Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à NVIDIA Corporation pela doação da placa gráfica e à Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do estado de Mato Grosso do Sul (FUNDECT).

REFERÊNCIAS

- [1] C. N. de Abastecimento (CONAB), “Compêndio de Estudos Conab: Evolução dos custos de produção de soja no Brasil (in português)”, Brasília, v.2, pp. 1–22, 2016. ISSN: 2448-3710
- [2] E. C. Tetila, B. B. Machado, N. A. d. S. Belete, D. A. Guimarães, and H. Pistori, “Identification of soybean foliar diseases using unmanned aerial vehicle images,” *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 12, pp. 2190–2194, 2017. DOI: 10.1109/LGRS.2017.2743715
- [3] A. Akintayo, G. L. Tylka, A. K. Singh, B. Ganapathysubramanian, A. Singh, and S. Sarkar, “A deep learning framework to discern and count microscopic nematode eggs,” *Scientific Reports - Nature*, vol. 8, no. 1, pp. 1–11, 2018. DOI: 10.1038/s41598-018-27272-w
- [4] J. Chen, Y. Fan, T. Wang, C. Zhang, Z. Qiu, and Y. He, “Automatic Segmentation and Counting of Aphid Nymphs on Leaves Using Convolutional Neural Networks,” *Agronomy*, vol. 8, no. 8, p. 129, 2018. DOI: 10.3390/agronomy8080129

- [5] F. L. da Silva, M. L. G. Sella, T. M. Franco, and A. H. R. Costa, "Evaluating classification and feature selection techniques for honeybee subspecies identification using wing images," *Computers and Electronics in Agriculture*, vol. 114, pp. 68 – 77, 2015. DOI: 10.1016/j.compag.2015.03.012
- [6] H. Liu, S.-H. Lee, and J. S. Chahl, "A review of recent sensing technologies to detect invertebrates on crops," *Precision Agriculture*, vol. 18, no. 4, pp. 635–666, Aug 2017. DOI: 10.1007/s11119-016-9473-6
- [7] J. G. A. Barbedo, "Using digital image processing for counting whiteflies on soybean leaves," *Journal of Asia-Pacific Entomology*, vol. 17, no. 4, pp. 685 – 694, 2014. DOI: 10.1016/j.aspen.2014.06.014
- [8] M. Maharlooei, S. Sivarajan, S. G. Bajwa, J. P. Harmon, and J. Nowatzki, "Detection of soybean aphids in a greenhouse using an image processing technique," *Computers and Electronics in Agriculture*, vol. 132, pp. 63 – 70, 2017. DOI: 10.1016/j.compag.2016.11.019
- [9] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition," *Sensors*, vol. 17, no. 9, p. 2022, 2017. DOI: 10.3390/s17092022
- [10] M. Martineau, D. Conte, R. Raveaux, I. Arnault, D. Munier, and G. Venturini, "A survey on image-based insect classification," *Pattern Recognition*, vol. 65, pp. 273 – 284, 2017. DOI: 10.1016/j.patcog.2016.12.020
- [11] J. A. Hartigan and M. A. Wong, "A K-means clustering algorithm," *JSTOR: Applied Statistics*, vol. 28, no. 1, pp. 100–108, 2013.
- [12] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. S. S. Strunk, "Slic superpixels compared to state-of-the-art superpixel methods," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 11, pp. 2274–2282, Nov 2012. DOI: 10.1109/TPAMI.2012.120
- [13] E. C. Tetila, INSECT10K7C - Insects pests dataset of soybean crop. <https://bit.ly/2Oy5Kjo>, 2019.
- [14] B. S. Corrêa-Ferreira, *Soja: manejo integrado de insetos e outros artrópodes-praga*. Londrina: Embrapa Soja, cap 9, p. 631-672. Embrapa, 2012. ISBN 978-85-7035-139-5
- [15] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 2016, pp. 2818–2826. DOI: 10.1109/CVPR.2016.308
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 2016, pp. 770–778. arXiv:1512.03385
- [17] G. Huang, Z. Liu, L. v. d. Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 2017, pp. 2261–2269. arXiv:1608.06993

CAPÍTULO 7 - CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou um sistema de visão computacional para identificar doenças foliares e insetos-praga na cultura da soja com imagens de VANT. Inicialmente, avaliou-se o desempenho de seis técnicas rasas de aprendizagem de máquina para identificar doenças na soja, usando cinco alturas de voo diferentes: 1, 2, 4, 8 e 16 metros. Os experimentos sustentaram a hipótese de que as alturas de voo mais próximas entre o VANT e a planta apresentam maiores taxas de classificação correta. O classificador SVM combinado com SLIC obteve 98,34% na identificação da doença foliar usando alturas de voo entre 1 e 2 metros, com decaimento de 2% a cada metro, uma vez que a resolução da planta na imagem diminui para alturas de voo mais altas. Os experimentos também confirmaram que mesmo catalogando novas doenças e aumentando o número de 3 para 6 classes, não houve evidência de diferença estatística significativa das métricas de desempenho para os dados coletados pelo VANT a 2 metros de altura da plantação.

Quatro arquiteturas de aprendizagem profunda - Inception-V3, Resnet-50, VGG-19 e Xception - foram avaliadas para o reconhecimento automático de doenças foliares da soja, usando imagens capturadas pelo VANT a 2 metros de altura da plantação. Considerou-se uma etapa de segmentação de imagem com o algoritmo SLIC Superpixels para segmentar as folhas das plantas nas imagens. Na etapa de classificação, o desempenho das arquiteturas de aprendizagem profunda foi comparado com outras abordagens tradicionais, usando diferentes estratégias de ajuste fino e transferência de aprendizagem. Os resultados experimentais mostraram que as arquiteturas de aprendizagem profunda possibilitam taxas de classificação mais altas em comparação a outras abordagens, atingindo uma acurácia de até 99,04%. Além disso, as estratégias de ajuste fino 100% e 75% alcançaram as maiores taxas de classificação em comparação a outras estratégias de treinamento, no entanto obtiveram longos tempos de treinamento porque o ajuste fino não apenas substitui e treina novamente o classificador no conjunto de dados, mas também ajusta os pesos da rede neural pré-treinados com o algoritmo de retropropagação. Juntos, nossos resultados mostram que modelos de aprendizagem profunda com pesos computados de ajuste fino generalizam bem em conjunto de dados de imagem de doenças da soja.

De maneira análoga, avaliou-se o desempenho das arquiteturas de aprendizagem profunda para a identificação de insetos-praga na soja, usando imagens coletadas por uma câmera digital a 50 cm de distância dos alvos de interesse em condições reais de campo. Os resultados mostraram que as arquiteturas de aprendizagem profunda treinadas com um ajuste fino obtêm maiores taxas de classificação em comparação a outras abordagens, alcançando uma acurácia de até 93,82% com a arquitetura Resnet-50. Por outro lado, o sistema de visão computacional não identificou com eficiência os insetos nas imagens capturadas com o VANT a 2 metros de altura da plantação, visto que para alturas de voo mais altas o tamanho dos insetos na imagem reduz gradativamente e, consequentemente,

a resolução da imagem dos insetos diminui, impactando no desempenho do sistema de visão computacional.

Como alternativa, sugerimos para o trabalho futuro embarcar câmeras RGB de maior resolução (por exemplo, 400 megapixels) no VANT para avaliar o desempenho da abordagem proposta em diferentes alturas de voo. Um voo mais alto com o VANT também permitiria aumentar a área de cobertura para avaliar níveis de infestação de doenças e insetos-praga em diferentes áreas do campo. Embora o investimento desses equipamentos ainda seja alto, eles tem caído de preço nos últimos anos, o que tem aumentado a viabilidade de sua aquisição pelo produtor rural. Também pretendemos aumentar o conjunto de dados, catalogando novas espécies de doenças (p.ex.: Crestamento foliar de cercospora, Mofobranco, Antracnose) e pragas (p. ex.: Percevejo-verde-pequeno, Falsa-medideira) a cada nova safra, pois algumas espécies não foram localizadas no campo durante o período de estudo.

No experimento com contagem, usamos os pesos do modelo de aprendizagem profunda que alcançou o melhor resultado para a acurácia em nosso sistema de visão computacional. O nível de infestação de uma região da lavoura foi avaliado a partir da soma dos insetos de cada classe de superpixels, tomando como entrada uma imagem do campo e retornando como saída o número de insetos de cada espécie e a sua localização na imagem. Resultados experimentais da contagem mostraram que a acurácia diminui quando um mesmo inseto é segmentado em dois superpixels diferentes. Este é um campo de pesquisa que tem sido explorado, mas ainda não está resolvido. Por outro lado, o sistema de visão computacional foi capaz de discriminar bem as espécies de insetos em um ambiente real com variações não controladas, como condições de iluminação e reflexão distintas, tamanho e posicionamento de objetos, oclusão, movimento das folhas, variações de fundo, acasalamento e fases de desenvolvimento. Essas variações nas condições reais de campo contribuem para o sistema operar em um cenário real. Como parte do trabalho futuro, sugerimos comparar os resultados quantitativos, usando o sistema de visão computacional, com os resultados quantitativos, usando algum método de amostragem manual (p. ex.: pano-de-batida), a fim de avaliar a correlação existente entre os métodos de amostragem manual (especialistas da área) e automático (sistema).

Outro parâmetro fundamental para o sucesso do monitoramento de pragas é adequação da tecnologia às condições climáticas no momento da coleta de imagens. Da mesma forma à aplicação por pulverização, a coleta de imagens com o VANT deve ser realizada no início da manhã ou no final da tarde para garantir boa cobertura, seguindo a mesma regra geral: temperatura ambiente abaixo de 30°C e umidade relativa do ar acima de 55%. Já o monitoramento de doenças deve ser realizado entre 10h e 14h para evitar o efeito de sombra no campo. No caso dos requisitos ambientais de voo, o DJI Phantom não deve ser utilizado em condições climáticas rigorosas. Isso inclui velocidade do vento excedendo 10m/s, neve, chuva e névoa, conforme especificações técnicas do fabricante.

Determinar o nível de ação de controle da doença ou praga para iniciar o controle químico não é uma tarefa trivial. O nível de ação de controle refere-se à menor densidade populacional da doença ou praga que indica a necessidade de controle químico para impedir que uma perda de produção de valor econômico seja atingida. Essa relação nunca é fixa, pois o custo de controle químico (valor dos insumos, operações com máquinas, etc) variam ao longo do tempo, assim como a produtividade de cada área e o valor da soja. Portanto, uma equação de nível de dano econômico deve guiar o momento a partir do qual o produtor deve realizar o controle, ou seja, a partir de que população há uma redução da produção de soja que seja capaz de pagar o controle e gerar lucro.

Também demonstramos como um modelo de aprendizagem profunda pode ser implementado em um sistema de visão computacional de ponta a ponta para operar em um ambiente de campo real, permitindo o diagnóstico do problema *in loco* da zona apontada na análise, tendo como objetivo o devido controle da área georreferenciada. O sistema de visão computacional consiste em segmentar uma imagem da plantação com o método SLIC e classificar cada segmento de superpixel em uma classe de doença ou inseto-praga usando os pesos da rede neural convolucional melhor avaliada para a acurácia na tarefa de classificação.

Os resultados indicam que os modelos de aprendizagem profunda, treinados com um ajuste fino, podem ser usados com sucesso para apoiar especialistas e agricultores no monitoramento dos níveis de ação de controle de doenças e pragas nos campos de soja, contribuindo com o setor agropecuário e o desenvolvimento local, uma vez que a região poderá ser beneficiada com uma inovação tecnológica capaz de (1) impulsionar um dos principais setores econômicos com a aplicação racional de insumos, reduzindo a quantidade necessária de aplicações de defensivos agrícolas nos campos de soja e os riscos de degradação ambiental em propriedades de todas as dimensões; (2) maximizar o retorno econômico com o aumento da produtividade agrícola a partir de uma solução tecnológica não-invasiva, uma vez que os métodos de amostragens tradicionais normalmente afetam o desenvolvimento das plantas pelo pisoteamento intenso causando danos na lavoura; (3) cooperar com o desenvolvimento social, mediante a contratação de novas vagas de trabalho de mão de obra especializada para monitorar doenças e pragas (empresas de consultoria ou prestadores de serviços na área de amostragem e geração de mapas), com a provável redução do número de profissionais capacitados para fazer a verificação em campo, como o técnico agrícola ou o engenheiro agrônomo, que demandam maior custo de produção devido ao piso salarial reconhecido; (4) contribuir com as políticas nacionais de ciência, tecnologia e inovação com base no Registro do Programa de Computador PYNOVISÃO, protocolado pelo INPI, Processo N.: BR512019000427-2; (5) e melhorar a saúde humana e a segurança alimentar por meio de uma alternativa tecnológica viável e ecologicamente correta capaz de garantir a sustentação da vida e a promoção do ser humano no âmbito das dinâmicas socioambientais internas e externas.

Como parte do trabalho futuro, pretendemos avaliar novas abordagens de aprendizado de máquina para detectar múltiplos objetos (insetos-praga, doenças, etc) usando câmeras RGB de alta resolução que podem ser integradas no VANT. Particularmente, estamos interessados em comparar a abordagem proposta, usando o método de segmentação SLIC e redes neurais profundas, com métodos estado da arte para detecção de objetos, como Yolo, Faster R-CNN, RetinaNet; e métodos para detecção de objetos integrada à segmentação semântica, como Mask R-CNN.

Os algoritmos de superpixel tem provado ser uma etapa inicial útil para segmentação e anotação de imagens, reduzindo a complexidade computacional pela substituição do uso de primitivas caras em nível de pixel por uma abstração de alto nível, os superpixels. Eles foram aplicados com sucesso tanto no contexto da análise tradicional de imagens quanto nas abordagens baseadas em aprendizagem profunda. Neste contexto, planejamos comparar a implementação iterativa padrão do algoritmo SLIC com uma implementação que pode ser substituída por uma execução paralela em sistemas multi-processados (*multi-threaded*), com prováveis ganhos em tempo de execução.

Por fim, cogitamos realizar uma análise multi-escala para a fusão de imagens de satélites de áreas da plantação que sofreram ataques de doenças e pragas em níveis de ação de controle. A fusão de imagens de satélites possibilitaria a coleta simultânea de imagens multiespectrais e pancromáticas com diferentes resoluções, aumentando a escalabilidade geográfica e a área de cobertura do campo. Desse modo, as imagens de satélites poderiam ser combinadas para gerar imagens híbridas que combinariam as propriedades das imagens originais numa única nova imagem, associando a informação espectral ao seu conteúdo espacial e à sua resolução.

REFERÊNCIAS

- ADHIKARI, S. et al. Tomato plant diseases detection system using image processing. In: [S.l.]: KEC Conference, 2018.
- AKINTAYO, A. et al. A deep learning framework to discern and count microscopic nematode eggs. *Scientific Reports*, v. 8, 12 2018.
- AL-SAQER, S.; HASSAN, G. M. Artificial neural networks based red palm weevil (*ryncophorus ferrugineous*, olivier) recognition system. *American Journal of Agricultural and Biological Science*, v. 6, p. 356–364, 08 2011.
- BAJWA, S. G. et al. Soybean disease monitoring with leaf reflectance. *Remote Sensing*, v. 9, n. 2, p. 127–133, 2017.
- BARBEDO, J. Using digital image processing for counting whiteflies on soybean leaves. *Journal of Asia-Pacific Entomology*, v. 17, p. 685–694, 12 2014.
- BERNARDI, A. C. de C. et al. *Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa Instrumentação (CNPDIA), 2014. 596 p. ISBN 978-85-7035-352-8. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/113993/1/Agricultura-de-precisao-2014.pdf>>.
- BRODBECK, C. et al. Using unmanned aircraft systems for early detection of soybean diseases. In: *2017 11th European Conference on Precision Agriculture (ECPA 2017)*. [S.l.: s.n.], 2017. v. 8, p. 802–806.
- CASTRO, C. de et al. Análise foliar. *Agência Embrapa de Informação Tecnológica / Embrapa Soja*, S.d. Disponível em: <http://www.agencia.cnptia.embrapa.br/gestor/soja/arvore/CONTAG01_40_271020069132.html>.
- CHELLADURAI, V. et al. Detection of *callosobruchus maculatus* (f.) infestation in soybean using soft x-ray and nir hyperspectral imaging techniques. *Journal of Stored Products Research*, v. 57, p. 43–48, 2014. ISSN 0022-474X.
- CHEN, J. et al. Automatic segmentation and counting of aphid nymphs on leaves using convolutional neural networks. *Agronomy*, v. 8, p. 129, 07 2018.
- CONAB. Compêndio de estudos conab: Evolução dos custos de produção de soja no brasil. v. 2, p. 1–22, 2016. ISSN 2448-3710. Disponível em: <https://www.conab.gov.br/institucional/publicacoes/compendio-de-estudos-da-conab/item/download/2512_c2638f76696e3b926ab22e93f9549d21>.
- CONAB. *Acompanhamento da safra brasileira grãos, v.6 - Safra 2018/19 - N.9 - Nono levantamento - Junho*. Brasília, DF: [s.n.], 2019. v. 6. 1-113 p. ISSN 2318-6852. Disponível em: <https://www.conab.gov.br/component/k2/item/download/26760_37779459c5d79f63129c8c8c4d634103>.
- CORRÊA-FERREIRA, B. S. *Soja - Manejo Integrado de Insetos e outros Artrópodes-Praga: Amostragem de pragas da soja*. Embrapa Soja, 2012. 631-672 p. ISBN 978-85-7035-139-5. Disponível em: <<http://www.cnpsa.embrapa.br/artropodes/Capitulo9.pdf>>.
- CORRÊA-FERREIRA, B. S. et al. Monitoramento de pragas na cultura da soja - mip soja. *Embrapa Soja (CNPSO)*, 2013. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/112027/1/ficha-mip.2013.pdf>>.

EMBRAPA. Tecnologias de produção de soja – região central do brasil 2014. *Sistemas de Produção / Embrapa Soja*, n. 16, p. 265, 2013. ISSN 2176-2902. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/95489/1/SP-16-online.pdf>>.

EMBRAPA. *Manual de identificação de doenças de soja*. 5. ed. Embrapa Soja, 2014. ISSN 1516-781X. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/105942/1/Doc256-OL.pdf>>.

EMBRAPA. *Manual de identificação de insetos e outros invertebrados da cultura da soja*. 3. ed. Embrapa Soja, 2014. ISSN 1516-781X. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/105924/1/Doc269-OL.pdf>>.

EMBRAPA. Mip reduz aplicação de inseticidas na soja. *Embrapa Soja*, 2015. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/2447598/mip-reduz-aplicacao-de-inseticidas-na-soja>>.

EMBRAPA. Arranjo contribui com aumento da produtividade da soja de crescimento indeterminado. *Embrapa Soja*, 2017. Disponível em: <<https://www.embrapa.br/en/busca-de-noticias/-/noticia/19511797/arranjo-contribui-com-aumento-da-produtividade-da-soja-de-crescimento-indeterminado>>.

EMBRAPA. Vazio sanitário e calendarização da semeadura da soja. *Embrapa Soja*, Consórcio Antiferrugem, 2017. Disponível em: <<https://www.embrapa.br/soja/ferrugem/vaziosanitariocalendarizacaosemeadura>>.

EMBRAPA. Monitoramento da lavoura. *Agência Embrapa de Informação Tecnológica*, S.d. Disponível em: <<http://www.agencia.cnptia.embrapa.br/gestor/soja/arvore/CONT000g0gpptav02wx5ok026zxp02i4z8v.html>>.

FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, Elsevier, n. September 2017, p. 311–318, 2018. ISSN 0168-1699.

FUENTES, A. et al. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, v. 17, p. 2022, 09 2017.

GARCIA-RUIZ, F. et al. Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees. *Comput. Electron. Agric.*, v. 91, p. 106–115, 2013. ISSN 0168-1699.

GEDEON, C. et al. An opto-electronic sensor for detecting soil microarthropods and estimating their size in field conditions. *Sensors*, v. 17, p. 1757, 08 2017.

GIRSHICK, R. et al. Rich feature hierarchies for accurate object detection and semantic segmentation. In: *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*. Washington, DC, USA: IEEE Computer Society, 2014. (CVPR '14), p. 580–587. ISBN 978-1-4799-5118-5. Disponível em: <<https://doi.org/10.1109/CVPR.2014.81>>.

GUI, J. et al. A new method for soybean leaf disease detection based on modified salient regions. *International Journal of Multimedia and Ubiquitous Engineering*, v. 10, n. 6, p. 45–52, 2015. ISSN 1975-0080.

HILLNHUETTER, C.; MAHLEIN, A.-K. Early detection and localisation of sugar beet diseases: new approaches. *Gesunde Pflanzen*, SPRINGER 233 SPRING ST, NEW YORK, NY 10013 USA, v. 60, n. 4, p. 143–149, 2008. Disponível em: <<http://dx.doi.org/10.1007/s10658-013-0349-6>>.

- HINTON, G. et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, v. 29, n. 6, p. 82–97, Nov 2012. ISSN 1053-5888.
- HOFFMANN-CAMPO, C. B. Pragas da soja no brasil e seu manejo integrado. *Embrapa Soja*, n. 30, p. 70, 2000. ISSN 1516-7860. Disponível em: <https://www.agencia.cnptia.embrapa.br/Repositorio/circtec30_000g46xpyyv02wx5ok0iuqaqkbbpq943.pdf>.
- IMAGENET. *About ImageNet*. [s.n.], 2016. Disponível em: <<http://www.image-net.org/about-overview>>.
- KARPATHY, A. et al. Large-scale video classification with convolutional neural networks. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 1725–1732. ISSN 1063-6919.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, a division of Macmillan Publishers Limited. All Rights Reserved, v. 521, p. 436–444, 2015. Disponível em: <<https://doi.org/10.1038/nature14539>>.
- LEOW, L. K. et al. Automated identification of copepods using digital image processing and artificial neural network. *BMC Bioinformatics*, v. 16, 12 2015.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. *CoRR*, abs/1411.4038, 2014. Disponível em: <<http://arxiv.org/abs/1411.4038>>.
- LU, J. et al. Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, v. 8, 12 2018.
- MA, Y. et al. Automatic threshold method and optimal wavelength selection for insect-damaged vegetable soybean detection using hyperspectral images. *Computers and Electronics in Agriculture*, Elsevier B.V., p. 102–110, 2014. ISSN 0168-1699.
- MAHARLOOEI, M. et al. Detection of soybean aphids in a greenhouse using an image processing technique. *Computers and Electronics in Agriculture*, v. 132, p. 63–70, 2017. ISSN 0168-1699.
- MAPA. Portaria no 852 - art. 1o criar a comissão brasileira de agricultura de precisão – cbap. diário oficial da república federativa do brasil, Brasília, df, 21 set. *Ministério da Agricultura, Pecuária e Abastecimento*, 2012.
- MAPA. Mercado de biodefensivos cresce mais de 70% no brasil em um ano. *Ministério da Agricultura, Pecuária e Abastecimento*, 2019. Disponível em: <<http://www.agricultura.gov.br/noticias/feffmercado-de-biodefensivos-cresce-em-mais-de-50-no-brasil>>.
- MILONE, G. *Estatística geral e aplicada*. São Paulo: Thomson Pioneira, 2003. 498 p. ISBN 8522103399.
- MOHANTY, S. P. et al. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, v. 7, 04 2016.
- PEDIGO, L. P.; RICE, M. E. *Entomology and Pest Management*. 6. ed. Prentice Hall, 2014. ISBN 978-1478622857. Disponível em: <<https://www.amazon.com/Entomology-Management-Sixth-Larry-Pedigo/dp/1478622857>>.

PIRES, R. D. L. et al. Local descriptors for soybean disease recognition. *Computers and Electronics in Agriculture*, v. 125, n. 1, p. 48–55, 2016. ISSN 0168-1699.

PUJARI, J. D. et al. Recognition and classification of produce affected by identically looking powdery mildew disease. *Acta Technologica Agriculturae*, v. 17, 01 2014.

PYNOVISÃO. *Pacote de Visão Computacional do Inovisão*. Programa de Computador registrado no INPI, Processo N.: BR512019000427-2. Autores: Adair da Silva Oliveira Junior, Alessandro dos Santos Ferreira, Diogo Nunes Gonçalves, Everton Castelão Tetila, Felipe Silveira Brito Borges, Gabriel Kirsten Menezes, Geazy Vilharva Menezes, Gercina Gonçalves da Silva, Gilberto Astolfi, Hemerson Pistori, Vanessa Aparecida de Moraes Weber, 2019. Disponível em: <<http://git.inovisao.ucdb.br/inovisao/pynovisao>>.

REICHSTEIN, M. et al. Deep learning and process understanding for datadriven earth system science. *Nature*, v. 566, p. 195–204, 2019. Disponível em: <<https://doi.org/10.1038/s41586-019-0912-1>>.

RUMPF, T. et al. Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture*, v. 74, n. 1, p. 91 – 99, 2010. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169910001262>>.

SARAN, P. E. Manual de identificação das doenças da soja. *Coletânea FMC*, 2013. Disponível em: <<http://www.faesb.edu.br/biblioteca/wp-content/uploads/2017/09/publication1.pdf>>.

SHRIVASTAVA, S.; HOODA, D. S. Automatic brown spot and frog eye detection from the image captured in the field. *American Journal of Intelligent Systems*, v. 4, n. 4, p. 131 – 134, 2014. ISSN 2165-8978.

SLADOJEVIC, S. et al. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, v. 2016, 2016.

TAN, K. Z. et al. Identification of diseases for soybean seeds by computer vision applying bp neural network. *International Journal of Agricultural and Biological Engineering*, v. 7, n. 3, p. 43–50, 2014. ISSN 19346352.

TETILA, E. C. et al. Identification of soybean foliar diseases using unmanned aerial vehicle images. *IEEE Geoscience and Remote Sensing Letters*, v. 14, n. 12, p. 2190–2194, Dec 2017. ISSN 1545-598X.

TETILA, E. C. et al. Automatic recognition of soybean leaf diseases using uav images and deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, v. 99, p. 1–5, 08 2019.

TETILA, E. C. et al. A computer vision system for soybean diseases recognition using uavs: preliminary results. In: . Natal, RN, Brasil: In XIII Workshop de Visão Computacional: anais do 13o Workshop de Visão Computacional realizado na UFRN, 2017. p. 7–12. ISBN 978-85-425-0775-1. Disponível em: <<https://repositorio.ufrn.br/jspui/handle/123456789/24811>>.

VAKILIAN, K. A.; MASSAH, J. Performance evaluation of a machine vision system for insect pests identification of field crops using artificial neural networks. *Archives of Phytopathology and Plant Protection*, v. 46, p. 1262–1269, 02 2013.

WANG, J. et al. A new automatic identification system of insect images at the order level. *Knowledge-Based Systems*, v. 33, p. 102–110, 09 2012.

WANG, N.; YEUNG, D.-Y. Learning a deep compact image representation for visual tracking. In: BURGESS, C. J. C. et al. (Ed.). *Advances in Neural Information Processing Systems 26*. Curran Associates, Inc., 2013. p. 809–817. Disponível em: <<http://papers.nips.cc/paper/5192-learning-a-deep-compact-image-representation-for-visual-tracking.pdf>>.

WEN, C. et al. Pose estimation-dependent identification method for field moth images using deep learning architecture. *Biosystems Engineering*, v. 136, 08 2015.

XING, J. H. C. W. X. H. J. Z. C. X. N. G. J. G. H. Association analysis of vegetable soybean quality traits with ssr markers. *Plant Breeding*, v. 130, n. 4, p. 444–449, 2011. Disponível em: <<https://doi.org/10.1111/j.1439-0523.2011.01852.x>>.

YAAKOB, S.; JAIN, L. An insect classification analysis based on shape features using quality threshold artmap and moment invariant. *Applied Intelligence - APIN*, v. 37, 07 2012.

YANG, G.; BAO, Y.; LIU, Z. Localization and recognition of pests in tea plantation based on image saliency analysis and convolutional neural network. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, v. 33, p. 156–162, 03 2017.

ANEXOS

ANEXO A – PRÊMIO DE MELHOR ARTIGO NO XIII WVC 2017



CERTIFICATE

We hereby confirm that the paper *A computer vision system for soybean diseases recognition using UAVs: preliminary results*, authored by **Everton Castelhão Tetila**, **Bruno Bransoli Machado**, **Hemerson Pistori** and **Gercina Gonçalves** was selected to receive the **Best Paper Award** at the XIII Workshop de Visão Computacional (WVC 2017) held in Natal, Rio Grande do Norte, Brazil, from October 30th to November 1st, 2017.

Natal, November 1st, 2017

Bruno Marques Ferreira da Silva
Conference Chair

Bruno Motta de Carvalho
Conference Co-Chair



ANEXO B – REGISTRO DE PROGRAMA DE COMPUTADOR



REPÚBLICA FEDERATIVA DO BRASIL

MINISTÉRIO DA ECONOMIA

INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL

DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512019000427-2**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 10/01/2018, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: PYNOVISÃO

Data de criação: 10/01/2018

Titular(es): FUNDAÇÃO UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL; MISSÃO SALESIANA DE MATO GROSSO

Autor(es): HEMERSON PISTORI; VANESSA APARECIDA DE MORAES WEBER; GERCINA GONÇALVES DA SILVA; GILBERTO ASTOLFI; FELIPE SILVEIRA BRITO BORGES; ALESSANDRO DOS SANTOS FERREIRA; GABRIEL KIRSTEN MENEZES; GEAZY VILHARVA MENEZES; DIOGO NUNES GONÇALVES; EVERTON CASTELÃO TETILA; ADAIR DA SILVA OLIVEIRA JÚNIOR

Linguagem: PYTHON

Campo de aplicação: AG-01; AG-10; AG-12; IF-01; IN-02

Tipo de programa: IA-01; TC-04

Algoritmo hash: SHA-512

Resumo digital hash:

0a44db9248906c7b672900a1a8a8571028ad9f0431cb750abce3d052f64a5199b0d473451a4ca345b138762b917c87279
9dac4ae5cb57b676f1f8376a3acd006

Expedido em: 19/03/2019

Aprovado por:

Liane Elizabeth Caldeira Lage

Diretora de Patentes, Programas de Computador e Topografias de Circuitos Integrados



EVERTON CASTELÃO TETILA - É doutor em Desenvolvimento Local pela Universidade Católica Dom Bosco (2019), mestre em Engenharia de Produção pela Universidade Paulista (2007) e bacharel em Ciência da Computação pela Universidade Estadual de Mato Grosso do Sul (2004). Desde 2010 é docente nos cursos de Engenharia de Computação, Sistemas de Informação e Licenciatura em Computação na Universidade Federal da Grande Dourados. Tem experiência na área de Ciência da Computação, com ênfase em Banco de Dados, Visão Computacional, Tecnologias da Informação e Comunicação (TICs) e Web Design. Vencedor do Prêmio Mercosul de Ciência e Tecnologia, Edição 2018, na categoria pesquisador sênior com o trabalho “Uma abordagem de aprendizagem profunda para contagem automática de insetos-praga na soja”. Revisor de periódicos internacionais de alto impacto: Sensors (ISSN 1424-8220), IEEE-GRSL (ISSN 0196-2892) e Computer and Electronics in Agriculture (ISSN 0168-1699). Membro da Comissão de Avaliação de Cursos da SED/FUNDECT. Lattes: <http://lattes.cnpq.br/4761324267689856> Website: <http://evertontetila.ws.ufgd.edu.br/>. ORCID ID: 0000-0001-5396-766X.

www.atenaeditora.com.br 

contato@atenaeditora.com.br 

[@atenaeditora](https://www.instagram.com/atenaeditora) 

www.facebook.com/atenaeditora.com.br 



DETECÇÃO E CLASSIFICAÇÃO DE DOENÇAS E PRAGAS DA SOJA USANDO IMAGENS DE VEÍCULO AÉREOS NÃO TRIPULADOS E TÉCNICAS DE VISÃO COMPUTACIONAL


Ano 2023

www.atenaeditora.com.br 

contato@atenaeditora.com.br 

[@atenaeditora](https://www.instagram.com/atenaeditora) 

www.facebook.com/atenaeditora.com.br 



DETECÇÃO E CLASSIFICAÇÃO DE DOENÇAS E PRAGAS DA SOJA USANDO IMAGENS DE VEÍCULO AÉREOS NÃO TRIPULADOS E TÉCNICAS DE VISÃO COMPUTACIONAL

 **Atena**
Editora
Ano 2023