

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

DIEGO ALVES DA SILVA

**MÉTODO DE FITOPATOMETRIA UTILIZANDO PROCESSAMENTO DE IMAGENS
E INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO E QUANTIFICAÇÃO DE
SINTOMAS E SINAIS DE FERRUGEM ASIÁTICA DA SOJA APLICADO AO
MELHORAMENTO GENÉTICO**

UBERLÂNDIA

2022

DIEGO ALVES DA SILVA

**MÉTODO DE FITOPATOMETRIA UTILIZANDO PROCESSAMENTO DE IMAGENS
E INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO E QUANTIFICAÇÃO DE
SINTOMAS E SINAIS DE FERRUGEM ASIÁTICA DA SOJA APLICADO AO
MELHORAMENTO GENÉTICO**

Tese apresentada ao Programa de Pós-Graduação em Genética e Bioquímica da Universidade Federal de Uberlândia, como exigência parcial para obtenção do Título de Doutor em Genética e Bioquímica.

Área de concentração: Genética

Orientadora: Prof.^a Dr.^a Ana Paula Oliveira Nogueira

Coorientador: Prof. Dr. Fernando Cezar Juliatti

UBERLÂNDIA

2022

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

S586m
2022 Silva, Diego Alves da, 1990-
Método de fitopatometria utilizando processamento de imagens e inteligência artificial para detecção e quantificação de sintomas e sinais de ferrugem asiática da soja aplicado ao melhoramento genético [recurso eletrônico] / Diego Alves da Silva. - 2022.

Orientadora: Ana Paula Oliveira Nogueira.

Coorientador: Fernando Cezar Juliatti.

Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Genética e Bioquímica.

Disponível em: <http://doi.org/10.14393/ufu.te.2022.5043>

Inclui bibliografia.

1. Genética. I. Nogueira, Ana Paula Oliveira, 1981-, (Orient.). II. Juliatti, Fernando Cezar, 1957-, (Coorient.). III. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Genética e Bioquímica. IV. Título.

CDU: 575

André Carlos Francisco
Bibliotecário – CRB-6/3408



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Genética e Bioquímica
 Av. Pará 1720, Bloco 2E, Sala 244 - Bairro Umuarama, Uberlândia-MG, CEP 38400-902
 Telefone: +55 (34) 3225-8438 - www.ppggb.ibtec.ufu.br - ppggb@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Genética e Bioquímica				
Defesa de:	Doutorado Acadêmico - PPGGB.				
Data:	Sete de dezembro de dois mil e vinte e dois	Hora de início:	14:00h	Hora de encerramento:	17:03
Matrícula do Discente:	11823GBI004				
Nome do Discente:	Diego Alves da Silva				
Título do Trabalho:	Método de fitopatometria utilizando processamento de imagens e inteligência artificial na detecção e quantificação de sintomas e sinais de ferrugem asiática da soja aplicado ao melhoramento genético.				
Área de concentração:	Genética				
Linha de pesquisa:	Genética, Epigenética, Biologia e Melhoramento de Plantas e Animais.				
Projeto de Pesquisa de vinculação:	Desenvolvimento e validação de técnicas de inteligência artificial para seleção de genótipos de soja resistentes à ferrugem asiática por fenotipagem por imagem.				

Aos treze dias do mês de dezembro de dois mil e vinte e dois, às 14:00 horas, reuniu-se via web conferência pela Plataforma Microsoft *Teams*, em conformidade com a Portaria nº 36, de 19 de março de 2020 da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, Resolução de nº06/2020 e Resolução nº 19/2022 do Conselho de Pesquisa e Pós-graduação pela Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Genética e Bioquímica, assim composta: Dr. Díbio Leandro Borges, Dr. Edson Hirose, Dr. Osvaldo Toshiyuki Hamawaki, Dr. Breno Cezar Marinho Juliatti e Dr^a. Ana Paula Oliveira Nogueira, orientador (a) do (a) candidato (a) e demais convidados presentes conforme lista de presença. Iniciando os trabalhos o (a) presidente da mesa, Dr^a. Ana Paula Oliveira Nogueira apresentou a Comissão Examinadora e o (a) candidato (a), agradeceu a presença do público, e concedeu o (à) Discente a palavra para a exposição do seu trabalho. A duração da apresentação do (a) Discente e o tempo de arguição e resposta foram conforme as normas do Programa de Pós-graduação em Genética e Bioquímica. A seguir o (a) senhor (a) presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o (a) candidato (a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu os conceitos finais. Em face do resultado obtido, a Banca Examinadora considerou o candidato (a):

APROVADO (A).

Esta defesa de Tese de Doutorado é parte dos requisitos necessários à obtenção do título de Doutor. O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do

Programa, a legislação pertinente e a regulamentação interna da UFU. Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Ana Paula Oliveira Nogueira, Professor(a) do Magistério Superior**, em 07/12/2022, às 17:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Oswaldo Tosiuyuki Hamawaki, Professor(a) do Magistério Superior**, em 07/12/2022, às 17:21, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Breno Cezar Marinho Juliatti, Usuário Externo**, em 07/12/2022, às 17:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Díbio Leandro Borges, Usuário Externo**, em 07/12/2022, às 17:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Edson Hirose, Usuário Externo**, em 08/12/2022, às 20:35, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4121465** e o código CRC **1E43ED5B**.

À minha mãe, Welbia, ao meu pai, Ecio, à minha irmã, Aline, e à minha avó, Rosa.

À minha esposa, Nágilla.

Aos meus avós, Heraldo, Irene e José, que não tiveram a oportunidade de estar aqui, mas sempre me deram todo apoio.

A todos que, nesses anos tão difíceis de 2020 e 2021, não tiveram a chance de concluir suas pesquisas ou que dedicaram as suas vidas para salvar outras vidas,

Dedico!!!

AGRADECIMENTOS

Agradeço primeiramente a Deus, por estar sempre ao meu lado dando forças e esperança.

Agradeço aos meus pais, Welbia Maria Alves da Silva e Ecio Tarcisio Alves da Silva, à minha irmã, Aline Alves da Silva, e à minha avó, Rosa Maria Alves, por sempre me apoiarem e incentivarem desde que iniciei essa longa jornada acadêmica.

Agradeço à minha esposa, Nágilla Regina Saraiva Vieira, por todo apoio e paciência ao longo desses anos de intenso estudo e dedicação.

Agradeço ao Programa de Melhoramento Genético em Soja, principalmente ao Prof. Dr. Osvaldo Toshiyuki Hamawaki, que está sempre em busca de melhores condições para a pesquisa na UFU.

Agradeço ao Lamip, principalmente ao Prof. Dr. Fernando Cezar Juliatti, que tanto auxiliou e me coorientou durante as atividades do doutorado.

Agradeço aos estudantes Alex, Bruna, Fábio, Lucas e ao técnico Borges, que sempre estiveram juntos comigo, desenvolvendo atividades do programa.

Agradeço à empresa Juliagro, que tanto auxiliou na execução dos experimentos em campo, principalmente ao Dr. Breno Cezar Marinho Juliatti, o qual sempre ajudou prontamente e contribuiu para a pesquisa.

Agradeço ao Prof. Dr. José Waldemar da Silva e ao Me. Ronaldo Pires Silva, que auxiliou nas análises estatísticas e no entendimento do enorme volume de dados gerados ao longo da pesquisa.

Agradeço ao Prof. Dr. Díbio Leandro Borges, por toda a sua dedicação em tudo que foi desenvolvido nesta pesquisa e enorme contribuição no meu amadurecimento como pesquisador.

Agradeço à Prof.^a Dr.^a Ana Paula Oliveira Nogueira, por toda dedicação e paciência para me ensinar atividades que eu nunca havia executado, aceitando embarcar junto comigo nessa nova área, permitindo o meu amadurecimento profissional e acadêmico.

Agradeço ao CNPQ, que financiou o projeto executado nesta pesquisa, e à Agência Intelecto, que ajudou em todas as etapas de registro de propriedade intelectual.

Agradeço à UFU e ao Programa de Pós-graduação em Genética e Bioquímica, pela possibilidade de realização do doutorado.

Agradeço a todos os membros das bancas de qualificação e defesa que se prontificaram a contribuir com a melhoria desta pesquisa.

A todas as pessoas que contribuíram direta ou indiretamente para a realização deste trabalho.

Muito obrigado!!!

*“We can only see a short distance ahead,
but we can see plenty there that needs to be done”*

(Alan Turing)

RESUMO

A soja está entre as principais culturas do mundo, tendo o Brasil como um dos protagonistas em sua produção e exportação. Devido à crescente demanda mundial pelos grãos de soja, necessita-se de um aumento recorrente na produção, que pode ser prejudicado pela infecção por doenças, como a ferrugem asiática da soja (FAS), causada pelo fungo *Phakopsora pachyrhizi*. A resistência à ferrugem asiática é poligênica, tendo genes de resistência já listados na literatura, entretanto, devido à diversidade de raças do fungo e seus diversos genes causadores de virulência, o processo de melhoramento genético com o foco de resistência à ferrugem asiática deve ser constante e aplicado de forma conjunta com o controle químico e técnicas de manejo. O processo de melhoramento genético utiliza a severidade dos sintomas da infecção para identificação de genótipos resistentes e é tradicionalmente feito de forma visual pelo melhorista em campo. O presente estudo propõe um método que pode ser aplicado na seleção de genótipos com níveis de resistência, para a detecção e quantificação de sintomas de FAS. Para a construção do método, o trabalho se inicia por uma revisão sistemática sobre o objeto de estudo Inteligência Artificial e Processamento de Imagens, utilizando os dados coletados para propor um estudo exploratório para compreender a detecção dos sintomas de ferrugem de imagem e propor um algoritmo. O algoritmo foi validado em relação a outros métodos já existentes, mostrando uma correlação maior que 0,9 e um *software* foi criado para executar a quantificação. Foi proposto um experimento para a criação do método com o foco em compreender o efeito de fungicida, forma de coleta de folíolos e forma de captura de imagem. O método e o *software* foram aplicados na seleção de genótipos de uma população. Além disso, como etapa adicional do trabalho, foi proposto o uso de uma Rede Neural Convolucional para a classificação de múltiplos patógenos em regiões do folíolo.

Palavras-chaves: Ferrugem Asiática da Soja. Fenotipagem por Imagem. Fitopatometria. Processamento de Imagem. Melhoramento Genético.

ABSTRACT

Soybeans are one of the most important crops in the world, with Brazil being one of the main players with its grain production and exports. Due to the increasing global demand for soybeans, a continuous increase in production is required, which could be affected by diseases such as Asian Soybean Rust (ASR) caused by the fungus *Phakopsora pachyrhizi*. Because of the diversity of races of the fungus and its several virulence causing genes, the process of genetic improvement focusing on resistance to ASR must be constant and applied in conjunction with chemical control and management techniques. The process of genetic breeding uses the severity of infection symptoms to identify resistant genotypes and is traditionally performed by the geneticist in the field in a visual manner. In this study, we propose a method for detecting and quantifying ASR symptoms using images that can be applied to the selection of genotypes with resistance levels. To develop the method, the work begins with a systematic review of the subject of study Artificial Intelligence and Image Processing, using the collected data to propose an exploratory study to understand the detection of image rust symptoms and develop an algorithm. The algorithm was validated against other existing methods, showing a correlation greater than 0.9, and software was developed to perform the quantification. An experiment was proposed to develop the method, focusing on understanding the effects of fungicides, the form of leaf collecting, and the form of image acquisition. The method and software were applied to the selection of genotypes from a population. In addition, another step of the work proposed the use of a convolutional neural network for classifying multiple pathogens in leaf areas.

Keywords: Asian Soybean Rust. Image Phenotyping. Phytopathometry. Image Processing. Genetic Breeding.

LISTA DE EQUAÇÕES

Equação 1 - Cálculo do índice de necrose	60
Equação 2 - Cálculo do índice de clorose	60
Equação 3 - Cálculo do limiar de dano.....	60
Equação 4 - Cálculo do índice de ferrugem	61
Equação 5 - Cálculo da área saudável.....	61
Equação 6 - Cálculo da AACPD.....	61

LISTA DE FIGURAS

Figura 1 - Exemplos de cores da pubescência da soja	24
Figura 2 - Exemplos de cores de hilo	25
Figura 3 - Exemplo de sintomas causados pela ferrugem	27
Figura 4 - Diferentes níveis de Infecção	29
Figura 5 - Exemplo de infecção por oídio	30
Figura 6 - Exemplo de infecção por <i>Cercospora sojina</i>	31
Figura 7 - Escala diagramática com 6 níveis	33
Figura 8 - Escala diagramática com 10 níveis	34
Figura 9 - Foto em diferentes espaços de cores	39
Figura 10 - Representação de uma imagem RGB em uma matriz tridimensional	39
Figura 11 - Matriz para conversão de RGB para CIE XYZ	40
Figura 12 - Representação do modelo HSI	41
Figura 13 - Conversão RGB para HSI	41
Figura 14 - Exemplo de agrupamento <i>k-means</i>	43
Figura 15 - Definição dos centroides <i>k-means</i>	44
Figura 16 - Representação computacional de um neurônio	45
Figura 17 - Exemplo de Rede Neural com 3 camadas	46
Figura 18 - Exemplo de campos receptivos locais	47
Figura 19 - Exemplo de arquitetura de RNC	48
Figura 20 - Exemplo de Convolução	48
Figura 21 - Exemplo de operação <i>max-pooling</i>	49
Figura 22 - Exemplo de bloco da DenseNet	50
Figura 23 - Exemplo de bloco da ResNet	50
Figura 24 - Exemplo de uso de RNC como Backbone, Pirâmide de Características e Classificação	51
Figura 25 - Resultado de detecção de folíolos e identificadores de parcela	52
Figura 26 - Experimentos para capturas de imagem	55
Figura 27 - Etapas do processamento da imagem	58
Figura 28 - Método de definição dos intervalos de filtragem	59
Figura 29 - Preparação do solo	63
Figura 30 - Semeadura 21/11/2020	64
Figura 31 - Captura da Época 1, no dia 21/12/2020	64

Figura 32 - Captura da Época 1, no dia 18/02/2021.....	64
Figura 33 - Colheita Época 1.....	65
Figura 34 - Exemplo de imagem capturada	67
Figura 35 - Exemplo de divisão de imagem	73
Figura 36 - Diagrama PRISMA com resultado da pesquisa	76
Figura 37 - Número de artigos científicos publicados e formatos de imagens utilizados	77
Figura 38 - Número de artigos científicos para as 10 principais culturas	79
Figura 39 - Criação da curva espectral	82
Figura 40 - Detecção de flores	85
Figura 41 - Cálculo de dano no folíolo.....	86
Figura 42 - Resultado da avaliação de 3 folíolos utilizando o <i>software</i> proposto.	88
Figura 43 - Distribuição dos Índices de Ferrugem calculados pelo <i>software</i> para o Experimento 1	89
Figura 44 - Análise da distribuição sintomas de clorose, necrose e limiar de dano para o experimento 1.....	90
Figura 45 - Resultado da AACPD para Experimento 2	92
Figura 46 - Exemplo de clorose sem infecção por ferrugem	93
Figura 47 - Resultados Experimento 3.....	96
Figura 48 - Resultados Experimento 4	97
Figura 49 - Infecção observada no microscópio 100x	98
Figura 50 - Evolução dos indicadores da RNC ao longo de 200 épocas de treinamento	99
Figura 51 - Precipitação em mm e temperatura máxima em °C em quatro épocas de semeadura de soja.....	101
Figura 52 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de novembro para a cultivar TMG7067IPRO	105
Figura 53 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de dezembro para a cultivar TMG7067IPRO	106
Figura 54 - AACPD dos efeitos significativos da interação entre face e fungicida e do efeito isolado terço para a cultivar TMG7067IPRO na semeadura de janeiro.....	106
Figura 55 - AACPD dos efeitos significativos da interação entre face e fungicida; e face e terço para a cultivar M7739IPRO na semeadura de novembro.....	108

Figura 56 - AACPD dos efeitos significativos dos fatores isolados face e terço para a semeadura de janeiro para a cultivar M7739IPRO.....	109
Figura 57 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de novembro para a cultivar ST721IRPO	110
Figura 58 - AACPD dos efeitos significativos dos fatores isolados face e terço para a semeadura de janeiro para a cultivar ST721IRPO	112
Figura 59 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar TMG70677IPRO com aplicação de fungicida	113
Figura 60 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar TMG70677IPRO sem aplicação de fungicida	114
Figura 61 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar ST721IPRO com aplicação de fungicida	114
Figura 62 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar ST721IPRO sem aplicação de fungicida	115
Figura 63 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar M7739IPRO com aplicação de fungicida	115
Figura 64 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar M7739IPRO sem aplicação de fungicida	116
Figura 65 - Gráfico da severidade de infecção por FAS ao longo de 45 dias.	117
Figura 66 - Média de AACPD para RustIndex faces adaxial e abaxial.....	121
Figura 67 - Média de índices por arquitetura.....	123
Figura 68 - Análise dos índices de precisão, recall e f1_score por classe e arquitetura	123
Figura 69 - Diagrama de resumo dos resultados	124

LISTA DE QUADROS

Quadro 1 - Tratamento de sementes	65
Quadro 2 - Aplicação de fungicidas.....	66
Quadro 3 - Aplicação de inseticida.....	66
Quadro 4 - Aplicações realizadas no experimento	71
Quadro 5 - Resultado da correlação de Pearson para os Experimentos 3 e 4	94
Quadro 6 - Análise de Variância da Produtividade de grãos de 3 cultivares de soja em 4 épocas de semeadura em Uberlândia – MG	100
Quadro 7 - Produtividade de grãos (kg ha^{-1}) de cultivares de soja em 4 épocas de semeadura – Uberlândia-MG	100
Quadro 8 - Análise de Variância do Peso de 100 sementes de 3 cultivares de soja em 4 épocas de semeadura em Uberlândia – MG	102
Quadro 9 - Peso de 100 sementes (g) de cultivares de soja em 4 épocas de semeadura – Uberlândia-MG	103
Quadro 10 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar TMG7067IPRO	105
Quadro 11 - AACPD das faces abaxial e adaxial para a semeadura de dezembro da cultivar TMG7067IPRO	105
Quadro 12 - AACPD das faces abaxial e adaxial para a semeadura de janeiro da cultivar TMG7067IPRO	106
Quadro 13 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar M7739IPRO, considerando interação entre fungicida e face	107
Quadro 14 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar M7739IPRO, considerando interação entre terço e face	107
Quadro 15 - AACPD das faces abaxial e adaxial para a semeadura de dezembro da cultivar M7739IPRO	108
Quadro 16 - AACPD das faces abaxial e adaxial para a semeadura de janeiro da cultivar M7739IPRO	109
Quadro 17 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar ST721IRPO.....	110
Quadro 18 - AACPD considerando o efeito do fungicida na interação tripla para a cultivar ST721IRPO na semeadura de dezembro	111

Quadro 19 - AACPD considerando o efeito do terço na interação tripla para a cultivar ST721IRPO na semeadura de dezembro	111
Quadro 20 - AACPD considerando o efeito do face na interação tripla para a cultivar ST721IRPO na semeadura de dezembro	111
Quadro 21 - AACPD das faces abaxial e adaxial para a cultivar ST721IRPO na semeadura de janeiro.....	112
Quadro 22 - Análise de Variância da AACPD do <i>RustIndex</i> face abaxial	118
Quadro 23 - Análise de Variância da AACPD do <i>NecrosisIndex</i> face abaxial.....	118
Quadro 24 - Análise de Variância da AACPD do <i>ChlorosisIndex</i> face abaxial.....	118
Quadro 25 - AACPD do <i>ChlorosisIndex</i> da face abaxial de folíolos em 64 genótipos de soja cultivados em Uberlândia-MG sob condições de infecção natural por FAS.....	120
Quadro 26 - Análise de Variância da AACPD do <i>RustIndex</i> face adaxial	121
Quadro 27 - Análise de Variância da AACPD do <i>NecrosisIndex</i> face adaxial.....	121
Quadro 28 - Análise de Variância da AACPD do <i>ChlorosisIndex</i> face adaxial.....	121
Quadro 29 - Análise de Variância da precisão	124

LISTA DE ABREVIATURAS E SIGLAS

AACPD	Área abaixo da curva de progresso da doença
ACP	Análise dos Componentes Principais
AUDPC	<i>The area under the disease progress curve</i>
CIE	<i>International Commission on Illumination</i>
CMY	<i>Cyan, magenta e yellow</i>
CMYK	<i>Cyan, magenta, yellow e black</i>
CSV	<i>Comma Separated Values</i>
DAS	Diagrama de Avaliação de Severidade
DBC	Delineamento de Blocos Casualizados
DIC	Delineamento Inteiramente Casualizado
DL	<i>Deep Learning</i>
DPI	<i>Dots per inch</i>
DSIFT	<i>Dense scale-invariant feature transform</i>
EUA	Estados Unidos da América
FAS	Ferrugem asiática da soja
FN	Falso Negativo
FP	Falso Positivo
GLI	<i>Green leaf index</i>
GNDVI	<i>Green normalized difference vegetation index</i>
GPU	<i>Graphics Processing Units</i>
HOG	<i>Histogram of oriented gradients</i>
HSI	<i>Hue, saturation e intensity</i>
HSV	<i>Hue, saturation e value</i>
IA	Inteligência Artificial
IF	Índice de Ferrugem
Lamip	Laboratório de Micologia e Proteção Vegetal
LD	Limiar de Dano
LiDAR	<i>Light Detection and Ranging</i>
NDVI	<i>Normalized difference vegetation index</i>
NIR	<i>Near Infrared</i>
PHOW	<i>Pyramid histograms of visual words</i>
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>

QoI	Inibidores externos de quinona
ResNet	<i>Residual Network</i>
RGB	<i>Red Green Blue</i>
RIS	<i>Information Systems Research</i>
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
SAVI	<i>Soil Adjusted Vegetation Index</i>
SIFT	<i>Scale-invariant feature transform</i>
SLIC	<i>Simple Linear Iterative Clustering</i>
SURF	<i>Speeded-Up robust features</i>
TVI	Triangular Vegetation Index
VANT	Veículos Aéreos Não Tripulados
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	21
2	REFERENCIAL TEÓRICO	24
2.1	A soja	24
2.2	Doenças da soja	26
2.2.1	Ferrugem Asiática da Soja	26
2.2.2	Septoriose	29
2.2.3	Oídio	30
2.2.4	Mancha olho-de-rã.....	31
2.3	Melhoramento genético da soja	31
2.3.1	Melhoramento genético com foco em resistência à Ferrugem Asiática da Soja e avaliação de severidade dos sintomas	32
2.3.1.1	<i>Correlação entre AACPD com produtividade e peso de 100 sementes</i>	36
2.3.2	Fenotipagem de alto rendimento	36
2.4	Visão computacional	37
2.4.1	Representação das imagens	37
2.4.2	Segmentação de imagem.....	42
2.5	Inteligência Artificial	43
2.5.1	Redes Neurais Convolucionais.....	47
2.5.2	Arquitetura das Redes Neurais Convolucionais	49
3	METODOLOGIA	53
3.1	Revisão sistemática	53
3.2	Criação do software	54
3.2.1	Experimentos para criação do software.....	54
3.2.1.1	<i>Experimento 1: Campo</i>	54
3.2.1.2	<i>Experimento 2: Folíolos destacados</i>	55
3.2.1.3	<i>Experimento 3: Dataset externo</i>	56
3.2.1.4	<i>Experimento 4: Escala diagramática</i>	57
3.2.2	Processamento de imagens, análise e cálculo dos índices.....	57
3.2.3	Protocolo de avaliação dos Experimentos 3 e 4	61
3.2.4	Processamento de dados e software utilizados.....	62
3.3	Experimentos para validação do software e criação de método	62
3.3.1	Experimento 5: Experimento com cultivares padrão de mercado.....	62

3.3.1.1	<i>Implantação do Experimento</i>	62
3.3.1.2	<i>Controle químico para doenças e pragas</i>	65
3.3.1.3	<i>Captura das imagens</i>	67
3.3.1.4	<i>Colheita, produtividade e peso de 100 sementes</i>	67
3.3.1.5	<i>Segmentação das imagens</i>	68
3.3.1.6	<i>Análise das imagens</i>	68
3.3.1.7	<i>Análise dos dados</i>	68
3.3.1.7.1	<i>Análise da produtividade em relação a fungicida e cultivar</i>	69
3.3.1.7.2	<i>Efeito de fungicida, face e terço na AACPD</i>	69
3.3.2	Experimento 6: Aplicação do <i>software</i> na caracterização de progênies de soja quanto à FAS	70
3.3.2.1	<i>Controle químico e aplicações de micronutrientes</i>	71
3.3.2.2	<i>Captura das imagens</i>	71
3.3.2.3	<i>Análise das imagens</i>	72
3.3.2.4	<i>Análise dos dados</i>	72
3.4	Experimentos para sistema com múltiplos patógenos e Redes Neurais Convolucionais	72
4	RESULTADOS E DISCUSSÃO	76
4.1	Resultados quantitativos da pesquisa sistemática	76
4.2	Resultados qualitativos pesquisa sistemática	79
4.3	Criação do <i>software</i>	88
4.3.1	Resultados do Experimento 1: Quantificação de sintomas de FAS em 200 imagens capturadas em campo	88
4.3.2	Resultados do Experimento 2: Quantificação de sintomas em folíolos destacados	90
4.3.3	Resultados do Experimento 3: Quantificação de sintomas em <i>dataset</i> externo	93
4.3.4	Resultados do Experimento 4: Quantificação de sintomas em escala diagramática	94
4.4	Rede Neural para detecção e segmentação de folíolos de soja	98
4.4.1	Resultados treinamento rede Yolov5 e segmentação dos folíolos nas imagens	98
4.5	Validação do <i>software</i> para detecção e quantificação de sintomas de FAS em folíolos de soja a partir de imagens	99

4.5.1	Desempenho agrônômico de cultivares de soja na ausência e presença de fungicida para controle de FAS	99
4.5.2	Efeito de fungicida, terço e face na AACPD pela infecção por FAS quantificada por imagem.....	103
4.5.3	Resultados Experimento 6: Caracterização e progênies de soja quanto à AACPD obtida por análise de imagem de folíolos usando o <i>software</i> NeChloDS.....	117
4.6	Resultado de análise de lesões utilizando Redes Neurais Convolucionais	122
5	CONCLUSÕES	126
	REFERÊNCIAS	128

1 INTRODUÇÃO

A soja é uma das principais culturas da atualidade, cuja produção mundial está em torno de 353 milhões de toneladas, sendo que o Brasil e Estados Unidos da América (EUA) são protagonistas, com a produção de 126 e 120 milhões de toneladas, respectivamente, na safra 2021/2022 (UNITED STATES DEPARTMENT OF AGRICULTURE [USDA], 2022). Com o crescimento da demanda mundial pela soja (BRASIL, 2022), existe a necessidade de aumento na produção, que pode ser feito pelo aumento da área cultivada ou da produtividade de grãos das áreas existentes.

O aumento da produtividade de grãos se dá por cultivares mais produtivos, pela redução de fatores que causam a perda de produtividade de grãos e pela melhoria das técnicas de manejo (SANTOS *et al.*, 2016; SANTOS JUNIOR *et al.*, 2016). Dentre os fatores que causam a perda da produtividade de grãos, pode-se destacar os bióticos, que são fungos, vírus, bactérias, insetos e animais (MATSUO; FERREIRA; SEDIYAMA, 2017); e os abióticos, que são macronutrientes, micronutrientes, fotoperíodo, temperatura e fatores hídricos (DANTAS *et al.*, 2017). Os impactos negativos dos fatores abióticos como limitadores da produção de grãos podem ser suprimidos com a adoção de estratégias de manejo, como o uso de fertilizantes para a correção do solo, irrigação e adequação de épocas de semeadura (SOARES; SEDIYAMA, 2016a, 2016b; SOARES; SEDIYAMA; TOBAR, 2016). Os fatores bióticos podem ser manejados com a aplicação de inseticidas, fungicidas, manejo integrado e o uso de cultivares resistentes (GODOY *et al.*, 2016). Além do aumento dos custos, que já ultrapassam 25% do custo total de produção (USDA, 2020), o uso não moderado de controle químico pode selecionar patógenos com resistência, causando grandes perdas. Dessa forma, é necessário buscar cultivares com resistência vertical, horizontal e tolerantes (JULIATTI *et al.*, 2019).

A criação de cultivares resistentes e tolerantes se dá pelo melhoramento genético (ACQUAAH, 2012). Os caracteres melhorados podem ser divididos em dois grupos: os qualitativos, que se baseiam na genética mendeliana e são regidos por um ou poucos genes, como resistência à pústula bacteriana; os quantitativos, em que a sua variação é contínua, com alta influência ambiental, regida por muitos genes e

tendem a adequar-se à distribuição normal (SILVA *et al.*, 2017), como a resistência horizontal à ferrugem asiática da soja e produtividade de grãos.

São relatadas no Brasil cerca de 40 doenças em soja com potencial de causar impactos econômicos (HENNING *et al.*, 2014). São exemplos de doenças por fungos: antracnose, cancro da haste, crestamento foliar, ferrugem asiática, mancha alvo, mancha parda, mancha olho-de-rã, requeima, oídio e mofo branco (HENNING *et al.*, 2014). A Ferrugem Asiática da Soja (FAS), causada pelo fungo *Phakopsora pachyrhizi*, se destaca devido ao seu grande potencial de destruição das lavouras, que pode chegar a 90%, sendo identificada no Brasil a partir da safra de 2001/2002 (GODOY *et al.*, 2016). As principais medidas de controle da FAS são o uso de fungicidas, vazios sanitários e cultivares resistentes, podendo ser resistência vertical e horizontal (GODOY *et al.*, 2016; JULIATTI *et al.*, 2019). O melhoramento focado em resistência genética a doenças utiliza a severidade dos sintomas como caráter de seleção, cujas estimativas são obtidas com o auxílio de escalas diagramáticas (FRANCESCHI *et al.*, 2020). Entretanto, a estimativa ainda é altamente dependente da acurácia do melhorista, uma vez que é feita a partir de atribuições de notas com base em uma comparação de modo visual com escalas diagramáticas, ocasionando uma perda de precisão e subjetividade nas análises. Assim, se faz necessário um método que aumente a uniformidade e confiabilidade da análise.

O presente trabalho visa propor um método para o uso de imagens na etapa de quantificação de sintomas causados pela FAS e identificação de genótipos com níveis de resistência. No trabalho, são apresentadas todas as etapas executadas para a proposição do método, iniciando por uma pesquisa sistemática que objetivou encontrar os resultados das principais pesquisas na área de Inteligência Artificial e Processamento de Imagem aplicada ao melhoramento genético e manejo de plantas. Isto seguido por um estudo exploratório com o objetivo de criar o algoritmo computacional para quantificação dos sintomas e pela execução de experimentos visando validar o método proposto e realizar o treinamento de Redes Neurais Convolucionais para classificar sintomas de múltiplos patógenos. É importante ressaltar que este trabalho é multidisciplinar, tendo como vertentes melhoramento genético de plantas, processamento de imagens, inteligência artificial e fitopatometria.

O presente estudo foi dividido em capítulos: Referencial Teórico, que tem como objetivo apresentar o arcabouço teórico para compreensão dos temas abordados; Metodologia, que expõe os caminhos metodológicos percorridos durante toda a execução do trabalho; Resultados, que sintetiza e discorre sobre os resultados obtidos em cada uma das etapas de execução dos experimentos, e Conclusão, que faz o fechamento de tudo que foi tentado ao longo dos estudos executados.

2 REFERENCIAL TEÓRICO

2.1 A soja

A soja, *Glycine max L. Merril*, é uma planta de ciclo anual comercialmente utilizada para a produção de óleo e proteína. Com o centro de origem na China, ela foi trazida para o Brasil em 1882, entretanto, como a soja é sensível ao fotoperíodo, foi necessário um período de “tropicalização”. Somente em 1891, ela foi introduzida no Brasil, em São Paulo, de forma que os programas de melhoramento genético foram sendo criados para a criação de cultivares adaptadas a diferentes regiões do país, como: em 1901, no Rio Grande do Sul; 1954, no Paraná; 1930, em Minas Gerais; 1950, em Goiás; em 1970, no Mato Grosso (SILVA *et al.*, 2017).

Recorrentemente, as cultivares de soja apresentam de 37% a 42% de proteína, podendo alcançar cerca de 52%, e o teor de óleo entre 17% e 22%. Além disso, a soja pode ser utilizada como adubo verde, forragem, feno e pastagens (SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016). A planta da soja varia de 0,2 m a 2,0 m de altura, podendo ser ramificada; o seu sistema radicular é predominantemente axial fasciculado, o caule é do tipo herbáceo ereto com pubescência, de forma que as pilosidades podem ser acinzentadas (Figura 1A) ou marrons (Figura 1B), com variação nos tons (SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016).

Figura 1 - Exemplos de cores da pubescência da soja

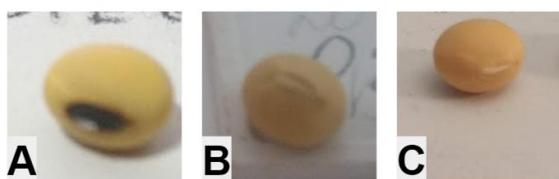


A: acinzentadas; B: marrons.

Fonte: Autoria própria.

Além da cor, a densidade da pubescência também tem influência genética, a sua avaliação pode ser importante para estudos que tentam correlacioná-la com a resistência a insetos (KOMATSU *et al.*, 2007). A cor da pubescência está relacionada com a cor do tegumento, que consiste na membrana que envolve o embrião completamente desenvolvido (CRANG; LYONS-SOBASKI; WISE, 2018), podendo ser amarela, amarela esverdeada, verde, marrom clara, marrom média, marrom escura e preta (CARPENTIERI-PIPOLO *et al.*, 2007; SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016). De acordo Carpentieri-Pipolo *et al.* (2007), os genes que produzem a pigmentação do tegumento também são responsáveis pela cor do hilo, que consiste na cicatriz deixada pela fixação da semente ao funículo (CRANG; LYONS-SOBASKI; WISE, 2018), podendo ser de cores cinza, amarela (Figura 2C), marrom clara (Figura 2B), marrom, preta imperfeita e preta (Figura 2A).

Figura 2 - Exemplos de cores de hilo



A: preto; B: marrom claro; C: amarela.

Fonte: Autoria própria.

A semente da soja ainda possui como características forma (esférica, esférica-achatada, alongada e alongada achatada) e o peso, que varia de 2 g a 53 g por 100 sementes. A semente é gerada dentro da vagem, que é o fruto da soja. Podendo conter de uma a cinco sementes, a vagem, assim como apresentado na Figura 1, tem pubescência e pode variar quanto à forma (achatada, arredondada, reta ou curvada) (SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016). A soja pode ser classificada quanto ao grupo de maturidade relativa, que consiste no número médio de dias até a maturidade em uma determinada faixa de latitude. Para isto, são usados 13 grupos de maturidade (SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016).

As características da planta da soja que já possuem uma definição clara em relação à interação genética de dominância e recessividade, podendo ser utilizadas

para diferenciar linhagens, permitindo o registro de cultivares. São exemplos de descritores da soja: pigmentação antocianínica do hipocótilo, cor da flor, intensidade do verde das folhas, forma do folíolo lateral, tamanho do folíolo lateral, tipo de crescimento, altura, hábito de crescimento, cor e densidade da pubescência, cor da vagem, ciclo vegetativo, ciclo total, tamanho e forma da semente, brilho e cor do tegumento, cor do hilo (BRASIL, 2009).

Além das características descritas anteriormente, são parâmetros para a diferenciação de cultivares a resistência à doença, como reação à pústula bacteriana, resistência à mancha olho-de-rã, cancro da haste, nematóide de galhas e nematóide de cisto (BRASIL, 2009). Isso mostra a importância do estudo das doenças na soja, seja na descoberta de fatores que promovem a resistência horizontal, resistência vertical (JULIATTI *et al.*, 2019) ou na criação de métodos de controle químico.

2.2 Doenças da soja

2.2.1 Ferrugem Asiática da Soja

A ferrugem asiática da soja é uma doença causada por duas espécies do fungo *Phakopsora*: *Phakopsora pachyrhizi* e *Phakopsora meibomiae* (SOUSA *et al.*, 2007). Ela foi identificada no Brasil em 2001 e, até hoje, são estudados métodos para o seu controle (GODOY *et al.*, 2017). A espécie *Phakopsora meibomiae* ocorre em temperaturas médias abaixo de 25 °C e a espécie *Phakopsora pachyrhizi* está adaptada para ambientes com temperaturas entre 15 °C e 30 °C, o que é mais próximo da realidade do clima brasileiro (YORINORI; LAZZAROTTO, 2004).

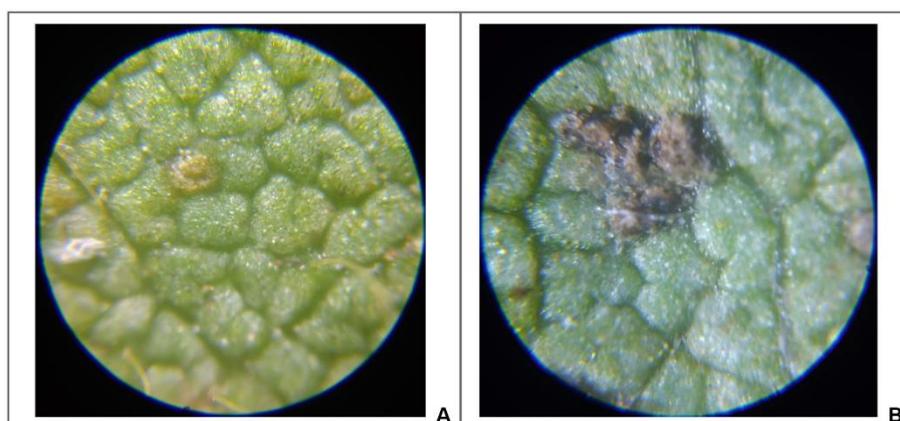
O processo de infecção pela FAS se inicia pela deposição dos urediniosporos, transportados pelo ar, na superfície foliar, que, em condições de temperatura e umidade (ROSA; SPEHAR; LIU, 2015), tornam possíveis a germinação e emissão do tubo germinativo, e se encerra com a produção do apressório, utilizado para a penetração do fungo no hospedeiro pelos estômatos (RUPE; SCONYERS, 2008). Após a penetração, se inicia a colonização, as hifas ramificadas primárias dão origem à formação de um micélio denso, preenchendo os espaços intercelulares e inserindo haustórios no mesofilo e nas células epidérmicas, iniciando a etapa de reprodução do

fungo, aproximadamente 8 dias após a infecção, que tem como primeiro sinal a agregação das hifas e início da formação de uredínia (ROSA; SPEHAR; LIU, 2015).

Existem três tipos de reações à infecção pelo fungo *Phakopsora pachyrhizi*: a resistência completa, quando não há a presença de estruturas reprodutivas; a resistência parcial, com lesões do tipo *Redish Brown (RB)*; a susceptibilidade, com lesões de coloração “tan” (HENNING *et al.*, 2014; ROSA; SPEHAR; LIU, 2015). Na Figura 3, é possível observar sintomas causados pela infecção, Figura 3A manchas de estágios iniciais e Figura 3B são pústulas ativas.

De acordo com Claudia Godoy *et al.* (2017), as principais medidas para o controle da ferrugem são: adoção de vazio sanitário (de cultura hospedeiras) com período mínimo de 90 dias (BRASIL, 2021a), uso de cultivares precoces, uso de cultivares com gene de resistência, controle químico e novas tecnologias de aplicação de fungicidas. O uso de cultivares com gene de resistência depende da criação de novas cultivares, que são resultados do processo de melhoramento genético da soja (SILVA *et al.*, 2017).

Figura 3 - Exemplo de sintomas causados pela ferrugem



A: pontos de clorose causados pela infecção; B: necrose.

Fonte: Autoria própria.

No melhoramento de plantas, ao se trabalhar com resistência a um patógeno, deve-se levar em consideração a resistência vertical (qualitativa) e horizontal (parcial), que se diferenciam pela durabilidade e quantidade de genes que as governam (JULIATTI *et al.*, 2019). A resistência natural da planta se dá a partir de genes que

conferem a resistência a um patógeno específico ou família de patógenos, sendo que encontrar estes genes pode reduzir o custo do controle químico, melhorar a eficiência e reduzir a pressão de seleção para resistência a fungicidas (GODOY *et al.*, 2016).

Já foram listados na literatura 7 genes dominantes que levam à resistência vertical à ferrugem da soja: *Rpp1*, *Rpp2*, *Rpp3*, *Rpp4*, *Rpp5*, *Rpp6* e *Rpp7* (CHILDS *et al.*, 2018; YAMANAKA; HOSSAIN, 2019), mas devido à quantidade de populações do fungo *P. pachyrhizi*, a resistência pode não ser durável. Considerando este fator, se dá a importância de estabelecer o uso da resistência horizontal, que é formada por vários genes e, mesmo que parcialmente, visa reduzir a intensidade da doença no campo (JULIATTI *et al.*, 2019).

Segundo Godoy *et al.* (2020), as cultivares que apresentam a resistência vertical, quando infectadas, apresentam um tipo de lesão do tipo *Redish Brown (RB)* (Figura 3B), que necrosa o tecido foliar ao redor do ponto no qual a pústula está presente, eliminando a fonte de alimento do fungo, de forma que a infecção é controlada. Além da resistência, que consiste na capacidade da planta de limitar a multiplicação do patógeno, ainda pode ser trabalhada a tolerância, que é a capacidade da planta de reduzir os efeitos da infecção na sua saúde, independentemente do nível de multiplicação (PAGÁN; GARCÍA-ARENAL, 2018). A tolerância também pode estar relacionada à capacidade da soja de resistir a tratamentos químicos, como é o caso da aplicação de fungicidas para o tratamento da ferrugem.

No caso da soja, uma planta tolerante a um patógeno deve completar o seu ciclo sem que o patógeno prejudique a sua produção (JULIATTI *et al.*, 2019), uma das formas de explorar essa capacidade é a implementação de plantas precoces, ou seja, que completam seu ciclo mais rapidamente (GODOY *et al.*, 2017). Dessa forma, quando a ferrugem se disseminar na planta, o período de enchimento da vagem já foi completado, reduzindo ou eliminando a perda de produtividade.

O controle químico se dá pelo uso de fungicidas, que podem ser classificados em três grupos: clorotalonitrilas, estrobilurinas e triazóis (RUPE; SCONYERS, 2008). Os fungicidas do grupo dos triazóis atuam como inibidores na etapa de biossíntese de esteróis fúngicos, os fungicidas do grupo das estrobilurinas atuam como inibidores externos de quinona (QoI) (TWIZEYIMANA; HARTMAN, 2017). Os fungicidas do tipo clorotalonitrilas afetam rotas bioquímicas do fungo, entretanto, eles não são

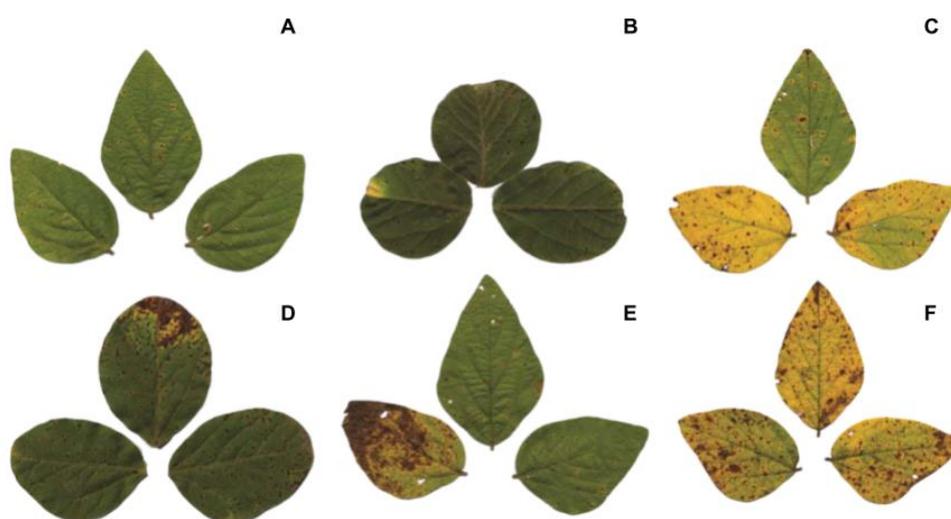
translocados pela planta, sendo suscetíveis à lixiviação (RUPE; SCONYERS, 2008). O desempenho dos fungicidas vem reduzindo ao longo dos anos (DALLA LANA *et al.*, 2018), reforçando a necessidade de criação de genótipos com níveis de resistência.

2.2.2 Septoriose

A septoriose, também chamada de mancha parda, é causada pelo fungo *Septoria glycines*, sendo que a planta que apresenta infecção por esse fungo tem como sintomas pontos marrons e manchas irregulares circundadas por clorose nos folíolos (LIN; MIDEROS, 2021).

A Figura 4 ilustra folhas de soja com diferentes níveis de infecção, é importante destacar que as imagens Figura 4A, C, D, E e F são da face adaxial e a Figura 4B é da face abaxial. Os sintomas na face adaxial são ligeiramente semelhantes à infecção causada pela ferrugem, contendo pontos marrons de necrose circundados por clorose. No entanto, é possível diferenciá-los ao considerar a regularidade das manchas, principalmente no início da infecção, que, na septoriose, pode ser considerada irregular.

Figura 4 - Diferentes níveis de Infecção



A: 0,9%; B: 2,3%; C: 4,5%; D: 10,6%; E: 17,0% e F: 19,0 %.

Fonte: Cruz *et al.* (2010).

Além dos sintomas foliares, a septoriose pode causar a desfolha da planta (LIN; VILLAMIL; MIDEROS, 2021) reduzindo a produtividade (CRUZ *et al.*, 2010). Dentre as formas de controle, as principais são rotação de cultura, uso de fungicida e tratamento de sementes (ALMEIDA *et al.*, 1997; CRUZ *et al.*, 2010).

2.2.3 Oídio

O oídio, causado pelo fungo *Erysiphe difusa*, atinge a soja, causando uma fina camada de micélio e esporos pulverulentos, que podem cobrir toda a superfície foliar, vagens e a haste com pequenos pontos brancos (SILVA *et al.*, 2016).

A Figura 5 ilustra dois exemplos de folíolos com infecção causada por oídio, que apesar de não estar entre as principais doenças da soja, pode gerar uma perda de produtividade, pois prejudica a taxa de fotossíntese da planta (ALMEIDA *et al.*, 2008). As condições que favorecem o aparecimento do fungo são temperaturas de 18° a 24 °C e baixa umidade relativa do ar (HENNING *et al.*, 2014). Os métodos de controle mais amplamente relatados são o uso de fungicidas e cultivares resistentes (HENNING *et al.*, 2014; PÉREZ-VEGA *et al.*, 2013).

Figura 5 - Exemplo de infecção por oídio



Fonte: Autoria própria.

2.2.4 Mancha olho-de-rã

A mancha olho-de-rã, causada pelo fungo *Cercospora Sojina*, é uma lesão que se inicia por uma mancha circular verde-clara e evolui para manchas arredondadas, atingindo 3 a 5mm de diâmetro (HENNING *et al.*, 2014).

A Figura 6 ilustra um exemplo da face abaxial e adaxial de folíolos de soja com mancha olho-de-rã, pode-se observar que, assim como a ferrugem asiática da soja e a septoriose, os sintomas são caracterizados por manchas marrons, porém, nesse caso, a mancha é regular e com pouco indício de clorose. Os métodos de controle são o uso de fungicidas benzimidazóis (HENNING *et al.*, 2014), o uso de sementes livres do patógeno e a utilização de cultivares com resistência genética (SOARES; ARIAS, 2016).

Figura 6 - Exemplo de infecção por *Cercospora sojina*



Fonte: Autoria própria.

2.3 Melhoramento genético da soja

Existem diversas definições para o melhoramento genético de plantas. De acordo com Fehr (1987), o melhoramento de plantas é a arte e a ciência do melhoramento genético das plantas, sendo que o termo “arte” está relacionado com a capacidade de observação das plantas mais desejáveis. De acordo com Acquaaah (2012), o melhoramento de plantas é um ramo da agricultura que se concentra na manipulação da hereditariedade das plantas para desenvolver tipos de plantas novos e melhorados para uso pela sociedade. Assim, o melhoramento genético da soja, assim como de outras culturas, é realizado com o intuito de desenvolver novos

genótipos que possuam genes que condicionam caracteres superiores, o que implicará, conseqüentemente, em plantas mais produtivas. Assim, um dos principais métodos adotados no melhoramento genético da soja é a hibridação, visando criar uma população com variabilidade genética, na qual será aplicada a seleção.

As características observadas no melhoramento genético podem ser divididas em: qualitativas, quando a herança é controlada por alelos em um único locus ou em poucos loci; quantitativas, em que a herança é controlada por vários genes e são mais influenciadas pelo ambiente; sendo estas mais valorizadas comercialmente, como produtividade e número de grãos por vagem (MILADINOVIC *et al.*, 2011; SILVA *et al.*, 2017).

Dentre os objetivos do melhoramento genético, pode-se listar: a produtividade, número de grãos por vagem, tipo de crescimento, precocidade e resistência a doenças (ACQUAAH, 2012; MILADINOVIC *et al.*, 2011). A criação de novos genótipos também está relacionada com processos fisiológicos da planta que impactam na interação com o ambiente. Essa interação pode estar relacionada com patógenos, fornecendo níveis de resistência e tolerância para a planta (ACQUAAH, 2012).

Doenças como o cancro da haste possuem fontes de resistência com dominância completa já registrada (MATSUO; FERREIRA; SEDIYAMA, 2017), a resistência genética à pústula bacterina, por sua vez, é controlada por um gene recessivo (KIM *et al.*, 2010). Doenças como FAS já possuem alguns genes de resistência listados, mas esta busca deve ser algo constante nos processos de melhoramento genético, devido à capacidade de modificação do patógeno.

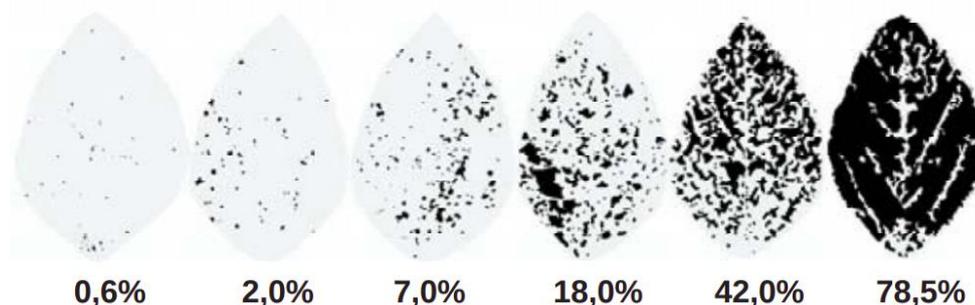
2.3.1 Melhoramento genético com foco em resistência à Ferrugem Asiática da Soja e avaliação de severidade dos sintomas

Como a resistência da ferrugem é um fator genético (JULIATTI *et al.*, 2019), é possível, por meio do melhoramento genético, criar cultivares com níveis de resistência ao fungo. Martins e Juliatti (2014) apresentam uma abordagem de melhoramento genético da soja, com o objetivo de investigar o controle genético da resistência à FAS em linhagens derivadas de cruzamentos entre Caiapônia e IAC-100, e Luziânia e Potenza. Foi utilizado o método de análise visual dos sintomas de 3

folíolos do terço médio da planta, executado por 3 avaliadores, com o auxílio de uma escala diagramática com os limiares de 0.5, 5, 20, 40, 60 e 80% de infecção. A avaliação foi realizada 80 dias após a semeadura, levando em consideração que, nesse estágio de desenvolvimento, houve maior expressão nas plantas suscetíveis.

Cruz *et al.* (2011) realizaram uma pesquisa sobre o progresso da ferrugem asiática na soja e, para isso, foram utilizadas 20 progênies F3, gerados a partir da combinação de 5 cultivares distintos. A avaliação da severidade foi feita utilizando a escala diagramática proposta por Godoy, Koga e Canteri (2006), na qual a severidade da infecção varia de 0.6 a 78.5%. Para isso, foram analisados, ao acaso, 30 folíolos de cada repetição dos tratamentos, realizando um total de 600 análises por tratamento. Esse processo foi feito 5 vezes, em um intervalo de 3 dias entre cada avaliação, e as plantas se encontravam entre os estádios de desenvolvimento R6 e R7, sendo que, com os dados das avaliações, foi feito o cálculo da Área Abaixo da Curva de Progresso da Doença (AACPD).

Figura 7 - Escala diagramática com 6 níveis



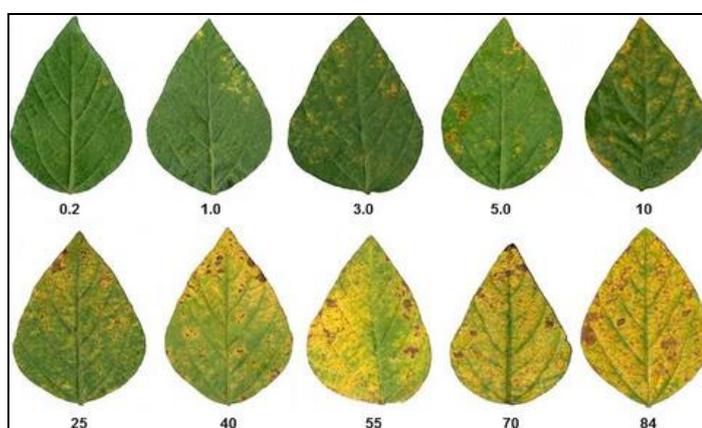
Fonte: Godoy, Koga e Canteri (2006).

A escala diagramática proposta por Godoy, Koga e Canteri (2006) apresentou 6 níveis de infecção por ferrugem (0,6%; 2%; 7%; 18%; 42% e 78,5%), como é mostrado na Figura 7. O objetivo da escala é auxiliar os avaliadores, melhorando a acurácia e precisão da avaliação. Para a sua criação, diversos folíolos foram analisados, utilizando um *software* para colorir manualmente os pontos de infecção e outro para realizar o cálculo da área total de infecção com base nos pontos coloridos. A validação dessa escala foi feita utilizando 44 imagens de folíolos de soja, que foram

apresentadas para 8 avaliadores (4 com experiência e 4 sem experiência de avaliação).

Franceschi *et al.* (2020) apresentaram uma atualização da escala diagramática, proposta por Godoy, Koga e Canteri (2006), com um modelo contendo 10 níveis de severidade, conforme ilustrado na Figura 8. Esse padrão foi elaborado utilizando a avaliação de 37 especialistas em um conjunto de 50 imagens com níveis variados de severidade da infecção por ferrugem.

Figura 8 - Escala diagramática com 10 níveis



Fonte: Franceschi *et al.* (2020).

Ainda existem outras escalas diagramáticas utilizadas na avaliação da severidade ferrugem, como é apresentado por Juliatti *et al.* (2019) em uma abordagem que visa avaliar genótipos promissores à resistência parcial contra a ferrugem. Neste trabalho, foram feitas avaliações aos 51, 61, 71 e 81 dias após a semeadura em cinco folíolos e dois trifólios por parcela útil, coletadas no terço médio das plantas. Então, a partir desses dados, foram calculadas a AACPD e a taxa de progresso da doença.

Como apresentado por Michereff *et al.* (2006) e por Godoy, Koga e Canteri (2006), quando os avaliadores não utilizam uma escala diagramática para realizar a avaliação da severidade das doenças foliares, existe uma tendência a apresentarem valores superestimados, tornando a avaliação não fidedigna aos índices reais de severidade.

O processo de criação de uma escala diagramática é semelhante, independentemente da cultura. Em suma, é coletada uma quantidade determinada de

folhas e uma análise detalhada é feita em cada uma delas, podendo ser por *softwares* genéricos de análise de imagem, mensuração de cores ou até mesmo por *softwares* de edição de imagem. Com a severidade real calculada, os limites inferior e superior são definidos a partir da proporção máxima e mínima da área lesionada em relação à área foliar. Os pontos intermediários da escala são definidos a partir das distribuições mais frequentes das lesões (NUNES; ALVES, 2012).

Ao se trabalhar em experimentos no campo, existe a possibilidade de infecção por múltiplos patógenos, tornando a avaliação menos precisa. Desse modo, experimentos utilizando o fungo *P. pachyrhizi* podem ser feitos em ambientes controlados, como casa de vegetação, câmaras de crescimento e até mesmo a inoculação na folha destacada. Todas essas formas se iniciam na coleta dos urediniósporos no ambiente, que pode ser feita a partir das plantas infectadas por uma colheitadeira a vácuo. Esse processo deve ser iniciado de 10 a 14 dias após a inoculação e continuando em intervalos semanais, sendo possível o uso de outras ferramentas além da colheitadeira a vácuo, como pincéis (BONDE *et al.*, 2006).

O armazenamento dos urediniósporos pode ser feito com o uso do nitrogênio líquido (-196 °C) (BONDE *et al.*, 2006), geladeira (5 °C), congelador (-20 °C) e *deep-freezer* (-80 °C), sendo que cada forma de armazenamento provê um nível de durabilidade aos urediniósporos (ZAMBENEDETTI *et al.*, 2007).

Para a análise de virulência da ferrugem, Bonde *et al.* (2006) mantiveram os urediniósporos hidratados em água, a solução foi diluída até uma concentração de 1×10^4 ou 2×10^4 mL⁻¹. Para cada duas plantas, foram pulverizados 2 mL da solução, as plantas foram mantidas por 16h a 20 °C em alta umidade; após esse período, as plantas foram transferidas para uma estufa com temperatura de 20 a 25 °C. O experimento realizado por Zambenedetti *et al.* (2007) seguiu processo semelhante, os urediniósporos foram colocados em suspensão em uma solução com uma concentração de 1mg de urediniósporos para 25 µL de Tween 20 por mL de água destilada, de forma que a concentração final foi de 3×10^4 urediniósporos por mL. Não foi feita a inoculação em plantas, os experimentos foram realizados em placas contendo ágar-ágar.

Ainda que existam métodos para a inoculação da ferrugem em ambiente controlado, se faz necessário um especialista treinado para a quantificação da

infecção por ferrugem nos folíolos, seja por meio visual ou em marcação com *softwares*. Com o objetivo de tornar o processo mais otimizado, pode-se utilizar imagem dos folíolos e visão computacional para auxiliar o pesquisador no processo de quantificação de doenças de forma automatizada.

2.3.1.1 Correlação entre AACPD com produtividade e peso de 100 sementes

Mueller *et al.* (2009) apresentam um experimento que visa comparar o efeito de fungicida e tempo de aplicação na produtividade da soja, no qual foi encontrada uma correlação negativa de 0.3 em todos os cenários abordados. Godoy *et al.* (2009) também encontraram uma correlação em produtividade e AACPD quando analisadas no estágio de crescimento R6, que está relacionado ao desenvolvimento da semente (SEDIYAMA; OLIVEIRA; SEDIYAMA, 2016). Entretanto, a ferrugem da soja pode apresentar diferentes resultados na produtividade a depender das condições climáticas, estágio de desenvolvimento (GODOY *et al.*, 2009) e época de semeadura (ALMEIDA; FORCELINI; FIALLOS, 2017).

O enchimento dos grãos está relacionado a fatores como o fotoperíodo que pode causar um desbalanço entre os estádios vegetativos e reprodutivos, quantidade de chuvas e a capacidade da planta de fornecer nutrientes (MUNDSTOCK; THOMAS, 2005). Assim sendo, deve-se analisar, além da época de plantio, o estágio de desenvolvimento que a ferrugem foi encontrada nas plantas.

2.3.2 Fenotipagem de alto rendimento

Dada a necessidade do aumento na quantidade e qualidade dos dados fenotípicos coletados no campo, surgiu a fenotipagem de alto rendimento, que consiste na utilização de novas técnicas de sensoriamento para a melhoria da coleta de dados agronômicos (ROTH *et al.*, 2022). Dentre as técnicas de sensoriamento, estão o uso de drones (SANTANA *et al.*, 2022), imagens de raio X (LIU *et al.*, 2020) e LiDAR (QIU *et al.*, 2019).

O uso de imagens capturadas por câmeras multiespectrais permite a criação de índices para a extração de características como biomassa, área foliar e teor de

água nas plantas (BROGE; LEBLANC, 2001; JULIATTI *et al.*, 2020). Os índices são criados utilizando espectros não visíveis ao olho humano, assim, a análise por imagens multiespectrais amplia a capacidade de observação do campo. Ao acoplar câmeras a veículos aéreos não tripulados e satélites, é possível aumentar a área de captura dos experimentos (DAS *et al.*, 2022).

O uso de novas técnicas de captura surge juntamente com a aplicação de novos dispositivos de *hardware* e novas soluções de *software*, como o uso de aprendizagem de máquinas para a captura de elementos semânticos e classificação de características da imagem (SINGH *et al.*, 2021). Além disso, foram aplicadas técnicas de Visão Computacional para o processamento das imagens capturadas.

2.4 Visão computacional

A visão computacional consiste em uma área de pesquisa que tem como objetivo o processamento visual de informações, buscando a percepção das características semânticas da imagem e a descrição das informações desejadas de forma autônoma (POGGIO; TORRE; KOCH, 1985). A imagem é uma representação de um conjunto de informações e cabe aos algoritmos de visão computacional dar ênfase às características de interesse. Para isso, são realizadas operações matemáticas nas imagens, como a alteração na forma de representação e espaço de cores, segmentação e classificação de regiões.

2.4.1 Representação das imagens

Uma imagem digital de duas dimensões consiste em um conjunto de coordenadas em um plano cartesiano, cada ponto é originado a partir da representação de forma discreta de um sinal contínuo (SOLOMON; BRECKON, 2011). Cada um desses pontos, também chamados de pixel, podem ser representados por um vetor de uma ou mais dimensões, que, quando sobrepostas, formam as cores (SOLOMON; BRECKON, 2011).

Uma imagem pode ser representada por diversos espaços de cores, como: *red, green e blue* (RGB); *cyan, magenta e yellow* (CMY); *cyan, magenta, yellow e black*

(CMYK); *hue, saturation e intensity* (HSI); *hue, saturation e value* (HSV) (KOSCHAN; ABIDI, 2008). A representação mais utilizada é o *Red Blue Green* (RGB), que é formada pela divisão de um pixel em três componentes de cores: vermelho, azul e verde, de forma que a sobreposição das componentes forma a cor desejada. Computacionalmente, uma imagem pode ser representada por um vetor tridimensional (SOLOMON; BRECKON, 2011).

A quantidade de bits utilizada em cada uma das posições do vetor tridimensional permite representar a quantidade de combinações de cores possíveis na imagem (AZAD; HASAN; NASEER, 2017). Por exemplo, uma imagem de 8 bits por pixel tem 2^8 (256) combinações possíveis de valores, que variam de 0 a 255. Como são três componentes de cores, existem 256^3 (16.777.216) combinações possíveis de cores para cada pixel.

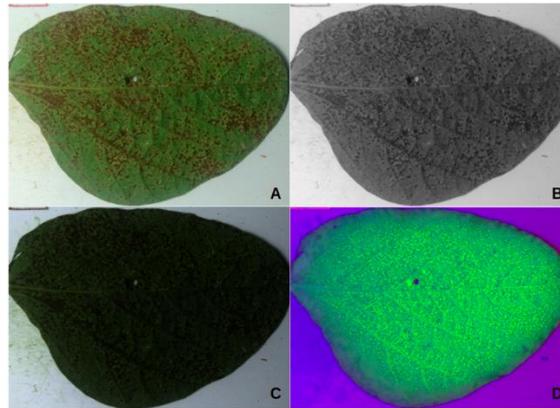
A imagem em RGB pode ser convertida para outros modelos de representação, como a escala de cinza. Essa conversão se dá pela função $I = f(R) + f'(G) + f''(B)$, sendo I a componente em escala de cinza gerada (AZAD; HASAN NASEER; 2017). Além disso, existem os padrões definidos pela Comissão Internacional de Iluminação (CIE): CIELab (ISO/CIE 11664-4, 2019), sendo que L representa a claridade de preto (0) para branco (100), “a” de verde (-) para vermelho (+) e “b” de azul (-) para amarelo (+); CIELUV (ISO/CIE 11664-5, 2016), sendo que L representa a claridade e u e v valores relacionados à croma e matiz. A transformação de RGB para CIELab ou CIELuv necessita de um padrão intermediário, que também foi definido pela CIE, chamado de CIE XYZ ou CIE 1931, que, basicamente, é uma extrapolação do padrão RGB sem valores negativos (PARKIN, 2016).

A conversão entre espaços de cores é dependente dos padrões de luminosidade, definido como fonte de iluminação presente na imagem (PARKIN, 2016). A definição correta desses padrões durante o processo de conversão contribui para melhoria da acurácia de um algoritmo para o reconhecimento de características. Existem diversos padrões de luminosidade definidos pela CIE, os principais são: D50, D55, D65 e D75 (PARKIN, 2016).

Na Figura 9, constam 4 imagens de um folíolo de soja, cada imagem está representada em um espaço de cores diferente. A Figura 9A está no espaço RGB, formato original de captura pela câmera. Utilizando uma representação de 8 bits por

pixel, um software para o processamento dessa imagem deve representá-la conforme a Figura 10.

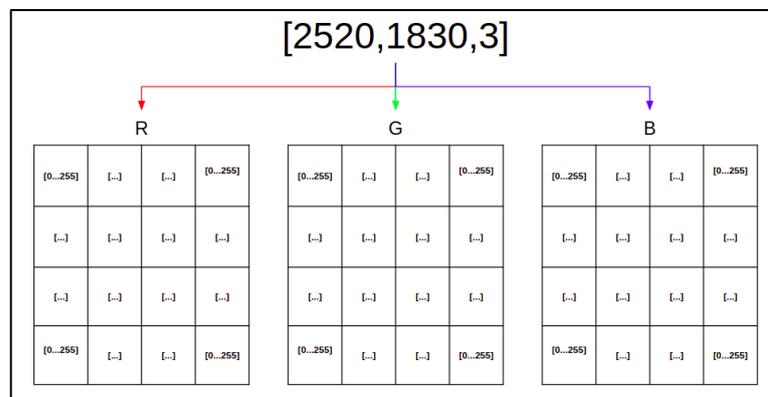
Figura 9 - Foto em diferentes espaços de cores



A: RGB; B: Escala de Cinza; C: XYZ; D: HSI.

Fonte: Autoria própria.

Figura 10 - Representação de uma imagem RGB em uma matriz tridimensional



Fonte: Autoria própria.

Na Figura 10, é possível observar três matrizes de dimensões 2520x1830, que representam a largura e altura da imagem em pixels, respectivamente, de forma que cada pixel é formado por uma posição de cada matriz, representando as cores vermelho (R), verde (G) e azul (B). Como a imagem está representada em 8 bits por pixel, os valores de cada componente podem variar entre 0 e 255. O padrão RGB permite uma boa visualização de cores e característica para o olho humano, entretanto, nem sempre representa as características necessárias para o

processamento digital da imagem. Para isso, são utilizadas transformações para outros espaços de cores, como apresentado nas Figura 9B, 9C e 9D.

A Figura 9B é a representação da Figura 9A em escala de cinza, sendo esse formato largamente utilizado para algoritmos de processamento de imagem devido à simplificação da representação da imagem em uma única dimensão. O princípio da conversão da imagem para a escala de cinza se dá por uma soma ponderada dos componentes de cor (BURGER; BURGE, 2009). A conversão para a escala de cinza pode utilizar outros padrões, mas sempre terá como resultante apenas um componente, monocromático, sendo que isto se faz muito importante para o processamento da imagem devido redução no tamanho de “3 x largura x altura” para “largura x altura”.

Na Figura 9C, está representado o padrão CIE XYZ, que é utilizado como um sistema de padronização do sistema tri-cromático RGB. Esse padrão, que surgiu em 1931 (SCHANDA, 2007), tem o objetivo de corrigir as regiões negativas geradas pelo espectro R do padrão RGB. A conversão do RGB para CIE XYZ é feita com base em uma multiplicação de matrizes, como ilustrado na Figura 11, sendo que a matriz tridimensional RGB deve ser convertida para uma matriz linear.

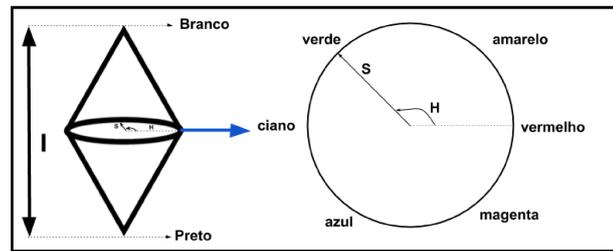
Figura 11 - Matriz para conversão de RGB para CIE XYZ

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & .0.212671 & 0.019334 \\ 0.357580 & .0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

Fonte: Burger e Burge (2009).

O padrão de iluminação adotado altera os valores contidos na matriz de conversão. Para esse exemplo, foi utilizado o padrão D65. Essa conversão é muito utilizada no processamento de imagens por ser um espaço de cores de intermediário para o CIELab.

Figura 12 - Representação do modelo HSI



Fonte: Autoria própria.

Na Figura 9D, está ilustrada uma imagem no espaço de cores HSI, que visa destacar a matiz, saturação e intensidade, assim, cada componente desse espaço de cores é calculado separadamente. De acordo com Gonzales, Woods e Eddins (2004), a matiz, representada por H, pode ser definida como a cor pura, ou seja, sem a presença de branco ou preto; a saturação, que é representada por S, é o grau de diluição da cor pura na cor branca e a intensidade das cores que é representada por I. O espaço HSI pode ser representado de forma geométrica, Figura 12, e a matiz representa o ângulo formado pela saturação e o vermelho, que pode ser calculado pela secante, como é mostrado nas Figura 13A. A saturação e intensidade podem ser calculadas conforme é apresentado nas Figura 13B e Figura 13C.

Figura 13 - Conversão RGB para HSI

$H = \begin{cases} \Theta & \text{se } B \leq G \\ 360 - \Theta & \text{se } B > G \end{cases}$	$S = 1 - \frac{3}{R+G+B} [\min(R, G, B)]$ <p style="text-align: right;">B</p>
$\Theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G)+(R-B)]}{[(R-G)^2+(R-B)(G-B)]^{\frac{1}{2}}} \right\}$ <p style="text-align: right;">A</p>	$I = \frac{1}{3} (R + G + B)$ <p style="text-align: right;">C</p>

A: Cálculo da Matiz; B: Cálculo da Saturação; I: Cálculo da Intensidade.

Fonte: Gonzalez, Woods e Eddins (2004).

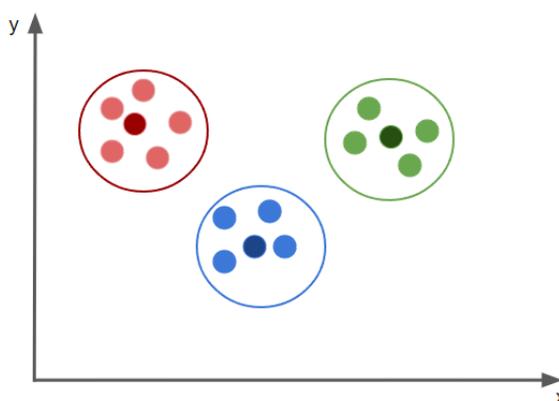
A representação de uma imagem em diferentes espaços de cores pode auxiliar no processamento e na extração de características. Ao analisar a semântica de uma imagem, o principal objetivo é compreender o comportamento de uma determinada característica, seja para calcular tamanho de objetos, intensidade de cores e outros.

Em imagens com vários elementos, como imagens foliares que podem conter solo, caule e outros elementos, é interessante remover os elementos que não serão analisados. A remoção desses elementos é feita pelos algoritmos de segmentação de imagem.

2.4.2 Segmentação de imagem

Utilizado por grande parte dos algoritmos de processamento de imagem, o processo de segmentação consiste em dividir a imagem em partes. Essa tarefa não deve ser feita de forma arbitrária, a segmentação tem como objetivo dividir a imagem em grupos semânticos, ou seja, que tenham relevância para as características que se deseja observar.

Uma das formas de segmentar uma imagem é utilizando algoritmos de agrupamento, como o *k-means* (KUBAT, 2017), que tem como principal objetivo agrupar dados que são semelhantes entre si, armazenando-os em *clusters*. A inicialização do algoritmo pode ser um problema, pois é necessário escolher os pontos que darão início aos agrupamentos, caso seja uma escolha arbitrária, poderá resultar em *clusters* sem nenhum membro, ou a um agrupamento não ótimo dos dados. Na Figura 14, está ilustrado um exemplo de agrupamento utilizando o método *k-means*, os elementos centrais podem ser observados como o círculo mais escuro de cada cor e cada cor representa um grupo. Visando obter melhorias na inicialização do algoritmo *k-means*, foram criadas propostas de otimização, como a apresentada por Bradley e Fayyad (1998), que tem como objetivo criar um método para tornar os pontos de início mais próximos do ponto ideal. Esse processo é feito a partir da execução do algoritmo *k-means* em subconjunto de dados com o objetivo de calcular uma função de distorção com base nas distâncias encontradas na execução do algoritmo nos subconjuntos de dados.

Figura 14 - Exemplo de agrupamento *k-means*

Fonte: Autoria própria.

Além do algoritmo *k-means*, existem outros algoritmos de segmentação, como o método baseado em grafo criado por Felzenszwalb e Huttenlocher (2004), o algoritmo *Quickshift* (VEDALDI; SOATTO, 2008), *Watershade* (NEUBERT; PROTZEL, 2014) e *Superpixel* (ACHANTA *et al.*, 2012), que consiste em uma abordagem de encontrar regiões da imagem que possuem grande semelhança e criar diversos “*superpixels*” que contenham essas regiões. Este algoritmo pode variar de acordo com a quantidade de “*superpixels*” desejada e o limiar que define a diferença entre as regiões. Os algoritmos de segmentação por agrupamento podem ser considerados como métodos de inteligência artificial, porém são métodos não supervisionados.

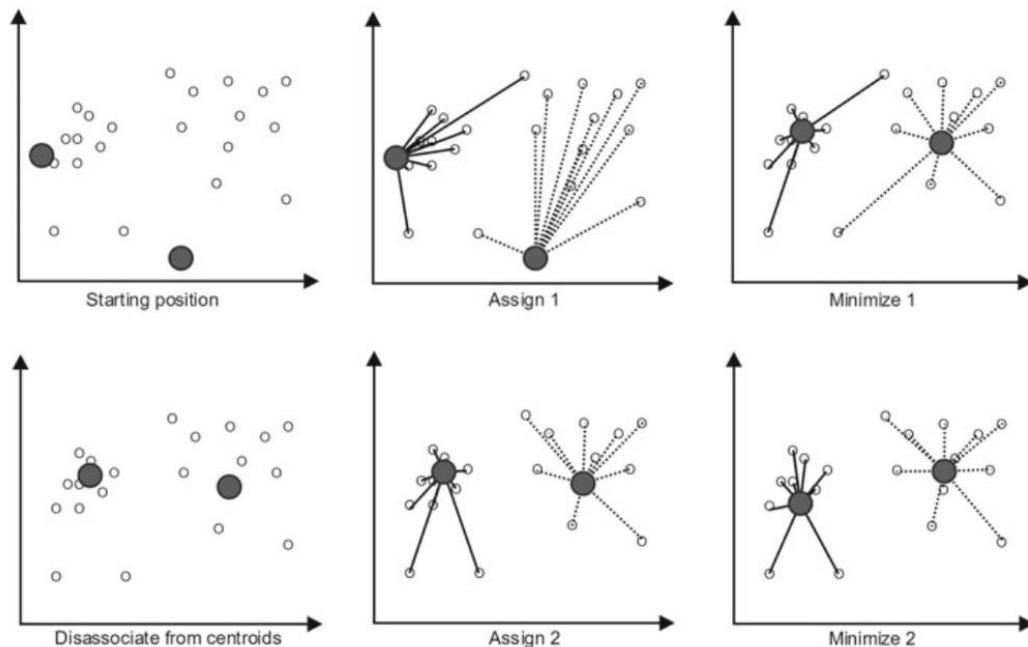
2.5 Inteligência Artificial

Inteligência Artificial (IA) pode ser descrita como qualquer técnica que tenha o objetivo de atribuir características do comportamento humano a um computador, o termo IA se relaciona recorrentemente ao processo de aprendizado, tomada de decisão, classificação, visão computacional, otimização e simulação (NGUYEN *et al.*, 2019). Um subconjunto de técnicas de IA que visam aprender com situações anteriores, para melhorar a solução de um problema, é chamado de aprendizado de máquina (NGUYEN *et al.*, 2019). Quando o aprendizado é realizado para simular as interações dos neurônios humanos, a técnica é chamada de Redes Neurais Artificiais (RNA), que são organizadas em camadas.

O aprendizado de máquinas é dividido em três ramos principais: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. O aprendizado não supervisionado é aprendizado sem rótulos ou alvos (SKANSI, 2018a). O exemplo da Figura 14 é o resultado da execução do *k-means*, que é um dos principais métodos não supervisionados. Entretanto, entre o conjunto de dados e o resultado, existe um processo de definição dos centroides, apresentado na Figura 15.

O processo aprendizagem se inicia com uma definição fixa ou aleatória dos centroides. Então, são executadas diversas vezes as fases de “atribuir” os dados aos grupos definidos e, posteriormente, minimizar a distância entre os membros do grupo e o centroide. Após o término dos ciclos, o resultado obtido é um hiperplano, que permitirá a atribuição de um novo elemento ao grupo mais próximo a ele (SKANSI, 2018a).

Figura 15 - Definição dos centroides *k-means*



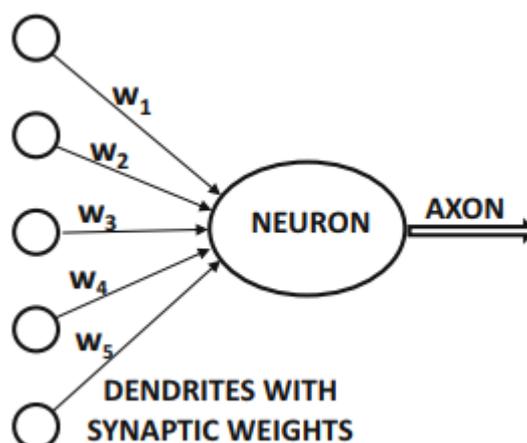
Fonte: Skansi (2018a).

O aprendizado por reforço é utilizado quando se tem um conjunto de dados muito complexo de ser classificado, porém passível de ser avaliado. Assim, o algoritmo utiliza um valor de recompensa que pode ser atribuído para cada ação de

aprendizado (AGGARWAL, 2018). O aprendizado supervisionado utiliza o conceito de aprendizagem humana. Para isto, são utilizados diversos neurônios conectados com a capacidade de tomada de decisão com base em pesos.

A Figura 16 é uma representação computacional de um neurônio, ele tem diversas entradas e apenas uma saída, cada entrada para um neurônio é dimensionada com um peso que afeta a função calculada naquela unidade. No aprendizado supervisionado, o algoritmo recebe um conjunto de dados e rótulos de treinamento, essa fase é chamada de treinamento, na qual o algoritmo cria um hiperplano, ajustando seus pesos internos (SKANSI, 2018a).

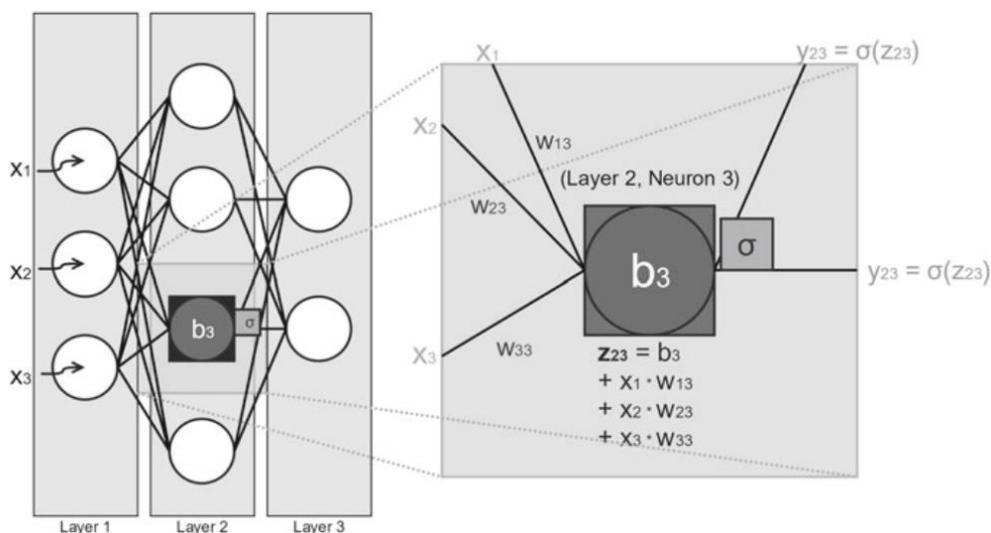
Figura 16 - Representação computacional de um neurônio



Fonte: Aggarwal (2018).

As RNAs são um conjunto de vários neurônios conectados, formando diversas camadas, a organização dessas camadas consiste na arquitetura da RNA, que poderá variar com base na complexidade do problema que será atacado. As RNAs mais complexas, com várias camadas de processamento, dão origem a uma técnica chamada *Deep Learning* (DL) (NGUYEN *et al.*, 2019).

Figura 17 - Exemplo de Rede Neural com 3 camadas



Fonte: Skansi (2018b).

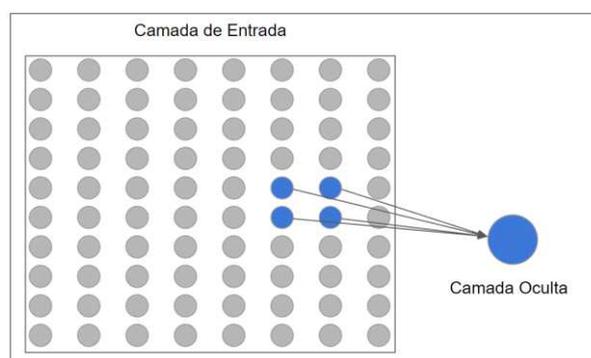
A Figura 17 ilustra uma RNA de três camadas, elas podem ser definidas como uma regressão logística, ou seja, um modelo estatístico que determina a probabilidade de um evento acontecer (SKANSI, 2018b). É interessante observar que cada neurônio de uma camada está conectado a todos os neurônios da camada subsequente e que o resultado de uma camada (saída (y)) é a entrada (x) de outra camada e será multiplicada pelos pesos e somada a um desvio (*bias*). A última camada sempre terá o número de saídas igual ao número de classes esperadas. O objetivo do treinamento de uma rede é encontrar um conjunto ideal de pesos e desvios via *backpropagation*, que consiste em um processo de ajuste dos pesos com base em um erro calculado com a tentativa de aproximar as entradas da camada com a saída esperada.

A RNA representada na Figura 17 tem três entradas. Ao se utilizar uma rede neural artificial para processar uma imagem, tem-se como entrada cada componente de cor de cada pixel da imagem, ou seja, uma imagem com a dimensão 2520x1830 necessitará de uma RNA com $2520 \times 1830 \times 3 = 13.834.800$ entradas. Para se trabalhar com imagens, devem ser utilizadas técnicas de processamento de imagem para realçar as características desejadas, reduzindo a quantidade de entradas necessárias. As Redes Neurais Convolucionais (RNC) são redes específicas para se trabalhar com imagens.

2.5.1 Redes Neurais Convolucionais

As Redes Neurais Convolucionais são RNAs que possuem uma ou mais camadas de convolução (SKANSI, 2018c), elas são focadas em classificação de entradas bidimensionais, como imagens. As RNC combinam três ideias arquiteturais que visam garantir a invariância no grau de deslocamento, escala e distorção: campos receptivos locais, pesos compartilhados e subamostragem espacial ou temporal (LECUN *et al.*, 1998). Ao se trabalhar com campos receptivos locais, cada neurônio na primeira camada oculta será conectado a uma pequena região dos neurônios de entrada, digamos, por exemplo, uma região de 2×2 , correspondendo a 4 pixels de entrada (Figura 18). O compartilhamento de pesos consiste que todos os neurônios da primeira camada-oculta deverão compartilhar os mesmos pesos, ou seja, devem detectar os mesmos recursos.

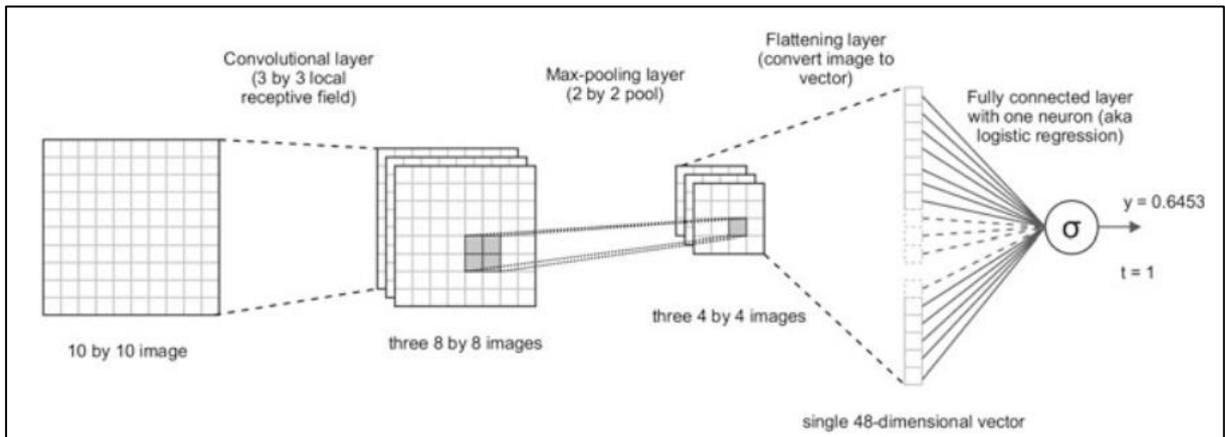
Figura 18 - Exemplo de campos receptivos locais



Fonte: Autoria própria.

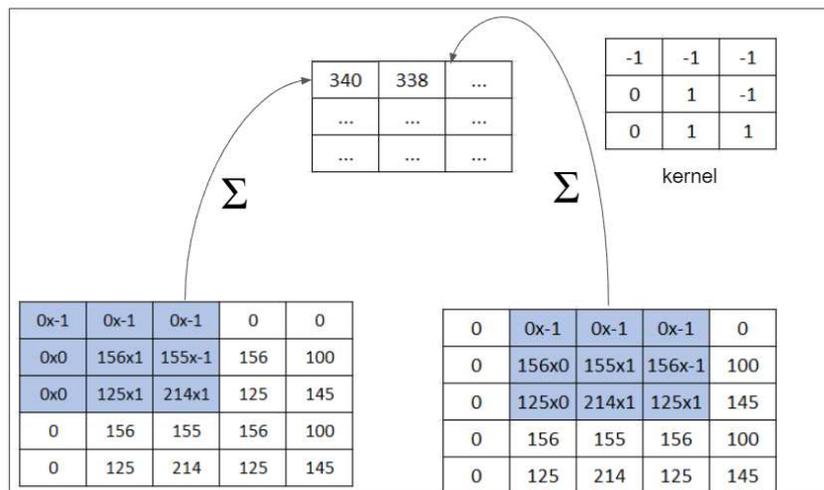
A partir da arquitetura de RNC que é ilustrada na Figura 19, são representadas etapas de convolução e *max-pooling*, que são operações executadas antes da conversão da imagem para um vetor de uma dimensão. A convolução consiste em uma operação de somatório do produto entre a multiplicação de um *kernel* (matriz) por uma região da imagem, com o objetivo de reduzir a imagem analisada e destacar as características mais evidentes. O processo de execução da convolução está ilustrado na Figura 20.

Figura 19 - Exemplo de arquitetura de RNC



Fonte: Skansi (2018c).

Figura 20 - Exemplo de Convolução

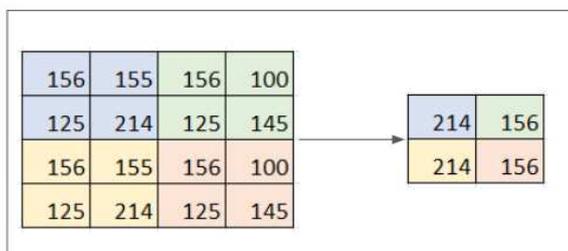


Fonte: Autoria própria.

A operação de *max-pooling* também utiliza uma região da imagem chamada de *kernel*, na qual serão selecionados os maiores valores da região, originando uma nova matriz, conforme apresentado na Figura 21. O objetivo dessa etapa do processo é a supressão de ruídos na região, selecionando somente os valores com maior relevância. Em uma mesma camada da RNC, podem ser executadas diversas etapas de convolução e *max-pooling* de forma simultânea em uma camada. Os estados em cada camada são organizados de acordo com uma estrutura de grade espacial e são herdados da camada anterior para a próxima, pois cada característica é baseada em

uma pequena região espacial local na camada anterior (AGGARWAL, 2018). A definição da organização das camadas consiste na arquitetura de uma rede.

Figura 21 - Exemplo de operação *max-pooling*



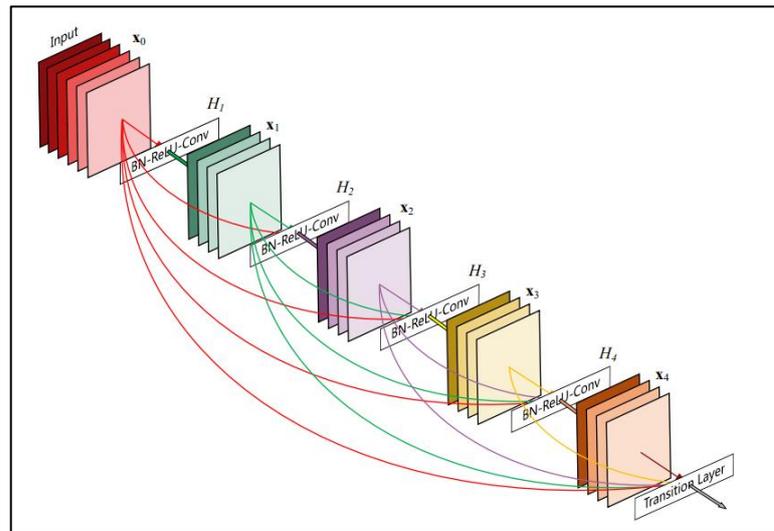
Fonte: Autoria própria.

2.5.2 Arquitetura das Redes Neurais Convolucionais

A aplicação das RNC no processamento de imagem deu origem a diversas arquiteturas, com o foco em solucionar problemas específicos, como segmentação, detecção de características e classificação de objetos, com configurações de *datasets* variadas. O *dataset* consiste em um conjunto de dados, já rotulados, que serão utilizados para o treinamento da rede, ou seja, a definição dos pesos e vieses de cada camada (SKANSI, 2018a).

LeCun *et al.* (1989) apresentaram uma arquitetura LeNet para detecção de códigos postais que utiliza 5 camadas, iniciando como entrada uma imagem em escala de cinza de tamanho 256, e uma saída de tamanho 10 que representa o numeral que foi escrito. A arquitetura da LeNet é totalmente conectada, ou seja, cada neurônio da camada anterior está conectado a todos os neurônios da camada corrente. Szegedy *et al.* (2015) apresentaram a arquitetura *Inception*, com o objetivo de encontrar uma estrutura esparsa local ótima, que se aproxima de uma estrutura de rede densa. Huang *et al.* (2017), por sua vez, propuseram a arquitetura DenseNet, que é formada por diversos blocos densos, ou seja, que a camada “i” está conectada à camada “i+1”, “i+2”, ..., “i + n”, conforme ilustrado na Figura 22. O objetivo dessa arquitetura é passar o maior número de informações para a camada “i+1”.

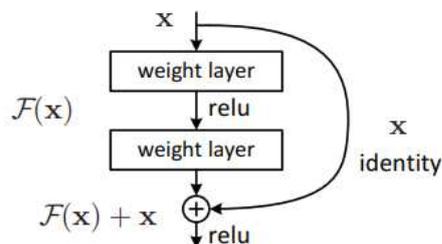
Figura 22 - Exemplo de bloco da DenseNet



Fonte: Huang *et al.* (2017).

Com o foco na otimização da etapa de treinamento, He *et al.* (2016) indicaram a *Residual Network*, também chamada de ResNet, que consiste em uma rede que utiliza funções residuais para enviar informações entre as camadas, conforme ilustrado na Figura 23. Essas funções podem ser vistas como um atalho que permite evitar uma ou mais camadas. Uma rede residual pode ter vários blocos em sua configuração, dando origem às redes ResNet34, ResNet50, ResNet101 e ResNet152 (HE *et al.*, 2016).

Figura 23 - Exemplo de bloco da ResNet

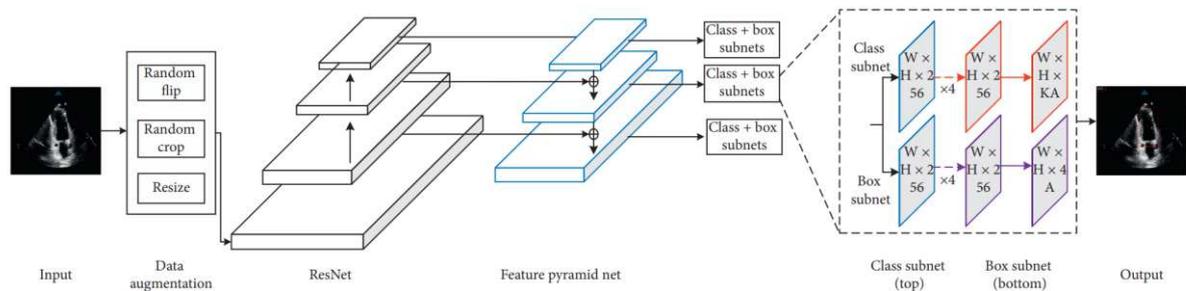


Fonte: He *et al.* (2016).

A arquitetura de uma RNC pode ser decomposta em várias etapas, como é apresentado na Figura 24. A etapa de *Data augmentation* consiste em realizar

transformações na imagem como rotação e cortes para aumentar o número de imagens no *dataset*. A extração de recursos da imagem (*backbone*), na Figura 24, é identificada como ResNet. Entretanto, essa etapa pode ser realizada por outras arquiteturas (ZHANG *et al.*, 2020). A pirâmide de recursos, que consiste em uma RNC atuando em diversos níveis de resolução da imagem, sendo o nível inferior com maior resolução e maior generalização e o superior com menor resolução e menor generalização. A última etapa são as sub redes de classificação, que têm o objetivo de classificar as características encontradas nas etapas anteriores (YANG *et al.*, 2020a). Essas arquiteturas são utilizadas para problemas de segmentação semântica da imagem e detecção de objetos em imagens.

Figura 24 - Exemplo de uso de RNC como Backbone, Pirâmide de Características e Classificação



Fonte: Yang *et al.* (2020a).

A segmentação de objetos nas imagens se faz muito importante em diversas áreas, principalmente na agricultura, pois as imagens possuem grandes níveis de ruído e a captura, recorrentemente, é feita em grande escala. A arquitetura Yolo é utilizada para a detecção de objetos na área foliar, como apresentado por Pereira *et al.* (2022). No presente estudo, para segmentar os folíolos e os identificadores de parcela nas imagens (Figura 25), foi feito o treinamento de uma rede do tipo Yolov5 (JOCHER *et al.*, 2022).

Figura 25 - Resultado de detecção de folíolos e identificadores de parcela



Fonte: Autoria própria.

O treinamento da rede utilizada foi feito com um *dataset* composto por 104 folíolos e 21 identificadores anotados na imagem. Com isso, foi possível atingir uma acurácia acima de 90% para a detecção dos objetos desejados.

Assim, considerando a natureza multidisciplinar do trabalho, o objetivo deste capítulo foi fornecer o arcabouço teórico necessário para a compreensão dos demais capítulos, bem como dos conceitos das diferentes áreas que fazem parte do objeto de estudo.

3 METODOLOGIA

3.1 Revisão sistemática

Diante da necessidade de explorar a produção acadêmica sobre as inovações ocorridas no uso de IA e processamento de imagens no melhoramento e manejo de plantas, bem como aprofundar o conhecimento sobre o assunto, foi executada pesquisa teórico-bibliográfica do tipo Estado da Questão. A pesquisa Estado da Questão visa caracterizar e delimitar o objeto de interesse, por meio da elucidação de um texto narrativo sobre a concepção e contribuição epistêmica do objeto no campo do conhecimento (NÓBREGA; THERRIEN, 2004).

A execução do estado da questão foi dividida em 5 etapas: busca de periódicos, classificação de periódicos, busca por palavras-chave e termos de filtragem em periódicos, seleção de publicações a partir do título, seleção de publicações por conteúdo, seguindo *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (SHAMSEER *et al.*, 2015). A escolha dos periódicos foi feita procurando os periódicos das Ciências Biológicas e Agrárias com os maiores fatores de impacto (A1, A2, B1 e B2). A busca dos artigos científicos foi feita diretamente no site dos periódicos provido pelos agregadores: *Science Direct, Elsevier, Springer, Science Societies, Bioinformatics, BMC Bioinformatics, Scielo, Taylor & Francis journals, American Chemical Society, Frontiers, IEEEXplore, Wiley, American Phytopathological Society, Plant Methods e Plant Science*.

Após a etapa de listagem, os periódicos foram selecionados por título e descrição, que deveriam estar relacionados aos termos: soja, melhoramento genético, computação, tecnologia, inovação, visão computacional e inteligência artificial. Ao determinar os periódicos selecionados, tornou-se possível realizar buscas por termos, o que foi feito de forma customizada para cada plataforma, utilizando os termos: “*Glycine max*” AND “*breeding*”, “*soybean*” AND “*breeding*”, “*phenotyping*” AND “*soybean*”, “*phenotyping*” AND “*image*”, “*phenotyping*” AND “*computer vision*”, “*High-Throughput Phenotyping*”, “*descriptors*” OR “*phenotype*” AND “*soybean*”, “*characters*” OR “*phenotype*” AND “*soybean*”, “*Artificial Intelligence*” AND “*breeding*” AND “*soybean*”, “*Artificial Intelligence*” AND “*soybean*”, “*soybean*” AND “*rust*”.

A utilização desses termos teve como objetivo abranger o maior número de publicações relacionadas com o objeto de estudo. O termo “Inteligência Artificial” foi adicionado à busca, considerando que diversos trabalhos utilizam IA para extrair as características nas imagens. Os artigos selecionados foram publicados no idioma inglês, com datas de publicação entre 2014 e 2021.

A busca por termos retornou muitos resultados, que foram exportados em formatos como *Information Systems Research (RIS)*, *BibTeX* e *Comma Separated Values (CSV)*, para que fosse possível tratar resultados repetidos utilizando o gerenciador de referências Zotero e planilhas. Após a retirada das repetições, as publicações foram filtradas por título e resumo, visando extrair aquelas que apresentam o uso de imagens no melhoramento e manejo de plantas. A última etapa realizada foi a extração dos dados da pesquisa realizada. Os dados extraídos foram: o formato de extração da imagem, a forma de extração, o cultivo em que o trabalho foi aplicado e o objetivo principal da pesquisa.

3.2 Criação do software

3.2.1 Experimentos para criação do software

3.2.1.1 *Experimento 1: Campo*

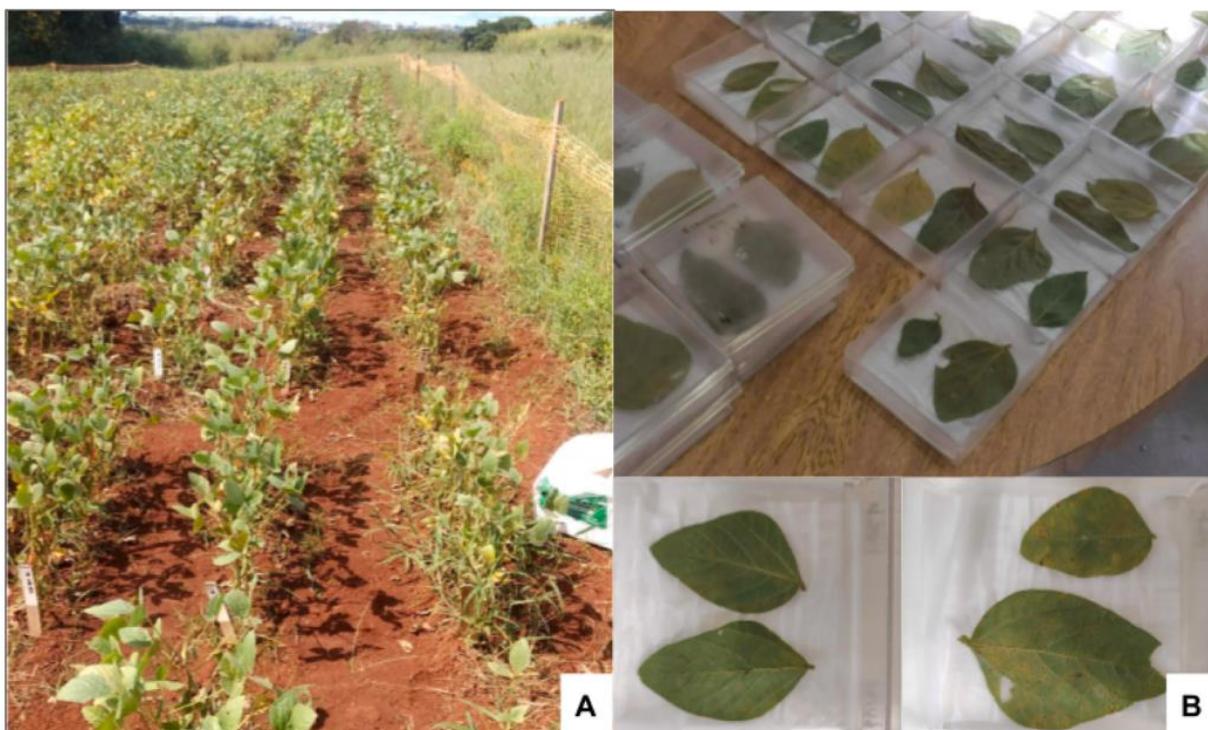
O Experimento 1 foi conduzido na fazenda experimental Capim Branco (18°53'24.5 "S, 48°20'26.9 "W, 835 m altitude), da Universidade Federal de Uberlândia, e constituído por progênies na geração F3 originadas do cruzamento entre as cultivares BMX DESAFIO RR e BRSGO 7560. Adotou-se o delineamento de blocos completos casualizados (DBC), com duas repetições, e cada parcela foi constituída por uma linha de 5 m com plantas de soja, conforme ilustrado na Figura 26A. O solo foi preparado com uma aração e duas gradagens, seguidas da abertura de linhas de semeadura no espaçamento de 50 cm. A semeadura ocorreu de forma manual no dia 14/02/2019.

Realizaram-se os tratos culturais, controle de pragas e doenças, conforme recomendações técnicas para a cultura, exceto para o controle da FAS. Logo, ocorreu

a infecção natural por *Phakopsora pachyrhizi* e folíolos de soja infectados foram amostrados para a captura de imagens.

A captura das imagens foi feita no dia 08/05/2019, de forma que plantas e folíolos foram amostrados de forma aleatória. Um total de 606 imagens da face abaxial dos folíolos de soja foi capturado e 200 imagens foram sorteadas para o processamento. A captura foi feita utilizando um celular do modelo Moto Z Play, posicionado a 20 cm dos folíolos, com especificações: 16MP, F/2.0 Aperture, tamanho do pixel: 1.3 μm . Foi utilizada iluminação fluorescente indireta, 24 bits de cor e resolução de 4000 x 3000 pixels.

Figura 26 - Experimentos para capturas de imagem



A: Experimento 1 em campo; B: Experimento 2 em laboratório.

Fonte: Silva *et al.* (2022).

3.2.1.2 Experimento 2: Folíolos destacados

Este experimento foi instalado na fazenda experimental Glória (18°56'35.6 "S 48°13'00.9 "W, 941 m altitude), na Universidade Federal de Uberlândia, e foi composto pelos cultivares de soja: UFUS 7910, UFUS Xavante, UFUS Guará, UFUS 8301 e

TMG 801. Foi utilizado o delineamento de blocos casualizados com 3 repetições, cada unidade experimental foi composta por 4 linhas de plantas de soja espaçadas 50 cm entre si. O solo foi preparado com uma aração e duas gradagens, seguidas da abertura de linhas de semeadura no espaçamento de 50 cm, com data de semeadura em 01/12/2020. Nesse experimento, os folíolos de soja do terço médio da planta foram amostrados aleatoriamente, embalados em sacos plásticos e levados ao Laboratório de Micologia e Proteção Vegetal (Lamip) da UFU, para realização do experimento de folíolos destacados, conforme ilustrado na Figura 26B.

No Lamip, o experimento com folhas destacadas foi conduzido. Considerando que os folíolos já haviam sido infectados de forma natural no campo, devido à existência de sintomas, dois folíolos foram colocados em cada recipiente de poliestireno com 100% de umidade relativa e iluminação constante. Nesse experimento, 4 a 6 capturas foram feitas em um intervalo de 3 dias, a variação na quantidade de capturas está relacionada com a necrose total do folíolo, que foi considerada como ponto de parada. Foram selecionados 84 folíolos e foram capturadas 798 imagens inicialmente, capturando duas imagens por questão de redundância. Como a finalidade do experimento foi acompanhar a evolução dos sintomas de infecção, parte dos folíolos foi eliminada antes do intervalo de 9 dias, devido à necrose completa.

Ao final do experimento, foram utilizadas 67 imagens, sendo, no mínimo, 3 imagens por folíolo. A captura foi feita utilizando um celular do modelo Moto Z Play, posicionado a 20 cm dos folíolos, com especificações: 16MP, F/2.0 Aperture, tamanho do pixel: 1.3 μm , foi utilizada iluminação fluorescente indireta, 24 bits de cor e resolução de 4000 x 3000 pixels.

3.2.1.3 Experimento 3: Dataset externo

Foi utilizado um *dataset* externo com 50 imagens de folíolos com presença de vários níveis de ferrugem (DEL PONTE, 2020). Para esse experimento, foi utilizada a cultivar NA 5909 RG suscetível à ferrugem, com inoculação artificial feita na casa de vegetação e aquisição da imagem por meio de *scanner* Hewlett Packard modelo 2130 com resolução de 300 *dpi* (FRANCESCHI *et al.*, 2020).

3.2.1.4 Experimento 4: Escala diagramática

Foi utilizado também um *dataset* externo, criado a partir da escala diagramática apresentada por Franceschi *et al.* (2020). A escala apresenta 10 folíolos com níveis diferentes de infecção por ferrugem, variando de 0,2 a 84%, como ilustrado na Figura 8.

3.2.2 Processamento de imagens, análise e cálculo dos índices

A abordagem proposta foi ilustrada na Figura 27 com todas as etapas após a seleção das amostras dos folíolos, a imagem utilizada foi no formato RGB (Figura 27-1). A etapa Figura 27-2 foi executada automaticamente e consistiu na conversão da imagem digital do espaço de cores RGB para CIELab (BORGES *et al.*, 2016; KOSCHAN; ABIDI, 2008), resultando em 3 bandas (L, a e b) que foram utilizadas nas próximas etapas do processo.

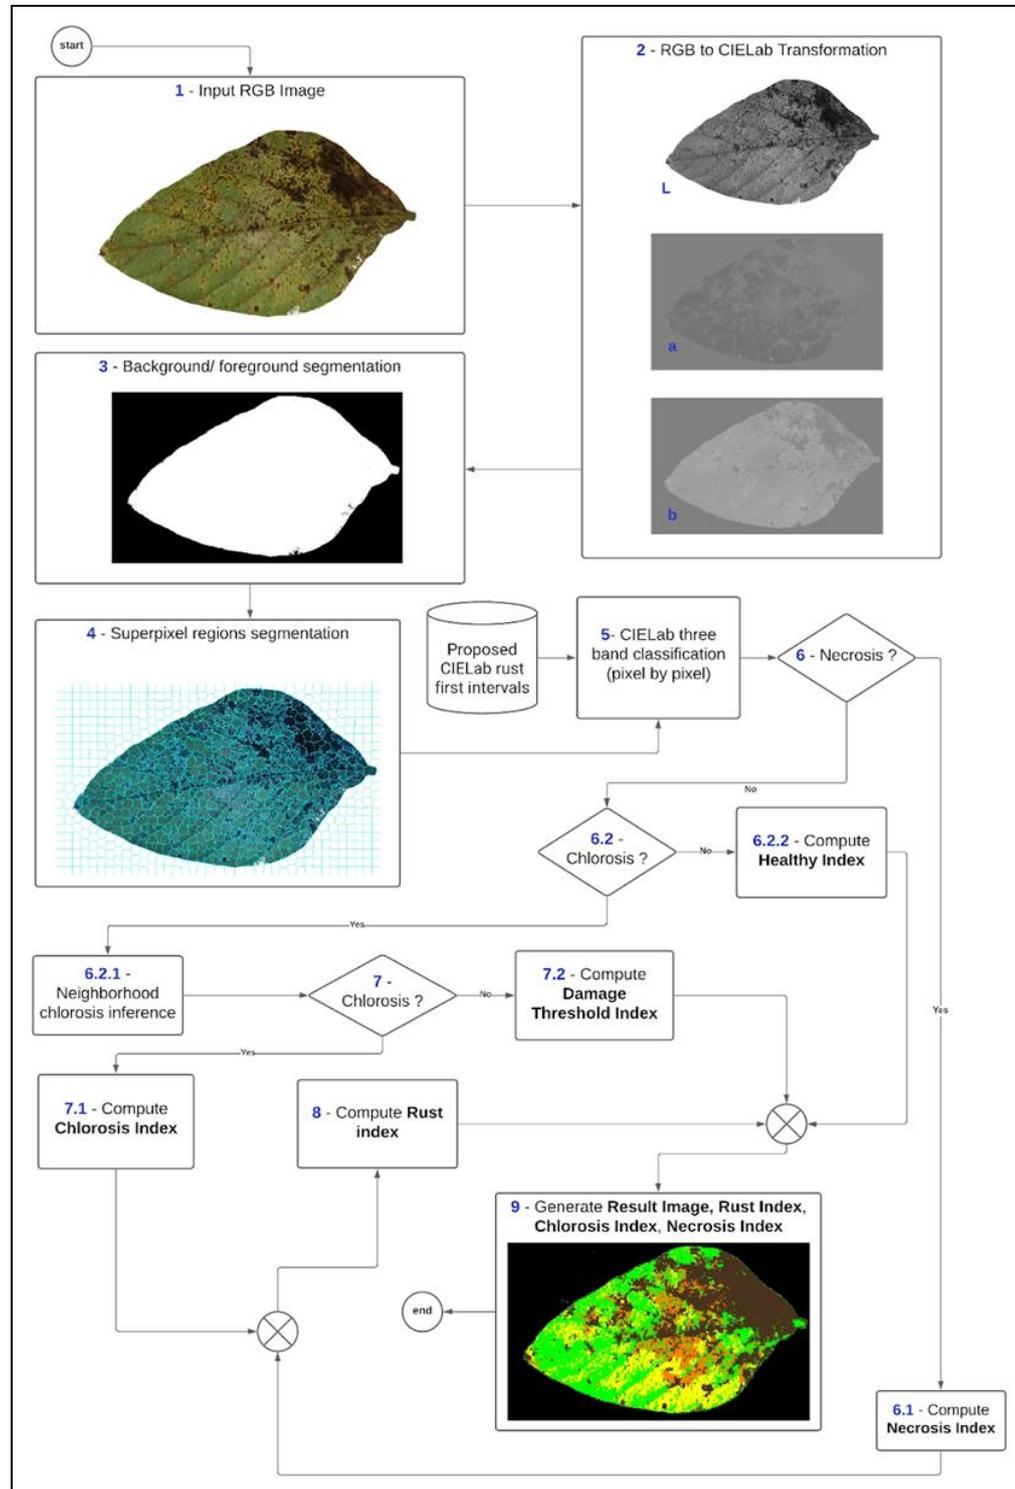
A segmentação do folíolo e separação de fundo, estágio (Figura 27-3), foi realizada usando as bandas CIELab por limiarização de fundo (considerando os intervalos L [0, 100], a [-128, 12], b [0, 127] como primeiro plano), resultando na área do folíolo em pixels (*Leaflet_area*). A imagem resultante passou por uma segunda etapa de segmentação (Figura 27-4), utilizando o algoritmo *Supapixel* (ACHANTA *et al.*, 2012). Para isso, 400 segmentos foram usados para que cada um dos segmentos resultantes representasse regiões maiores e mais visualmente coerentes e significativas dentro do folíolo.

O processo demonstrado na etapa 5 (Figura 27-5) consistiu em uma categorização da imagem pixel a pixel, visando classificar as regiões *supapixel* em clorose ou necrose, dependendo de uma escala inicialmente proposta de primeiros intervalos de ferrugem das bandas CIELab (necrose (L[0, 100], a[-6, 128], b[0, 51]); clorose (L[25, 90], a[-12, 40], b[18, 128])). A definição dos intervalos de filtragem foi feita de forma empírica, utilizando o processo ilustrado na Figura 28.

Começando com uma amostra de imagens de folíolos com diferentes níveis de infecção por ferrugem, as imagens foram divididas com base no algoritmo *supapixel* (ACHANTA *et al.*, 2012), que segmenta as imagens em regiões maiores, agrupando-

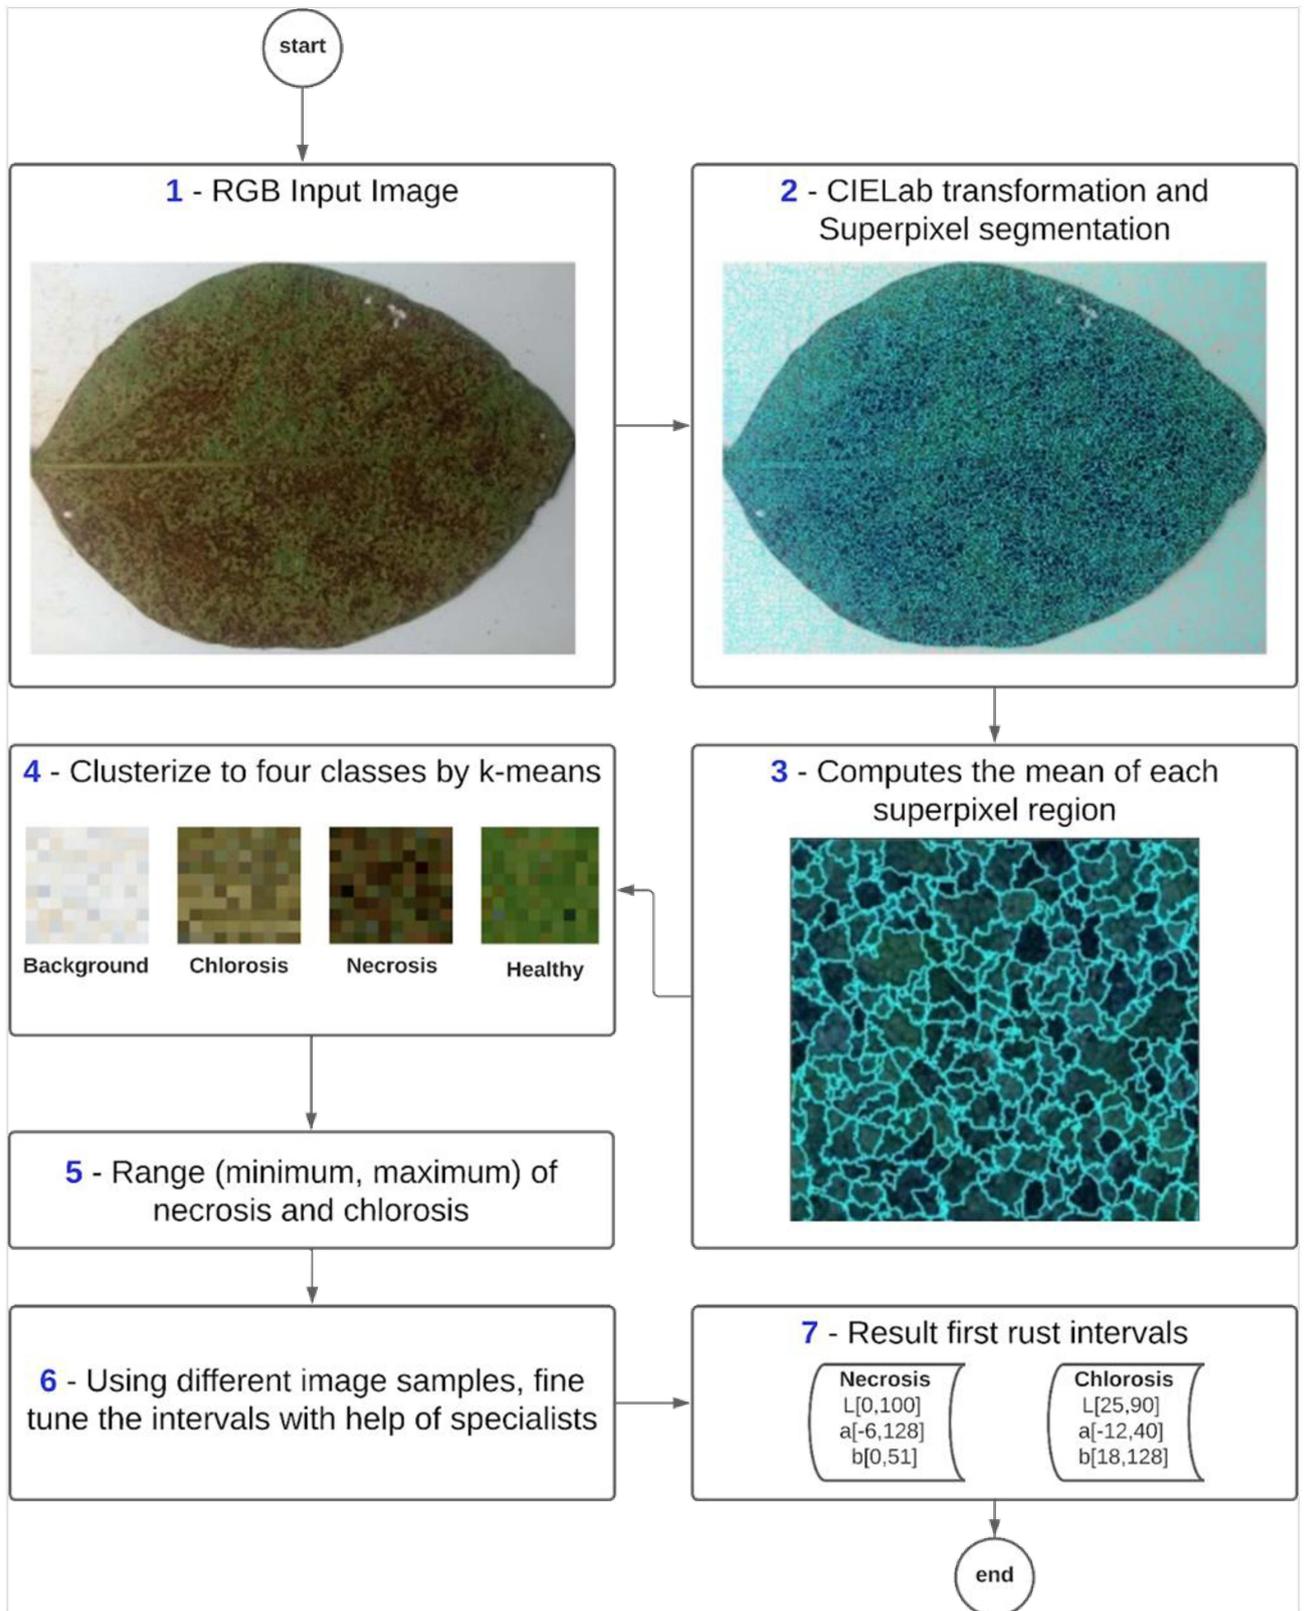
as em regiões semanticamente semelhantes, chamadas de *superpixel*. Nessa etapa, cada imagem produziu cerca de 400 regiões (Figura 28-2).

Figura 27 - Etapas do processamento da imagem



Fonte: Silva *et al.* (2022).

Figura 28 - Método de definição dos intervalos de filtragem



Fonte: Silva *et al.* (2022).

Essas regiões foram agrupadas usando o algoritmo de inteligência artificial *k-means* em 4 classes (Fundo, Clorose, Necrose, Saudável) (Figura 28-4) e o intervalo de valores para cada uma é extraído (Figura 28-5). Esse procedimento foi executado em uma amostra separada de 10 folíolos, então, os intervalos finais são apresentados a um conjunto de especialistas para ajustar os resultados e analisar áreas coerentes de necrose, clorose e saudáveis ou desconhecidas (Figura 28-6), resultando nos intervalos utilizados pelo software na filtragem das cores (Figura 28-7).

Na etapa Figura 27-6, se um pixel estiver contido na primeira faixa de banda classificada como necrose, irá compor o Índice de Necrose (Equação 1). Se um pixel estiver contido em uma faixa de cores classificada como clorose (Figura 27-6.2.1), será utilizada a moda da sua vizinhança para inferir se a clorose representa ou não a infecção por ferrugem. Se a moda calculada estiver no intervalo de necrose, o pixel de clorose será considerado parte do Índice de Clorose (Equação 2) (Figura 27-7.1). Caso contrário, o pixel irá compor o Limiar de Dano (Equação 3) e não fará parte do Índice de Ferrugem (Equação 4). As etapas 8 e 9, ilustradas na Figura 27, representam o cálculo do índice de ferrugem.

Equação 1 - Cálculo do índice de necrose

$$Necrosis_{index} = \frac{Necrosis_{area}}{Leaflet_{area}} \quad (1)$$

Fonte: Silva *et al.* (2022).

Equação 2 - Cálculo do índice de clorose

$$Chlorosis_{index} = \frac{Chlorosis_{area}}{Leaflet_{area}} \quad (2)$$

Fonte: Silva *et al.* (2022).

Equação 3 - Cálculo do limiar de dano

$$DamageThreshold_{index} = \frac{DamageThreshold_{area}}{Leaflet_{area}} \quad (3)$$

Fonte: Silva *et al.* (2022).

Equação 4 - Cálculo do índice de ferrugem

$$Rust_{index} = Necrosis_{index} + Chlorosis_{index} \quad (4)$$

Fonte: Silva *et al.* (2022).

Equação 5 - Cálculo da área saudável

$$Healthy_{index} = 1 - (Rust_{index} + DamageThreshold_{index}) \quad (5)$$

Fonte: Silva *et al.* (2022).

Equação 6 - Cálculo da AACPD

$$AUDPC = \sum_{i=1}^{n-1} \left(\frac{y_i + y_{i+1}}{2} \right) * (t_{i+1} - t_i) \quad (6)$$

Fonte: Silva *et al.* (2022).

Para os experimentos que utilizaram a metodologia de folhas destacadas, foi possível calcular a Área Sob a Curva de Progresso da Doença AACPD (Equação 6), em que “y” corresponde ao Índice de Ferrugem no folheto e t corresponde ao número de dias de avaliação (ALVES *et al.*, 2017).

3.2.3 Protocolo de avaliação dos Experimentos 3 e 4

O Experimento 3 foi desenvolvido para analisar a correlação entre o método proposto e um banco de dados público (DEL PONTE, 2020) de folíolos de soja rotulados com diversos níveis de severidade de infecção por FAS. Nessa base de dados, os autores utilizaram principalmente software Quant-A (DO VALE *et al.*, 2001) para indicar manualmente os valores limiares da infecção. As imagens não foram marcadas pixel a pixel, mas apenas com um rótulo de gravidade da infecção por ferrugem; para comparação, foi realizada uma correlação de Pearson (FREEDMAN;

PISANI; PURVES, 2007) entre as avaliações rotuladas no conjunto de dados e os índices propostos: *Rustindex* e *Rustindex + DamageThresholdindex*.

O Experimento 4 teve como objetivo comparar os resultados do *RustIndex* proposto com um padrão diagramático fornecido por Franceschi *et al.* (2020), também rotulado, mas não marcado pixel por pixel. Neste, também foi calculada uma correlação de Pearson nas 10 imagens fornecidas como padrões para infecção por severidade de FAS, e os índices propostos: *Rustindex* e *Rustindex + DamageThresholdindex*.

3.2.4 Processamento de dados e software utilizados

A manipulação das imagens e os processos de extração de dados foram programados utilizando a linguagem de programação Python v.3.7.7., com as bibliotecas scikit-image v.0.16.2, numpy v.1.18.1, pandas v.1.0.3, opencv-contrib-python v.4.2.0.34, pillow v.7.0.0, sklearn v.1.14.0, seaborn v.0.10.1, scipy v.1.4.1 e keras-preprocessing v.1.1.1. Os testes de correlação e significância foram feitos utilizando a linguagem R v.3.6.1.

3.3 Experimentos para validação do software e criação de método

3.3.1 Experimento 5: Experimento com cultivares padrão de mercado

3.3.1.1 Implantação do Experimento

O experimento foi instalado na estação experimental Juliagro (18°53'47"S, 48°25'00"W, 836m). Para esse experimento, foram utilizadas 3 cultivares de soja TMG7067IPRO, M7739IPRO e ST721IPRO. A cultivar TMG7067IPRO representou o padrão de resistência à FAS, as cultivares M7739IPRO e ST721IPRO são suscetíveis à FAZ. Além disso, é importante ressaltar que, entre os critérios de escolhas das cultivares, o grupo de maturidade relativa foi considerado, de forma que foi possível realizar o plantio e a colheita de todas as parcelas na mesma data. O delineamento

utilizado foi o Delineamento Inteiramente Casualizado (DIC), o solo foi gradeado e arado.

O experimento foi composto por 4 épocas de semeadura: 20/11/2020 para a época 1, 18/12/2020 para a época 2, 20/01/2021 para a época 3 e 19/02/2021 para a época 4. Em cada época, foram semeadas 8 linhas de 20 metros de cada linhagem, que foram divididas em 4 linhas de 5 metros, cada conjunto de 4 linhas de 5 metros representou uma repetição. Foram semeadas 4 repetições de cada variedade com aplicação de fungicida e 4 repetições de cada variedade sem aplicação de fungicida, totalizando 24 parcelas por época.

As Figuras 29, 30, 31 e 32 ilustram etapas da Época 1, que foram desde a semeadura até a colheita. É importante observar que foi feita a preparação do solo, mantendo o ambiente homogêneo para a semeadura. Toda a semeadura foi feita utilizando semeadora de 8 linhas, conforme ilustrado na Figura 29.

Figura 29 - Preparação do solo



Fonte: Autoria própria.

Figura 30 - Semeadura 21/11/2020



Fonte: Autoria própria.

Figura 31 - Captura da Época 1, no dia 21/12/2020



Fonte: Autoria própria.

Figura 32 - Captura da Época 1, no dia 18/02/2021



Fonte: Autoria própria.

Figura 33 - Colheita Época 1



Fonte: Autoria própria.

3.3.1.2 Controle químico para doenças e pragas

Para a semeadura, foram utilizadas sementes tratadas com o controle químico descrito no Quadro 1. Após a semeadura, foram feitas 3 aplicações de fungicida e 3 aplicações de inseticidas por época, conforme descrito nos Quadros 2 e 3. A aplicação de fungicida foi feita somente para os tratamentos previstos, considerando que a aplicação de fungicida foi um fator analisado.

Quadro 1 - Tratamento de sementes

Cultivar	Tratamento e dose para 100 Kg de Sementes
TMG7067IPRO	Fipronil 100ml + Tiometoxam 200ml + 0,20g Metalaxil-M + 0,15g Tiabendazol + 0,25g Fludioxonil + DISCO AG L-630 150ml
M7739IPRO	Tiometoxam 200ml + 0,20g Metalaxil-M + 0,15g Tiabendazol + 0,25g Fludioxonil + 0,3g Ciantraniliprole
ST721IPRO	0,6g Carboxina + 0,6g Tiram + Tiometoxam 200ml

Fonte: Autoria própria.

Quadro 2 - Aplicação de fungicidas

Época	Data	Dias*	Princípio ativo e dose por hectare
1	04/01/2021	45	mancozebe 1,5 kg
1	19/01/2021	60	50 g bixafem + 70 g protioconazol + 60 g trifloxistrobina
1	03/02/2021	75	1012,5 g Mancozebe + 67,5 g Azoxistrobina + 45 g Ciproconazol + 700 g Fenpropimorfe
2	01/02/2021	45	mancozebe 1,5k g
2	16/02/2021	60	50 g bixafem + 70 g protioconazol + 60 g trifloxistrobina
2	03/03/2021	75	1012,5 g Mancozebe + 67,5 g Azoxistrobina + 45 g Ciproconazol + 700 g Fenpropimorfe
3	06/03/2021	45	mancozebe 1,5kg
3	21/03/2021	60	50 g bixafem + 70 g protioconazol + 60 g trifloxistrobina
3	05/04/2021	75	1012,5 g Mancozebe + 67,5 g Azoxistrobina + 45 g Ciproconazol + 700 g Fenpropimorfe
4	05/04/2021	45	mancozebe 1,5kg
4	20/04/2021	60	50 g bixafem + 70 g protioconazol + 60 g trifloxistrobina
4	05/05/2021	75	1012,5 g Mancozebe + 67,5 g Azoxistrobina + 45 g Ciproconazol + 700 g Fenpropimorfe

* Quantidade de dias a partir da data de semeadura.

Fonte: Autoria própria.

Quadro 3 - Aplicação de inseticida

Época	Data	Dias*	Princípio ativo e dose por hectare
1	29/01/2021	70	86 g metomil
1	05/02/2021	77	1164 g acefato + 210 g imidacloprido
1	12/02/2021	84	75 g acetamiprido + 75 g bifentrina
2	26/02/2021	70	86 g metomil
2	05/03/2021	77	1164 g acefato + 210 g imidacloprido
2	12/03/2021	84	75 g acetamiprido + 75 g bifentrina
3	11/03/2021	50	86 g metomil
3	26/03/2021	65	1164 g acefato + 210 g imidacloprido
3	10/04/2021	80	75 g acetamiprido + 75 g bifentrina
4	10/04/2021	50	86 g metomil
4	25/04/2021	65	1164 g acefato + 210 g imidacloprido
4	10/05/2021	80	75 g acetamiprido + 75 g bifentrina

* Quantidade de dias a partir da data de semeadura.

Fonte: Autoria própria.

3.3.1.3 Captura das imagens

Para cada parcela, foram feitas 4 capturas em intervalos de 15 dias, a partir da identificação de folíolos com sintomas iniciais de infecção por FAS. Em cada dia de captura, foram amostrados 5 folíolos do terço médio e 5 folíolos do terço superior de plantas diferentes escolhidas aleatoriamente dentro da parcela, conforme ilustrado na Figura 34. A captura foi feita utilizando o dispositivo Xiaomi Mi 9t lite, posicionado a 20 cm dos folíolos, com especificações: *Aperture: f/1,79*, tamanho do sensor: 1/30 4,74 mm, 12 MP, tamanho do pixel: 0.8 μ m, foi utilizada iluminação fluorescente indireta, 24 bits de cor e resolução de 4000 x 3000 pixels.

Figura 34 - Exemplo de imagem capturada



Fonte: Autoria própria.

3.3.1.4 Colheita, produtividade e peso de 100 sementes

A colheita do experimento foi feita de forma manual e a trilhagem foi feita utilizando uma trilhadeira. Após a trilhagem da parcela, os grãos foram pesados em balança digital e foram amostrados e pesados 100 grãos em balança digital com precisão de 0,1 g.

3.3.1.5 Segmentação das imagens

Para reduzir a quantidade de capturas necessárias, foram adicionados até 5 folíolos por imagem e um identificador da parcela que os folíolos pertenciam. Como a quantificação de sintomas pelo *software* proposto é feita utilizando 1 folíolo por imagem, foi inserida a etapa de segmentação dos objetos no processo de análise das imagens, visando transformar uma imagem com 5 folíolos em 5 imagens com apenas um folíolo. Para isso, foi feito o treinamento de uma rede do tipo Yolov5 (JOCHER *et al.*, 2022) para identificação dos folíolos e dos identificadores das parcelas.

Para o treinamento, foram rotuladas 237 imagens, semelhantes à Figura 34, identificando os elementos da classe *leaflets* e os elementos da classe *label*. As imagens foram divididas em três grupos: *train*, *test* e *valid*, sendo utilizados para as etapas de treinamento, teste e validação, respectivamente.

Os hiper parâmetros utilizados para o treinamento foram: taxa de aprendizado = 0.01, *momentum* = 0.937, *weight-decay* = 0.0005, *warmup-epochs* = 3.0, *warmup-momentum* = 0.8, *warmup-bias_lr* = 0.1, *batch-size* = 30, épocas = 200. A configuração de *hardware* utilizada para o treinamento foi NVIDIA GeForce RTX 3060 Laptop GPU 6144MiB, processador 11th Gen Intel(R) Core (TM) i7-11800H @ 2.30GHz, 32 Gb memória.

3.3.1.6 Análise das imagens

O processo de análise das imagens foi feito utilizando o método proposto na Figura 27. Os folíolos segmentados pela RNA treinada foram organizados em pastas para cada data de captura e parcela, a execução foi feita utilizando código próprio.

3.3.1.7 Análise dos dados

O principal objetivo desse experimento foi responder questões sobre a execução do método proposto, formas de captura das imagens, posição da planta que o folíolo deverá ser removido e face do folíolo que deverá ser analisado. Para isso, foi feita uma análise de variância em esquema fatorial. Além disso, foi feita a correlação

entre AACPD, produtividade e peso de 100 sementes para verificar a existência de correlação linear entre fatores. A verificação dessa correlação foi feita utilizando a correlação de Pearson para cada tratamento separadamente, utilizando os dados de todas as épocas, ou seja, 6 análises de correlação com 12 amostras, considerando as 3 épocas de semeadura em que foi possível calcular a AACPD.

3.3.1.7.1 Análise da produtividade em relação à fungicida e cultivar

O experimento 5 foi feito em Delineamento Inteiramente Casualizado (DIC) e a análise foi feita utilizando o modelo fatorial duplo (FERREIRA, 2018b):

$$Y_{ij} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \epsilon_{ij}, \text{ em que:}$$

- μ corresponde à média geral do experimento;
- α_i corresponde ao efeito do i-ésimo nível do fator 1;
- β_j corresponde ao efeito do j-ésimo nível do fator 2;
- γ_{ij} corresponde ao efeito da interação entre os fatores;
- ϵ_{ij} corresponde ao erro aleatório.

A verificação dos pressupostos do experimento foi feita utilizando o teste de Shapiro-Wilk (SHAPIRO; WILK, 1965) para a normalidade dos resíduos e os testes de Bartlett (ARSHAM; LOVRIC, 2011) e Levene (BROWN; FORSYTH, 1974) para a homogeneidade das variâncias.

3.3.1.7.2 Efeito de fungicida, face e terço na AACPD

Com esta análise, tem-se o objetivo de verificar o efeito da face (abaxial ou adaxial), do terço (médio ou superior) e do fungicida na severidade da infecção representada pela variável resposta AACPD. O experimento utilizou Delineamento Inteiramente Casualizados (DIC) (FERREIRA, 2018b) e a análise foi feita utilizando o esquema fatorial triplo, tendo como fatores fungicida (sim ou não), face (abaxial ou adaxial) e terço (médio ou superior) com o seguinte modelo estatístico:

$Y_{ijk} = \mu + \alpha_i + \beta_j + \delta_k + \gamma_{ij} + \theta_{ik} + \vartheta_{jk} + \epsilon_{ijk}$, em que:

- μ corresponde à média geral do experimento;
- α_i corresponde ao efeito do i-ésimo nível do fator 1;
- β_j corresponde ao efeito do j-ésimo nível do fator 2;
- γ_{ij} corresponde ao efeito da interação entre os fatores 1 e 2;
- θ_{ik} corresponde ao efeito da interação entre os fatores 1 e 3;
- ϑ_{jk} corresponde ao efeito da interação entre os fatores 2 e 3;
- ϵ_{ijk} corresponde ao erro aleatório.

A verificação dos pressupostos do experimento foi feita utilizando o teste de Shapiro-Wilk (SHAPIRO; WILK, 1965) para a normalidade dos resíduos e os testes de Bartlett (ARSHAM; LOVRIC, 2011) e Levene (BROWN; FORSYTH, 1974) para a homogeneidade das variâncias.

3.3.2 Experimento 6: Aplicação do *software* na caracterização de progênies de soja quanto à FAS

O experimento 6 foi instalado na fazenda experimental Capim Branco (18°53'24.5 "S, 48°20'26.9 "W, 835 m altitude). Foram utilizadas progênies F2:6 de duas populações diferentes do programa de melhoramento de soja da Universidade Federal de Uberlândia. A população 1 consiste em um cruzamento UFUS6901 x TMG 801 e a população 2 de um cruzamento UFUS6901 x BRSGO 7560. O delineamento experimental foi do tipo Látice Tríplo 8x8 (GOMES; GARCIA, 1991), com 64 tratamentos de 2 linhas de 5 m com espaçamento de 0,5 m entre linhas e 3 repetições, totalizando 192 parcelas. O solo foi preparado com uma aração e duas gradagens, seguidas da abertura de linhas de semeadura no espaçamento de 50 cm. O experimento foi semeado no dia 03/12/2022.

3.3.2.1 Controle químico e aplicações de micronutrientes

Durante o experimento, foram feitas aplicações de micronutrientes, herbicidas, inseticidas e fungicida. As informações sobre o controle químico aplicado, bem como o período de aplicação, estão representadas no Quadro 4.

Quadro 4 - Aplicações realizadas no experimento

Data aplicação	Princípio ativo e dose por hectare
03/12/2021	1440g s-metolaclo-ro
23/12/2021	12g molibdenio e 2g cobalto
03/01/2022	488,16 g clorpirifós
Estádio R1	81g piraclostrobina + 50g fluxapirroxade + 50g epoxiconazol + 1500g mancozeb
30 dias após a aplicação anterior	50g bixafem + 70g protioconazol + 60g trifloxistrobina + 1500g mancozeb
Estádio R5	750g acefato 21,15g tiametoxam + 15,9 lambda-cialotrina
Estádio R7	750g acefato 21,15g tiametoxam + 15,9 lambda-cialotrina

Fonte: Autoria própria.

3.3.2.2 Captura das imagens

Para esse experimento, foram selecionadas 128 parcelas e, para cada parcela, fez-se 3 dias captura (05/02/2022, 20/02/2022 e 12/03/2022). Para cada parcela, foram sorteados 4 folíolos do terço médio de forma aleatória, em plantas diferentes. Então, foi feita uma captura de imagem dos 4 folíolos nas faces abaxial e adaxial. A captura foi feita utilizando o dispositivo Xiaomi Mi 9t lite, posicionado a 20 cm dos folíolos, com especificações: *Aperture: f/1,79*, tamanho do sensor: 1/30 4,74 mm, 12 MP, tamanho do pixel: 0.8µm, foi utilizada iluminação fluorescente indireta, 24 bits de cor e resolução de 4000 x 3000 pixels.

3.3.2.3 Análise das imagens

A análise das imagens foi iniciada com o processo de segmentação, conforme descrito na seção 3.3.1.5, e a quantificação dos sintomas foi feita conforme análise descrita na seção 3.3.1.6.

3.3.2.4 Análise dos dados

Foram analisadas 128 parcelas do experimento, totalizando 8 blocos com 16 parcelas cada, caracterizando blocos incompletos parcialmente balanceados (BOSE; NAIR, 1939), utilizando o seguinte modelo estatístico (SILVA; FERREIRA; PACHECO, 2000):

$$y_{il(j)} = \mu + t_i + r_j + \left(\frac{b}{r}\right)_{l(j)} + \epsilon_{il(j)}$$

Em que:

- $y_{il(j)}$ consiste no valor observado do tratamento (i), no bloco incompleto (l) na repetição j;
- μ é uma constante inerente a todas as observações;
- t_i é o efeito do tratamento i;
- r_j é o efeito da repetição j;
- $\left(\frac{b}{r}\right)_{l(j)}$ é o efeito do bloco incompleto l dentro da repetição j;
- $\epsilon_{il(j)}$ é o erro aleatório assoado à observação $y_{il(j)}$.

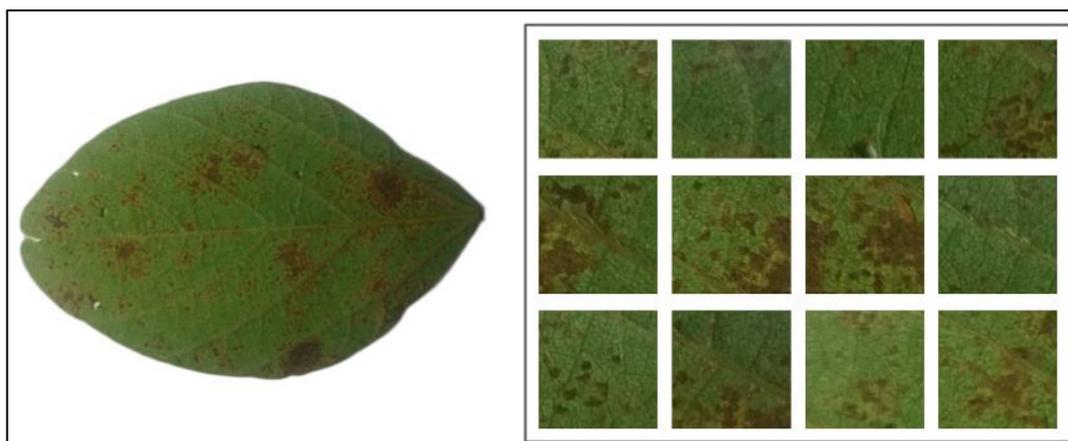
3.4 Experimentos para sistema com múltiplos patógenos e Redes Neurais Convolucionais

Até aqui, foi apresentado e validado um algoritmo para a quantificação de sintomas da Ferrugem Asiática da Soja (FAS), bem como um método para o processo de captura das imagens. Ainda que sejam utilizados meios de reduzir a quantidade de patógenos durante o processo de melhoramento, existe a possibilidade de infecção

por múltiplos patógenos. Assim, como proposta adicional, foram feitos experimentos para classificar regiões de folíolos com sintomas causados por ferrugem, oídio e olho-de-rã, e regiões que não apresentam sintomas. Para a classificação, foram treinadas 3 Redes Neurais Convolucionais (RNC): *alexnet* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), *densenet* (HUANG *et al.*, 2017) e *resnet18* (HE *et al.*, 2016).

Para os experimentos, foram selecionadas 114 imagens de folíolos com sintomas de ferrugem, 55 imagens de folíolos com sintomas causados por oídio, 88 imagens de folíolos com sintomas causados por olho-de-rã e 77 imagens de folíolos saudáveis. Cada imagem foi dividida em segmentos de 200x200 pixels e apenas as regiões com sintomas das doenças de interesse foram selecionadas, conforme ilustrado na Figura 35.

Figura 35 - Exemplo de divisão de imagem



Fonte: Autoria própria.

Para descrever as métricas analisadas a partir do treinamento, é interessante definir os conceitos de Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). O VP consiste nos resultados que deveriam ser positivos e foram classificados como positivos, VN são os resultados que deveriam ser negativos e foram classificados como negativos, FP são os resultados que deveriam ser negativos e foram classificados como positivos e FN são os resultados que deveriam ser positivos e foram classificados como negativos (GONÇALVES *et al.*, 2021).

A partir dos índices VP, VN, FP e FN, é possível calcular a acurácia do modelo, que consiste na quantidade de acertos divididos pela quantidade total de análises, que se diferencia da precisão, que visa verificar qual o índice de classificações positivas foram corretas (SKANSI, 2018a). O índice de revogação consiste em analisar, dentro das que deveriam ser consideradas como positivas, quais foram consideradas corretamente (GONÇALVES *et al.*, 2021). E tem-se o f1-score, que consiste na média harmônica entre os índices de precisão e revogação. O cálculo dessas métricas segue as equações (GONÇALVES *et al.*, 2021; SKANSI, 2018a; SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006):

$$acuracia = \frac{VP + VN}{VP + VN + FP + FN}$$

$$precisao = \frac{VP}{VP + FP}$$

$$revogação = \frac{VP}{VP + FN}$$

$$f1score = \frac{2 * (precisao * recall)}{(precisao + recall)}$$

Para a análise de dados, foi utilizado o Delineamento de Blocos Casualizados (DBC) (FERREIRA, 2018a), considerando as classes como blocos e as arquiteturas analisadas como tratamentos, tendo como variável resposta a precisão. O DBC segue o modelo estatístico:

$$Y_{ij} = \mu + t_i + b_j + \epsilon_{ij}, \text{ em que:}$$

- Y_{ij} é o valor observado para a variável;
- μ é a média dos tratamentos;
- t_i é o efeito do tratamento i no valor observado Y_{ij} ;
- b_j é o efeito devido ao j -ésimo bloco na parcela experimental;
- ϵ_{ij} é o erro experimental associado ao valor observado Y_{ij} .

A verificação dos pressupostos do experimento foi feita utilizando o teste de Shapiro-Wilk (SHAPIRO; WILK, 1965) para a normalidade dos resíduos e os testes

de Bartlett (ARSHAM; LOVRIC, 2011) e Levene (BROWN; FORSYTH, 1974) para a homogeneidade das variâncias.

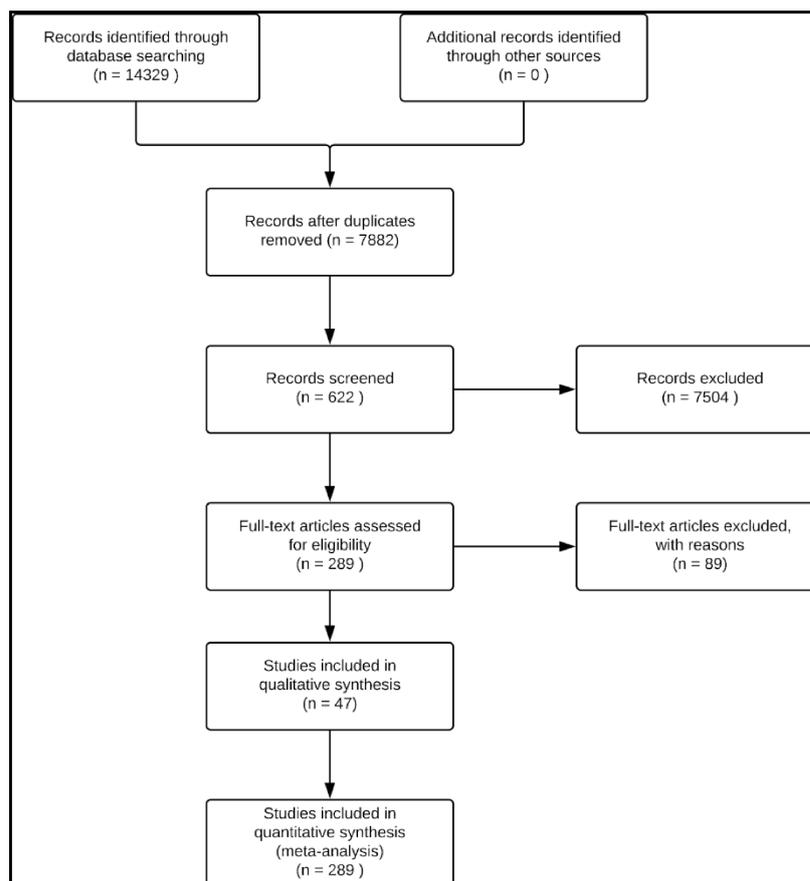
A construção do *software* utilizou as bibliotecas python-3.9.7, pytorch-1.10.0, torchvision-0.11.1, matplotlib-3.4.3, scikit-learn-1.0.1 e bibliotecas indiretamente necessárias para a execução das supracitadas. Os hiper parâmetros utilizados para o treinamento foram: taxa de aprendizado = 0.001, *momentum* = 0.9, batch-size = 4, épocas = 40. A configuração de *hardware* utilizada para o treinamento foi NVIDIA GeForce RTX 3060 Laptop GPU 6144 MiB, processador 11th Gen Intel(R) Core (TM) i7-11800H @ 2.30GHz, 32 Gb memória.

4 RESULTADOS E DISCUSSÃO

4.1 Resultados quantitativos da pesquisa sistemática

A pesquisa quantitativa de periódicos científicos que tiveram publicação envolvendo o uso de IA, processamento de imagens no melhoramento e manejo de plantas resultou na identificação de 2030 periódicos candidatos em Ciências Agrárias e 1948 em Ciência Biológicas, quando adotou-se como critério inicial a classificação de periódicos. Posteriormente, ao excluir as repetições e com a análise dos títulos dos periódicos, foi possível listar 20 periódicos que englobaram 622 artigos científicos. O resultado da pesquisa está resumido no diagrama de fluxo PRISMA, na Figura 36.

Figura 36 - Diagrama PRISMA com resultado da pesquisa

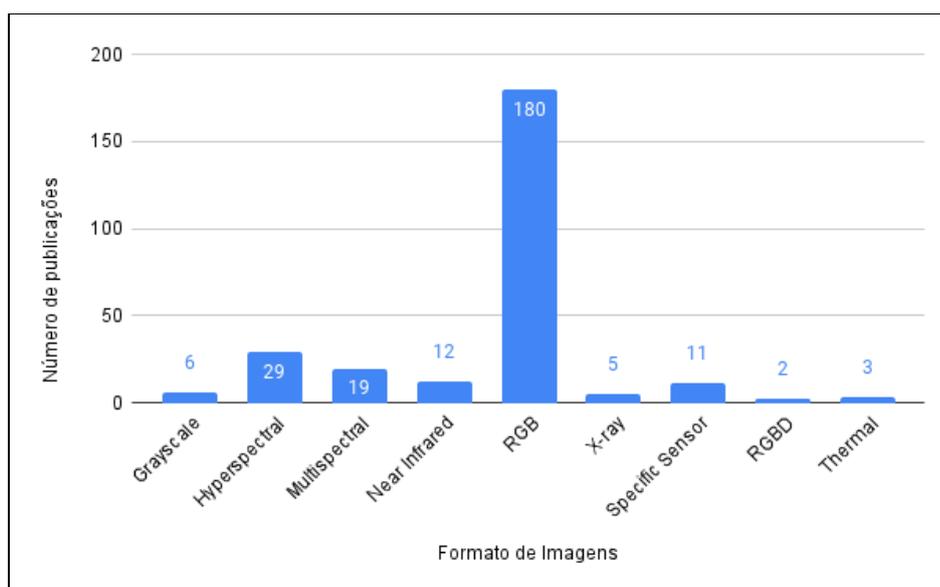


Fonte: Autoria própria.

Pela análise dos 289 artigos científicos, foram analisadas 67 diferentes culturas relacionadas a trabalhos que utilizaram IA e processamento de imagem para o melhoramento genético e técnicas de manejo. Foram identificados seis formatos de imagem principais utilizados nas publicações: tons de cinza, hiperespectral, multiespectral, infravermelho próximo (NIR), raio-X e RGB (Figura 37). Além desses formatos, alguns estudos apresentaram formatos capturados por sensores específicos, em uma frequência que não se enquadra em nenhum dos outros grupos.

Observou-se predominância no uso de imagens do tipo RGB (Figura 37), que, possivelmente, tenha sido adotado preferencialmente pelos pesquisadores, pelo menor custo de aquisição. O formato de captura é outro ponto interessante a ser apresentado, uma vez que formatos popularizados, como o RGB, permitem variadas formas de extração, como câmeras profissionais, câmeras de smartphones, câmeras acopladas a Veículos Aéreos Não Tripulados (VANT) (YANG *et al.*, 2017), satélites (ASHOURLOO *et al.*, 2020) e scanners. Imagens multiespectrais (YANG *et al.*, 2020b), Hiperespectrais (YOOSEFZADEH-NAJAFABADI *et al.*, 2021) e radiográficas (LIU *et al.*, 2020) necessitam de equipamentos especializados, tornando o custo de aquisição superior aos demais tipos.

Figura 37 - Número de artigos científicos publicados e formatos de imagens utilizados



Fonte: Autoria própria.

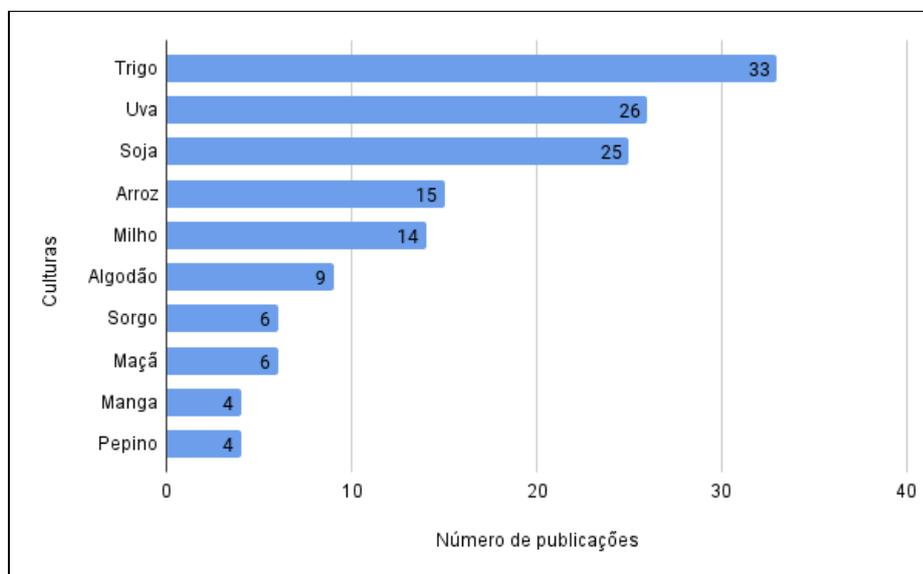
Certas abordagens utilizaram a geração do modelo 3D após a aquisição da imagem, como a apresentada por Zhou *et al.* (2019), em que foi criado o modelo 3D a partir da combinação de duas ou mais imagens, permitindo a fenotipagem da soja. Ainda é possível gerar um modelo 3D a partir de um scanner específico, conforme apresentado por Mack *et al.* (2018), que utilizaram o scanner *Artec 3D Spider* para gerar uma nuvem de pontos a partir de um laser e, então, reconstruir a estrutura dos cachos de uva, fazendo avaliações como tamanho do fruto, quantidade de fruto por cacho e análise de textura. Os conceitos de criação de modelos 3D das plantas a partir de imagens podem ser aplicados na avaliação da arquitetura das plantas de soja e auxiliando na previsão de produtividade.

Conforme ilustrado na Figura 38, as culturas mais estudadas foram uva, trigo, milho, soja, arroz, maçã, algodão, manga, pepino e frutas cítricas; com um total de 142 estudos de uso de imagens para melhoramento genético e manejo integrado. Dentre as publicações analisadas, pode-se destacar trabalhos que utilizaram a cultura como meio para otimizar algoritmos de processamento de imagens (cultura como meio) ou trabalhos que utilizaram algoritmos e imagens aplicados ao melhoramento genético e manejo das culturas de interesse (cultura como fim). Ambas as aplicações são especialmente importantes, mas quando a pesquisa utiliza a cultura como meio, significa que o método é enfatizado e, em vários casos, a solução pode ser adaptada e aplicada a outras culturas, como a soja. Dessa forma, esses estudos foram adicionados aos resultados. O trigo foi a cultura com maior número de pesquisas encontradas, cujos estudos estão relacionados à classificação de grãos (OLGUN *et al.*, 2016), diagnóstico por imagem (JOHANNES *et al.*, 2017) e extração de características.

É importante ressaltar que existem estudos que utilizam a mesma tecnologia tanto para a cultura da soja quanto para o trigo, como os apresentados por Bai *et al.* (2016) e Liu *et al.* (2020). A videira também tem um papel importante no uso e evolução da tecnologia (Figura 38), os trabalhos se destacam no uso de algoritmos para estimar o tamanho do cacho a partir de imagens no formato RGB, maturidade fenológica (viabilidade de sementes) a partir de fotos de sementes (ROSCHER *et al.*,

2014), identificação de brotos sob condições específicas (PÉREZ; BROMBERG; DIAZ, 2017) e estimativa de produtividade (AQUINO *et al.*, 2018; LIU *et al.*, 2017).

Figura 38 - Número de artigos científicos para as 10 principais culturas



Fonte: Autoria própria.

4.2 Resultados qualitativos pesquisa sistemática

Pela análise dos artigos selecionados na revisão sistemática, foi possível constatar que as pesquisas estão relacionadas a IA e processamento de imagens, visando aumento na produtividade, melhorias no manejo. Para que as técnicas propostas consigam ser aplicadas de forma comercial, se faz necessário que os custos de sua aplicação sejam condizentes com os ganhos fornecidos por ela. Por isso, é interessante que as propostas utilizem recursos de baixo custo, como smartphones e câmeras de baixo custo, ou que a relação custo-benefício seja favorável em sua aplicação. A combinação de recursos de baixo custo com técnicas de Inteligência Artificial e Processamento de Imagem pode aprimorar os processos supracitados.

Alexander Johannes *et al.* (2017) apresentaram uma abordagem para a detecção de sintomas de doenças em estágios iniciais no trigo, utilizando imagens de *smartphones* para a detecção de septoriose, ferrugem e mancha marrom. Para

identificar as características das doenças alvo, foi necessário segmentar a área foliar, o que foi feito utilizando o algoritmo *Simple Linear Iterative Clustering (SLIC)*. As características foram identificadas no espaço de cores CIELAB, utilizando *Local Binary Patterns*, variância de cores e a média de cores no canal de cores “b”. A identificação e quantificação de doenças podem ser utilizadas tanto na aplicação de defensivos, quanto na identificação de indivíduos promissores no processo de melhoramento genético.

No melhoramento genético de plantas, um dos caracteres estudados é a seleção dos grãos, seja pela composição ou características morfológicas, permitindo definir os melhores genótipos para a característica de interesse, como quantidade de óleo, proteína ou massa. Murat Olgun *et al.* (2016) elaboraram uma abordagem na qual utilizam imagens no formato *RGB* e o algoritmo *Dense Scale Invariant Features (DSIFT)*, que se baseia nos conceitos de vizinhança do algoritmo de IA (*k-means*) para realizar a classificação de grãos de trigo, conseguindo um índice de precisão de 88,33%.

Com o foco no manejo de plantas no campo, um ponto a ser analisado é a taxa de emergência, que consiste no número de plantas que emergem do solo em relação às semeadas. Sankaran, Khot e Carter (2015) apresentaram uma abordagem na qual são utilizadas imagens aéreas multiespectrais para analisar a taxa de emergência do trigo. Um ponto relevante nesse trabalho é o uso de uma imagem multiespectral, que utiliza o canal *Near Infrared (NIR)* além das bandas *RGB*, e, com isso, se torna possível trabalhar com o *green normalized difference vegetation index (GNDVI)* para realizar a segmentação da imagem, ou seja, retirar os ruídos e manter apenas as partes que são de interesse para a pesquisa.

O uso de imagens multiespectrais não se limita ao cálculo do *GNDVI*. Juliatti *et al.* (2020) apresentaram um estudo sobre a análise de fungicidas em cana-de-açúcar, no qual foram utilizadas imagens multiespectrais, capturadas por drones, para avaliação da transpiração da planta, carbono acumulado, índice de vegetação e área foliar verde, calculada a partir do *Green leaf index (GLI)*. Existem vários índices para a extração de características, cada um deles utiliza um conjunto de comprimentos de onda e uma razão entre os valores das bandas extraídas, como o *Soil Adjusted Vegetation Index (SAVI)*, que é utilizado para ajustar o *NDVI* utilizando os efeitos do

solo e o *Triangular Vegetation Index* (TVI) (BROGE; LEBLANC, 2001), podendo este ser utilizado para estimar a área verde da planta (HUNT *et al.*, 2013). A análise dos índices vegetativos pode ser utilizada na quantificação de características no melhoramento genético.

Quando se trabalha com espectros fora do *RGB*, a partir de imagens multiespectrais e hiperespectrais, é possível criar sensores específicos para os espectros de interesse, bem como criação de equipamentos para a captura dos dados, como a abordagem apresentada por Geng Bai *et al.* (2016), em que um equipamento e um *software* foram criados para extrair os dados fenotípicos a partir de câmeras *RGB* e sensores infravermelho, com o objetivo de calcular o índice *Normalized Difference Vegetation Index* (NDVI) para medir a biomassa da plantação.

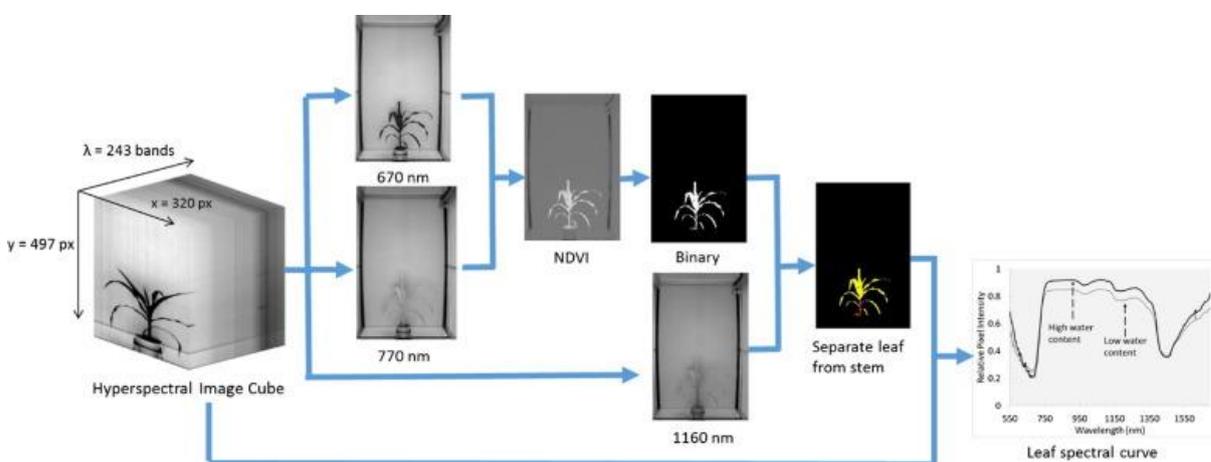
A caracterização de cultivares é uma demanda dos projetos de pesquisa, o método proposto por Charytanowicz *et al.* (2018) permitiu realizar a identificação de cultivares de trigo a partir da análise de imagens de Raio X dos respectivos grãos. Após a aquisição das imagens, elas foram processadas com o uso de *software* e analisadas utilizando o método de análise estatística multivariada Análise dos Componentes Principais (ACP) (SANTOS *et al.*, 2019).

Novas formas de identificação de cultivares são muito importantes para as grandes culturas, como o milho, soja e trigo, que necessitam aumentar a produtividade a cada dia. Na abordagem apresentada por Lu *et al.* (2015), características como quantidade, granulação, largura, perímetro e diâmetro dos pendões do milho são identificadas por um sistema de câmeras em ambiente aberto. Um dos desafios desse tipo de abordagem está relacionado com a tarefa de segmentação da imagem, que pode ser influenciada pela diferença de luminosidade, distância do objeto e diversos outros tipos de ruídos, pois o ambiente não é controlado. Sistemas de lasers podem auxiliar em ambientes com ruídos, como no trabalho apresentado por Qiu *et al.* (2019), em que um sensor do tipo *Light Detection And Ranging* (LiDAR) foi usado para extrair o espaçamento entre linhas e a altura da planta, usando histogramas de banda de profundidade e densidade de ponto horizontal.

A aferição do teor de água nas folhas e nas sementes tem importância para a agricultura. Nas sementes, o teor de água está relacionado à qualidade de armazenamento (SARMENTO *et al.*, 2015) e época de colheita; na folha, pode estar

relacionado com a eficiência do cultivar no consumo de água. Uma das formas de identificar o teor de água se dá pelo uso de imagens hiperespectrais, como é apresentado por Bai *et al.* (2016), que utilizaram uma combinação de diversos comprimentos de onda para gerar a curva espectral de uma planta, permitindo estimar o teor de água, como é apresentado na Figura 39. Nela, são combinados os comprimentos de onda 670 nm e 770 nm para gerar o NDVI e realizar o processo de segmentação da imagem. Após esse processo, a banda 131 (1160 nm) é combinada para gerar a curva de espectro e estimar o teor de água.

Figura 39 - Criação da curva espectral



Fonte: Bai *et al.* (2016).

Como parte das plantações utiliza como fonte principal de irrigação as águas pluviais, longos períodos de escassez podem causar estresse hídrico, prejudicando uma safra gravemente. A resistência ao estresse hídrico está relacionada com a eficiência no uso da água pela planta e pode ser melhorada geneticamente (CASAGRANDE *et al.*, 2001). O estudo apresentado por Mohd *et al.* (2018) expõe uma abordagem para identificar os fenótipos com resistência a estresse hídrico pelo uso de imagens hiperespectrais. Uma característica interessante desse trabalho se dá na captura da imagem em distâncias curtas. Como vantagem, existe a redução da interferência da luminosidade, porém também reduz a área de abrangência do experimento.

O sistema radicular pode ser um carácter alvo de seleção, de forma que a análise das raízes das plantas pode demonstrar se as condições ambientais e de manejo estão adequadas, permitindo identificar o estresse biótico causado por patógenos. Borianne *et al.* (2018) apresentam uma abordagem de fenotipagem do arroz, utilizando imagens *RGB* das raízes com o objetivo de melhorar a segmentação do sistema radicular para otimizar o processo de análise das características. Uma limitação desse trabalho se dá na sobreposição de partes das raízes ao gerar a imagem da silhueta que será analisada.

Além da aplicação da tecnologia no campo, os algoritmos de tratamento de imagem podem auxiliar no melhoramento de processos na indústria, como análise de frutos e grãos defeituosos. Quando a aplicação de uma tecnologia sai da área da pesquisa e chega nas indústrias por meio de um produto, as ferramentas de captura podem ser especializadas e fabricadas sob demanda. A abordagem apresentada por Marschalek *et al.* (2017) demonstra um *scanner* capaz de extrair características dos grãos de arroz, como tamanho do grão, defeitos e qualidade da moagem utilizando um sensor a laser.

O aumento da produtividade de uma cultura se dá por duas razões: melhoria das técnicas de manejo e melhoramento genético com foco em aumento de produtividade e redução de perdas. A identificação de genótipos resistentes a doenças contribui para a redução de perdas, uma das formas de mensurar essas características é detectar e quantificar os sintomas durante o processo de melhoramento. O processo de detecção de doenças, recorrentemente, é feito de forma visual, consumindo tempo e sendo altamente dependente da acurácia do pesquisador (PIRES *et al.*, 2016). A visão computacional torna possível o reconhecimento de doenças com sintomas visuais, até mesmo por espectros que estão fora do intervalo da luz visível. O estudo apresentado por Al-Ahmadi *et al.* (2018) mostra que é possível identificar os efeitos das toxinas liberadas pelo fungo *Macrophomina phaseolina* na soja, utilizando dados de um sensor hiperespectral, nos espectros compreendidos entre 900 e 2400 nm.

Quando se utiliza visão computacional para a detecção de doenças, é usual a aplicação de métodos de IA, como Redes Neurais Artificiais (RNA) e algoritmos de agrupamento, como o *k-means*. A identificação e classificação de características na

superfície foliar podem ser feitas utilizando RNA (OIDE; NINOMIYA, 2000). A detecção de doenças pode ser feita aplicando o algoritmo K-NN, como é apresentado por Shrivastava e Hooda (2014), em uma abordagem que utiliza imagens de *smartphone* para reconhecer manchas marrons e manchas olho-de-rã nos folíolos da soja. Uma outra abordagem apresentada por Pires *et al.* (2016) mostra o uso das técnicas de descritores locais, para a detecção de ferrugem e míldio nos folíolos da soja, são elas: *Scale-invariant feature transform* (SIFT), *Dense scale-invariant feature transform* (DSIFT), *Pyramid histograms of visual words* (PHOW), *Speeded-Up robust features* (SURF) e *Histogram of oriented gradients* (HOG).

No melhoramento genético da soja, o número de vagens e número de sementes por vagem é uma característica importante de ser avaliada, pois está relacionada com a produção da planta. A separação e contagem das vagens é recorrentemente feita de forma manual, tornando o processo demorado e custoso. Entretanto, Uzal *et al.* (2018) apresentam uma abordagem na qual utilizam uma Rede Neural Convolutiva (RNC) para identificar as sementes dentro da vagem. A captura das imagens foi feita por uma câmera RGB, posteriormente, sendo rotuladas em três classes (2, 3 e 4 sementes por vagem). Então, cada classe foi dividida em um grupo de treinamento e um de testes para a etapa de treinamento da RNC. Por fim, o restante do conjunto de dados é aplicado à etapa de avaliação, para testar a acurácia do modelo, que, nesse caso, foi de 0.92 ± 0.05 .

A presença de fatores no ambiente que não são favoráveis para o crescimento e produção das plantas, como déficit de água, salinidade do solo, temperatura e radiação é classificada como estresse abiótico (OLIVEIRA *et al.*, 2010). Essas condições podem causar sintomas como clorose e manchas avermelhadas nas folhas. O estudo realizado por Zhou *et al.* (2018) apresenta uma abordagem de detecção de sintomas causados pela alteração na salinidade do solo, o experimento foi conduzido em casa de vegetação utilizando imagens *RGB*.

Durante o processo de desenvolvimento de cultivares de soja, a fenotipagem de plantas quanto ao ciclo vegetativo e total se faz necessária, pois faz parte do rol das características alvo. Assim, é comum a necessidade de avaliar a data de florescimento e maturação. A aferição dessas propriedades, quando feita de forma visual, requer um alto custo por parte do pesquisador, devido ao grande número de

plantas avaliadas. A abordagem realizada por Yahata *et al.* (2017) apresenta dois métodos de sensoriamento que permitem a identificação de vagens e flores nas plantas de soja, a diferença entre os métodos está no algoritmo aplicado para a detecção.

Um exemplo de detecção de flores utilizando um dos métodos descritos está ilustrado na Figura 40: o *Simple Linear Iterative Clustering* (SLIC). Na porção (c) da figura, é possível observar o reconhecimento das diversas partes da flor, que, posteriormente, é classificada como uma flor na porção (d) por uma RNC.

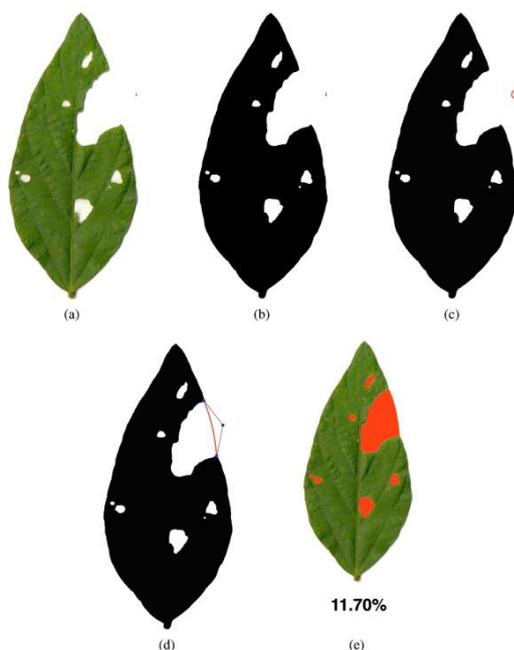
Figura 40 - Detecção de flores



Fonte: Yahata *et al.* (2017).

O ataque de insetos pode ser uma causa de perda de produção. Além disso, no processo de melhoramento genético, ao reduzir a produtividade, prejudica-se a avaliação realizada pelo melhorista. Machado *et al.* (2016) apresentaram um aplicativo (*BioLeaf*) que é capaz de medir os danos causados por um inseto em um folíolo. A Figura 41 ilustra o processo utilizado para o cálculo do dano causado. A primeira etapa (a) representa a imagem original, a etapa (b) e (c) representam a segmentação e remoção de ruídos, respectivamente. Na etapa (d), o usuário cria pontos de controle para ajustar a curva do folíolo. E a última etapa (e) se dá pelo cálculo do dano causado no folíolo.

Figura 41 - Cálculo de dano no folíolo



Fonte: Machado *et al.* (2016).

Além da detecção e quantificação dos danos causados por pragas, outro fator importante é a detecção deles nas plantações, pois isso permite o seu controle pela aplicação de inseticidas e de identificação de cultivares tolerantes aos ataques. Objetivando a redução do uso de agentes químicos nas plantações, que pode ser um fator preocupante para a saúde humana, são criadas soluções, como o controle integrado de pragas (EBRAHIMI *et al.*, 2017). A detecção do inseto de forma manual é complexa, necessitando de uma pessoa especializada para realizar a tarefa e de tempo para percorrer as plantações. Além da detecção dos insetos, muitas vezes, é importante classificá-los, pois existem insetos que prejudicam e auxiliam certos tipos de cultura. Xie *et al.* (2015) apresentaram uma abordagem para a classificação de insetos a partir de imagens RGB. O processo utilizado para a classificação dos insetos se inicia na captura da imagem por um *smartphone*, depois são feitos: a remoção de ruídos, a normalização e o treinamento do classificador com base em 24 classes definidas.

Os nutrientes e a água presentes no solo são recursos finitos. Então, quanto maior for o número de plantas em um determinado local, maior será a competição para a obtenção dos macros e micronutrientes. O aumento da competição por

recursos causado por ervas daninhas pode acarretar perdas de produção e camuflar indivíduos promissores em experimentos de melhoramento genético. Kazmi *et al.* (2015) e Bakhshipour e Jafari *et al.* (2018) apresentaram estudos sobre as superfícies foliares, visando a detecção de ervas daninhas utilizando imagens RGB, sendo que a primeira pesquisa utiliza descritores locais e a segunda utiliza Redes Neurais Artificiais. Ainda contribuindo com o cenário de detecção de ervas daninhas, Zhang *et al.* (2016) apresentam uma abordagem que utiliza as nervuras foliares para diferenciação entre espécies, mesmo quando existem sobreposições entre as folhas da planta alvo e as ervas daninhas.

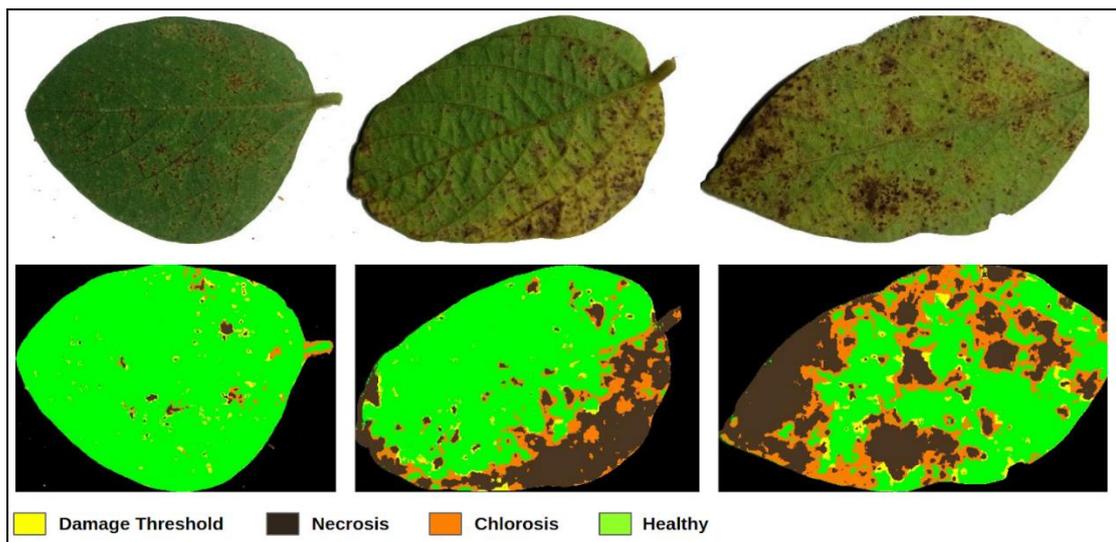
Foram abordadas as culturas que mais utilizam análise de imagem nos processos de melhoramento e manejo, os tipos de imagens utilizadas e os processos que podem ser melhorados com o uso de imagens. Para concluir este estudo, faz-se importante discutir os métodos computacionais aplicados no processamento das imagens. As abordagens que utilizam Inteligência Artificial, recorrentemente, lidam com a classificação entre determinadas classes. As técnicas de IA mais utilizadas foram as Redes Neurais Artificiais, dentre as RNAs, ainda estão as RNAs do tipo *perceptron* multicamadas e as RNAs Convolucionais. As RNAs Convolucionais são largamente utilizadas para o tratamento de imagem, pois possuem recursos que auxiliam no processo de detecção, reconhecimento e segmentação das imagens (LECUN; BENGIO; HINTON, 2015). Nesta pesquisa, as aplicações diretas das RNAs Convolucionais ficaram em torno de 10% das publicações selecionadas e são utilizadas para o reconhecimento e classificação de características nas imagens, como Yang *et al.* (2019), Zhang *et al.* (2019), Ferreira *et al.* (2017) e Park *et al.* (2018). As abordagens que não utilizam aprendizagem de máquina possuem como foco principal o processamento de imagens e a melhoria de processos, como segmentação. Assim, a parte de classificação pode ser feita posteriormente por um pesquisador.

4.3 Criação do software

4.3.1 Resultados do Experimento 1: Quantificação de sintomas de FAS em 200 imagens capturadas em campo

Neste experimento, uma amostra de 200 imagens foi selecionada, de forma aleatória, a partir das imagens capturadas do Experimento 1, e submetida ao processo proposto para calcular seu índice de ferrugem, apresentando a imagem do resultado. A Figura 42 ilustra exemplos de imagens de entrada e seus respectivos resultados para todos os índices, as 3 imagens demonstram como ocorre a evolução da ferrugem no folíolo, surgindo inicialmente com pústulas de cor marrom que são seguidas de clorose e necrose do folíolo. Esse comportamento foi a base biológica utilizada para a inferência se um pixel representa uma região saudável ou não. No geral, os índices propostos capturaram bem a infecção por ferrugem, separando necrose, clorose, saudável e o que poderia ser o limiar de dano da infecção, mas não incluídos como uma determinada parte do índice de ferrugem. No entanto, como pode ser visto na Figura 42, as regiões são marcadas com cores para que um especialista possa analisar melhor os resultados e validá-los.

Figura 42 - Resultado da avaliação de 3 folíolos utilizando o *software* proposto

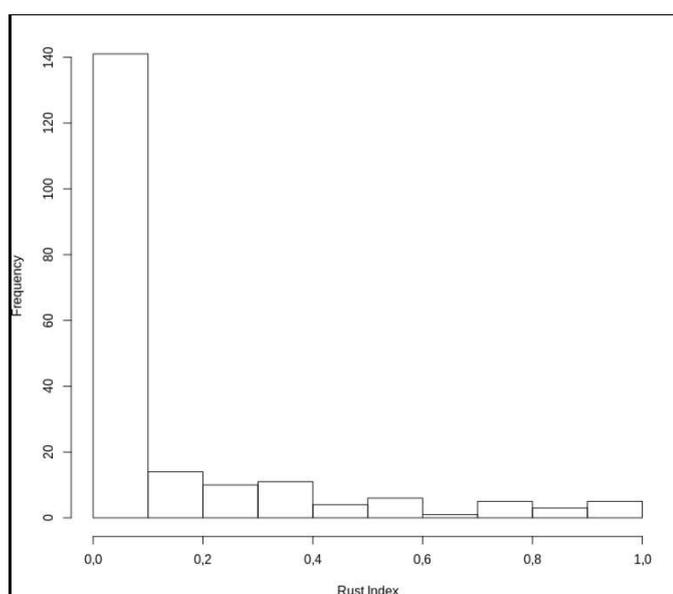


Fonte: Silva *et al.* (2022).

A distribuição do Índice de Ferrugem (IF) para as 200 imagens do Experimento 1 é dada na Figura 43, na qual pode-se observar que a maioria dos folíolos estava no estágio inicial de infecção, considerando que as imagens foram capturadas no mesmo dia e local. Quando se aplica uma análise para seleção de indivíduos promissores, com o foco em melhoramento genético, a distribuição deverá apresentar valores variados, devido à presença de indivíduos com níveis diferentes de resistência. Nesse caso, é possível supor, na Figura 43, que parte dos indivíduos possui um nível de susceptibilidade à ferrugem. Como o Experimento 1 está na geração F3, ainda existe um nível de heterozigose entre os indivíduos e espera-se que gerações mais avançadas tenham uma distribuição mais homogênea dos sintomas.

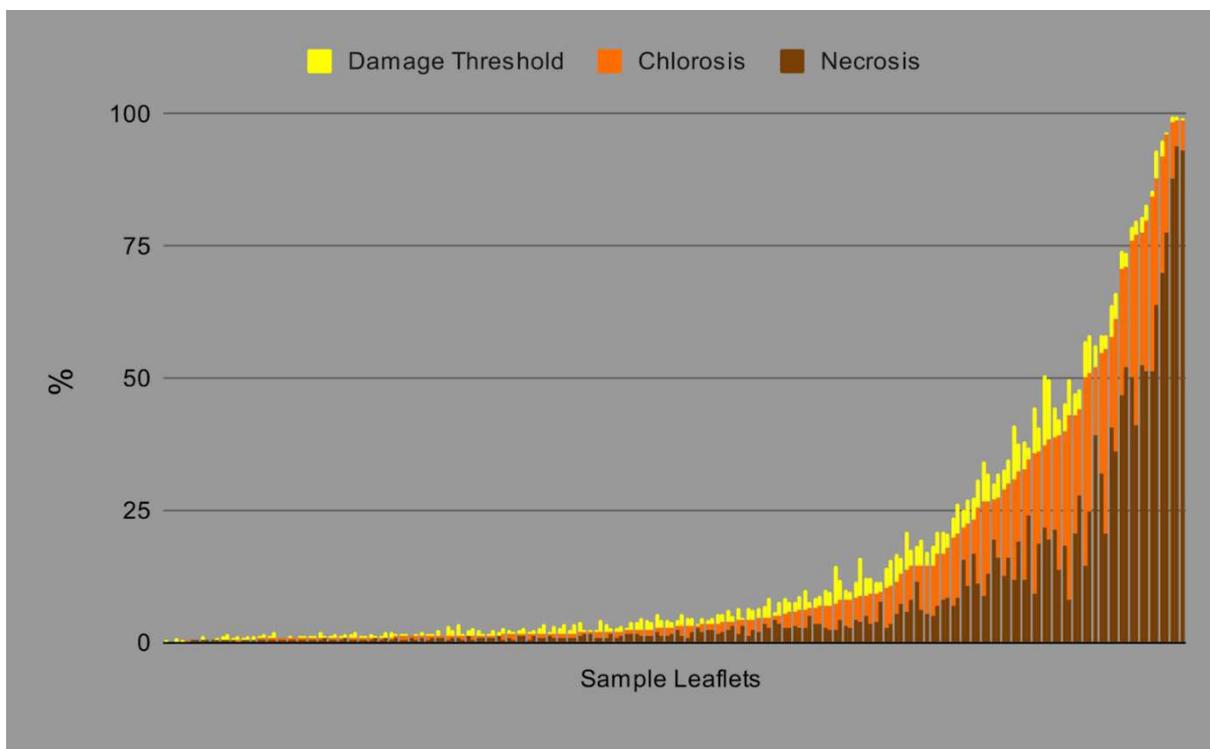
Um dos pontos de destaque do método proposto no presente trabalho é a partição dos sintomas em clorose e necrose. A Figura 44 fornece um gráfico de barras com a porcentagem de sintomas de necrose e clorose para cada folíolo no Experimento 1, sendo possível observar que, em certas amostras, o sintoma predominante é a necrose e, em outras, é a clorose. Na seleção de indivíduos, esse é um fator que pode ser observado, pois a rápida evolução da ferrugem prejudica a fotossíntese, comprometendo o enchimento dos grãos, por sua vez, reduzindo a produtividade.

Figura 43 - Distribuição dos Índices de Ferrugem calculados pelo *software* para o Experimento 1



Fonte: Silva *et al.* (2022).

Figura 44 - Análise da distribuição sintomas de clorose, necrose e limiar de dano para o experimento 1



Fonte: Silva *et al.* (2022).

4.3.2 Resultados do Experimento 2: Quantificação de sintomas em folíolos destacados

O Experimento 2 utilizou folíolos destacados, sendo possível capturar imagens do mesmo folíolo ao longo de um intervalo de dias para analisar a evolução da ferrugem asiática para cada folíolo, por meio do cálculo AACPD.

Uma vantagem ao se utilizar essa metodologia se dá pela possibilidade de realizar apenas uma extração de folíolos e acompanhar a evolução dos sintomas para um genótipo, permitindo o processo de seleção. No entanto, é importante ressaltar que, para este experimento, a infecção ocorreu naturalmente no campo e os folíolos extraídos foram amostrados por identificação de sintomas de ferrugem. Portanto, no dia 0, já foi possível identificar manchas de clorose e necrose.

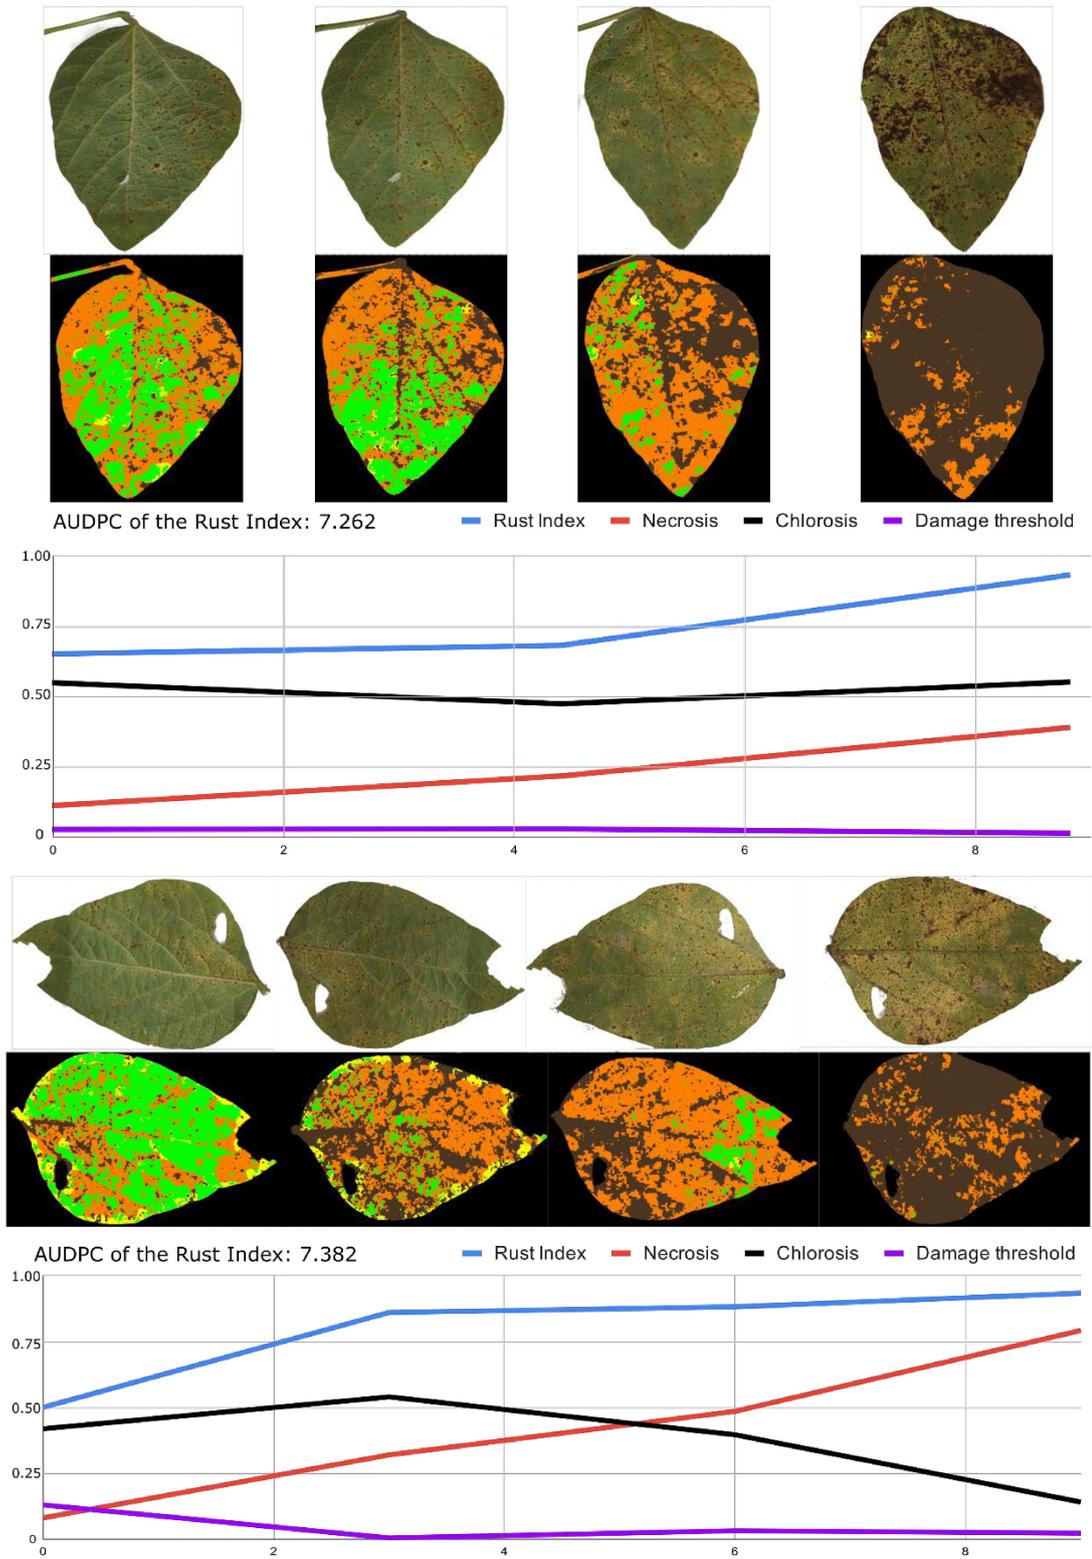
A Figura 45 mostra um folíolo fotografado em 4 dias diferentes, cada imagem de resultado com índices calculados para a ferrugem asiática e um gráfico com AACPD. No total, este experimento possui 67 imagens, pois o nível inicial de infecção foi diferente para cada amostra. Para os testes com folhas destacadas, Experimento 2, os folíolos foram colocados em um recipiente de poliestireno (*gerbox*) e as imagens foram capturadas em intervalos diferentes para cada folíolo. Quando se considera a evolução da infecção e o gráfico da Figura 45, é possível notar que o aumento da necrose é precedido pelo aumento da clorose. Esse comportamento se dá até um limite que as manchas cloróticas aumentam linearmente, após esse limite, as manchas começaram a necrosar, ocorrendo a perda total do folíolo.

O Limiar de Dano (LD) tem um comportamento inverso ao restante dos índices, pois tende a diminuir de acordo com o aumento do índice de necrose do folíolo. A divisão da clorose em dois índices torna o algoritmo mais ponderado, de forma que o LD pode ser considerado como um ponto de dúvida, ou seja, pode ser ou não ser um sintoma causado pela ferrugem e o comportamento de sua redução está dentro do esperado, pois, ao longo dos dias, os sintomas causados pela ferrugem asiática tendem a aumentar, ocupando todo o folíolo.

Esses resultados permitem uma discussão mais aprofundada sobre o papel do sistema proposto na quantificação dos sintomas de ferrugem. Principalmente, quando existe a possibilidade de múltiplos patossistemas e condições inadequadas de manejo no processo de melhoramento, que poderiam ser identificadas pelo melhorista em campo e tratadas isolando os índices que melhor correspondam à condição desejada.

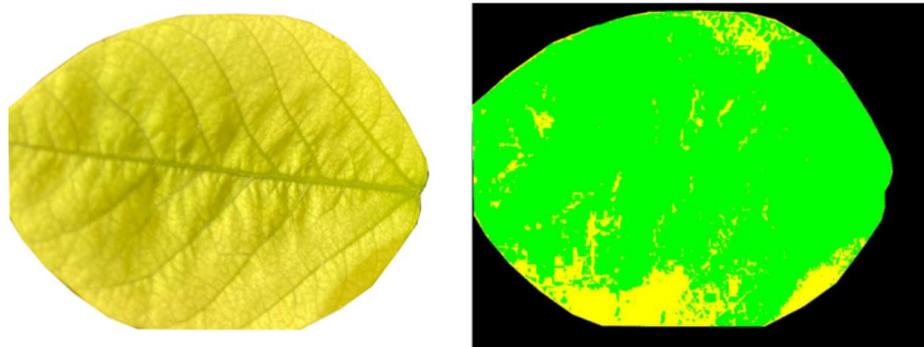
A Figura 46 ilustra uma situação em que o uso da vizinhança para o cálculo do índice pode evitar um falso positivo, pois o folíolo apresenta apenas clorose, sem infecção por ferrugem. Nesse caso, o método indica apenas um limiar de dano (clorose e sem necrose). Por exemplo, o índice de ferrugem proposto é zero, pois apenas computa clorose em torno de necrose segura ou pústulas encontradas nos folíolos.

Figura 45 - Resultado da AACPD para Experimento 2



Fonte: Silva *et al.* (2022).

Figura 46 - Exemplo de clorose sem infecção por ferrugem



Fonte: Silva *et al.* (2022).

4.3.3 Resultados do Experimento 3: Quantificação de sintomas em *dataset* externo

O Experimento 3 usou um conjunto de dados de imagens externas (DEL PONTE, 2020) com 50 imagens, mostrando diferentes níveis gerais de infecção por ferrugem (somente o índice total). Esses resultados e conjuntos de dados são usados neste experimento como forma de comparação com os resultados do método proposto. A análise apresentada em (DEL PONTE, 2020) foi realizada utilizando o *software* Quant-A® (VALE; FERNANDES, 2001). Utilizando o método aqui proposto, IF e LD, o Experimento 3 teve como objetivo comparar os resultados de ambos os índices propostos com o conjunto de dados de (DEL PONTE, 2020).

Foi feita uma correlação de Pearson (FREEDMAN; PISANI; PURVES, 2007) para a comparação entre os resultados da análise externa e pelo método proposto no presente trabalho, pois o banco de dados apresentava somente uma medição global de infecção por ferrugem para cada imagem, não uma marcação pixel por pixel e a diferenciação entre clorose e necrose. O teste de Pearson foi realizado tanto para IF quanto para IF + LD, comparado com cada nível de ferrugem relatado do conjunto de dados de (DEL PONTE, 2020). O Quadro 5 mostra os resultados da correlação. O IF apresentou correlação de 0,63, e IF + LD de 0,98, confirmando uma correlação moderada entre IF e o conjunto de dados de (DEL PONTE, 2020), e forte considerando IF + LD. O resultado está dentro do esperado, pois o índice de ferrugem proposto é conservador, garantindo que apenas pústulas e clorose próximas sejam contadas, com o objetivo de evitar resultados falsos positivos. No entanto, a área

marcada pelo *software* proposto como limiar de dano é marcada na imagem e poderá compor o índice caso o pesquisador julgue pertinente. O algoritmo proposto é automático e dá um resultado mais transparente do que outros *softwares* existentes.

Quadro 5 - Resultado da correlação de Pearson para os Experimentos 3 e 4

Experimento	Índice	p-valor	ρ
Experimento 3	IF + LD	$< 2,200 \cdot 10^{-16}$	0,98
Experimento 3	IF	$< 7,859 \cdot 10^{-7}$	0,63
Experimento 4	IF + LD	$< 1,025 \cdot 10^{-10}$	0,99
Experimento 4	IF	$< 4,919 \cdot 10^{-5}$	0,94

Fonte: Autoria própria.

A Figura 47 mostra 3 imagens de amostra do conjunto de dados, seus resultados após o processamento pelo método proposto e um gráfico de barras com a porcentagem medida de necrose, clorose e limiar de dano de todas as 50 amostras. Os números de identificação das amostras de imagem correspondem aos do conjunto de dados em (DEL PONTE, 2020).

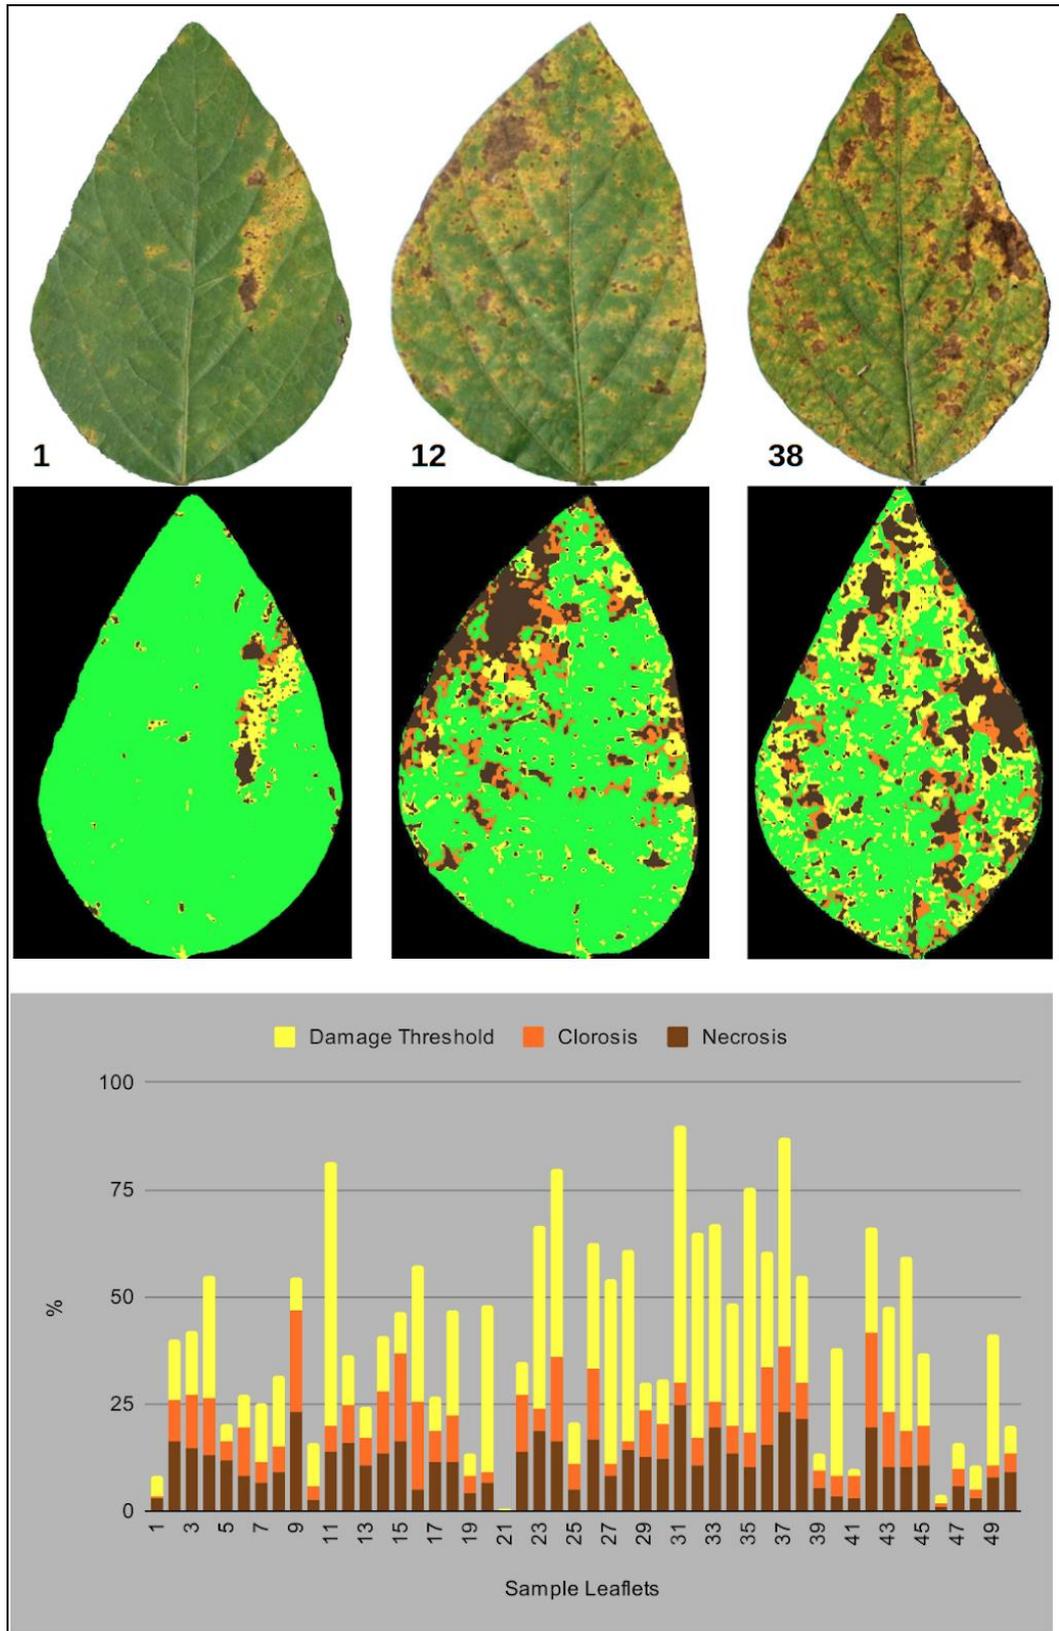
4.3.4 Resultados do Experimento 4: Quantificação de sintomas em escala diagramática

O Experimento 4 mostra a aplicação do sistema proposto a 10 imagens do padrão diagramático de (FRANCESCHI *et al.*, 2020), um Diagrama de Avaliação de Severidade (DAS). Conforme apresentado no Quadro 5, observou-se uma correlação de 0,94 para o Índice de Ferrugem (*RustIndex*) e 0,99 para o Índice de Ferrugem acrescido do Limiar de Dano (*DamageThreshold*). Essas imagens específicas são representações de estágios da evolução da infecção por Ferrugem Asiática da Soja e podem ser utilizadas como teste para avaliar métodos. A Figura 47 mostra as 10 imagens do padrão diagramático (linhas 1 e 3), bem como as respectivas imagens resultantes do método proposto.

A imagem padrão diagramática ds.10, Figura 47, e seu respectivo resultado rs.10, apontam para uma vantagem positiva e interessante do método proposto sobre as técnicas de filtragem de imagem por limiar. Além da imagem geral (Figura 48 ds.10) ter mais pontos de clorose do que de necrose, o resultado correspondente Figura 48 rs.10 deu um bom resultado de correspondência para o IF geral. Uma pústula é o sinal visual mais evidente da infecção por ferrugem e, geralmente, começa pequena e se espalha por todo o folíolo, mostrando os primeiros sinais de clorose e depois necrose.

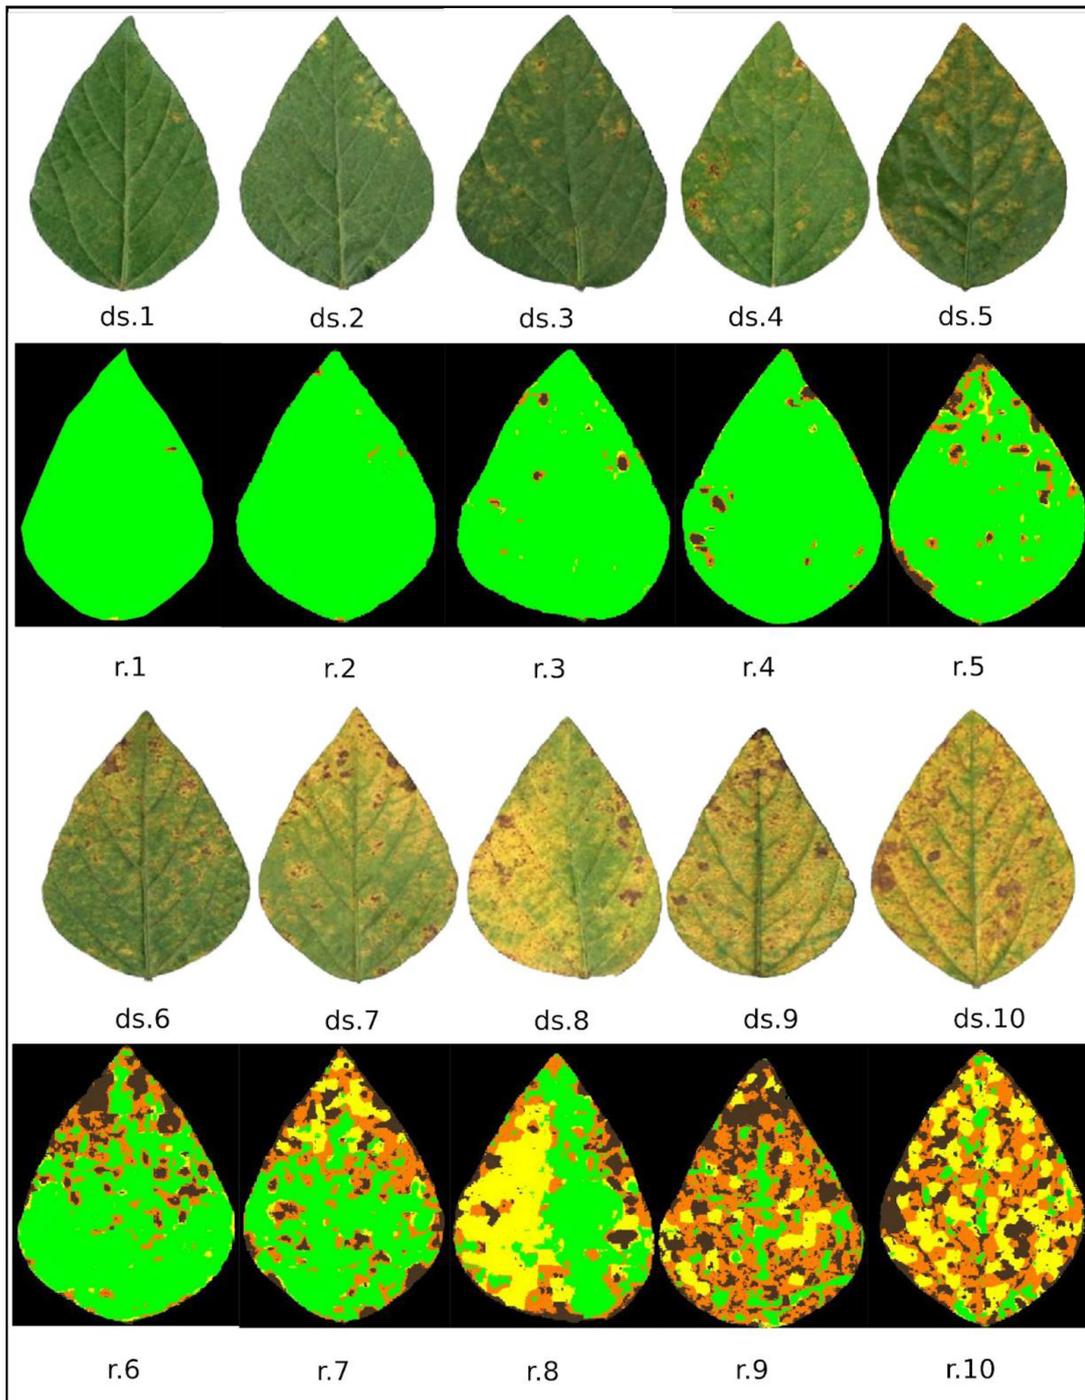
A Figura 49 mostra um exemplo de área ampliada de um folíolo infectado, e pode-se observar que existem áreas necróticas e áreas esverdeadas entre elas. Ao considerar uma análise de vizinhança a partir da necrose segura, como fazem os índices de Clorose propostos, pode-se estimar a gravidade da doença com mais precisão ao considerar o dano do aparelho fotossintético causado pelo patógeno no tecido ao redor da lesão.

Figura 47 - Resultados Experimento 3



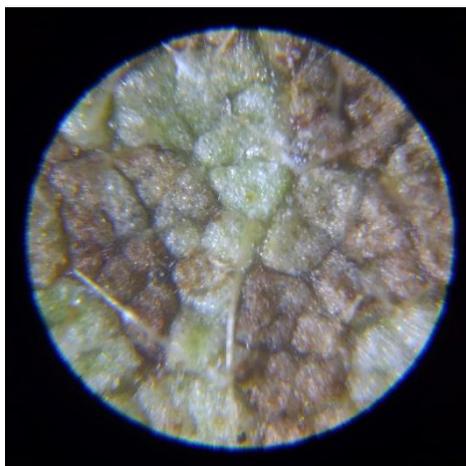
Fonte: Silva *et al.* (2022).

Figura 48 - Resultados Experimento 4



Fonte: Silva *et al.* (2022).

Figura 49 - Infecção observada no microscópio 100x



Fonte: Silva *et al.* (2022).

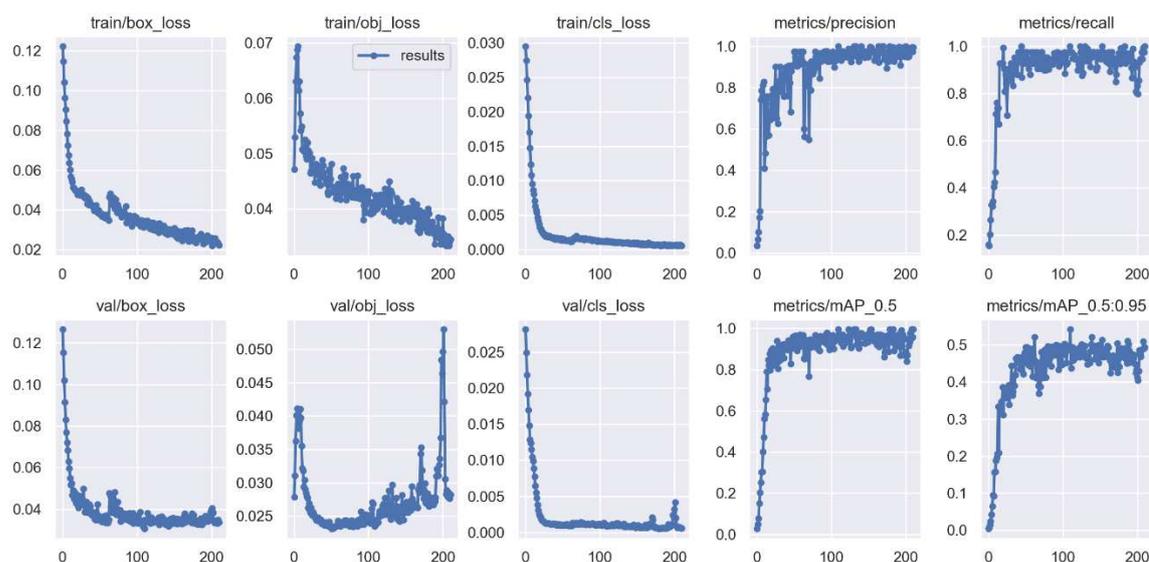
4.4 Rede Neural para detecção e segmentação de folíolos de soja

Em 7 dias de captura, intervalados em média de 15 dias, foram capturadas cerca de 1263 imagens contendo 5 folíolos de soja por imagem. Em cada parcela, foram selecionadas 10 plantas de forma aleatória, sendo retirados 5 folíolos do terço médio e 5 folíolos do terço superior, foi feita uma captura contendo os cinco folíolos na face abaxial e uma captura da face adaxial. Como o *software* proposto processa somente um folíolo por etapa e cada imagem capturada continha até 5 folíolos, foi feito o treinamento de uma rede RNC do tipo Yolov5 para identificar cada folíolo na imagem e gerar uma nova imagem contendo somente 1 folíolo. A imagem gerada foi, posteriormente, analisada pelo *software* proposto.

4.4.1 Resultados treinamento rede Yolov5 e segmentação dos folíolos nas imagens

O treinamento da rede é composto de sucessivas etapas, chamadas de época de treinamento, no qual os pesos da rede são calculados e corrigidos em relação ao erro calculado. Ao final das 200 épocas de treinamento, foi obtida uma acurácia e precisão acima de 0,90 para a identificação dos folíolos e dos identificadores da parcela. Na Figura 50, é possível observar a taxa de redução da função de perda, bem como o aumento da acurácia ao longo das épocas.

Figura 50 - Evolução dos indicadores da RNC ao longo de 200 épocas de treinamento



Fonte: Autoria própria.

Após o processo de segmentação, cada imagem gerou em torno de 6 imagens, sendo 5 folíolos e o identificador das parcelas, totalizando 6300 imagens a serem analisadas para o cálculo da AACPD.

4.5 Validação do software para detecção e quantificação de sintomas de FAS em folíolos de soja a partir de imagens

4.5.1 Desempenho agrônomo de cultivares de soja na ausência e presença de fungicida para controle de FAS

Pela análise de variância em esquema fatorial, observou-se interação não significativa ao nível de 5% pelo teste F para a produtividade de grãos nas quatro épocas de semeadura. Para os fatores isolados, notou-se efeito significativo para o fator cultivar na semeadura de dezembro e para ambos os fatores (cultivar e fungicida) na semeadura de fevereiro (Quadro 6).

Na semeadura de fevereiro, verificou-se maior produtividade de grãos para os tratamentos em que foram feitas aplicações de fungicida (Quadro 7). Considerando o

fator cultivar, a M7739IPRO obteve maior produtividade na época 4, na qual houve uma redução de produtividade em relação a outras épocas, conforme apresentado no Quadro 7. Nas semeaduras cujas condições ambientais foram mais favoráveis ao crescimento e desenvolvimento da planta, notou-se superioridade da cultivar TMG7067IRPO, que possui resistência a FAS (TMG, 2022). Por outro lado, nas semeaduras de janeiro e fevereiro, quando houve, além da ferrugem asiática, o déficit hídrico, o desempenho superior foi da cultivar M7739IPRO.

Quadro 6 - Análise de Variância da Produtividade de grãos de 3 cultivares de soja em 4 épocas de semeadura em Uberlândia – MG

Fonte de Variação	Época 1 – Nov.			Época 2 – Dez.			Época 3 - Jan.			Época 4 – Fev.		
	GL	Q.M.	p-valor	GL	Q.M.	p-valor	GL	Q.M.	p-valor	GL	Q.M.	p-valor
Fungicida	1	1,483	0,170	1	0,015	0,870	1	0,119	0,180	1	5,968	2,51*10 ⁻²
Cultivar	2	0,296	0,670	2	4,104	5*10 ⁻³	2	0,200	0,061	2	42,255	1,59*10 ⁻⁷
Fungicida x Cultivar	2	0,129	0,839	2	0,797	0,273	2	0,004	0,968	2	1,337	2,87*10 ⁻¹
Resíduos	18	0,725	-----	18	0,5720	-----	18	0,061	-----	18	0,018	-----

Fonte: Autoria própria.

Quadro 7 - Produtividade de grãos (kg ha⁻¹) de cultivares de soja em 4 épocas de semeadura – Uberlândia-MG

Fungicida	M7739IPRO	ST721IPRO	TMG7067IPRO	Médias
Época 1 (novembro de 2020)				
não	3830	4381	4341	4184 a
sim	4596	4643	4803	4680 a
Médias	4213 A	4512 A	4572 A	
Época 2 (dezembro de 2020)				
não	2877	3461	4487	3608 a
sim	3503	2837	4332	3557 a
Médias	3190 B	3147 B	4409 A	
Época 3 (janeiro de 2021)				
não	1481	1170	1208	1286 a
sim	1316	1065	1056	1146 a
Época 4 (fevereiro de 2021)				
não	1167	555	758	826 b
sim	1237	625	1017	959 a
Médias	1202 A	590 C	887 B	

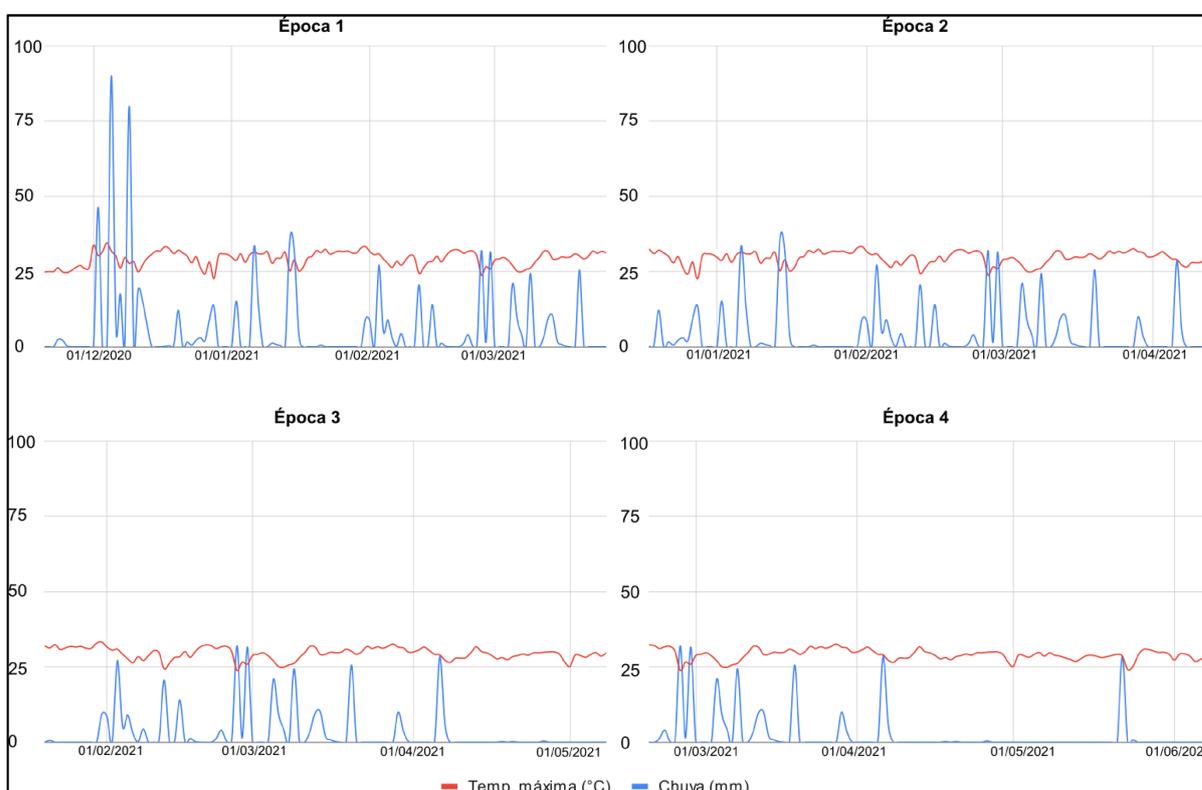
Letras minúsculas representam a análise do fator fungicida e maiúsculas representam o fator cultivar. Letras iguais na mesma linha ou coluna representam médias que não se diferem no teste de Tukey a 5% de significância.

Fonte: Autoria própria.

Uberlândia se encontra na região edafoclimática 303 (BRASIL, 2021b). De acordo com as especificações técnicas das cultivares utilizadas, os períodos ideais de semeadura são: segunda semana de outubro a terceira semana de novembro para M7739IPRO (AGROBAYER, 2022); primeira semana de outubro a primeira semana de dezembro para TMG7067IPRO (TMG, 2022); segunda semana de outubro a última semana de novembro para a ST721IPRO (BASF, 2022). O fator época de semeadura pode ser responsável pela melhor produtividade da TMG7067IPRO.

Nas semeaduras de janeiro e fevereiro, ocorreu uma queda na produtividade de grãos em todas as cultivares, conforme apresentado no Quadro 7. Esse resultado pode estar relacionado a um estresse hídrico causado no período de enchimento dos grãos e durante todo o ciclo das cultivares, conforme ilustrado na Figura 51. Esse fator pode ter contribuído para a superioridade da cultivar M7739IPRO, que apresenta resistência para estresse hídrico (VITAL, 2019).

Figura 51 - Precipitação em mm e temperatura máxima em °C em quatro épocas de semeadura de soja



Fonte: Autoria própria.

Na semeadura de fevereiro, houve efeito significativo tanto para o fator fungicida quanto cultivar. No Quadro 7, foi possível observar a superioridade da cultivar M7739IPRO e de todas as cultivares com a aplicação de fungicida. Entretanto, devido à desfolha precoce, foi possível realizar somente duas capturas de imagem, impossibilitando o cálculo da AACPD.

Para o peso de 100 sementes, não houve interação significativa entre os fatores fungicida e cultivar. Considerando os fatores isolados, foi possível observar efeitos significativos da aplicação de fungicida e dos cultivares, conforme apresentado no Quadro 8. A aplicação de fungicida contribuiu para evitar a redução do peso de 100 grãos nas semeaduras de novembro, dezembro e janeiro. No entanto, além dos danos causados pela infecção por *F. o*, o resultado observado pode estar relacionado a condições ambientais e ao fator cultivar, pois, conforme apresentado no Quadro 9, foi possível observar diferença significativa entre as cultivares para todas as épocas, com superioridade da cultivar TMG7067IPRO para três épocas.

Quadro 8 - Análise de Variância do Peso de 100 sementes de 3 cultivares de soja em 4 épocas de semeadura em Uberlândia – MG

Fonte de Variação	Época 1 – Nov.			Época 2 – Dez.			Época 3 - Jan.			Época 4 – Fev.		
	GL	Q.M.	p-valor	GL	Q.M.	p-valor	GL	Q.M.	p-valor	GL	Q.M.	p-valor
Fungicida	1	2,282	2,59*10 ⁻²	1	9,127	2,59*10 ⁻²	1	1,042	4,48*10 ⁻²	1	0,167	6,30*10 ⁻¹
Variedade	2	42,518	8,16*10 ⁻¹¹	2	86,904	1,83*10 ⁻⁸	2	20,302	3,99*10 ⁻¹⁰	2	16,402	9,05*10 ⁻⁶
Fungicida x Cultivar	2	0,814	1,51*10 ⁻¹	2	3,256	1,51*10 ⁻¹	2	0,522	1,26*10 ⁻¹	2	0,407	5,66*10 ⁻¹
Resíduos	18	0,387		18	1,547		18	0,224		18	0,692	

Fonte: Autoria própria.

Quadro 9 - Peso de 100 sementes (g) de cultivares de soja em 4 épocas de semeadura – Uberlândia-MG

Fungicida	M7739IPRO	ST721IPRO	TMG7067IPRO	Médias
Época 1 (novembro de 2020)				
não	14,300	11,825	16,500	14,20 b
sim	15,637	12,212	16,625	14,83 a
Médias	14,96 B	12,02 C	16,56 A	
Época 2 (dezembro de 2020)				
não	11,700	9,150	16,000	12,28 b
sim	14,375	9,925	16,250	13,51 a
Médias	13,03 B	9,54 C	16,12 A	
Época 3 (janeiro de 2021)				
não	13,675	11,600	10,625	11,96 a
sim	13,475	10,600	10,575	11,55 b
Médias	13,57 A	11,10 B	10,60 B	
Época 4 (fevereiro de 2021)				
não	12,250	9,675	12,600	11,51 a
sim	11,950	10,275	12,800	11,67 a
Médias	12,10 A	9,98 B	12,70 A	

Letras minúsculas representam a análise do fator fungicida e maiúsculas representam o fator cultivar. Letras iguais na mesma linha ou coluna representam médias que não se diferem no teste de Tukey a 5% de significância.

Fonte: Autoria própria.

4.5.2 Efeito de fungicida, terço e face na AACPD pela infecção por FAS quantificada por imagem

A resistência genética à FAS é poligênica (CHILDS *et al.*, 2018) e seu uso deve ser concomitante a outras metodologias de manejo, como a aplicação de fungicidas, todavia, em menor número de aplicações. Considerando o potencial destrutivo desse patógeno, dependendo do nível de pressão, pode ocasionar perdas de até 90% (GODOY *et al.*, 2016). Durante o processo de obtenção de genótipos resistentes, pode-se utilizar aplicações de fungicida para reduzir a pressão do inóculo do fungo e viabilizar a avaliação dos genótipos quanto à resistência à FAS e o desempenho agrônomo em condições de exposição ao patógeno (LIMA *et al.*, 2012).

Na avaliação da severidade da FAS por meio de metodologias convencionais, é comum o uso de escalas diagramáticas para atribuição de notas para a severidade dos sintomas. Então, o pesquisador atribui visualmente uma nota em uma parcela contendo plantas de soja infectadas. Assim, para promover uma melhoria na acurácia

da avaliação, o uso de imagens de folíolos torna-se uma opção. No entanto, para o desenvolvimento de uma metodologia que possa ser aplicada ao processo de melhoramento, requer a definição do número de folíolos coletados, da posição do folíolo a ser coletado nas plantas de soja e a face do folíolo na qual a imagem será capturada.

Nesta pesquisa, foi desenvolvido um *software* capaz de detectar e quantificar sintomas de FAS em folíolos de soja e, por essa razão, fez-se necessário obter informações a respeito da coleta de folíolos e captura das imagens. Nesse contexto, o experimento 5 foi realizado com o intuito de compreender o comportamento da AACPD em cultivares suscetíveis à ferrugem (M7739IPRO e ST721IPRO) e com resistência (TMG7067IPRO) à FAS, sob condições de ausência e presença de fungicida.

Para a cultivar TMG7067IPRO, não foi detectada interação significativa para os 3 fatores (fungicida, terço e face) nas sementeiras de novembro e dezembro. Por outro lado, constatou-se efeito significativo ao nível de 5% pelo teste F para os fatores isolados fungicida e face em todas as épocas de sementeira (Figura 52, Figura 53 e Figura 54). Pelo Quadro 11, observou-se que a aplicação de fungicida reduziu a AACPD em média 42%.

Ainda para a cultivar TMG7067, a interação dupla entre fungicida e face foi detectada (Figura 54), contudo, a aplicação de fungicida resultou em um aumento da AACPD para a face adaxial. Entretanto, para a face abaxial, a aplicação de fungicida não promoveu uma redução da AACPD (Quadro 12). Em todas as sementeiras, os sintomas da ferrugem foram significativamente maiores na face abaxial das plantas (Quadro 10, Quadro 11 e Quadro 12).

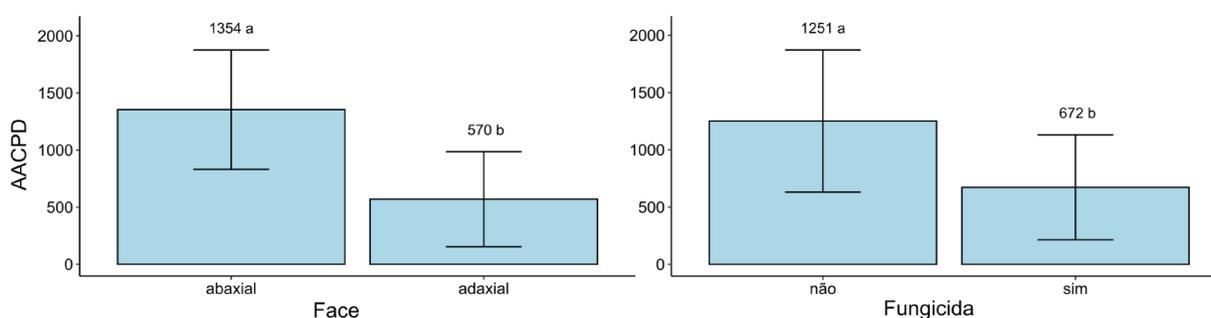
Quadro 10 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar TMG7067IPRO

Fungicida	Terço	Abaxial	Adaxial	Médias
não	Médio	1781,85	965,75	1251,32 a
não	Superior	1524,67	733,03	
sim	Médio	962,74	200,32	672,36 b
sim	Superior	1146,04	380,34	
Médias		1353,83 A	567,86 B	

Médias com letras minúsculas distintas diferenciam efeito de fungicida e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 52 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de novembro para a cultivar TMG7067IPRO



Fonte: Autoria própria.

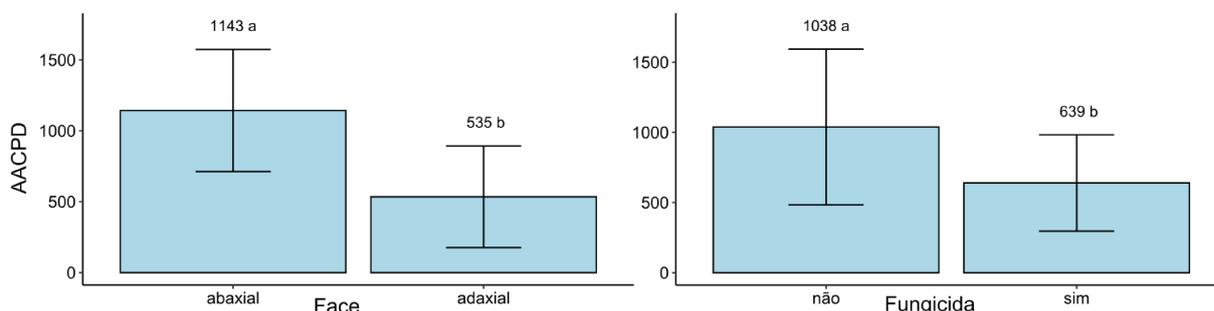
Quadro 11 - AACPD das faces abaxial e adaxial para a semeadura de dezembro da cultivar TMG7067IPRO

Fungicida	Terço	Abaxial	Adaxial	Médias
não	Médio	1292,34	441,38	1038,32 a
não	Superior	1402,27	1017,26	
sim	Médio	913,43	252,24	639,15 b
sim	Superior	963,15	427,77	
Médias		1142,80 A	534,66 B	

Médias com letras minúsculas distintas diferenciam efeito de fungicida e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 53 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de dezembro para a cultivar TMG7067IPRO



Fonte: Autoria própria.

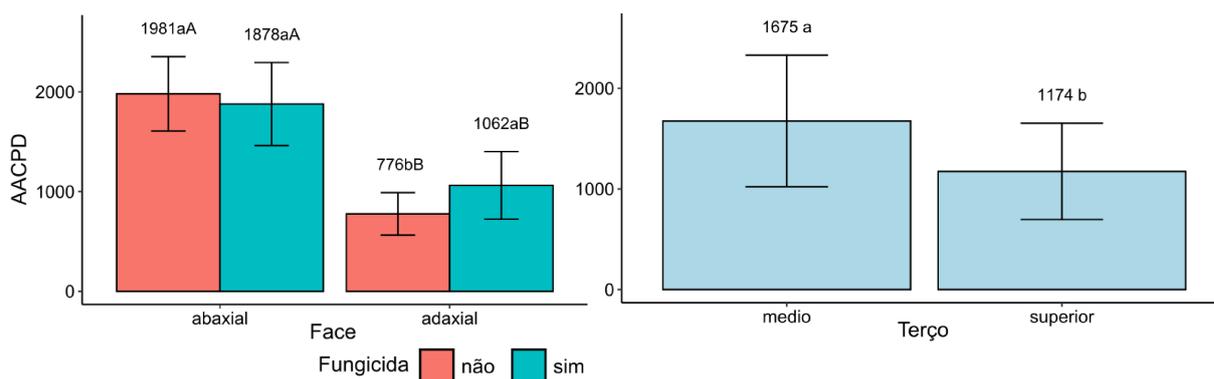
Quadro 12 - AACPD das faces abaxial e adaxial para a semeadura de janeiro da cultivar TMG7067IPRO

Fungicida	Terço	Abaxial	Adaxial
não	Médio	2294,85	874,47
não	Superior	1666,54	678,38
Médias		1981,70 aA	776,43 bB
sim	Médio	2215,31	1314,1
sim	Superior	1541,05	809,74
Médias		1878,18 aA	1061,92 bA

Médias com letras minúsculas distintas diferenciam efeito de fungicida e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 54 - AACPD dos efeitos significativos da interação entre face e fungicida e do efeito isolado terço para a cultivar TMG7067IPRO na semeadura de janeiro



Fonte: Autoria própria.

Na semeadura de novembro, para a cultivar M7739IPRO, constatou-se interações duplas significativas para os fatores fungicida e face; terço e face (Figura 55). A aplicação de fungicida promoveu considerável redução da AACPD na face

adaxial. Contudo, o efeito não foi observado na face abaxial, uma vez que as estimativas médias de AACPD foram semelhantes, conforme (Quadro 13). Em relação às AACPD nos terços, verificou-se estimativas médias maiores no terço médio (Quadro 14).

Quadro 13 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar M7739IPRO, considerando interação entre fungicida e face

Fungicida	Terço	Abaxial	Adaxial
Não	Médio	1243,50	799,91
Não	Superior	1016,52	866,16
Médias		1130 aA	833 aB
Sim	Médio	1370,49	188,30
Sim	Superior	846,76	234,23
Médias		1109 aA	211 bB

Médias com letras minúsculas distintas diferenciam efeito de fungicida e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

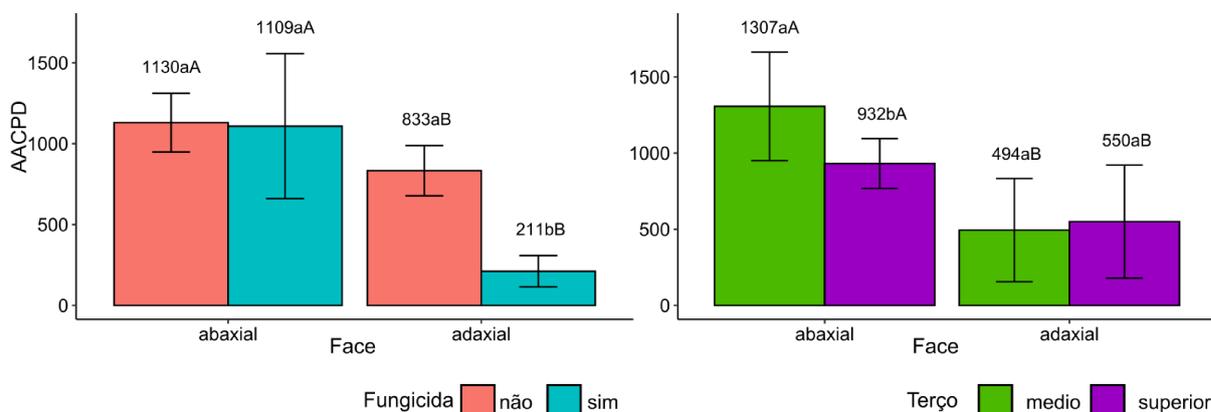
Quadro 14 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar M7739IPRO, considerando interação entre terço e face

Fungicida	Terço	Abaxial	Adaxial
Sim	Médio	1243,50	799,91
Não	Médio	1370,49	188,30
Médias		1307 aA	494 aB
Sim	Superior	1016,52	866,16
Não	Superior	846,76	234,23
Médias		932 bA	550 aB

Médias com letras minúsculas distintas diferenciam efeito de terço e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 55 - AACPD dos efeitos significativos da interação entre face e fungicida; e face e terço para a cultivar M7739IPRO na semeadura de novembro



Fonte: Autoria própria.

Para as semeaduras de dezembro, apenas o fator face foi significativo pelo teste F, cujas estimativas médias foram maiores para a face abaxial, conforme Quadro 15. Na semeadura de janeiro, foi observado efeito significativo apenas para os fatores terço e face (Quadro 16), cujas estimativas médias foram maiores para o terço médio e abaxial (Figura 56).

Quadro 15 - AACPD das faces abaxial e adaxial para a semeadura de dezembro da cultivar M7739IPRO

Fungicida	Terço	Abaxial	Adaxial
não	Médio	1265,66	593,24
não	Superior	903,22	360,88
sim	Médio	784,03	148,04
sim	Superior	801,08	278,40
Médias		938,49 a	345,14 b

Médias com letras minúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

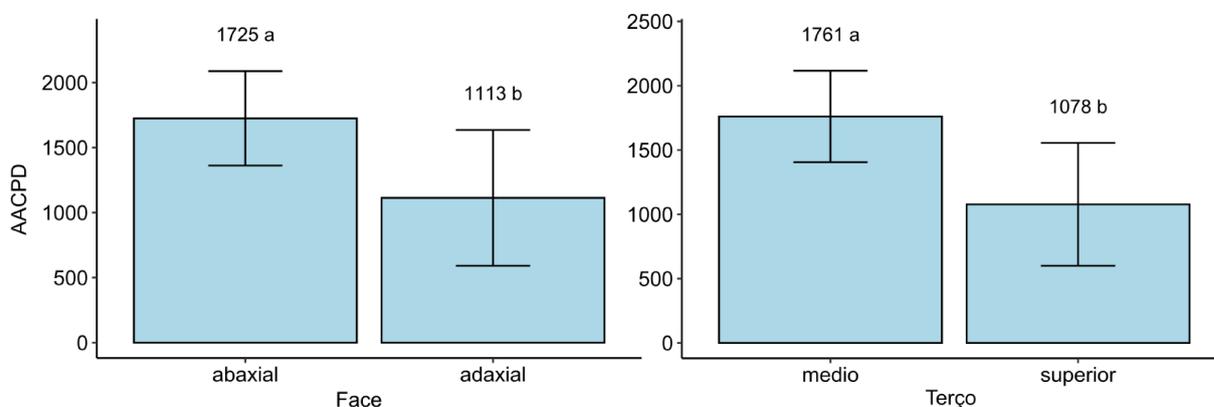
Quadro 16 - AACPD das faces abaxial e adaxial para a semeadura de janeiro da cultivar M7739IPRO

Fungicida	Terço	Abaxial	Adaxial	Médias
não	Superior	1449,08	659,34	1077,81 b
sim	Superior	1523,32	679,52	
não	Médio	1911,30	1590,17	1760,72 a
sim	Médio	2016,55	1524,86	
Médias		1725,06 A	1113,47B	

Médias com letras minúsculas distintas diferenciam efeito de terço e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 56 - AACPD dos efeitos significativos dos fatores isolados face e terço para a semeadura de janeiro para a cultivar M7739IPRO



Fonte: Autoria própria.

Para a cultivar ST721IPRO, que é suscetível à FAS, na semeadura de novembro, observou-se efeito significativo dos fatores isolados fungicida e face (Figura 57). A aplicação de fungicida promoveu a redução de aproximadamente 42% nos índices de AACPD (Quadro 17). Quanto ao fator face, foi constatado maior valor de AACPD para a face abaxial (Quadro 17).

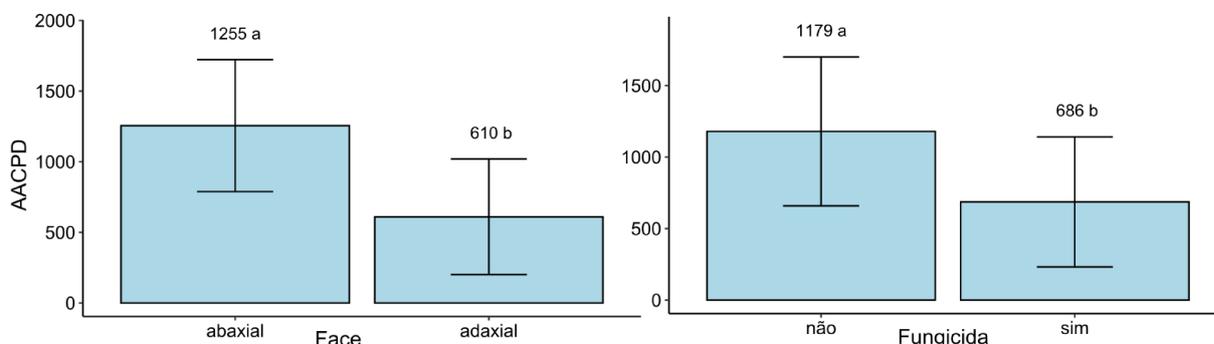
Quadro 17 - AACPD das faces abaxial e adaxial para a semeadura de novembro da cultivar ST721IRPO

Fungicida	Terço	Abaxial	Adaxial	Médias
não	Superior	1595,60	870,48	1179,10 a
não	Médio	1212,32	1038,02	
sim	Superior	1048,48	328,86	686,36 b
sim	Médio	1164,39	203,27	
Médias		1255,31 A	610,16 B	

Médias com letras minúsculas distintas diferenciam efeito de fungicida e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 57 - AACPD dos efeitos significativos dos fatores isolados face e fungicida para a semeadura de novembro para a cultivar ST721IRPO



Fonte: Autoria própria.

Em relação à semeadura de dezembro, notou-se a interação tripla entre os fatores (fungicida, terço e face), cujas estimativas médias de AACPD foram maiores para a aplicação de fungicidas no terço médio e face abaxial (Quadro 18, Quadro 19, Quadro 20). Por outro lado, nas demais condições de terço e face, não houve efeito da aplicação de fungicida nas estimativas de AACPD. Ao analisar os terços e as faces, constataram-se maiores estimativas de AACPD no terço médio e na face abaxial (Quadro 19, Quadro 20).

Quadro 18 - AACPD considerando o efeito do fungicida na interação tripla para a cultivar ST721RPO na semeadura de dezembro

Terço	Face	Fungicida	Médias
Médio	Abaxial	Sim	2006,17 a
		Não	1516,99 b
Médio	Adaxial	Sim	658,40 a
		Não	435,29 a
Superior	Abaxial	Sim	871,32 a
		Não	774,00 a
Superior	Adaxial	Sim	642,46 a
		Não	294,24 a

Médias com letras minúsculas distintas diferenciam efeito de fungicida ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Quadro 19 - AACPD considerando o efeito do terço na interação tripla para a cultivar ST721RPO na semeadura de dezembro

Fungicida	Face	Terço	Médias
Não	Abaxial	Médio	1516,99 a
		Superior	774,00 b
Não	Adaxial	Médio	658,40 a
		Superior	294,24 a
Sim	Abaxial	Médio	2006,17 a
		Superior	871,32 b
Sim	Adaxial	Médio	435,29 a
		Superior	642,46 a

Médias com letras minúsculas distintas diferenciam efeito de terço ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Quadro 20 - AACPD considerando o efeito do face na interação tripla para a cultivar ST721RPO na semeadura de dezembro

Fungicida	Terço	Face	Médias
Não	Médio	Abaxial	1516,99 a
		Adaxial	658,40 b
Não	Médio	Abaxial	774,00 a
		Adaxial	294,24 b
Sim	Superior	Abaxial	2006,17 a
		Adaxial	435,29 b
Sim	Superior	Abaxial	871,32 a
		Adaxial	642,46 a

Médias com letras minúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Em relação à semeadura de janeiro, observou-se efeitos significativos isolados para os fatores terço e face (Figura 58). Houve maiores índices de AACPD para o terço médio e face abaxial, conforme pode ser observado no Quadro 21. Nessa época de semeadura, não houve efeito significativo da aplicação de fungicida para o cultivar ST721IRPO.

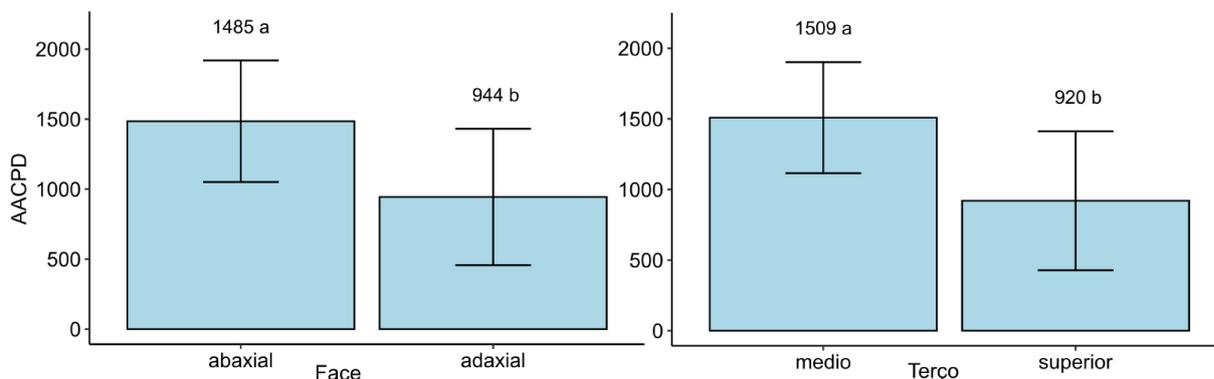
Quadro 21 - AACPD das faces abaxial e adaxial para a cultivar ST721IRPO na semeadura de janeiro

Fungicida	Terço	Abaxial	Adaxial	Médias
não	Médio	1763,44	1200,03	1508,78 a
sim	Médio	1734,06	1337,57	
não	Superior	1094,24	451,75	920,37 b
sim	Superior	1347,61	787,87	
Médias		1484,84 A	944,30 B	

Médias com letras minúsculas distintas diferenciam efeito de terço e médias com letras maiúsculas distintas diferenciam efeito de face ao nível de 5% de significância pelo teste de Tukey.

Fonte: Autoria própria.

Figura 58 - AACPD dos efeitos significativos dos fatores isolados face e terço para a semeadura de janeiro para a cultivar ST721IRPO



Fonte: Autoria própria.

É interessante ressaltar que foram utilizados fungicidas do tipo multissítios, triazóis, estrobilurinas e carboximidas, nos tratamentos com fungicida. Considerando que o efeito de cada um dos fungicidas está relacionado com o ciclo de infecção do fungo e que o desempenho pode estar sujeito a condições ambientais durante e após a aplicação (RUPE; SCONYERS, 2008), o efeito do fungicida pode não ser encontrado em alguns resultados. Além disso, como os tratamentos sem o uso de fungicida estavam próximos, aumenta-se a pressão por inóculo na área, prejudicando

tanto o desempenho do fungicida quanto a resistência genética. Os fungicidas foram aplicados com o uso de pulverizadores. Assim, a cobertura foliar se dá, principalmente, na face adaxial das folhas, podendo ter contribuído com a redução dos sintomas nessa face.

Para verificar a existência de uma correlação linear entre produtividade, peso de 100 grãos e AACPD calculada nas faces abaxial e adaxial, e nos terços médio e superior, foi feita uma matriz de correlações entre todas as variáveis envolvidas no experimento 5, conforme ilustrado nas figuras Figura 59, Figura 60, Figura 61, Figura 62, Figura 63 e Figura 64.

Figura 59 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar TMG70677IPRO com aplicação de fungicida

	tmg_fg_prd	tmg_fg_p100	tmg_fg_ab_m	tmg_fg_ad_m	tmg_fg_ab_s	tmg_fg_ad_s
tmg_fg_prd	—					
tmg_fg_p100	0.886 ***	—				
tmg_fg_ab_m	-0.850 ***	-0.921 ***	—			
tmg_fg_ad_m	-0.863 ***	-0.922 ***	0.958 ***	—		
tmg_fg_ab_s	-0.383	-0.598 *	0.697 *	0.683 *	—	
tmg_fg_ad_s	-0.627 *	-0.719 **	0.837 ***	0.878 ***	0.622 *	—

Nota. * p < .05, ** p < .01, *** p < .001

Identificadores: “fg” aplicação de fungicida, “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

A correlação foi feita considerando cada um dos tratamentos nas 3 épocas de semeadura (novembro, dezembro e janeiro), totalizando 6 matrizes, e permitiu verificar a forte correlação entre peso de 100 sementes e produtividade para a variedade TMG7067IPRO e M7739IPRO com aplicação de fungicida, de forma que esse resultado pode indicar que a infecção por ferrugem prejudica tanto o enchimento dos grãos quanto a produtividade de grãos, alterando a correlação das cultivares suscetíveis sem a aplicação de fungicida corroborado por não ser encontrada uma correlação negativa entre o peso de 100 sementes e a infecção por AACPD.

Figura 60 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar TMG70677IPRO sem aplicação de fungicida

	tmg_prd	tmg_p100	tmg_ab_m	tmg_ab_s	tmg_ad_m	tmg_ad_s
tmg_prd	—					
tmg_p100	0.918 ***	—				
tmg_ab_m	-0.736 **	-0.705 *	—			
tmg_ab_s	-0.170	-0.324	0.593 *	—		
tmg_ad_m	-0.255	-0.278	0.710 **	0.744 **	—	
tmg_ad_s	0.360	0.309	-0.314	0.151	-0.067	—

Nota. * p < .05, ** p < .01, *** p < .001

Identificadores: “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

Figura 61 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar ST721IPRO com aplicação de fungicida

	st_fg_prd	st_fg_p100	st_fg_ab_m	st_fg_ab_s	st_fg_ad_m	st_fg_ad_s
st_fg_prd	—					
st_fg_p100	0.668 *	—				
st_fg_ab_m	-0.406	-0.537	—			
st_fg_ab_s	-0.355	0.265	0.345	—		
st_fg_ad_m	-0.721 **	-0.257	0.469	0.707 *	—	
st_fg_ad_s	-0.255	-0.077	0.705 *	0.657 *	0.708 *	—

Nota. * p < .05, ** p < .01, *** p < .001

Identificadores: “fg” aplicação de fungicida, “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

Figura 62 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar ST721IPRO sem aplicação de fungicida

	st_prd	st_p100	st_ab_m	st_ab_s	st_ad_m	st_ad_s
st_prd	—					
st_p100	-0.104	—				
st_ab_m	-0.739 **	0.044	—			
st_ab_s	0.134	0.290	-0.370	—		
st_ad_m	-0.371	0.338	0.156	0.067	—	
st_ad_s	0.426	0.365	-0.449	0.314	0.473	—

Nota. * p < .05, ** p < .01, *** p < .001

Identificadores: “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

Figura 63 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar M7739IPRO com aplicação de fungicida

	ms_fg_prd	ms_fg_p100	ms_fg_ab_m	ms_fg_ab_s	ms_fg_ad_m	ms_fg_ad_s
ms_fg_prd	—					
ms_fg_p100	0.879 ***	—				
ms_fg_ab_m	-0.617 *	-0.348	—			
ms_fg_ab_s	-0.783 **	-0.568	0.659 *	—		
ms_fg_ad_m	-0.877 ***	-0.666 *	0.782 **	0.857 ***	—	
ms_fg_ad_s	-0.823 **	-0.591 *	0.672 *	0.853 ***	0.859 ***	—

Nota. * p < .05, ** p < .01, *** p < .001

Identificadores: “fg” aplicação de fungicida, “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

Na variedade TMG7067IPRO, com aplicação de fungicida, Figura 59, foi encontrada uma correlação negativa forte entre produtividade e os sintomas de infecção por ferrugem na face abaxial e terço médio. Essa perda de produtividade pode estar relacionada com a redução da capacidade de fotossíntese da planta e enchimento dos grãos, considerando que houve somente 3 aplicações de fungicida que podem não ter sido suficiente (LEVY, 2005). Entretanto, é necessário considerar que houve estresse hídrico no período de enchimento de grãos na época 3, juntamente com a forte infecção.

Figura 64 - Correlações entre AACPD, peso 100 sementes e produtividade de grãos para cultivar M7739IPRO sem aplicação de fungicida

	ms_prd	ms_p100	ms_ab_m	ms_ab_s	ms_ad_m	ms_ad_s
ms_prd	—					
ms_p100	-0.095	—				
ms_ab_m	0.015	-0.449	—			
ms_ab_s	-0.262	0.054	0.690 *	—		
ms_ad_m	-0.214	-0.122	0.849 ***	0.899 ***	—	
ms_ad_s	0.107	0.508	0.136	0.079	0.168	—

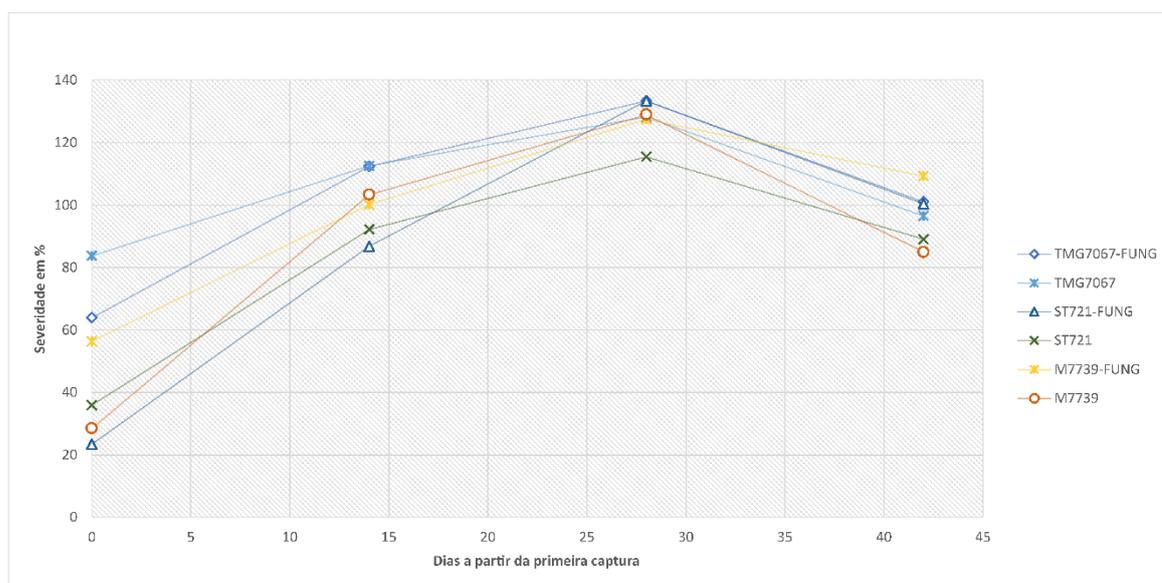
Nota. * $p < .05$, ** $p < .01$, *** $p < .001$

Identificadores: “prd” produtividade, “p100” peso de 100 sementes, “ab” face abaxial, “ad” face adaxial, “m” terço médio e “s” terço superior.

Fonte: Autoria própria.

Em suma, considerando as análises realizadas no Experimento 5, foi possível observar o comportamento biológico esperado com base na análise da produtividade em relação ao fator fungicida, bem como a AACPD. A queda na produtividade foi acentuada nas épocas 3 e 4, podendo ser causada pela pressão pela infecção da ferrugem e por condições ambientais (Figura 51). O período de baixas chuvas na época 3 gerou um cenário que deve ser analisado em novos experimentos, pois, devido ao ambiente mais seco, os folíolos com sintomas sofreram desfolha, restando folíolos com menor índice de infecção, ocasionando em uma queda na severidade média dos tratamentos, conforme gráfico apresentado na Figura 65. O resultado não foi comprometido devido ao ciclo da soja ser curto, porém, ao atingir índices de severidade média acima de 80%, pode ser interessante interromper o processo de captura e utilizar somente os dados já coletados.

Figura 65 - Gráfico da severidade de infecção por FAS ao longo de 45 dias



Fonte: Autoria própria.

A avaliação da ferrugem obteve maior sensibilidade quando analisada na face abaxial das plantas e o terço médio se mostrou promissor como posição de início de captura. Dessa forma, é interessante que experimentos com o foco na identificação de indivíduos com maior resistência à ferrugem sejam feitos utilizando, preferencialmente, imagens da face abaxial das plantas, devendo sempre manter a padronização na coleta do folíolo e captura das imagens. Além disso, os dados também mostram que o efeito da aplicação de um fungicida pode ser visualizado utilizando a AACPD e que os dados de produtividade estão relacionados a mais fatores além dos sintomas de ferrugem.

4.5.3 Resultados Experimento 6: Caracterização e progênies de soja quanto à AACPD obtida por análise de imagem de folíolos usando o *software* NeChloDS

A partir dos experimentos 1, 2, 3, 4, foi possível desenvolver o *software* que permite analisar imagens de folíolos de soja infectados por FAS. Assim, avaliaram-se 64 genótipos de soja infectados naturalmente por faz, cujos resultados dos índices *RustIndex*, *NecrosisIndex* e *ChlorosisIndex* obtidos com imagens abaxial constam nos

Quadros 22, 23 e 24. Observou-se existência de efeito significativo ao nível de 5% de significância pelo teste F apenas para o índice *ChlorosisIndex*, evidenciando a importância em dividir a quantificação da infecção por FAS em dois índices (*NecrosisIndex* e *ChlorosisIndex*).

Quadro 22 - Análise de Variância da AACPD do *RustIndex* face abaxial

Fonte de Variação	G.L.	Q.M	p-valor
Genótipos	63	114781	0,2776
Resíduos	49	97484	

Fonte: Autoria própria.

Quadro 23 - Análise de Variância da AACPD do *NecrosisIndex* face abaxial

Fonte de Variação	G.L.	Q.M	p-valor
Genótipos	63	33099	0,2298
Resíduos	49	26986	

Fonte: Autoria própria.

Quadro 24 - Análise de Variância da AACPD do *ChlorosisIndex* face abaxial

Fonte de Variação	G.L.	Q.M	p-valor
Genótipos	63	101626	0,005188
Resíduos	49	49772	

Fonte: Autoria própria.

Pela análise de variância apresentada nos Quadros 22, 23 e 24, foi possível observar que não houve efeito significativo entre os genótipos para o *RustIndex* e *NecrosisIndex*, mas houve efeito significativo para o *ChlorosisIndex*, o que permitiu ranquear os genótipos de soja quanto à AACPD utilizando o índice *ChlorosisIndex*. Esse resultado está de acordo com o que é proposto na literatura, ou seja, cultivares com níveis de resistência vão apresentar manchas do tipo RB (*Reddish brown*), apresentando um índice menor de clorose (GODOY *et al.*, 2020).

A média de AACPD pelo índice variou de 801,80 a 2082,07, respectivamente, para as linhagens UFUFB_175_145_48 e UFUFB_39_33_16 (Quadro 25). Notou-se que os 64 genótipos foram distribuídos em dois grupos, sendo que aproximadamente 35% constituíram o grupo de menores estimativas de AACPD, sendo, portanto,

genótipos potenciais para resistência a FAS. Entre os genótipos do grupo de menores estimativas de AACPD, cerca de 57% são linhagens originadas de cruzamentos que envolveu a cultivar resistente BRSGO7560 (PIEROZZI *et al.*, 2008). Esse resultado corrobora com Lima *et al.* (2012), que constataram progênies de soja com resistência genética a FAS originadas da cultivar BRSGO7560.

Quadro 25 - AACPD do *ChlorosisIndex* da face abaxial de folíolos em 64 genótipos de soja cultivados em Uberlândia-MG sob condições de infecção natural por FAS

Genótipo	Média	Genótipo	Média
UFUFB_39_33_16	2082,07 a	UFUFB_30_27_14	1583,48 a
TUPI	2015,43 a	UFUFB_129_103_34	1559,29 a
UFUFB_165_135_42	1998,55 a	UFUFB_166_136_43	1547,52 a
UFUFB_13_12_6	1910,52 a	UFUFB_198_163_59	1545,44 a
UFUFB_23_21_12	1852,62 a	BRSGO7560	1543,71 a
UFUFB_8_8_3	1840,26 a	UFUFB_20_18_10	1540,71 a
UFUFB_41_35_17	1830,31 a	UFUFB_73_61_25	1513,22 a
UFUFB_72_60_24	1820,06 a	UFUFB_199_164_60	1493,52 a
UFUFB_24_22_13	1801,84 a	UFUFB_51_45_19	1491,57 a
UFUS 6901	1800,31 a	UFUFB_52_46_20	1477,19 b
UFUFB_186_152_54	1793,19 a	UFUFB_10_10_5	1474,21 b
UFUFB_174_144_47	1749,50 a	UFUFB_194_159_57	1469,11 b
UFUFB_189_154_55	1735,79 a	UFUFB_33_28_15	1445,36 b
UFUFB_132_106_37	1734,06 a	UFUFB_100_82_30	1442,53 b
TMG801	1717,72 a	UFUFB_96_79_29	1420,28 b
UFUFB_53_47_21	1714,56 a	UFUFB_17_15_8	1411,91 b
UFUFB_7_7_2	1693,14 a	UFUFB_184_150_52	1401,84 b
UFUFB_9_9_4	1689,38 a	UFUFB_180_147_50	1383,43 b
UFUFB_16_14_7	1685,72 a	UFUFB_173_143_46	1381,75 b
UFUFB_94_77_28	1681,98 a	UFUFB_172_142_45	1321,64 b
UFUFB_162_132_41	1667,76 a	UFUFB_191_156_56	1301,26 b
UFUFB_170_140_44	1663,75 a	UFUFB_178_146_49	1293,38 b
UFUFB_1_2_1	1654,65 a	UFUFB_21_19_11	1277,21 b
UFUFB_127_101_33	1654,08 a	UFUFB_79_66_26	1241,43 b
UFUFB_185_151_53	1640,92 a	UFUFB_151_124_39	1221,76 b
UFUFB_143_116_38	1635,69 a	UFUFB_196_161_58	1175,13 b
UFUFB_181_148_51	1634,59 a	UFUFB_113_89_31	1142,43 b
UFUFB_131_105_36	1634,08 a	UFUFB_66_56_22	1118,05 b
UFUFB_18_16_9	1633,93 a	UFUFB_130_104_35	1057,05 b
UFUFB_69_57_23	1621,25 a	UFUFB_47_41_18	1041,98 b
UFUFB_153_126_40	1616,04 a	UFUFB_118_93_32	960,22 b
UFUFB_92_75_27	1607,80 a	UFUFB_175_145_48	801,80 b

Médias com a mesma letra pertencem ao mesmo grupo homogêneo ao nível de 5% de significância pelo teste de Scott-Knott.

Fonte: Autoria própria.

Conforme apresentado nos Quadros 26, 27 e 28, quando analisadas as médias de AACPD para cada um dos índices, não houve efeito significativo entre os genótipos para a face adaxial. A análise da face adaxial, recorrentemente, apresenta médias inferiores às da face abaxial, conforme ilustrado na Figura 66.

Quadro 26 - Análise de Variância da AACPD do *RustIndex* face adaxial

Fonte de Variação	G.L.	Q.M	p-valor
Tratamento	63	24684	0,769
Resíduos	49	30007	

Fonte: Autoria própria.

Quadro 27 - Análise de Variância da AACPD do *NecrosisIndex* face adaxial

Fonte de Variação	G.L.	Q.M	p-valor
Tratamento	63	4818,0	0,727
Resíduos	49	5655,4	

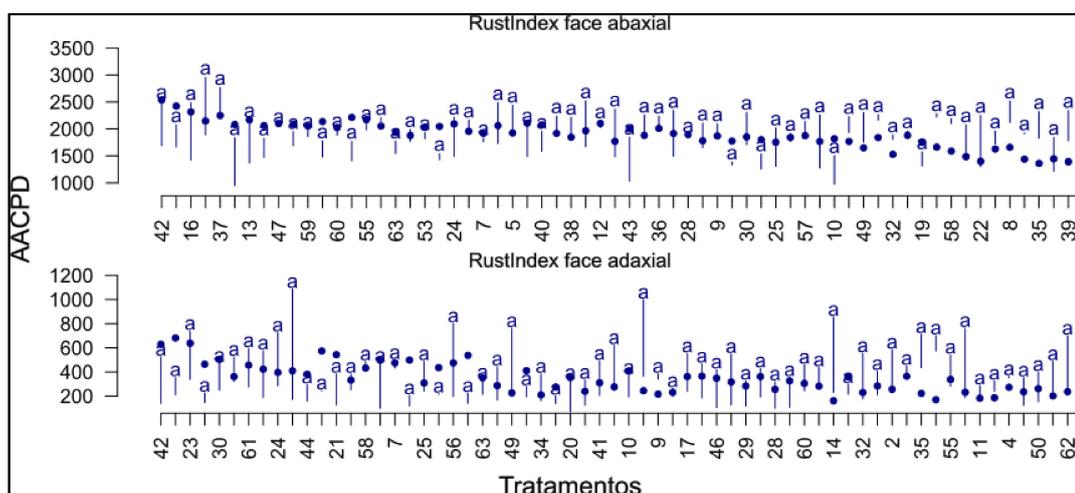
Fonte: Autoria própria.

Quadro 28 - Análise de Variância da AACPD do *ChlorosisIndex* face adaxial

Fonte de Variação	G.L.	Q.M	p-valor
Tratamento	63	17409	0,309
Resíduos	49	15156	

Fonte: Autoria própria.

Figura 66 - Média de AACPD para *RustIndex* faces adaxial e abaxial



Fonte: Autoria própria.

Os dados apresentados pela análise de variância do Experimento 6 indicam que existem genótipos com níveis de resistência dentre os analisados. A diferença entre as médias não foi significativa quando os índices são analisados de forma conjunta. Todavia, quando analisado somente o índice de clorose, existe diferença entre os genótipos. Isso reforça o conceito do método em dividir os sintomas em clorose e necrose, permitindo uma análise mais específica por parte do melhorista.

A análise de índices de forma separada pode auxiliar o melhorista a entender como foi a contaminação das plantas com base na quantidade de pústulas utilizando o *NecrosisIndex*. O fato de não haver diferença significativa nesse índice pode indicar que houve uma infecção uniforme entre as parcelas. Após a infecção, a evolução dos sintomas se dá por mais pontos de necrose e clorose do folíolo, que pode levar à desfolha, prejudicando a fotossíntese e reduzindo a produtividade da planta.

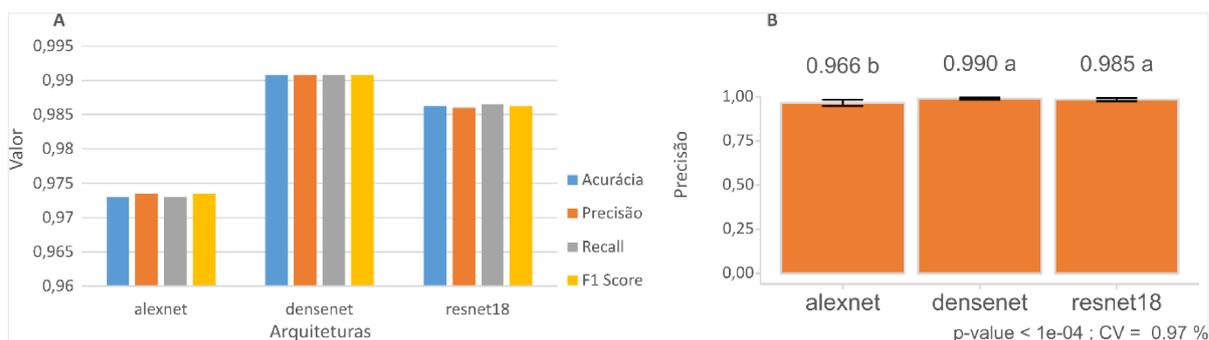
Desse modo, a análise de cada um dos índices pode indicar mais fatores além da severidade da infecção por FAS e pode ser combinada com outras variáveis como altura de plantas, acamamento e produtividade, permitindo uma seleção mais acurada dos genótipos superiores.

4.6 Resultado de análise de lesões utilizando Redes Neurais Convolucionais

Como etapa adicional do trabalho, foi proposta uma análise qualitativa do folíolo para verificar a existência de sintomas de múltiplos patógenos, considerando os sintomas de oídio e mancha olho-de-rã, que, recorrentemente, são verificadas durante etapas da evolução de gerações em processo de melhoramento. Essa análise consistiu na criação de um conjunto de dados a partir da segmentação de folíolos saudáveis e com sintomas, resultando em um *dataset* com imagens de ferrugem (2872), oídio (895), mancha olho-de-rã (913) e saudável (3882).

Para o treinamento, foi utilizado método “k-fold” da biblioteca “scikit-image” para fazer a divisão do *dataset* em 4 conjuntos contendo dados para as etapas de treinamento e validação. Foram treinadas as redes do tipo *alexnet*, *densenet* e *resnet18*.

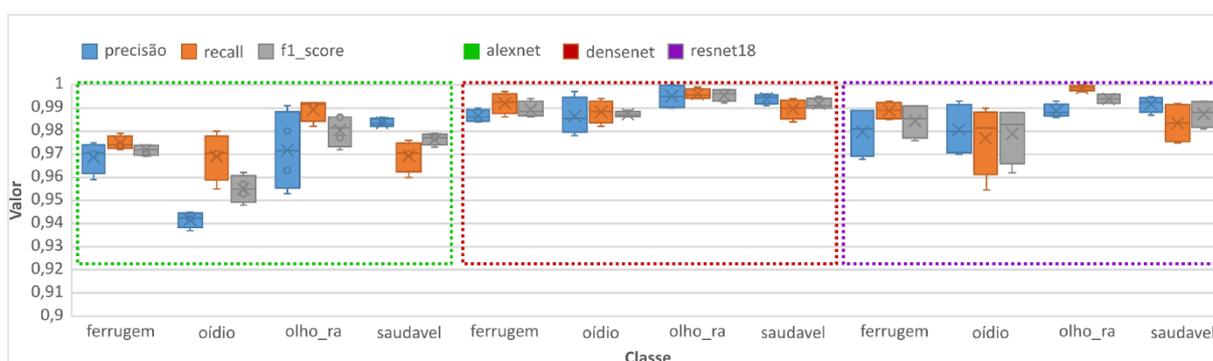
Figura 67 - Média de índices por arquitetura



Fonte: Autoria própria.

Está ilustrado na Figura 67A um gráfico que compara os valores médios dos índices de acurácia, precisão, recall e f1-score para cada uma das arquiteturas comparadas. É importante ressaltar que todas as arquiteturas obtiveram um índice f1-score maior que 0,97 mostrando, mas a arquitetura *densenet* se destacou com índices superiores a 0,98.

Figura 68 - Análise dos índices de precisão, recall e f1_score por classe e arquitetura



Fonte: Autoria própria.

Para ampliar o entendimento sobre os resultados obtidos, a análise dos índices de precisão e recall foi feita para cada uma das classes que compõe o *dataset*, de forma que o resultado está ilustrado na Figura 68. É possível perceber que, além da arquitetura *densenet* obter uma média maior, os resultados dela também mostram um desvio menor, principalmente em relação à classe oídio, como pode ser observado nos resultados da *alexnet*.

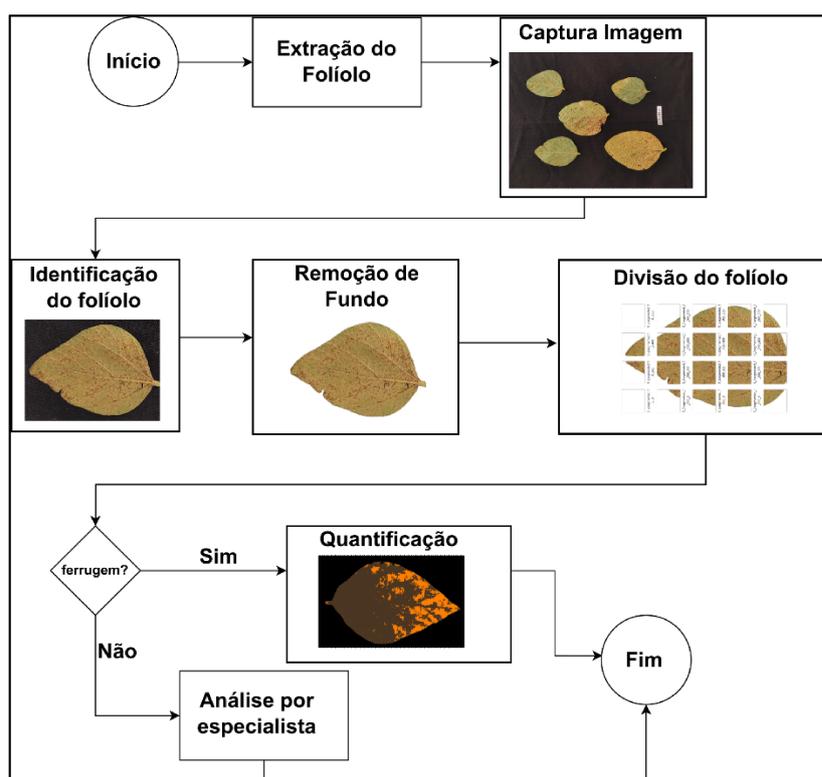
Quadro 29 - Análise de Variância da precisão

Fonte de Variação	G.L.	Q.M	p-valor
Arquitetura	2	$2,56 \cdot 10^{-3}$	$1,67 \cdot 10^{-8}$
Classe	3	$9,17 \cdot 10^{-4}$	$3,84 \cdot 10^{-5}$
Resíduos	42	$9,06 \cdot 10^{-5}$	

Fonte: Autoria própria.

A partir da análise de variância em DBC (Quadro 29) com a arquitetura como fator de variação e as classes como blocos, considerando como hipótese a ausência de interação entre a classe e arquitetura, obtém-se uma diferença significativa que pode ser observada no gráfico da Figura 67B, no qual as redes *densenet* e *resnet* tiveram o melhor desempenho.

Figura 69 - Diagrama de resumo dos resultados



Fonte: Autoria própria.

Considerando os resultados obtidos na classificação de sintomas em partes de fíoliolos pelo uso de uma Rede Neural Convolucional, uma nova etapa poderá ser

adicionada no processo proposto, que deverá anteceder a etapa de quantificação da ferrugem, conforme ilustrado de forma sumarizada na Figura 69. É importante ressaltar que essa aplicação consiste em uma etapa adicional, não obrigatória para a quantificação da FAS, de forma que o objetivo do presente trabalho está relacionado com a FAS.

As etapas da identificação de múltiplos patógenos antecederem as etapas ilustradas Figura 27, porém o folíolo com o fundo removido será utilizado na quantificação da doença. Essa etapa permite que o trabalho seja continuado na implementação de novos algoritmos para a quantificação de sintomas de oídio, mancha olho-de-rã, bem como outras doenças, de forma que a RNC será utilizada para definir de forma automática qual algoritmo será utilizado para a quantificação dos sintomas.

5 CONCLUSÕES

O presente trabalho permitiu desenvolver um método que possa ser aplicado no melhoramento genético da soja para a identificação de genótipos com nível de resistência à ferrugem asiática pela quantificação de sintomas em imagens de folíolos. A construção do método se iniciou por uma pesquisa sistemática do tipo estado da questão e um total de 289 artigos foi analisado de forma quantitativa e qualitativa, no qual verificou-se que imagens no formato RGB são largamente utilizadas juntamente com as Redes Neurais Convolucionais para a classificação de características em imagens nas áreas de Ciências Agrárias e Biológicas. Com isso, foi feito um experimento utilizando IA não supervisionada para encontrar os intervalos de cores que correspondem aos sintomas causados pela FAS.

Com a identificação dos intervalos de cores, foi possível criar um algoritmo para a quantificação de sintomas da FAS, que também apresenta como inovação a diferenciação de sintomas e o uso da distribuição dos sintomas no folíolo para a validação da ferrugem. Os resultados do algoritmo proposto foram comparados com resultados já validados no processo de criação de uma escala diagramática de sintomas de ferrugem, sendo encontrada uma correlação linear forte, acima de 0,9. O algoritmo, bem como todo o processo de criação, foi publicado (SILVA *et al.*, 2022). O *software* foi registrado no Instituto Nacional da Propriedade Industrial (BR512022002741-0).

Após a criação e publicação do algoritmo, foi feito um experimento com 3 cultivares no qual foram analisados os efeitos dos sintomas da ferrugem nas faces abaxial e adaxial, no terço médio e superior da planta de soja, com e sem a aplicação de fungicidas. Com esse experimento, foi possível constatar que a face abaxial, no terço médio, possui maior sensibilidade aos sintomas de ferrugem. Além disso, foi possível verificar o efeito de três aplicações de fungicida na AACPD calculada pelo *software*.

O *software* e o método proposto foram utilizados para a captura de imagens e quantificação de sintomas em um experimento de avanço de geração de duas populações F2:6. Nesse experimento, foi possível identificar genótipos com menores índices de clorose, que sugerem nível de resistência à FAS.

Ao final, foi proposto o uso de uma Rede Neural Convolucional para identificar e classificar sintomas de múltiplos patógenos (ferrugem, oídio e mancha olho-de-rã). Essa etapa adicional contribuiu para aumentar a confiabilidade do método e permite a continuidade do trabalho para a implementação de novos algoritmos para a quantificação dos sintomas de oídio, mancha olho-de-rã e outras doenças, por meio dos processos já utilizados para a ferrugem, o que foi o foco do presente trabalho. Entretanto, ampliar a quantidade de sintomas passíveis de serem quantificados demanda a execução de outros experimentos em campo.

Por fim, além das contribuições supracitadas, como a revisão bibliográfica sobre o tema, o método de seleção de intervalos de cores de sintomas foliares, o algoritmo publicado para quantificação de FAS, o *software* para a quantificação dos sintomas de FAS em folíolos de soja, o método de captura de imagens em experimentos de campo e o método de classificação de sintomas de múltiplos patógenos, é importante destacar o treinamento da Rede Neural do tipo Yolov5 para a identificação de folíolos de soja em imagens, que permitiu mais de um folíolo por captura, reduzindo o número de imagens. Foram gerados, ao longo do trabalho, diversos conjuntos de imagem: 600 folíolos com diferentes níveis de FAS, 60 imagens com a evolução dos sintomas de FAS em folíolos destacados, mais de 6000 imagens de folíolos de 4 épocas de semeadura com diferentes níveis de sintomas, 1536 imagens em experimento de melhoramento genético, 250 imagens divididas em sintomas de FAS, oídio e mancha olho-de-rã e 8562 imagens de partes de folíolos com sintomas causados por FAS, oídio e mancha olho-de-rã.

REFERÊNCIAS

ACHANTA, R. *et al.* SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v. 34, n. 11, p. 2274–2282, 2012. DOI: <https://doi.org/10.1109/TPAMI.2012.120>. Disponível em: <https://ieeexplore.ieee.org/document/6205760>. Acesso em: 2 nov. 2022.

ACQUAAH, G. Overview and historical perspectives. *In*: ACQUAAH, G. **Principles of Plant Genetics and Breeding**. Maryland: George Acquaah, 2012. p. 1-22.

AGGARWAL, C. C. An Introduction to Neural Networks. *In*: AGGARWAL, C. C. (Org.). **Neural Networks and Deep Learning: A Textbook**. Cham: Springer International Publishing, 2018. p. 1–52. DOI: https://doi.org/10.1007/978-3-319-94463-0_1. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-94463-0_1. Acesso em: 2 nov. 2022.

AGROBAYER. Monsoy 7739. **Agro Bayer Brasil**, São Paulo, 2022. Disponível em: <https://www.agro.bayer.com.br/essenciais-do-campo/sementes/monsoy/m-7739-ipro>. Acesso em: 12 ago. 2022.

AL-AHMADI, A. H. *et al.* Detection of charcoal rot (*Macrophomina phaseolina*) toxin effects in soybean (*Glycine max*) seedlings using hyperspectral spectroscopy. **Computers and Electronics in Agriculture**, [s. l.], v. 150, p. 188–195, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.04.013>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917311638>. Acesso em: 2 nov. 2022.

ALMEIDA, A. M. R. *et al.* Characterization of powdery mildews strains from soybean, bean, sunflower, and weeds in Brazil using rDNA-ITS sequences. **Tropical Plant Pathology**, Brasília, v. 33, n. 1, p. 20–26, 2008. DOI: <https://doi.org/10.1590/S1982-56762008000100004>. Disponível em: <https://www.scielo.br/j/tpp/a/vXLvz8GcG3KjWws5CFKWFNv>. Acesso em: 2 nov. 2022.

ALMEIDA, A. M. R. *et al.* Doenças da Soja. *In*: KIMATI, H. *et al.* (Orgs.). **Manual de Fitopatologia: Doenças das Plantas Cultivadas**. 3. ed. São Paulo: Editora Agronômica CERES, 1997. p. 596–619. (Agronômica Ceres, v. 2).

ALMEIDA, R.; FORCELINI, C. A.; FIALLOS, F. R. G. Chemical control of foliar diseases in soybean depends on cultivar and sowing date. **Bioscience Journal**, Uberlândia, v. 33, n. 5, p. 1188–1196, 2017. DOI: <https://doi.org/10.14393/BJ-v33n5a2017-36931>. Disponível em: <https://seer.ufu.br/index.php/biosciencejournal/article/view/36931>. Acesso em: 2 nov. 2022.

ALVES, D. P. *et al.* Artificial neural network for prediction of the area under the disease progress curve of tomato late blight. **Scientia Agricola**, Piracicaba, v. 74, n.

1, p. 51–59, 2017. DOI: <https://doi.org/10.1590/1678-992X-2015-0309>. Disponível em: <https://www.scielo.br/j/sa/a/s6rPhSVH9VPC7KqyS3ZpvrP>. Acesso em: 2 nov. 2022.

AQUINO, A. *et al.* Automated early yield prediction in vineyards from on-the-go image acquisition. **Computers and Electronics in Agriculture**, [s. l.], v. 144, p. 26–36, 2018. DOI: <https://doi.org/10.1016/j.compag.2017.11.026>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917303964>. Acesso em: 2 nov. 2022.

ARSHAM, H.; LOVRIC, M. Bartlett's Test. *In*: LOVRIC, M. (Org.). **International Encyclopedia of Statistical Science**. Berlin: Springer, 2011. p. 87–88. DOI: https://doi.org/10.1007/978-3-642-04898-2_132. Disponível em: https://link.springer.com/referenceworkentry/10.1007/978-3-642-04898-2_132. Acesso em: 17 ago. 2022.

ASHOURLOO, D. *et al.* A novel method for automatic potato mapping using time series of Sentinel-2 images. **Computers and Electronics in Agriculture**, [s. l.], v. 175, p. 105583, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105583>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169920314940>. Acesso em: 2 nov. 2022.

AZAD, M. M.; HASAN, M.; NASEER, M. Color Image Processing in Digital Image. **International Journal of New Technology and Research**, Jaipur, v. 3, n. 3, p. 56–62, 2017. Disponível em: <https://www.ijntr.org/color-image-processing-in-digital-image>. Acesso em: 8 abr. 2020.

BAI, G. *et al.* A multi-sensor system for high throughput field phenotyping in soybean and wheat breeding. **Computers and Electronics in Agriculture**, [s. l.], v. 128, p. 181–192, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.08.021>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169916302289>. Acesso em: 3 nov. 2022.

BAKHSIPOUR, A.; JAFARI, A. Evaluation of support vector machine and artificial neural networks in weed detection using shape features. **Computers and Electronics in Agriculture**, [s. l.], v. 145, p. 153–160, 2018. DOI: <https://doi.org/10.1016/j.compag.2017.12.032>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917301333>. Acesso em: 3 nov. 2022.

BASF. SoyTech 721. **BASF**, São Paulo, 2022. Disponível em: <https://agriculture.basf.com/br/pt/protecao-de-cultivos-e-sementes/produtos/soytech/SoyTech/ST-721-IPRO.html>. Acesso em: 12 ago. 2022.

BONDE, M. R. *et al.* Evaluation of Virulence of *Phakopsora pachyrhizi* and *P. meibomia* Isolates. **Plant Disease**, [s. l.], v. 90, n. 6, p. 708–716, 2006. DOI:

<https://doi.org/10.1094/pd-90-0708>. Disponível em:
<https://pubmed.ncbi.nlm.nih.gov/30781228/>. Acesso em: 3 nov. 2022.

BORGES, D. L. *et al.* Detecting and grading severity of bacterial spot caused by *Xanthomonas* spp. in tomato (*Solanum lycopersicon*) fields using visible spectrum images. **Computers and Electronics in Agriculture**, [s. l.], v. 125, p. 149–159, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.05.003>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0168169916302204>. Acesso em: 3 nov. 2022.

BORIANNE, P. *et al.* GT-RootS: An integrated software for automated root system measurement from high-throughput phenotyping platform images. **Computers and Electronics in Agriculture**, [s. l.], v. 150, p. 328–342, 2018. DOI:
<https://doi.org/10.1016/j.compag.2018.05.003>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0168169916311437>. Acesso em: 3 nov. 2022.

BOSE, R. C.; NAIR, K. R. Partially Balanced Incomplete Block Designs. **Sankhyā: The Indian Journal of Statistics (1933-1960)**, [s. l.], v. 4, n. 3, p. 337–372, 1939. Disponível em: <https://www.jstor.org/stable/40383923>. Acesso em: 3 nov. 2022.

BRADLEY, P. S.; FAYYAD, U. M. Refining Initial Points for K-Means Clustering. *In*: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 15., 1998, San Francisco. **Anais** [...]. San Francisco: Morgan Kaufmann Publishers Inc., 1998. p. 91–99.

BRASIL. Companhia Nacional de Abastecimento. Safra 2022/23: Produção de grãos pode chegar a 308 milhões de t impulsionada pela boa rentabilidade de milho, soja e algodão. **Conab**, Brasília, 24 ago. 2022. Disponível em:
<https://www.conab.gov.br/ultimas-noticias/4731-safra-2022-23-producao-de-graos-pode-chegar-a-308-milhoes-de-toneladas-impulsionada-pela-boia-rentabilidade-de-milho-soja-e-algodao>. Acesso em: 27 set. 2022.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Instruções para execução dos ensaios de distinguibilidade, homogeneidade e estabilidade de cultivares de soja (*glycine max* (l.) merrill). **Site do Ministério da Agricultura, Pecuária e Abastecimento**, Brasília, 2009. Disponível em:
<https://www.gov.br/agricultura/pt-br/assuntos/insumos-agropecuarios/insumos-agricolas/protecao-de-cultivar/agricolas>. Acesso em: 9 jun. 2022.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária. **Portaria nº 388, de 31 de agosto de 2021**. Altera a Portaria nº 306, de 13 de maio de 2021, que institui o Programa Nacional de Controle da Ferrugem Asiática da Soja -*Phakopsora pachyrhizi* (PNCFS). **Diário Oficial da União**: seção 1, Brasília, DF, n. 166, p. 23, 31 ago. 2021a. Disponível em:
<https://www.in.gov.br/en/web/dou/-/portaria-n-388-de-31-de-agosto-de-2021-341897292>. Acesso em: 6 nov. 2022.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Política Agrícola. Instrução Normativa SPA/MAPA nº 1, de 9 de novembro de 2021. Estabelece as macrorregiões sojícolas e respectivas regiões edafoclimáticas para fins de indicação de cultivares de soja no Zoneamento Agrícola de Risco Climático - ZARC. **Diário Oficial da União**: seção 1, Brasília, DF, n. 212, p. 12, 11 nov. 2021b. Disponível em: <https://www.in.gov.br/web/dou/-/instrucao-normativa-spa/mapa-n-1-de-9-de-novembro-de-2021-358997272>. Acesso em: 6 nov. 2022.

BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, [s. l.], v. 76, n. 2, p. 156–172, 2001. DOI: [https://doi.org/10.1016/S0034-4257\(00\)00197-8](https://doi.org/10.1016/S0034-4257(00)00197-8). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425700001978>. Acesso em: 3 nov. 2022.

BROWN, M. B.; FORSYTHE, A. B. Robust Tests for the Equality of Variances. **Journal of the American Statistical Association**, [s. l.], v. 69, n. 346, p. 364–367, 1974. DOI: <https://doi.org/10.1080/01621459.1974.10482955>. Disponível em: <https://www.jstor.org/stable/2285659>. Acesso em: 3 nov. 2022.

BURGER, W.; BURGE, M. J. Colorimetric Color Spaces. *In*: BURGER, W.; BURGE, M. J. **Principles of Digital Image Processing: Core Algorithms**. 1. ed. Londres: Springer London, 2009. p. 97-124.

CARPENTIERI-PIPOLO, V. *et al.* Herança de hilo esparramado em sementes de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, n. 1, p. 127-129, 2007. DOI: <https://doi.org/10.1590/S0100-204X2007000100017>. Disponível em: <https://www.scielo.br/j/pab/a/XjR8rLDTxnM47bpBckPKh6q>. Acesso em: 29 abr. 2020.

CASAGRANDE, E. C. *et al.* Expressão gênica diferencial durante déficit hídrico em soja. **Revista Brasileira de Fisiologia Vegetal**, Campinas, v. 13, n. 2, p. 168-184, 2001. DOI: <https://doi.org/10.1590/S0103-31312001000200006>. Disponível em: <https://www.scielo.br/j/rbfv/a/Tqv3r47yJSDp6zhTSpFz5Jw>. Acesso em: 17 nov. 2022.

CHARYTANOWICZ, M. *et al.* An evaluation of utilizing geometric features for wheat grain classification using X-ray images. **Computers and Electronics in Agriculture**, [s. l.], v. 144, p. 260–268, 2018. DOI: <https://doi.org/10.1016/j.compag.2017.12.004>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917301990>. Acesso em: 3 nov. 2022.

CHILDS, S. P. *et al.* Discovery of a seventh Rpp soybean rust resistance locus in soybean accession PI 605823. **Theoretical and Applied Genetics**, [s. l.], v. 131, n. 1, p. 27-41, 2018. DOI: <https://doi.org/10.1007/s00122-017-2983-4>. Disponível em: <https://link.springer.com/article/10.1007/s00122-017-2983-4>. Acesso em: 17 nov. 2022.

CRANG, R.; LYONS-SOBASKI, S.; WISE, R. Plant Cell Structure and Ultrastructure. *In: CRANG, R.; LYONS-SOBASKI, S.; WISE, R. (Orgs.). Plant Anatomy: A Concept-Based Approach to the Structure of Seed Plants.* Cham: Springer International Publishing, 2018. p. 77-121.

CRUZ, C. *et al.* Impact of Brown Spot Caused by *Septoria glycines* on Soybean in Ohio. **Plant Disease**, [s. l.], v. 94, n. 7, p. 820–826, 2010. DOI: <https://doi.org/10.1094/pdis-94-7-0820>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30743556/>. Acesso em: 3 nov. 2022.

CRUZ, M. F. A. *et al.* Reação de genótipos de soja à infecção natural por ferrugem asiática. **Pesquisa Agropecuária Brasileira**, Brasília, v. 46, n. 2, p. 215-218, 2011. DOI: <https://doi.org/10.1590/S0100-204X2011000200015>. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2011000200015&lng=en&nrm=iso. Acesso em: 20 abr. 2020.

DALLA LANA, F. *et al.* Meta-Analytic Modeling of the Decline in Performance of Fungicides for Managing Soybean Rust after a Decade of Use in Brazil. **Plant Disease**, [s. l.], v. 102, n. 4, p. 807–817, 2018. DOI: <https://doi.org/10.1094/PDIS-03-17-0408-RE>. Disponível em: <https://apsjournals.apsnet.org/doi/full/10.1094/PDIS-03-17-0408-RE>. Acesso em: 18 dez. 2022.

DANTAS, S. A. G. *et al.* Melhoramento para Tolerância a Estresses Abióticos. *In: SILVA, F. et al. (Orgs.). Melhoramento da Soja.* 1. ed. Viçosa: Editora UFV, 2017. p. 457–478. (v. 1).

DAS, S. *et al.* A High-Throughput Phenotyping Pipeline for Rapid Evaluation of Morphological and Physiological Crop Traits Across Large Fields. *In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM*, 42., 2022, Kuala Lumpur. **Anais [...]**. Kuala Lumpur: IGARSS, 2022. p. 7783–7786.

DEL PONTE, E. M. Plant Disease Severity Annotation Image Database. **OSF**, [s. l.], 2020. DOI: <https://doi.org/10.17605/OSF.IO/3HSGC>. Disponível em: <https://osf.io/3hsgc/>. Acesso em: 5 nov. 2020.

DO VALE, F. X. R. *et al.* Quant-A software to quantify plant disease severity. *In: INTERNATIONAL WORKSHOP ON PLANT DISEASE EPIDEMIOLOGY*, 8., 2001, Ouro Preto. **Anais [...]**. Ouro Preto: [s. n.], 2001. p. 161.

EBRAHIMI, M. A. *et al.* Vision-based pest detection based on SVM classification method. **Computers and Electronics in Agriculture**, [s. l.], v. 137, p. 52–58, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.03.016>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816991631136X>. Acesso em: 3 nov. 2022.

FEHR, W. R. Role of Plant Breeding Agriculture. *In: FEHR, W. R. Principles of Cultivar Development: Theory and Technique.* [S. l.: s. n.], 1987. p. 1-8.

FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. Efficient Graph-Based Image Segmentation. **International Journal of Computer Vision**, [s. l.], v. 59, n. 2, p. 167–181, 2004. DOI: <https://doi.org/10.1023/B:VISI.0000022288.19776.77>. Disponível em: <https://link.springer.com/article/10.1023/B:VISI.0000022288.19776.77>. Acesso em: 6 nov. 2022.

FERREIRA, A. S. *et al.* Weed detection in soybean crops using ConvNets. **Computers and Electronics in Agriculture**, [s. l.], v. 143, p. 314–324, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.10.027>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917301977>. Acesso em: 6 nov. 2022.

FERREIRA, P. V. Delineamento em Blocos Casualizados. *In*: FERREIRA, P. V. **Estatística Experimental Aplicada às Ciências Agrárias**. Viçosa: Editora UFV, 2018a. p. 145–172.

FERREIRA, P. V. Experimentos Fatoriais. *In*: FERREIRA, P. V. **Estatística Experimental Aplicada às Ciências Agrárias**. Viçosa: Editora UFV, 2018b. p. 218–294.

FRANCESCHI, V. T. *et al.* A new standard area diagram set for assessment of severity of soybean rust improves accuracy of estimates and optimizes resource use. **Plant Pathology**, [s. l.], v. 69, n. 3, p. 495–505, 2020. DOI: <https://doi.org/10.1111/ppa.13148>. Disponível em: <https://bsppjournals.onlinelibrary.wiley.com/doi/abs/10.1111/ppa.13148>. Acesso em: 6 nov. 2022.

FREEDMAN, D.; PISANI, R.; PURVES, R. **Statistics**. 4. ed. New York: WW Norton & Company, 2007. p. 119-158.

GODOY, C. V. *et al.* Asian soybean rust in Brazil: past, present, and future. **Pesquisa Agropecuária Brasileira**, Brasília, v. 51, n. 5, p. 407- 421, 2016. DOI: <https://doi.org/10.1590/S0100-204X2016000500002>. Disponível em: <https://www.scielo.br/j/pab/a/X34LY9zyrpFmh6y59syDsRx/>. Acesso em: 24 abr. 2020.

GODOY, C. V. *et al.* **Boas práticas para o enfrentamento da ferrugem-asiática da soja**. Londrina: Embrapa Soja, 2017. (Comunicado Técnico n. 92). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/163428/1/ComTec92-OL.pdf>. Acesso em: 23 abr. 2020.

GODOY, C. V. *et al.* Eficiência do controle da ferrugem asiática da soja em função do momento de aplicação sob condições de epidemia em Londrina, PR. **Tropical Plant Pathology**, Brasília, v. 34, n. 1, p. 56–61, 2009. DOI: <https://doi.org/10.1590/S1982-56762009000100011>. Disponível em: <https://www.scielo.br/j/tpp/a/PPXW3bygBjZhrKvktMzMhmq>. Acesso em: 6 nov. 2022.

GODOY, C. V. *et al.* **Ferrugem-asiática da soja**: bases para o manejo da doença e estratégias antirresistência. Londrina: Embrapa Soja, 2020. (Documentos / Embrapa Soja, ISSN 2176-2937, n. 428).

GODOY, C. V.; KOGA, L. J.; CANTERI, M. G. Diagrammatic scale for assessment of soybean rust severity. **Fitopatologia Brasileira**, Brasília, v. 31, n. 1, p. 63-68, 2006. DOI: <https://doi.org/10.1590/S0100-41582006000100011>. Disponível em: <https://www.scielo.br/j/fb/a/7zsWfRPH6xXNGHjsS4ZSNwN/>. Acesso em: 20 abr. 2020.

GOMES, F. P.; GARCIA, C. H. Experimentos em látice: planejamento e análise por meio de “pacotes” estatísticos. **Série Técnica IPEF**, Piracicaba, v. 7, n. 23, p. 1-69, 1991. Disponível em: <https://www.ipef.br/publicacoes/stecnica/nr23/cap01.pdf>. Acesso em: 6 nov. 2022.

GONÇALVES, J. P. *et al.* Deep learning architectures for semantic segmentation and automatic estimation of severity of foliar symptoms caused by diseases or pests. **Biosystems Engineering**, [s. l.], v. 210, p. 129–142, 2021. DOI: <https://doi.org/10.1016/j.biosystemseng.2021.08.011>. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1134326/deep-learning-architectures-for-semantic-segmentation-and-automatic-estimation-of-severity-of-foliar-symptoms-caused-by-diseases-or-pests>. Acesso em: 6 nov. 2022.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital Image Processing Using MATLAB**. 3. ed. [S. l.]: Pearson Education, 2004. p. 194-237.

HE, K. *et al.* Deep Residual Learning for Image Recognition. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 29., 2016, Las Vegas. **Anais** [...]. Las Vegas: [s. n.], 2016. p. 770–778.

HENNING A. A. *et al.* **Manual de identificação de doenças de soja**. Londrina: Embrapa Soja, 2014. (Documentos / Embrapa Soja, ISSN 1516-781X, n. 256). Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/991687/manual-de-identificacao-de-doencas-de-soja>. Acesso em: 23 abr. 2020.

HUANG, G. *et al.* Densely Connected Convolutional Networks. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 30., 2017, Honolulu. **Anais** [...]. Honolulu: [s. n.], 2017. p. 2261–2269.

HUNT, E. R. *et al.* A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 21, p. 103–112, 2013. DOI: <https://doi.org/10.1016/j.jag.2012.07.020>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0303243412001791>. Acesso em: 6 nov. 2022.

ISO/CIE 11664-4:2019. [CIE LEAD] **Colorimetry Part 4: CIE 1976 L*a*b* colour space**. Geneva: [s. n.], 2019. Disponível em: <https://www.iso.org/standard/74166.html>. Acesso em: 8 abr. 2020.

ISO/CIE 11664-5:2016. [CIE LEAD] **Colorimetry Part 5: CIE 1976 L*u*v* colour space and u', v' uniform chromaticity scale diagram**. Geneva: [s. n.], 2016. Disponível em: <https://www.iso.org/standard/69034.html>. Acesso em: 8 abr. 2020.

JOCHER, G. *et al.* **ultralytics/yolov5: v6.1 - TensorRT, TensorFlow Edge TPU and OpenVINO Export and Inference (Software)**. [S. l.]: Zenodo, 2022. DOI: <https://doi.org/10.5281/zenodo.6222936>. Disponível em: <https://zenodo.org/record/6222936#.Y2fy1HbMLUQ>. Acesso em: 6 nov. 2022.

JOHANNES, A. *et al.* Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. **Computers and Electronics in Agriculture**, [s. l.], v. 138, p. 200–209, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.04.013>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816991631050X>. Acesso em: 6 nov. 2022.

JULIATTI, F. C. *et al.* Caracterização de genótipos de soja com resistência parcial à ferrugem da soja. **Summa Phytopathologica**, Botucatu, v. 45, n. 3, p. 313-319, 2019. DOI: <https://doi.org/10.1590/0100-5405/190552>. Disponível em: <https://www.scielo.br/j/sp/a/3s8rpZmvxf9hwRmLW5x37TJ>. Acesso em: 24 abr. 2020.

JULIATTI, F. C. *et al.* Como e quando aplicar fungicidas na cana. **Revista Cultivar**, Pelotas, 2 jun. 2020. Disponível em: <http://www.grupocultivar.com.br/noticias/como-e-quando-aplicar-fungicidas-na-cana>. Acesso em: 5 ago. 2020.

KAZMI, W. *et al.* Exploiting affine invariant regions and leaf edge shapes for weed detection. **Computers and Electronics in Agriculture**, [s. l.], v. 118, p. 290–299, 2015. DOI: <https://doi.org/10.1016/j.compag.2015.08.023>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169915002495>. Acesso em: 6 nov. 2022.

KIM, D. H. *et al.* Fine mapping of a resistance gene to bacterial leaf pustule in soybean. **Theoretical and Applied Genetics**, [s. l.], v. 120, n. 7, p. 1443-1450, 2010. DOI: <https://doi.org/10.1007/s00122-010-1266-0>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20087567/>. Acesso em: 17 nov. 2022.

KOMATSU, K. *et al.* Quantitative trait loci mapping of pubescence density and flowering time of insect-resistant soybean (*Glycine max* L. Merr.). **Genetics and Molecular Biology**, São Paulo, v. 30, n. 3, p. 635-639, 2007. DOI: <https://doi.org/10.1590/S1415-47572007000400022>. Disponível em: <https://www.scielo.br/j/gmb/a/8GQsfgfD3JqB8KQtMfrmHKq>. Acesso em: 29 abr. 2020.

KOSHCHAN, A.; ABIDI, M. Color Spaces and Color Distances. *In*: KOSHCHAN, A.; ABIDI, M. **Digital Color Image Processing**. Hoboken: Wiley, 2008. p. 37–70. (Imaging Systems & Technology).

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet Classification with Deep Convolutional Neural Networks. *In*: PEREIRA, F. *et al* (Orgs.). **Advances in Neural Information Processing Systems**. Atlanta: Curran Associates Inc., 2012. p. 1-9.

KUBAT, M. Unsupervised Learning. *In*: KUBAT, M. **An Introduction to Machine Learning**. 2. ed. Berlim: Springer, 2017. p. 273-295. Disponível em: <https://link.springer.com/book/10.1007/978-3-319-63913-0>. Acesso em: 23 jun. 2022.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, [s. l.], v. 521, n. 7553, p. 436–444, 2015. DOI: <https://doi.org/10.1038/nature14539>. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 18 nov. 2022.

LECUN, Y. *et al*. Backpropagation Applied to Handwritten Zip Code Recognition. **Neural Computation**, [s. l.], v. 1, n. 4, p. 541–551, 1989. DOI: <https://doi.org/10.1162/neco.1989.1.4.541>. Disponível em: <https://ieeexplore.ieee.org/document/6795724>. Acesso em: 6 nov. 2022.

LECUN, Y. *et al*. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, [s. l.], v. 86, n. 11, p. 2278–2324, 1998. DOI: <https://doi.org/10.1109/5.726791>. Disponível em: <https://ieeexplore.ieee.org/document/726791>. Acesso em: 6 nov. 2022.

LEVY, C. Epidemiology and Chemical Control of Soybean Rust in Southern Africa. **Plant Disease**, [s. l.], v. 89, n. 6, p. 669–674, 2005. DOI: <https://doi.org/10.1094/PD-89-0669>. Disponível em: <https://apsjournals.apsnet.org/doi/10.1094/PD-89-0669>. Acesso em: 6 nov. 2022.

LIMA, W. F. *et al*. Metodologias para obtenção de resistência e/ou tolerância da soja à ferrugem-asiática. **Summa Phytopathologica**, Botucatu, v. 38, p. 67-72, 2012. DOI: <https://doi.org/10.1590/S0100-54052012000100011>. Disponível em: <https://www.scielo.br/j/sp/a/YrZQDYwhCDp8xpffjQ8Ndhj>. Acesso em: 17 nov. 2022.

LIN, H.-A.; MIDEROS, S. X. Accurate quantification and detection of *Septoria glycines* in soybean using quantitative PCR. **Current Plant Biology**, [s. l.], v. 25, p. 100-192, 2021. DOI: <https://doi.org/10.1016/j.cpb.2020.100192>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214662820300736>. Acesso em: 6 nov. 2022.

LIN, H.-A.; VILLAMIL, M. B.; MIDEROS, S. X. Characterization of *Septoria brown spot* disease development and yield effects on soybean in Illinois. **Canadian Journal of Plant Pathology**, [s. l.], v. 43, n. 1, p. 62–72, 2021. DOI: <https://doi.org/10.1080/07060661.2020.1755366>. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/07060661.2020.1755366>. Acesso em: 6 nov. 2022.

LIU, S. *et al.* A computer vision system for early stage grape yield estimation based on shoot detection. **Computers and Electronics in Agriculture**, [s. l.], v. 137, p. 88–101, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.03.013>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916311334>. Acesso em: 6 nov. 2022.

LIU, W. *et al.* High-Throughput Phenotyping of Morphological Seed and Fruit Characteristics Using X-Ray Computed Tomography. **Frontiers in Plant Science**, [s. l.], v. 11, p. 1-10, 2020. DOI: <https://doi.org/10.3389/fpls.2020.601475>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2020.601475/full>. Acesso em: 6 nov. 2022.

LU, H. *et al.* Fine-grained maize tassel trait characterization with multi-view representations. **Computers and Electronics in Agriculture**, [s. l.], v. 118, p. 143–158, 2015. DOI: <https://doi.org/10.1016/j.compag.2015.08.027>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169915002537>. Acesso em: 6 nov. 2022.

MACHADO, B. B. *et al.* BioLeaf: A professional mobile application to measure foliar damage caused by insect herbivory. **Computers and Electronics in Agriculture**, [s. l.], v. 129, p. 44–55, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.09.007>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916307670>. Acesso em: 6 nov. 2022.

MACK, J. *et al.* Semantic labeling and reconstruction of grape bunches from 3D range data using a new RGB-D feature descriptor. **Computers and Electronics in Agriculture**, [s. l.], v. 155, p. 96–102, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.10.011>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918309554>. Acesso em: 6 nov. 2022.

MARSCHALEK, R. *et al.* Image - Rice Grain Scanner: a three-dimensional fully automated assessment of grain size and quality traits. **Crop Breeding and Applied Biotechnology**, Viçosa, v. 17, p. 89–97, 2017. DOI: <https://doi.org/10.1590/1984-70332017v17n1s15>. Disponível em: <https://www.scielo.br/j/cbab/a/cC9TbHnJgqq6Km6mXpNBnRv/?lang=en>. Acesso em: 6 nov. 2022.

MARTINS, J. A. S.; JULIATTI, F. C. Genetic control of partial resistance to Asian soybean rust. **Acta Scientiarum Agronomy**, Maringá, v. 36, n. 1, p. 11-17, 2014. DOI: <https://doi.org/10.4025/actasciagron.v36i1.16919>. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1807-86212014000100003&lng=en&nrm=iso. Acesso em: 20 abr. 2020.

MATSUO, E.; FERREIRA, P. A.; SEDIYAMA, T. Resistência a Doenças. *In*: SILVA, F. et al. (Orgs.). **Melhoramento da Soja**. 1. ed. Viçosa: Editora UFV, 2017. p. 418–447. (v. 1).

MICHEREFF, S. J. *et al.* Elaboração e validação de escala diagramática para a cercosporiose do pimentão. **Summa Phytopathologica**, Botucatu, v. 32, n. 3, p. 260–266, 2006. DOI: <https://doi.org/10.1590/S0100-54052006000300008>. Disponível em: <https://www.scielo.br/j/sp/a/TbdCHSxFBFtc55rBXtjH5qJ>. Acesso em: 20 abr. 2020.

MILADINOVIC, J. *et al.* Soybean breeding: comparison of the efficiency of different selection methods. **Turkish Journal of Agriculture and Forestry**, Ankara, v. 35, n. 5, p. 469–480, 2011. DOI: <https://doi.org/10.3906/tar-1011-1474>. Disponível em: <https://journals.tubitak.gov.tr/agriculture/vol35/iss5/3/>. Acesso em: 6 nov. 2022.

MOHD ASAARI, M. S. *et al.* Close-range hyperspectral image analysis for the early detection of stress responses in individual plants in a high-throughput phenotyping platform. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s. l.], v. 138, p. 121–138, 2018. DOI: <https://doi.org/10.1016/j.isprsjprs.2018.02.003>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271618300327>. Acesso em: 6 nov. 2022.

MUELLER, T. A. *et al.* Effect of Fungicide and Timing of Application on Soybean Rust Severity and Yield. **Plant Disease**, [s. l.], v. 93, n. 3, p. 243–248, 2009. DOI: <https://doi.org/10.1094/PDIS-93-3-0243>. Disponível em: <https://apsjournals.apsnet.org/doi/10.1094/PDIS-93-3-0243>. Acesso em: 6 nov. 2022.

MUNDSTOCK, C. M.; THOMAS, A. L. **Soja**: fatores que afetam o crescimento e o rendimento de grãos. 1. ed. Porto Alegre: Departamento de Plantas de Lavoura da Universidade Federal do Rio Grande do Sul: Evangraf, 2005.

NEUBERT, P.; PROTZEL, P. Compact Watershed and Preemptive SLIC: On Improving Trade-offs of Superpixel Segmentation Algorithms. *In*: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 22., 2014, Stockholm. **Anais [...]**. Stockholm: [s. n.], 2014. p. 996–1001. DOI: <https://doi.org/10.1109/ICPR.2014.181>. Disponível em: <https://ieeexplore.ieee.org/document/6976891>. Acesso em: 17 nov. 2022.

NGUYEN, G. *et al.* Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. **Artificial Intelligence Review**, [s. l.], v. 52, n. 1, p. 77–124, 2019. DOI: <https://doi.org/10.1007/s10462-018-09679-z>. Disponível em: <https://link.springer.com/article/10.1007/s10462-018-09679-z>. Acesso em: 6 nov. 2022.

NÓBREGA-TERRIEN, S. M.; TERRIEN, J. Trabalhos científicos e o estado da questão. **Estudos em Avaliação Educacional**, São Paulo, v. 15, n. 30, p. 5–16, 2004. DOI: <https://doi.org/10.18222/eae153020042148>. Disponível em: <https://publicacoes.fcc.org.br/eae/article/view/2148>. Acesso em: 6 nov. 2022.

NUNES, C. C.; ALVES, S. A. M. Elaboração e validação de escala diagramática para quantificação da severidade de entomosporiose em folhas de pereira. **Summa Phytopathologica**, Botucatu, v. 38, n. 3, p. 239-244, 2012. DOI: <https://doi.org/10.1590/S0100-54052012000300011>. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-54052012000300011&lng=en&nrm=iso. Acesso em: 22 abr. 2020.

OIDE, M.; NINOMIYA, S. Discrimination of soybean leaflet shape by neural networks with image input. **Computers and Electronics in Agriculture**, [s. l.], v. 29, n. 1, p. 59–72, 2000. DOI: [https://doi.org/10.1016/S0168-1699\(00\)00136-8](https://doi.org/10.1016/S0168-1699(00)00136-8). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169900001368>. Acesso em: 6 nov. 2022.

OLGUN, M. *et al.* Wheat grain classification by using dense SIFT features with SVM classifier. **Computers and Electronics in Agriculture**, [s. l.], v. 122, p. 185–190, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.01.033>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916300060>. Acesso em: 6 nov. 2022.

OLIVEIRA, A. C. *et al.* **Ácido abscísico e o estresse abiótico**. Pelotas: Embrapa Clima Temperado, 2010. (Embrapa Clima Temperado, Documentos, 307). Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/884372/acido-abscisico-e-o-estresse-abiotico>. Acesso em: 10 ago. 2020.

PAGÁN, I.; GARCÍA-ARENAL, F. Tolerance to Plant Pathogens: Theory and Experimental Evidence. **International Journal of Molecular Sciences**, [s. l.], v. 19, n. 3, p. 810, 2018. DOI: <https://doi.org/10.3390/ijms19030810>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/29534493/>. Acesso em: 6 nov. 2022.

PARK, K. *et al.* Classification of apple leaf conditions in hyper-spectral images for diagnosis of Marssonina blotch using mRMR and deep neural network. **Computers and Electronics in Agriculture**, [s. l.], v. 148, p. 179–187, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.02.025>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917308050>. Acesso em: 6 nov. 2022.

PARKIN, A. G. Colorimetry. *In*: PARKIN, A. G. **Digital Imaging Primer**. 1. ed. Berlim: Springer, 2016. p. 279-281. Disponível em: <https://link.springer.com/book/10.1007/978-3-540-85619-1>. Acesso em: 22 jun. 2022.

PEREIRA, R. C. *et al.* Detection and classification of whiteflies and development stages on soybean leaves images using an improved deep learning strategy. **Computers and Electronics in Agriculture**, [s. l.], v. 199, p. 107132, 2022. DOI: <https://doi.org/10.1016/j.compag.2022.107132>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169922004495>. Acesso em: 6 nov. 2022.

PÉREZ, D. S.; BROMBERG, F.; DIAZ, C. A. Image classification for detection of winter grapevine buds in natural conditions using scale-invariant features transform, bag of features and support vector machines. **Computers and Electronics in Agriculture**, [s. l.], v. 135, p. 81–95, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.01.020>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916301818>. Acesso em: 6 nov. 2022.

PÉREZ-VEGA, E. *et al.* Genetic mapping of two genes conferring resistance to powdery mildew in common bean (*Phaseolus vulgaris* L.). **Theoretical and Applied Genetics**, [s. l.], v. 126, n. 6, p. 1503–1512, 2013. DOI: <https://doi.org/10.1007/s00122-013-2068-y>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/23456179/>. Acesso em: 6 nov. 2022.

PIEROZZI, P. H. B. *et al.* New soybean (*Glycine max* Fabales, Fabaceae) sources of qualitative genetic resistance to Asian soybean rust caused by *Phakopsora pachyrhizi* (Uredinales, Phakopsoraceae). **Genetics and Molecular Biology**, São Paulo, v. 31, n. 2, p. 505-511, 2008. DOI: <https://doi.org/10.1590/S1415-47572008000300018>. Disponível em: <https://www.scielo.br/j/gmb/a/bSP5MMcbPccXmnDcq5WQKDh/>. Acesso em: 17 nov. 2022.

PIRES, R. D. L. *et al.* Local descriptors for soybean disease recognition. **Computers and Electronics in Agriculture**, [s. l.], v. 125, p. 48–55, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.04.032>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816991630179X>. Acesso em: 6 nov. 2022.

POGGIO, T.; TORRE, V.; KOCH, C. Computational vision and regularization theory. **Nature**, [s. l.], v. 317, p. 314–319, 1985. DOI: <https://doi.org/10.1038/317314a0>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/2413361>. Acesso em: 6 nov. 2022.

QIU, Q. *et al.* Field-Based High-Throughput Phenotyping for Maize Plant Using 3D LiDAR Point Cloud Generated With a “Phenomobile”. **Frontiers in Plant Science**, [s. l.], v. 10, p. 554, 2019. DOI: <https://doi.org/10.3389/fpls.2019.00554>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/31134110/>. Acesso em: 6 nov. 2022.

ROSA, C. R. E.; SPEHAR, C. R.; LIU, J. Q. Asian Soybean Rust Resistance: An Overview. **Journal of Plant Pathology & Microbiology**, Londres, v. 6, n. 9, p. 1–7, 2015. DOI: <https://doi.org/10.4172/2157-7471.1000307>. Disponível em: <https://www.walshmedicalmedia.com/open-access/asian-soybean-rust-resistance-an-overview-12602.html>. Acesso em: 18 dez. 2022.

ROSCHER, R. *et al.* Automated image analysis framework for high-throughput determination of grapevine berry sizes using conditional random fields. **Computers and Electronics in Agriculture**, [s. l.], v. 100, p. 148–158, 2014. DOI: <https://doi.org/10.1016/j.compag.2013.11.008>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0168169913002780>. Acesso em: 6 nov. 2022.

ROTH, L. *et al.* High-throughput field phenotyping of soybean: Spotting an ideotype. **Remote Sensing of Environment**, [s. l.], v. 269, p. 112797, 2022. DOI: <https://doi.org/10.1016/j.rse.2021.112797>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425721005174>. Acesso em: 18 dez. 2022.

RUPE, J.; SCONYERS, L. Soybean rust. **The American Phytopathological Society (APS)**, [s. l.], 2008. Disponível em: <https://www.apsnet.org/edcenter/disandpath/fungalbasidio/pdlessons/Pages/SoybeanRust.aspx>. Acesso em: 18 dez. 2022.

SANKARAN, S.; KHOT, L. R.; CARTER, A. H. Field-based crop phenotyping: Multispectral aerial imaging for evaluation of winter wheat emergence and spring stand. **Computers and Electronics in Agriculture**, [s. l.], v. 118, p. 372–379, 2015. DOI: <https://doi.org/10.1016/j.compag.2015.09.001>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169915002768>. Acesso em: 6 nov. 2022.

SANTANA, D. C. *et al.* High-throughput phenotyping allows the selection of soybean genotypes for earliness and high grain yield. **Plant Methods**, [s. l.], v. 18, n. 1, p. 13, 2022. DOI: <https://doi.org/10.1186/s13007-022-00848-4>. Disponível em: <https://plantmethods.biomedcentral.com/articles/10.1186/s13007-022-00848-4>. Acesso em: 18 dez. 2022.

SANTOS JUNIOR, A. *et al.* Manejo Integrado de Plantas Daninhas. *In*: SEDIYAMA, T. (Ed.). **Produtividade da Soja**. Londrina: Editora Mecnas, 2016. p. 195–216.

SANTOS, M. G. P. S. *et al.* Evolução da produção e da produtividade da soja. *In*: SEDIYAMA, T. (Ed.). **Produtividade da Soja**. Londrina: Editora Mecnas, 2016. p. 19–30.

SANTOS, R. O. *et al.* Principal Component Analysis and Factor Analysis: differences and similarities in Nutritional Epidemiology application. **Revista Brasileira de Epidemiologia**, São Paulo, v. 22, e190041, 2019. DOI: <https://doi.org/10.1590/1980-549720190041>. Disponível em: <http://www.scielo.br/j/rbepid/a/TvfZv7LnNBzrXZDZjHkdGGs>. Acesso em: 23 jul. 2022.

SARMENTO, H. G. S. *et al.* Determinação do teor de água em sementes de milho, feijão e pinhão-mansão por métodos alternativos. **Energia na Agricultura**, Botucatu, v. 30, n. 3, p. 250–256, 2015. DOI: <https://doi.org/10.17224/EnergAgric.2015v30n3p250-256>. Disponível em: <https://revistas.fca.unesp.br/index.php/energia/article/view/1005>. Acesso em: 6 nov. 2022.

SCHANDA, J. CIE Colorimetry. *In*: SCHANDA, J. (Ed.). **Colorimetry: Understanding the CIE System**. New Jersey: Wiley-Interscience, 2007. p. 29-32. DOI: <https://doi.org/10.1002/9780470175637>. Disponível em: <https://www.wiley.com/en-us/Colorimetry%3A+Understanding+the+CIE+System-p-9780470049044>. Acesso em: 23 jun. 2022.

SEDIYAMA, T.; OLIVEIRA T. R. C.; SEDIYAMA H. A. A Soja. *In*: SEDIYAMA, T. (Ed.). **Produtividade da Soja**. Londrina: Editora Mecenas, 2016. p. 11-44.

SHAMSEER, L. *et al.* Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015: elaboration and explanation. **BMJ**, [s. l.], v. 349, g7647, 2015. DOI: <https://doi.org/10.1136/bmj.g7647>. Disponível em: <https://www.bmj.com/content/349/bmj.g7647>. Acesso em: 6 nov. 2022.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, Oxônia, v. 52, n. 3-4, p. 591-611, 1965. DOI: <https://doi.org/10.2307/2333709>. Disponível em: <https://www.jstor.org/stable/2333709>. Acesso em: 6 nov. 2022.

SHRIVASTAVA, S.; HOODA, D. S. Automatic Brown Spot and Frog Eye Detection from the Image Captured in the Field. **American Journal of Intelligent Systems**, [s. l.], v. 4, p. 131-134, 2014.

SILVA, F. C. S. *et al.* Manejo de Doenças. *In*: SEDIYAMA, T. (Ed.). **Produtividade da Soja**. Londrina: Editora Mecenas, 2016. p. 228-263.

SILVA, D. A. *et al.* An automatic phytopathometry system for chlorosis and necrosis severity evaluation of asian soybean rust infection. **Computers and Electronics in Agriculture**, [s. l.], v. 192, p. 106542, 2022. DOI: <https://doi.org/10.1016/j.compag.2021.106542>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921005597>. Acesso em: 6 nov. 2022.

SILVA, F. C. S. *et al.* Importância Econômica e Evolução do Melhoramento. *In*: SILVA, F. *et al.* (Orgs.). **Melhoramento da Soja**. 1. ed. Viçosa: Editora UFV, 2017. p. 9-26. (v. 1).

SILVA, H. D.; FERREIRA, D. F.; PACHECO, C. A. P. Avaliação de quatro alternativas de análise de experimentos em látice quadrado, quanto à estimação de componentes de variância. **Bragantia**, Campinas, v. 59, n. 1, p. 117-123, 2000. DOI: <https://doi.org/10.1590/S0006-87052000000100018>. Disponível em: <https://www.scielo.br/j/brag/a/GvPd6YJGYJrhd5WptwDYZZt>. Acesso em: 6 nov. 2022.

SINGH, A. K. *et al.* High-Throughput Phenotyping in Soybean. *In*: ZHOU, J.; NGUYEN, H. T. (Orgs.). **High-Throughput Crop Phenotyping**. Cham: Springer International Publishing, 2021. p. 129-163. (Concepts and Strategies in Plant Sciences).

SKANSI, S. Convolutional Neural Networks. *In: SKANSI, S. Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence*. Cham: Springer International Publishing, 2018c. p. 121–133. DOI: https://doi.org/10.1007/978-3-319-73004-2_3. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-73004-2_3. Acesso em: 6 nov. 2022.

SKANSI, S. Feedforward Neural Networks. *In: SKANSI, S. Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence*. Cham: Springer International Publishing, 2018b. p. 79–105. DOI: https://doi.org/10.1007/978-3-319-73004-2_3. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-73004-2_3. Acesso em: 6 nov. 2022.

SKANSI, S. Machine Learning Basics. *In: SKANSI, S. Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence*. Cham: Springer International Publishing, 2018a. p. 51–77. DOI: https://doi.org/10.1007/978-3-319-73004-2_3. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-73004-2_3. Acesso em: 6 nov. 2022.

SOARES, M. M.; SEDIYAMA, T. Macronutrientes. *In: SEDIYAMA, T. (Ed.). Produtividade da Soja*. Londrina: Editora Mecenias, 2016b. p. 64–80.

SOARES, M. M.; SEDIYAMA, T. Manejo e Textura do Solo. *In: SEDIYAMA, T. (Ed.). Produtividade da Soja*. Londrina: Editora Mecenias, 2016a. p. 30–44.

SOARES, M. M.; SEDIYAMA, T.; TOBAR, L. M. S. Micronutrientes. *In: SEDIYAMA, T. (Ed.). Produtividade da Soja*. Londrina: Editora Mecenias, 2016. p. 81–98.

SOARES, R. M.; ARIAS, C. A. A. **Seleção de linhagens de soja da Embrapa para resistência a doenças: histórico de 2008 a 2014**. Londrina: Embrapa Soja, 2016. (Documentos / Embrapa Soja, ISSN 2176-2937, n. 376). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/148979/1/Doc-376.pdf>. Acesso em: 6 nov. 2022.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. *In: SATTAR, A.; KANG, B.-H. (Orgs.). AI 2006: Advances in Artificial Intelligence*. Heidelberg: Springer, 2006. p. 1015–1021. (Lecture Notes in Computer Science).

SOLOMON, C.; BRECKON, T. **Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab**. Chichester: Wiley-BlackWell, 2011.

SOUSA, P. F. C. *et al.* Distribuição e identificação de *Phakopsora pachyrhizi*, agente causal da ferrugem da soja no estado de Minas Gerais. **Ciência e Agrotecnologia**, Lavras, v. 31, n. 3, p. 672-677, 2007. DOI: <https://doi.org/10.1590/S1413-70542007000300011>. Disponível em: <https://www.scielo.br/j/cagro/a/vSD4Bh4bX7qDzgLRHjBkbJH/?lang=pt>. Acesso em: 22 abr. 2020.

SZEGEDY, C. *et al.* Going deeper with convolutions. *In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION*, 28., 2015, Boston. **Anais [...]**. Boston: [s. n.], 2015. p. 1-9. DOI: <https://doi.org/10.1109/CVPR.2015.7298594>. Disponível em: <https://ieeexplore.ieee.org/document/7298594>. Acesso em: 17 nov. 2022.

TMG. Informações TMG7067. **TMG**, Cambé, 2022. Disponível em: <https://www.tmg.agr.br/ptbr/cultivar/tmg-7067-ipro>. Acesso em: 12 ago. 2022.

TWIZEYIMANA, M.; HARTMAN, G. L. Sensitivity of *Phakopsora pachyrhizi* Isolates to Fungicides and Reduction of Fungal Infection Based on Fungicide and Timing of Application. **Plant Disease**, [s. l.], v. 101, n. 1, p. 121–128, 2017. DOI: <https://doi.org/10.1094/PDIS-04-16-0552-RE>. Disponível em: <https://apsjournals.apsnet.org/doi/10.1094/PDIS-04-16-0552-RE>. Acesso em: 18 dez. 2022.

USDA (UNITED STATES DEPARTMENT OF AGRICULTURE). **Oilseeds and Products Annual - Brazil**. United States: United States Department of Agriculture, 2020.

USDA (UNITED STATES DEPARTMENT OF AGRICULTURE). **World Agricultural Production: Foreign Agricultural Service Circular Series WAP 9-22**. United States: United States Department of Agriculture, 2022. Disponível em: <https://apps.fas.usda.gov/psdonline/circulars/production.pdf>. Acesso em: 27 set. 2022.

UZAL, L. C. *et al.* Seed-per-pod estimation for plant breeding using deep learning. **Computers and Electronics in Agriculture**, [s. l.], v. 150, p. 196–204, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.04.024>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816991731582X>. Acesso em: 6 nov. 2022.

VALE, X. R.; FERNANDES, E. I. Quant: a software plant disease severity assessment. *In: INTERNATIONAL CONGRESS OF PLANT PATHOLOGY*, 8., 2001, Ouro Preto. **Anais [...]**. Ouro Preto: [s. n.], 2001. p. 105.

VEDALDI, A.; SOATTO, S. Quick Shift and Kernel Methods for Mode Seeking. *In: FORSYTH, D.; TORR, P.; ZISSERMAN, A. (Orgs.). Computer Vision: ECCV 2008*. Heidelberg: Springer Berlin Heidelberg, 2008. p. 705–718.

VITAL, R. G. **Mecanismos da tolerância ao déficit hídrico e à alta temperatura em cultivares de soja**. 2019. Tese (Doutorado em Ciências Agrárias - Agronomia) – Instituto Federal Goiano, Rio Verde, 2019. Disponível em: https://sistemas.ifgoiano.edu.br/sgcursos/uploads/anexos_5/2020-07-24-06-24-142019-11-20-12-04-221-Roberto%20Vital.pdf. Acesso em: 6 nov. 2022.

XIE, C. *et al.* Automatic classification for field crop insects via multiple-task sparse representation and multiple-kernel learning. **Computers and Electronics in Agriculture**, [s. l.], v. 119, p. 123–132, 2015. DOI: <https://doi.org/10.1016/j.compag.2015.10.015>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169915003282>. Acesso em: 6 nov. 2022.

YAHATA, S. *et al.* A hybrid machine learning approach to automatic plant phenotyping for smart agriculture. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 30., 2017, Anchorage. **Anais** [...]. Anchorage: [s. n.], 2017. p. 1787–1793.

YAMANAKA, N.; HOSSAIN, M. M. Pyramiding three rust-resistance genes confers a high level of resistance in soybean (*Glycine max*). **Plant Breeding**, [s. l.], v. 138, n. 6, p. 686-695, 2019. DOI: <https://doi.org/10.1111/pbr.12720>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/pbr.12720>. Acesso em: 17 nov. 2022.

YANG, G. *et al.* Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, [s. l.], v. 8, p. 1-26, 2017. DOI: <https://doi.org/10.3389/fpls.2017.01111>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2017.01111/full>. Acesso em: 6 nov. 2022.

YANG, H.-W. *et al.* Differentiating between morphologically similar species in genus *Cinnamomum* (Lauraceae) using deep convolutional neural networks. **Computers and Electronics in Agriculture**, [s. l.], v. 162, p. 739–748, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.05.003>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918315916>. Acesso em: 6 nov. 2022.

YANG, M. *et al.* Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, [s. l.], v. 11, p. 1-16, 2020b. DOI: <https://doi.org/10.3389/fpls.2020.00927>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2020.00927/full>. Acesso em: 6 nov. 2022.

YANG, M. *et al.* Deep RetinaNet for Dynamic Left Ventricle Detection in Multiview Echocardiography Classification. **Scientific Programming**, [s. l.], v. 2020, p. 7025403, 2020a. DOI: <https://doi.org/10.1155/2020/7025403>. Disponível em: <https://www.hindawi.com/journals/sp/2020/7025403/>. Acesso em: 6 nov. 2022.

YOOSEFZADEH-NAJAFABADI, M. *et al.* Application of Machine Learning Algorithms in Plant Breeding: Predicting Yield From Hyperspectral Reflectance in Soybean. **Frontiers in Plant Science**, [s. l.], v. 11, p. 1-14, 2021. DOI: <https://doi.org/10.3389/fpls.2020.624273>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2020.624273/full>. Acesso em: 6 nov. 2022.

YORINORI, J. T.; LAZZAROTTO J. J. **Situação da Ferrugem Asiática da Soja no Brasil e na América do Sul**. Londrina: Embrapa Soja, 2004. (Documentos/Embrapa Soja, ISSN 1516-781X, n. 236). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPSo-2009-09/24989/1/documentos236.pdf>. Acesso em: 23 abr. 2020.

ZAMBENEDETTI, E. B. *et al.* Germination of urediniospores from *Phakopsora pachyrhizi* on different techniques of preservation. **Summa Phytopathologica**, Botucatu, v. 33, n. 1, p. 83–85, 2007. DOI: <https://doi.org/10.1590/S0100-54052007000100013>. Disponível em: <https://www.scielo.br/j/sp/a/hcSgXff9dVRt7LWwWhr6Pyz>. Acesso em: 6 nov. 2022.

ZHANG, L. *et al.* Individual leaf identification from horticultural crop images based on the leaf skeleton. **Computers and Electronics in Agriculture**, [s. l.], v. 127, p. 184–196, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.06.017>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916303969>. Acesso em: 6 nov. 2022.

ZHANG, R. *et al.* Comparison of Backbones for Semantic Segmentation Network. **Journal of Physics: Conference Series**, [s. l.], v. 1544, n. 1, p. 012196, 2020. DOI: <https://doi.org/10.1088/1742-6596/1544/1/012196>. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1544/1/012196>. Acesso em: 6 nov. 2022.

ZHANG, S. *et al.* Cucumber leaf disease identification with global pooling dilated convolutional neural network. **Computers and Electronics in Agriculture**, [s. l.], v. 162, p. 422–430, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.03.012>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918317976>. Acesso em: 6 nov. 2022.

ZHOU, J. *et al.* Automated segmentation of soybean plants from 3D point cloud using machine learning. **Computers and Electronics in Agriculture**, [s. l.], v. 162, p. 143–153, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.04.014>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918318519>. Acesso em: 6 nov. 2022.

ZHOU, J. *et al.* Development of an automated phenotyping platform for quantifying soybean dynamic responses to salinity stress in greenhouse environment. **Computers and Electronics in Agriculture**, [s. l.], v. 151, p. 319–330, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.06.016>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169918300218>. Acesso em: 6 nov. 2022.