



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

YURI GUERREIRO RAMOS

**RELAÇÃO INJÚRIA-DANO, INDICES DE VEGETAÇÃO E  
REDES NEURAIAS CONVOLUCIONAIS COMO MÉTODOS DE  
DETECÇÃO E PREDIÇÃO DE DANOS PARA MANCHAS  
FOLIARES DO MILHO**

---

Londrina  
2025

YURI GUERREIRO RAMOS

**RELAÇÃO INJÚRIA-DANO, INDICES DE VEGETAÇÃO E  
REDES NEURAS CONVOLUCIONAIS COMO MÉTODOS DE  
DETECÇÃO E PREDIÇÃO DE DANOS PARA MANCHAS  
FOLIARES DO MILHO**

Tese apresentada ao Programa de Pós-graduação em Agronomia da Universidade Estadual de Londrina, como requisito à obtenção do título de Doutor em Agronomia.

Orientador: Prof. Dr. Marcelo Giovanetti Canteri

Londrina  
2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

G934r Guerreiro Ramos, Yuri.

Relação injúria-dano, índices de vegetação e redes neurais convolucionais como métodos de detecção e predição de danos para manchas foliares do milho / Yuri Guerreiro Ramos. - Londrina, 2025.  
139 f. : il.

Orientador: Marcelo Giovanetti Canteri.

Tese (Doutorado em Agronomia) - Universidade Estadual de Londrina, Centro de Ciências Agrárias, Programa de Pós-Graduação em Agronomia, 2025.  
Inclui bibliografia.

1. Relação injúria-dano - Tese. 2. Sensoriamento remoto - Tese. 3. Limiar de Dano Econômico - Tese. 4. Redes neurais convolucionais - Tese. I. Giovanetti Canteri, Marcelo. II. Universidade Estadual de Londrina. Centro de Ciências Agrárias. Programa de Pós-Graduação em Agronomia. III. Título.

CDU 63

YURI GUERREIRO RAMOS

**RELAÇÃO INJÚRIA-DANO, INDICES DE VEGETAÇÃO E  
REDES NEURAS CONVOLUCIONAIS COMO MÉTODOS DE  
DETECÇÃO E PREDIÇÃO DE DANOS PARA MANCHAS  
FOLIARES DO MILHO**

Tese apresentada ao Programa de Pós-graduação em Agronomia da Universidade Estadual de Londrina, como requisito à obtenção do título de Doutor em Agronomia.

**BANCA EXAMINADORA**

---

Orientador: Prof. Dr. Marcelo Giovanetti Canteri  
Universidade Estadual de Londrina – UEL

---

Prof. Dr. Rui Pereira Leite Jr  
Instituto de Desenvolvimento Rural do Paraná –  
IAPAR-EMATER – IDR-Paraná

---

Prof. Dr. Daniel dos Santos Kaster  
Universidade Estadual de Londrina – UEL

---

Prof. Dr. Adriano Augusto P. Custódio  
Instituto de Desenvolvimento Rural do Paraná –  
IAPAR-EMATER – IDR-Paraná

---

Dra. Sheila Ariana Xavier Valencio  
Fitovision Agridata

Londrina, 27 de fevereiro de 2025

Dedico este trabalho aos meus amados pais Adilson e Maria Marlene, avós, bisavós e antepassados que há séculos zelaram e criaram seus rebentos em meio a guerras, odisseias em terra e alto mar, na garupa de geadas ou torvelinho das tropeadas, proporcionando que hoje eu estivesse aqui.

## **AGRADECIMENTOS**

À Universidade Estadual de Londrina pela oportunidade de realização deste trabalho.

Ao meu orientador Dr. Marcelo Giovanetti Canteri, por compartilhar com excelência e humildade o seu vasto conhecimento na fitopatologia. Obrigado também por incentivar e inspirar inovação.

Ao pesquisador Dr. Adriano Custódio pelo companheirismo e valiosos conselhos.

À empresa ALVAZ Agritech, na figura dos colegas Jorge Benigno e Ana Julia Righetto, pela parceria, atenção e prontidão.

À empresa Bayer S. A., principalmente na figura dos colegas Rodrigo Guerzoni, Ana Claudia Klosowski e Marco Guimarães, pelo apoio e amizade.

Ao colega Matheus Ortiz por trazer à luz questões de uma área do conhecimento até então incomum para mim.

Aos colegas Alan Machado e Ednilson Parra. Mais do que o suporte técnico, nossa cumplicidade foi o principal insumo para a realização das atividades de campo.

Aos meus amados pais Adilson Cavalheiro Ramos e Maria Marlene Guerreiro Ramos e irmãos Gerson, Deborah, Emanuelle e Michele. Ser o filho mais novo é temer cada grão de areia da ampulheta ao cair, é apressar-se em agradecer e retribuir, antes de todo o tempo se esvaír.

Aos saudosos avós Flaterno Gonçalves Guerreiro, Djanira Bueno Guerreiro, Sebastião José Ramos e Iracema Cavalheiro de Liz Ramos. Seus legados são perpétuos em nossos traços, costumes, memórias e batalhas.

Aos meus amados sobrinhos Gabriela, Daniella, Raphaela, José Felipe, Jamile Chafia, Eduardo, João Leonardo, Yasmeen, Cecília Aurora, Ibrahim, Maria Theresa e Maria Luisa. Nas lembranças de suas infâncias, seus inocentes olhares de esperança sempre foram fonte de força e acalento.

À minha namorada Daniela pelo amor, paciência e bondade. O amor é o criador e ao mesmo tempo salvador de todos os desafios de uma vida.

Aos meus amigos da irmandade O.V. de Sapopema – PR, responsáveis por memoráveis momentos de celebração e comunhão.

GUERREIRO RAMOS, Yuri. **Relação injúria-dano, índices de vegetação e redes neurais convolucionais como métodos de detecção e predição de danos para manchas foliares do milho**. 2025. 139 p. Tese (Doutorado em Agronomia) – Universidade Estadual de Londrina, Londrina, 2025.

## RESUMO

A elaboração de modelos matemáticos para estimar danos a partir de dados de injúria é de importância para a predição de epidemias e tomada de decisão. Comprimentos de onda, índices de vegetação e redes neurais convolucionais (RNC), são capazes de diferenciar tecidos saudáveis e doentes. Esse trabalho teve como objetivo estabelecer a relação injúria-dano para mancha foliar do milho (mancha branca, mancha de turcicum e mancha de bipolaris) (Artigo A), verificar o potencial uso de índices de vegetação como métodos de detecção e predição de danos para manchas foliares do milho (Artigo B) e, de RNC para a detecção de manchas foliares do milho (Artigo C). Foram instalados quatro experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), no município de Londrina, PR, no milho na safra de 2022. O delineamento experimental utilizado foi blocos ao acaso com oito tratamentos e quatro repetições. Os tratamentos consistiram na aplicação dos fungicidas Prothioconazol + Trifloxistrobina + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>) na dose de 500 mL.ha<sup>-1</sup> do produto comercial em diferentes estágios fenológicos da cultura. A quantificação da severidade das doenças foi realizada de acordo com as escalas diagramáticas, sendo que os valores foram utilizados para o cálculo da área abaixo da curva de progresso da doença (AACPD). A colheita foi mensurada nas duas linhas centrais de cada parcela, estimando-se a produtividade (kg.ha<sup>-1</sup>). O Limiar de Dano Econômico (LDE) foi calculado utilizando a equação  $ID = [Cc/(Pp \times Cd)] \times Ec$ . As capturas foram realizadas com sensor Micasense-MX acoplado a um drone DJI Inspire 2 e os cálculos dos índices de vegetação foram realizados com os softwares Agisoft e ArcGIS PRO. Foram calculadas as AACPD dos índices NDVI, NQAB, NQAF, NDRE, VARI e NIR. Os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5% de probabilidade. As relações entre os parâmetros foram analisadas por regressão linear. Para o estudo de RNC, foram obtidas 2.120 imagens e as arquiteturas utilizadas foram a VGG16, MobileNetV2 e um Modelo Manual. A contribuição desse estudo consiste nas equações de dano propostas e nos altos coeficientes de determinação obtidos para a relação da AACPD de manchas foliares com o dano, atingindo valores de 71 a 92% para os diferentes híbridos. A relação da AACPD de manchas foliares com a AACPD do índice NDVI foi a que obteve melhor correlação na maioria dos híbridos, com valores entre 58 e 72%, sendo que o VARI e NDVI foram os que apresentaram as melhores correlações com a produtividade. Para este estudo, a VGG16 foi a arquitetura de CNN que obteve a maior acurácia na detecção de manchas foliares na cultura do milho segunda safra, atingindo 96,76% na etapa de treinamento e de 84,67% na etapa de validação.

**Palavras-chave:** limiar de ação; sensoriamento remoto; inteligência artificial.

GUERREIRO RAMOS, Yuri. **Injury-damage relation, vegetation indexes and convolutional neural networks as methods of detection and prediction of damage for leaf spots in corn.** 2025. 139 p. Thesis (Doctorate in Agronomy) – Universidade Estadual de Londrina, Londrina, 2025.

## ABSTRACT

The development of mathematical models to estimate damage from injury data is extremely important for predict epidemics and to make decisions. Wavelengths, vegetation indexes, and convolutional neural networks (CNNs) are capable of differentiating healthy and diseased tissues. This study aimed to establish the injury-damage relation for leaf spots in corn (maize white spot (MWS), northern corn leaf blight (NCLB) and southern corn leaf blight (SCLB)) (Article A), and to verify the potential use of vegetation indices as methods for detecting and predicting damage to leaf spots in corn (Article B) and, the CNN for detection of leaf spots in corn (Article C). Four experiments were established at the School Farm of the State University of Londrina (UEL), in Londrina, PR, Brazil, in corn second season of 2022. The experimental design used was randomized blocks with eight treatments and four replications. Treatments consisted of the application of the fungicides Prothioconazole + Trifloxystrobin + Bixafen (175 + 150 + 125 g a.i. L<sup>-1</sup>) at a dose of 500 mL.ha<sup>-1</sup> of the commercial product at different phenological stages of the crop. Disease severity quantification was performed according to diagrammatic scales, and the values were used to calculate the area under the disease progress curve (AUDPC). The harvest was measured in the two central lines of each plot, estimating productivity (kg.ha<sup>-1</sup>). The Economic Damage Threshold (EDT) was calculated using the equation  $ID = [Cc/(Pp \times Cd)] \times Ec$ . The captures were taken with a Micasense-MX sensor coupled to a DJI Inspire 2 drone and the vegetation indexes calculations were carried out using Agisoft and ArcGIS PRO software. The AACP of the NDVI, NQAB, NQAF, NDRE, VARI and NIR indexes were calculated. The data were subjected to analysis of variance using the F test and differences between means, when significant, were compared by the Scott Knott test, at a 5% probability level. The relation between the parameters were analyzed by linear regression. For the CNN study, 2.120 images were obtained and the architectures used were VGG16, MobileNetV2 and a Manual Model. The contribution of this study consists of the proposed damage equations and the high coefficients of determination obtained for the relation between the AUDPC of leaf spots and the damage, reaching values of 71 to 92% for the different hybrids. The relation between the AUDPC of leaf spots and the AACP of the NDVI index was the one that obtained the best correlation in most hybrids, with values between 58 and 72%, with VARI and NDVI being the ones that presented the best correlations with productivity. For this study, VGG16 was the CNN architecture that obtained the highest accuracy in the detection of leaf spots in the second corn crop, reaching 96,76% in the training stage and 84,67% in the validation stage.

**Keywords:** action threshold; remote sensing; artificial intelligence.

## LISTA DE FIGURAS

<b>Figura 1</b> – Curva de reflectância de uma folha verde.....	33
<b>Figura 2</b> – Representação de neurônio biológico.....	36
<b>Figura 3</b> – Composição de neurônio artificial.....	37
<b>Figura 4</b> – Equação de neurônio artificial.....	37
<b>Figura 5</b> – Exemplo hipotético de neurônio artificial.....	38
<b>Figura 6</b> – Redes neurais multicamadas.....	38
<b>Figura 7</b> – Exemplo de convolução de imagem.....	39
<b>Figura 8</b> – Aplicação das ReLUs ( <i>Rectified Linear Units</i> ).....	40
<b>Figura 9</b> – Etapas de <i>Max Pooling</i> e <i>Flattening</i> .....	40
<b>Figura 10</b> – Visão geral da RNC (Redes Neurais Convolucionais).....	41
<b>Figura 11</b> – Imagem aérea com as delimitações das parcelas (A) e croqui dos experimentos com tratamentos e códigos dos híbridos (B).....	47
<b>Figura 12</b> – Escala diagramática da mancha branca.....	50
<b>Figura 13</b> – Escala diagramática da mancha de turcicum.....	51
<b>Figura 14</b> – Escala diagramática da cercosporiose, utilizada para avaliar mancha de bipolaris.....	51
<b>Figura 15</b> – Sintomas de mancha de bipolaris em folhas do estádio V11 de planta de milho do híbrido AG 9021.....	55
<b>Figura 16</b> – Sintomas de mancha de turcicum em folhas do estádio V10 de planta de milho do híbrido AG 9025.....	57
<b>Figura 17</b> – Sintomas de mancha branca em folha do estádio R3 de planta de milho do híbrido FÓRMULA VIP.....	59
<b>Figura 18</b> – Relação entre produtividade e o número de aplicações de fungicidas no início do ciclo (Figura A), no final do ciclo (Figura B) e relação entre produtividade e o atraso no início do controle (Figura C), na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR.....	65
<b>Figura 19</b> – Sensor Micasense-MX utilizado para captura dos dados.....	75
<b>Figura 20</b> – Equipamento VANT DJI Inspire 2 utilizado para realização dos voos.....	75
<b>Figura 21</b> – Equipamento radiômetro GreenSeeker Hand Held Model 505.....	76
<b>Figura 22</b> – Prancha coberta com folhas de milho com sintomas de mancha branca para a leitura.....	77

<b>Figura 23</b> – Recortes das pranchas de folhas saudáveis, folhas com sintomas de mancha de bipolaris, de mancha de turcicum e de mancha branca. ....	77
<b>Figura 24</b> – Imagens aéreas da cultura do milho ( <i>Zea mays</i> L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR. ....	80
<b>Figura 25</b> – Índice de fotossíntese (NQAF) na cultura do milho ( <i>Zea mays</i> L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR. ....	81
<b>Figura 26</b> – Folhas de milho do híbrido AG 9021 com sintomas de mancha branca, coletadas em experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), Londrina, PR. ....	96
<b>Figura 27</b> – Fixação de folha de planta de milho em mesa para os registros fotográficos.....	97
<b>Figura 28</b> – Ferramenta <i>Pixlr Remove BG</i> para remoção de fundo de imagem. ....	97
<b>Figura 29</b> – Imagens de folhas de milho do híbrido AG 9021 com sintomas de mancha branca após a divisão utilizando a ferramenta <i>Pinetools Bulk split image</i> . ....	98
<b>Figura 30</b> – Precisão de acertos nos dados de treinamento e validação para o Modelo Manual.....	101
<b>Figura 31</b> – Precisão de acertos nos dados de treinamento e validação para o VGG16. ....	103
<b>Figura 32</b> – Precisão de acertos nos dados de treinamento e validação para o MobileNetV2.....	104

## LISTA DE TABELAS

<b>Tabela 1</b> – Época e ano de condução, data de semeadura, híbrido ou cultivar, data da aplicação de fungicidas e estágio de desenvolvimento da cultura. Londrina – PR.....	48
<b>Tabela 2</b> – Tratamentos, estádios de desenvolvimento das plantas e número de aplicações dos fungicidas para controle de doenças fúngicas na cultura do milho. Londrina – PR.....	49
<b>Tabela 3</b> – Cultura, época e ano de condução, híbrido, datas das avaliações e estádios de desenvolvimento das plantas de milho. Londrina – PR. ....	52
<b>Tabela 4</b> –Área abaixo da curva de progresso da doença (AACPD) para mancha de bipolaris em híbridos de milho ( <i>Zea mays</i> L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR. ....	56
<b>Tabela 5</b> – Área abaixo da curva de progresso da doença (AACPD) para mancha de turcicum em híbridos de milho ( <i>Zea mays</i> L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR. ....	58
<b>Tabela 6</b> – Área abaixo da curva de progresso da doença (AACPD) para mancha branca em híbridos de milho ( <i>Zea mays</i> L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR. ....	60
<b>Tabela 7</b> – Equações de função de dano e coeficientes de determinação para doenças em diferentes híbridos de milho ( <i>Zea mays</i> L.). Safrinha 2022, Londrina – PR. ....	61
<b>Tabela 8</b> – Equações de função de dano, coeficientes de determinação, Limiar de Dano Econômico (LDE) e Limiar de Ação (LA) em relação aos estádios de desenvolvimento na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	63
<b>Tabela 9</b> – Época e ano de condução, data de semeadura, híbrido ou cultivar, data da aplicação de fungicidas e estágio de desenvolvimento da cultura. Londrina – PR.....	72
<b>Tabela 10</b> – Tratamentos, estádios de desenvolvimento da planta e número de aplicações dos fungicidas para controle de doenças	

fúngicas na cultura do milho. Londrina – PR.....	74
<b>Tabela 11</b> – Cultura, época e ano de condução, híbrido, data da captura de dados com sensor e estágio de desenvolvimento das plantas de milho. Londrina – PR.....	75
<b>Tabela 12</b> – Equações de função de severidade para mancha de bipolaris e coeficientes de determinação para a AACP dos índices de vegetação e NIR, na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	83
<b>Tabela 13</b> – Equações de função de severidade para mancha de turcicum e coeficientes de determinação para a AACPs dos índices de vegetação e NIR, na cultura do milho ( <i>Zea mays</i> L.) Safrinha 2022. Londrina – PR. ....	84
<b>Tabela 14</b> – Equações de função de severidade para mancha branca e coeficientes de determinação para a AACP dos índices de vegetação e NIR, na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	86
<b>Tabela 15</b> – Equações de função de severidade para manchas foliares e coeficientes de determinação para a AACP dos índices de vegetação e NIR, na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	87
<b>Tabela 16</b> – Índices de vegetação obtidos por radiômetro, nos tratamentos com diferentes pranchas de doenças, na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	88
<b>Tabela 17</b> – Equações de função de dano e coeficientes de determinação para a AACPs dos índices de vegetação e NIR, na cultura do milho ( <i>Zea mays</i> L.). Safrinha 2022. Londrina – PR. ....	90

## LISTA DE ABREVIATURAS E SIGLAS

%	Porcentagem
°C	Graus Celsius
AACPD	Área Abaixo da Curva de Progresso da Doença
AUDPC	Area Under the Disease Progress Curve
AP	Aprendizagem Profunda
ARM	<i>Advanced Risk Machine</i>
AT	<i>Action Threshold</i>
$b_k$	Valor de bias
Cc	Custo do controle do fungicida
Cd	Coeficiente de dano
Cfa	Clima subtropical úmido
cm	Centímetros
CNN	<i>Convolutional Neural Network</i>
CONAB	Companhia Nacional de Abastecimento
CIMMYT	<i>Centro Internacional de Mejoramiento de Maíz y Trigo</i>
DMI	Inibidores da desmetilação de esteróis
Ec	Eficiência do fungicida a ser usado
ED	Estádio de desenvolvimento
EDT	<i>Economic Damage Threshold</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FRAC	<i>Fungicide Resistance Action Committe</i>
g i.a. L <sup>-1</sup>	Gramas de ingrediente ativo por litro
GRENDVI	<i>Green-Red Normalized Difference Vegetation Index</i>
GSD	<i>Ground Sample Distance</i>
ID	Intensidade de doença
IVP	Infravermelho próximo
kg	Quilos
kg.ha <sup>-1</sup>	Quilos por hectare
L.ha <sup>-1</sup>	Litros por hectare
LA	Limiar de ação
LDE	Limiar de Dano Econômico
m	Metro
m <sup>2</sup>	Metros quadrados
MBC	Metil benzimidazol carbamato

MCARI	<i>Modified Chlorophyll Absorption in Reflectance Index</i>
mL.ha <sup>-1</sup>	Mililitros por hectare
MP	<i>Megapixel</i>
MWS	<i>Maize White Spot</i>
NCLB	<i>Northern Corn Leaf Blight</i>
NDRE	<i>Normalized Difference Red Edge</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infra-Red</i>
NPQI	<i>Normalized Phaeophytinization Index</i>
NQAB	Índice de Biomassa
NQAF	Índice de Fotossíntese
NQAE	Índice de Estresse Vegetal
nm	Nanômetro
OSAVI	<i>Optimized Soil-Adjusted Vegetation Index</i>
Pp	Preço da tonelada do produto
PRENDVI	<i>Pan Normalized Difference Vegetation Index</i>
PRI515	<i>Photochemical Reflectance Index</i>
QoI	Inibidores da quinona externa
R <sup>2</sup>	Coeficiente de determinação
RDVI	<i>Renormalized Difference Vegetation Index</i>
ReLU	<i>Rectified Linear Units</i>
RGB	<i>Red, Green and Blue</i>
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
SCLB	<i>Southern Corn Leaf Blight</i>
TCARI	<i>Transformed Chlorophyll Absorption in Reflectance Index</i>
u	Função de ativação através da saída
UEL	Universidade Estadual de Londrina
USDA	<i>United States Department of Agriculture</i>
VANT	Veículos Aéreos Não Tripulados
VARI	<i>Visible Atmospherically Resistant Index</i>
WI	<i>Water Index</i>
W <sub>k1</sub> , W <sub>k2</sub>	Pesos de entrada
x <sub>1</sub> , x <sub>2</sub>	Sinais de entrada
y <sub>k</sub>	Saída
μm	Micrómetro

$\phi$

Função do axônio

## SUMÁRIO

1	<b>INTRODUÇÃO</b> .....	19
2	<b>REVISÃO DE LITERATURA</b> .....	21
2.1	A CULTURA DO MILHO ( <i>Zea Mays</i> , L.) .....	21
2.2	MANCHA BRANCA.....	22
2.2.1	Etiologia e Ciclo Biológico .....	22
2.2.2	Sintomatologia.....	23
2.3	MANCHA DE TURCICUM.....	24
2.3.1	Etiologia e Ciclo Biológico .....	24
2.3.2	Sintomatologia.....	25
2.4	MANCHA DE BIPOLARIS.....	25
2.4.1	Etiologia e Ciclo Biológico .....	25
2.4.2	Sintomatologia.....	26
2.5	MEDIDAS DE CONTROLE DE DOENÇAS .....	27
2.5.1	Controle de Mancha Branca .....	28
2.5.2	Controle de Mancha de Turcicum.....	29
2.5.3	Controle da Mancha de Bipolaris.....	30
2.6	RELAÇÃO DE INJÚRIA-DANO E LIMIAR DE DANO ECONÔMICO .....	30
2.7	SENSORIAMENTO REMOTO .....	32
2.8	REDES NEURAIS CONVOLUCIONAIS .....	35
3	<b>ARTIGO A: RELAÇÃO INJÚRIA-DANO PARA MANCHAS FOLIARES DO MILHO</b> .....	<b>43</b>
3.1	RESUMO.....	43
3.2	ABSTRACT .....	44
3.3	INTRODUÇÃO .....	45
3.4	MATERIAL E MÉTODOS .....	46
3.4.1	Localização dos Experimentos .....	46
3.4.2	Instalação dos Experimentos e Delineamento Experimental.....	47
3.4.3	Adubação e Manutenção Fitossanitária.....	48
3.4.4	Tratamentos .....	49
3.4.5	Condições Climáticas .....	50
3.4.6	Avaliação da Severidade das Doenças .....	50
3.4.7	Área Abaixo da Curva de Progresso da Doença .....	52

3.4.8	Produtividade.....	52
3.4.9	Relação entre AACPD e Produtividade .....	53
3.4.10	Limiar de Dano Econômico (LDE) e Limiar de Ação (LA).....	53
3.4.11	Produtividade em Função das Aplicações de Fungicidas.....	54
3.4.12	Análise dos Dados.....	54
3.5	RESULTADOS E DISCUSSÃO .....	54
3.5.1	Severidade e Área Abaixo da Curva de Progresso da Doença (AACPD).....	54
3.5.1.1	Mancha de Bipolaris .....	54
3.5.1.2	Mancha de Turcicum .....	56
3.5.1.3	Mancha Branca.....	58
3.5.2	Relação Injúria-Dano .....	60
3.5.3	Limiar de Dano Econômico (LDE) e Limiar de Ação (LA).....	62
3.5.4	Produtividade em Função das Aplicações de Fungicidas.....	65
3.6	CONCLUSÕES .....	66
<b>4</b>	<b>ARTIGO B: ÍNDICES DE VEGETAÇÃO COMO MÉTODOS DE DETECÇÃO E PREDIÇÃO DE DANOS CAUSADOS POR MANCHAS FOLIARES DO MILHO .....</b>	<b>69</b>
4.1	RESUMO.....	69
4.2	ABSTRACT .....	70
4.3	INTRODUÇÃO .....	71
4.4	MATERIAL E MÉTODOS .....	72
4.4.1	Localização dos Experimentos .....	72
4.4.2	Instalação dos Experimentos e Delineamento Experimental .....	72
4.4.3	Adubação e Manutenção Fitossanitária.....	73
4.4.4	Tratamentos .....	73
4.4.5	Condições Climáticas .....	74
4.4.6	Captura dos Dados com Sensor Acoplado à VANT .....	74
4.4.7	Captura dos Dados com Radiômetro.....	76
4.4.8	Área Abaixo da Curva de Progresso dos Índices de Vegetação e NIR .....	78
4.4.9	Relação Injúria-Dano-Índices de Vegetação e NIR .....	78
4.4.10	Análise dos Dados.....	79
4.5	RESULTADOS E DISCUSSÃO .....	79
4.5.1	Cultura do Milho.....	79

4.5.1.1	Resposta de Índices de Vegetação e NIR às Aplicações de Fungicidas .....	79
4.5.1.2	Relação Injúria-Índices de Vegetação e NIR .....	82
4.5.1.2.1	Mancha de Bipolaris .....	82
4.5.1.2.2	Mancha de Turcicum .....	84
4.5.1.2.3	Mancha Branca .....	85
4.5.1.2.4	Manchas Foliaves .....	86
4.5.1.3	Avaliação da Prancha com Folhas Destacadas de Milho .....	87
4.5.1.4	Relação Dano-Índices de Vegetação e NIR .....	89
4.6	CONCLUSÕES .....	91
<b>5</b>	<b>ARTIGO C: REDES NEURAS CONVOLUCIONAIS COMO MÉTODOS DE DETECÇÃO DE MANCHAS FOLIARES DO MILHO .....</b>	<b>93</b>
5.1	RESUMO.....	93
5.2	ABSTRACT .....	94
5.3	INTRODUÇÃO .....	95
5.4	MATERIAL E MÉTODOS .....	96
5.4.1	Coleta de Folhas Doentes e Sadias de Plantas de Milho .....	96
5.4.2	Registros Fotográficos das Folhas .....	96
5.4.3	Tratamento das Imagens.....	97
5.4.4	Treinamento da Rede Neural Convolutiva (RNC).....	98
5.5	RESULTADOS E DISCUSSÃO .....	100
5.6	CONCLUSÕES .....	105
<b>6</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>106</b>
	<b>REFERÊNCIAS.....</b>	<b>107</b>
	<b>APÊNDICES .....</b>	<b>125</b>
	<b>ANEXOS .....</b>	<b>137</b>

## 1 INTRODUÇÃO

O Brasil é o terceiro maior produtor mundial de milho e um dos maiores exportadores desse grão, fazendo dessa cultura uma das mais importantes para a economia do país.

O uso incorreto do controle químico na agricultura acarreta pressão de seleção sobre os organismos, resultando em baixa eficiência de diferentes ingredientes ativos, gerando perdas de produtividade e problemas econômicos.

As bases do manejo integrado, para a implantação dos diferentes pilares de controle são a identificação do patógeno, o monitoramento de sintomas e sinais ao longo do ciclo do hospedeiro e a devida atenção aos níveis de controle. Desta forma, é possível determinar o momento adequado biologicamente, ecologicamente e economicamente para implementar medidas de controle.

Diferentes trabalhos têm proposto modelos de ponto crítico, múltiplos pontos, superfície resposta, integral e sincológicos com a finalidade de relacionar a injúria com o dano. Ou seja, estas equações e coeficientes de determinação permitem prever e quantificar os danos de epidemias futuras a partir dos níveis da doença, fornecendo também a informação do quão forte é a relação entre as duas variáveis.

Com o surgimento dos veículos aéreos não tripulados (VANT) acoplados a sensores multiespectrais, abriu-se uma nova frente na detecção e avaliação de doenças, bem como na quantificação dos danos ocasionados por elas, através da obtenção das reflectâncias e cálculos dos índices de vegetação. Apesar de não eximir as avaliações *in loco*, tornou-se mais uma ferramenta no manejo integrado de doenças.

Outro avanço na detecção e quantificação de doenças são as Redes Neurais Convolucionais (RNC) que, através do treinamento de inteligências artificiais, proporcionam o reconhecimento de padrões. Essas RNC dispensam o uso de câmeras espectrais, e propiciam ao usuário uma experiência mais acessível com o reconhecimento de imagens capturadas a campo com um aparelho de celular.

Esse trabalho teve como objetivo estabelecer a relação injúria-dano para mancha foliares do milho (mancha branca, mancha de turcicum e mancha de bipolaris), verificar o potencial uso de índices de vegetação como métodos de

detecção e predição de danos para manchas foliares do milho e, de Redes Neurais Convolucionais para a detecção de manchas foliares do milho.

## 2 REVISÃO DE LITERATURA

### 2.1 A CULTURA DO MILHO (*ZEA MAYS*, L.)

O milho (*Zea mays* L.) pertence à família Gramineae/Poaceae e possui caráter monoico. Seus aspectos vegetativos e reprodutivos podem ser modificados através da interação com os fatores ambientais, os quais afetam o controle da ontogenia do desenvolvimento. Essa modificação, proveniente de seleção natural e domesticação, culminou em uma planta anual, robusta e ereta, com um a quatro metros de altura, “construída” para a produção de grãos (MAGALHÃES, 2002).

Na safra 2023/2024 foram produzidas cerca de 1,23 bilhões de toneladas de milho no mundo, sendo os Estados Unidos o principal produtor com 377,6 milhões de toneladas, seguido pela China com 294,9 milhões de toneladas e o Brasil com 126 milhões de toneladas (USDA, 2024).

A produção total de milho no Brasil para 2023/2024 foi de 115,697 milhões de toneladas, produtividade média de 5.496 Kg.ha<sup>-1</sup> e área plantada de 21,050 milhões de hectares. O milho segunda safra é o mais expressivo, com produção de 90,255 milhões de toneladas, seguido do milho primeira safra com 22,962 milhões de toneladas e do milho terceira safra com 2,480 milhões de toneladas (CONAB, 2024).

Na safra total 2023/2024 houve decréscimo de 12,3% na produção em relação à safra anterior. A estimativa de consumo interno do grão é de 84,24 milhões de toneladas, importação de 2,5 milhões de toneladas, exportação de 36 milhões de toneladas e estoque final de 5 milhões de toneladas (CONAB, 2024).

O estado do Paraná é o segundo maior produtor do grão no País, alcançando, na safra 2023/2024, o patamar de 14,9 milhões de toneladas, produtividade média de 5.339 Kg.ha<sup>-1</sup> e área de 2,80 milhões de hectares (CONAB, 2024).

Para a safra 2024/2025, considerando o total das safras de milho para o Brasil, esperam-se aumentos de 5,5% da produção, de 4,5% da produtividade e de 0,7% da área plantada, em relação à safra anterior (CONAB, 2024).

A ocorrência de doenças, plantas invasoras e pragas afetam significativamente o potencial produtivo da planta de milho (ÁVILA; PANIZZI, 1995; CHOCOROSQUI; PANIZZI, 2004; ROZA-GOMES, 2011).

## 2.2 MANCHA BRANCA

### 2.2.1 Etiologia e Ciclo Biológico

A mancha branca do milho é uma doença endêmica no Brasil e sua incidência e severidade tem aumentado significativamente a partir dos anos 1990, sendo encontrada em todas as regiões do país (FERNANDES; OLIVEIRA, 1997).

A primeira identificação do agente causal da mancha branca no Brasil concluiu que se tratava do fungo *Sphaerulina maydis* (P. Henn.) (HENNING, 1902) classificado posteriormente como *Phaeosphaeria maydis* (P. Henn.) Rane, Payak & Renfro, na Índia (RANE et al., 1965). Porém, trabalhos posteriores descreveram a bactéria *Pantoea ananatis* como agente causal da doença (PACCOLA-MEIRELLES et al., 2001; FANTIN et al., 2002; BOMFETI et al., 2008).

Técnicas moleculares identificaram *P. ananatis* em plantas infectadas a campo e por inoculação, reforçando a hipótese de que a bactéria é o agente etiológico (GONÇALVES et al., 2013). *P. ananatis* é uma bactéria que forma colônias amarelas, sendo uma espécie que apresenta genes de nucleação de gelo (*ice nucleation activity* - INA), os quais permitem a formação de cristais de gelo sob temperaturas desfavoráveis (ABE et al., 1989).

A mancha branca também pode ser considerada um complexo. Segundo Silva (1997, apud JULIATTI, 2014): “*Dentre os diversos patógenos que ocorrem na cultura do milho e que causam prejuízos expressivos no Brasil, destaca-se o complexo de agentes etiológicos da mancha branca do milho: Phaeosphaeria maydis, Phoma sorghina, Phoma sp. (seção Plenodomus), Sporomiella sp. e também a bactéria Pantoea ananatis*”

Devido à dificuldade em isolar e reproduzir os sintomas do fungo *P. maydis*, não é possível afirmar que seja o principal agente causal da doença (MANERBA, 2010). Sendo assim, o agente causal da mancha branca ainda é tema de discussão na comunidade científica (COSTA et al., 2009).

A mancha branca ocorre em temperaturas amenas (15 a 20 °C) e alta umidade (acima de 60%) (COSTA et al., 2011). Chuvas constantes e bem distribuídas podem acarretar maior severidade e diminuir significativamente a produtividade (SAWAZAKI et al., 1997). A presença de água livre na superfície foliar favorece as infecções, sendo essas condições comuns em regiões com altitude acima de 600 m (PEREIRA et al., 2005). Os plantios tardios propiciam o aumento da severidade da doença, já que as condições climáticas favoráveis ao patógeno no florescimento acarretam um acometimento maior, devido à sensibilidade da planta nessa fase (COSTA et al., 2009).

O inóculo primário que ocasiona esta doença é proveniente de restos culturais, não tendo sido identificado um hospedeiro intermediário, sendo a disseminação realizada através do vento, sementes ou água (PEREIRA, 1997). Esses restos aumentam a severidade da doença, uma vez que a bactéria *P. ananatis* sobrevive nas formas saprofítica, epifítica, endofítica e patogênica e, em diferentes estádios da planta (FIGUEIREDO et al., 2012). Já os fungos do complexo são necrotróficos, sobrevivendo também em restos de cultura, “alimentando” a fonte de inóculo para as safras seguintes (PEREIRA et al., 2005).

Sendo assim, os possíveis agentes causais desta doença também podem ser controlados por rotação de cultura (REIS et al., 2004; ELENA et al., 2008).

### 2.2.2 Sintomatologia

Inicialmente, as lesões da doença são circulares, aquosas e verdes claras, sendo que depois tornam-se necróticas, de cor palha, elípticas, com formatos irregulares e diâmetro de 0,3 a 1 cm, podendo haver coalescência entre as lesões. Aparecem inicialmente na ponta das folhas e progridem para a base, e em relação à planta, primeiro nas folhas inferiores, evoluindo posteriormente para as folhas superiores. Os sintomas se tornam mais severos após a fase de pendoamento, podendo levar à senescência das folhas, reduzindo o ciclo e comprometendo a produtividade. Em alta severidade, a doença também pode ser observada na palha da espiga (COSTA et al., 2011; PACCOLA-MEIRELLES et al., 2001).

Geralmente, lesões dessa doença não ocorrem em plântulas no campo e o tamanho das lesões também é variável entre os diferentes híbridos

(COSTA et al., 2011; PACCOLA-MEIRELLES et al., 2001). Apesar de menos frequente, em casos de ocorrência em plantas jovens de genótipos suscetíveis, durante a fase vegetativa, a doença resulta na seca prematura (ROLIM et al., 2007), sendo que híbridos suscetíveis à mancha branca podem sofrer até 60% de perda da produção (FERNANDES; OLIVEIRA, 1997).

Os danos acarretados por mancha branca estão relacionados à suscetibilidade do hospedeiro, ao seu estágio de desenvolvimento na infecção e às condições ambientais favoráveis ao desenvolvimento da doença (PEREIRA et al., 2005). A partir do estágio R5 (grão farináceo duro), um aumento de 1% na severidade resulta em uma redução de 0,23% na produtividade e de 0,16% no peso dos grãos (CARSON, 2005).

## 2.3 MANCHA DE TURCICUM

### 2.3.1 Etiologia e Ciclo Biológico

A mancha de turcicum ocorre em todas as regiões produtoras de milho do Brasil, sendo considerado um dos principais problemas dessa cultura, gerando danos quantitativos e qualitativos em locais com alta umidade e temperaturas moderadas (PINTO, 2004). A doença tem maior intensidade na safrinha e causa maiores prejuízos nas infecções que ocorrem no período de floração (FERNANDES; OLIVEIRA, 2000).

Segundo White (2000, apud COTA et al., 2013), o agente etiológico da mancha de turcicum é o fungo *Exserohilum turcicum* (Pass.) K. J. Leonard & E. G. Suggs (sinônimos *Helminthosporium turcicum* Pass.; *Bipolaris turcica* (Pass.) Shoemaker; *Drechslera túrcica* (Pass.) Subramanian & P. C. Jain). A fase teleomórfica do fungo, ou forma perfeita, é o ascomiceto *Setosphaeria turcica* (Luttrell) K. J. Leonard & E. G. Suggs (sinônimo *Trichometasphaeria turcica* Luttrell). O patógeno, produz conídios de coloração verde-oliva ou marrom-escura, fusiformes, curvos contendo 3 a 8 septos, medindo 20 x 105 µm, com hilo basal saliente e germinação através de tubo germinativo polar. Os conidióforos são oliváceos, com 2 a 4 septos, medindo de 7-9 x 150-250 µm. A fase teleomórfica raramente ocorre na natureza, porém é passível de ser induzida em condições controladas, produzindo peritécios globosos e escuros. As ascas são cilíndricas,

contendo de 1 a 8 ascósporos, sendo que estes são hialinos, triseptados, retos ou ligeiramente curvos de dimensões de 13-17 x 42-78 µm (COTA et al, 2013).

A infecção causada por *Exserohilum turcicum* é favorecida por temperaturas entre 16 °C a 30 °C (JULIATTI et al., 2005).

Restos de cultura provenientes do sistema de plantio direto são fontes de inóculo para o desenvolvimento da doença, sendo que o patógeno pode sobreviver como saprófita ou formar esporos de resistência, os clamidósporos. Ciclos secundários também ocorrem após a dispersão de conídios pelo vento (LEACH et al., 1977; LEVY, 1984; LEVY, 1995; LEVY; COHEN, 1981; LEVY; PATAKY, 1992).

### 2.3.2 Sintomatologia

Os sintomas da mancha de turcicum são lesões necróticas no formato elíptico e alongado, com coloração acinzentada, pardas ou marrons, sem bordos delimitados, medindo de 2,5 a 15 cm de comprimento, iniciando pelas folhas inferiores (CASELA et al., 2006; ELLIOT; JENKINS, 1946). Em ataques severos, pode ocorrer a queima completa dos tecidos (WHITE, 2000).

A doença também pode aumentar a suscetibilidade dos tecidos às podridões do colmo, ocasionadas pelos agentes *Diplodia* sp. e *Fusarium* sp. (BALMER; PEREIRA, 1987).

Os danos causados pela doença podem exceder 40% da produção de grãos, sendo considerada limitante para a produção em algumas partes do mundo (COTA et al., 2013).

## 2.4 MANCHA DE BIPOLARIS

### 2.4.1 Etiologia e Ciclo Biológico

A mancha de bipolaris na cultura do milho é causada pelo ascomiceto *Bipolaris maydis* (Teleomorfo: *Cochliobolus heterostrophus*). O patógeno tem sobrevivência na forma de micélio e conídios em restos de cultura, sendo dispersados através do vento, ocasionando infecções primárias em condições

favoráveis ao desenvolvimento da doença, como em alta umidade e temperaturas de 20 a 32 °C e, posteriormente, infecções secundárias, originadas a partir da disseminação dos conídios produzidos nas lesões (KIMATI et al., 2005). Um ciclo da doença pode ocorrer em um período de 60 a 72 horas (raça T) (MUNKVOLD; WHITE, 2016). O fungo pode ser identificado através da verificação dos conídios em microscópio, os quais são produzidos nas lesões foliares ou em meio de cultura. Os conídios, medindo de 15 a 20 µm por 70 a 160 µm, apresentam coloração marrom oliváceo, curvos em sua maioria, com as extremidades afuniladas e arredondadas, apresentando de 5 a 11 septos. A germinação dos conídios é do tipo bipolar. A forma sexual do fungo tem sido observada apenas em meio de cultura, com a produção característica de 4 a 8 ascósporos, em ascas hialinas e cilíndricas. As dimensões dos ascósporos são de 6 a 7 µm por 130 a 340 µm, os quais tem coloração escura e possuem de 5 a 9 septos (COSTA et al., 2014).

#### 2.4.2 Sintomatologia

Os sintomas da doença são variáveis, dependendo do genótipo do hospedeiro e das raças do fungo que estejam infectando as plantas. A raça O é a que mais ocorre, geralmente atacando apenas folhas e causando lesões inicialmente pequenas e ovaladas, posteriormente evoluindo para lesões alongadas, medindo de 0,2 a 0,6 cm de largura por 0,5 a 2,0 cm de comprimento, limitadas pelas nervuras, e apresentando coloração palha. Os sintomas causados pela raça T são lesões ovais e ligeiramente maiores que os causados raça O, apresentando borda de coloração marrom escura, medindo de 0,6 a 1,2 cm de largura por 0,6 a 2,7 cm de comprimento. Além de causar lesões em toda a parte epígea das plantas, a raça T também pode causar podridão nas espigas. A raça C causa lesões estreitas, alongadas e necróticas (COSTA et al., 2014; KIMATI et al., 2005).

Em elevada pressão da doença, principalmente ocorrendo infecção antes do florescimento, as lesões podem coalescer, resultando na queima do limbo foliar. Em alguns casos, essas lesões podem ser confundidas com as da cercosporiose do milho, sendo possível fazer a distinção observando-se as bordas e o tamanho das lesões. As lesões da cercosporiose apresentam os bordos delimitados pelas nervuras e são bem definidos, com formatos retilíneos, sendo mais estreitas e alongadas que as da mancha de bipolaris. Estas últimas, apesar de

também serem delimitadas pela nervura, não são predominantemente retilíneas, apresentando bordas com tortuosidades (COSTA et al., 2014).

Em relação aos danos, a doença é mais nociva em regiões de clima temperado e tropicais quentes e úmidas, nas quais tem sido relatadas perdas de produção superiores a 70% (COSTA et al., 2018)

## 2.5 MEDIDAS DE CONTROLE DE DOENÇAS

As interações entre hospedeiro suscetível, patógeno nocivo e ambiente favorável culminam no desenvolvimento de doenças, as quais irão impactar na produtividade e lucratividade (AGRIOS, 2004; VALE et al., 2004). Ao longo dos anos, diferentes princípios de controle foram sistematizados de acordo com suas respectivas atuações nas relações patógeno-hospedeiro e ambiente: Exclusão, erradicação, evasão (atuação no patógeno), proteção, imunização, terapia (atuação no hospedeiro), regulação e evasão (atuação no ambiente) (WHETZEL, 1929; MARCHIONATTO, 1949).

Dentre as medidas de manejo de doenças na cultura do milho, estão a época de plantio adequada, utilização de sementes de boa qualidade e tratadas com fungicidas, rotação de culturas, adubação equilibrada, população adequada, controle de pragas e de plantas daninhas e colheita no período adequado. O manejo integrado visa reduzir o inóculo na lavoura e dar longevidade à resistência genética das cultivares comerciais (CASELA et al., 2006). A suscetibilidade da planta, pressão da doença, condições ambientais e momento da aplicação vão influenciar na efetividade do controle químico (GENET et al., 2000).

Os fungicidas são moléculas químicas, orgânicas ou inorgânicas, utilizadas para evitar os processos de sobrevivência, disseminação, colonização e reprodução dos fungos e dos oomicetos causadores de doenças. Sendo assim, podem atuar segundo vários princípios de controle em função da natureza do produto, da época e da metodologia de aplicação, podendo ser classificados quanto à finalidade, ao princípio geral de controle, mobilidade na planta, modo de ação, classe toxicológica, uso ou emprego e grupo químico (BERGAMIN FILHO et al., 2018).

Quanto ao princípio geral de controle, podem ter ação erradicante,

protetora e curativa e quanto à mobilidade podem ser sistêmicos, mesostêmicos e tópicos. Em relação à classificação pelo modo de ação, proposta pelo Comitê de Ação de Resistência de Fungos a Fungicidas (FRAC), os grupos dos fungicidas mais utilizados na cultura do milho são: G, para biossíntese de esteróis da membrana; C, para atuação na respiração e M, ação multissítio. De uma maneira geral, os principais fungicidas utilizados no controle de doenças de plantas pertencem aos grupos Inibidores da quinona externa (Qol), Inibidores da desmetilação de esteróis (DMI), Metil benzimidazol carbamato (MBC), Inibidores da enzima succinato desidrogenase (SDHI), ditiocarbamatos e produtos inorgânicos (BERGAMIN FILHO et al., 2018).

### 2.5.1 Controle de Mancha Branca

As medidas de manejo mais importantes para a mancha branca do milho são o controle genético com plantio de cultivares resistentes e controle cultural com plantios antecipados e rotação de culturas (CASELA et al., 2006). A utilização de híbridos resistentes é a melhor medida de controle para a mancha branca (PEREIRA et al., 2005; COSTA et al., 2011).

O controle químico também é uma importante ferramenta no manejo dessa doença e tem sido galgado principalmente nos fungicidas pertencentes aos grupos dos triazóis, estrobilurinas e carboxamidas e suas combinações (CUSTODIO et al., 2019). Para a intervenção química, primeiramente é preciso levar em consideração o estágio de aparecimento dos primeiros sintomas mediante monitoramento (COSTA; COTA, 2009).

Recentemente, ensaios de rede têm sido realizados com o objetivo de observar o comportamento de diferentes tratamentos no controle da mancha branca, dentre os quais obtiveram controles satisfatórios, acima de 80%: hidróxido de cobre; clorotalonil; mancozebe + azoxistrobina; mancozebe + hidróxido de cobre; piraclostrobina + epoxiconazol + fluxapiroxade; trifloxistrobina + protioconazol + bixafen; carboxamida + difenoconazol; piraclostrobina + fluxapiroxade + mefentriflunconazol; e azoxistrobina + difenoconazol + clorotalonil (CUSTODIO et al., 2019).

Fungicidas multissítio como mancozebe, e clorotalonil têm se mostrado eficientes no controle da mancha branca e cercosporiose (SOUZA et al.,

2015; CUSTODIO et al., 2019). Mancozebe também controlou a bactéria *in vitro* e em situações de campo, sustentando a hipótese de que a bactéria é realmente uma das causadoras dessa doença (BOMFETI et al., 2007).

Os antibióticos constituem um grupo de compostos químicos produzidos por microrganismos capazes de inibir ou matar microrganismos em baixas concentrações e com alto grau de especificidade (BERGAMIN FILHO et al., 2018). Segundo Gonçalves (2013), o antibiótico oxitetraciclina proporcionou o menor número de lesões de mancha branca em condições de campo e em laboratório inibiu o desenvolvimento da bactéria. De acordo com Juliatti et al. (2014), o antibiótico kasugamicina, aplicado isoladamente, controla a mancha branca, porém é mais efetivo em combinações com fungicidas como Epoxiconazol, Ciproconazol e Azoxistrobina.

## 2.5.2 Controle de Mancha de Turcicum

Para a mancha de turcicum, a principal medida de controle é a resistência genética (COTA et al., 2013), a qual resulta em menor número de lesões, aumento dos períodos de incubação e latente, redução da produção de conídios e consequentemente redução da taxa de progresso da doença (CARSON, 2006).

O uso de fungicidas para o manejo dessa doença é recomendado quando de elevada severidade, ocasionada pelo uso de materiais suscetíveis, condições climáticas favoráveis ao patógeno e plantio direto sem rotação de culturas (COTA et al., 2013). Os fungicidas contendo as formulações com protioconazol + trifloxistrobina; propiconazol e ciproconazol + azoxistrobina apresentaram controle satisfatório por até 21 dias após a inoculação com *Exserohilum turcicum*. Para o controle curativo, ciproconazol + azoxistrobina; benzovindiflupir + azoxistrobina; propiconazol; protioconazol + trifloxistrobina e azoxistrobina apresentaram controle satisfatório até 15 dias após a inoculação, sendo que o fungicida protioconazol + trifloxistrobina proporcionou a menor taxa de expansão de lesões de *Exserohilum turcicum* curativamente (CAMARA et al., 2019).

As aplicações nos estágios de pré-florescimento e V8 + pré-florescimento da safrinha de milho, utilizando os fungicidas trifloxistrobina + tebuconazol, diminuíram a severidade tanto de mancha de turcicum quanto de cercosporiose (MOTERLE; SANTOS, 2019).

### 2.5.3 Controle da Mancha de Bipolaris

A aplicação de fungicidas foliares como propiconazol, mancozeb e zineb foram eficazes na redução da epidemia de mancha de bipolaris (TURGEON; BAKER, 2007; AMIN et al., 2012; DIDVANIA et al., 2012). Contudo, o melhor método de controle para a doença é o uso de variedades resistentes (MARGARET et al., 2013; BASHIR et al., 2017). Os híbridos que não possuem o citoplasma T, são resistentes à raça T. A raça O pode ser controlada a partir de cultivares resistentes (KIMATI et al., 2005).

O controle biológico através da pulverização de suspensão de conídios de *Trichoderma harzianum* (SH2303) e *Trichoderma atroviride* (SG3403) demonstrou uma forte atividade contra o patógeno, raça O, pois têm a capacidade de formar associações endofíticas mutualísticas juntamente com diferentes espécies de plantas (MENG et al., 2015).

Práticas culturais como rotação de culturas e preparo do solo ajudam a minimizar a sobrevivência do patógeno em restos de cultura, diminuindo a fonte de inóculo (CALVERT; MARCUS, 2012). Há a necessidade contínua de desenvolvimento e avaliação de mais variedades que sejam resistentes à doença, bem como a utilização de ferramentas moleculares mais avançadas para detectar o agente patogénico (KUTAWA et al., 2021).

## 2.6 RELAÇÃO DE INJÚRIA-DANO E LIMIAR DE DANO ECONÔMICO

A severidade é um parâmetro da fitopatometria (quantificação de doenças) utilizado para mensurar a porcentagem da área de tecido coberto por sintomas que retrata a quantidade de uma doença, podendo ser medida através de escalas diagramáticas e análises de imagens por computador (BERGAMIN FILHO et al., 2018). As escalas diagramáticas são representações ilustradas de uma série de plantas, folhas ou partes de plantas com sintomas em diferentes níveis de severidade para a quantificação de doenças (BERGAMIN FILHO et al., 1996). Estas escalas diminuem a subjetividade das estimativas entre os avaliadores, melhorando a acurácia e a precisão nas avaliações (MARTINS et al., 2004).

A quantificação dos danos é imprescindível para a definição de

estratégias de controle. Segundo Zadoks (1985, apud BERGAMIN FILHO et al., 1996) qualquer agente que cause dano à uma lavoura é um organismo nocivo, sendo que a injúria é qualquer sintoma na planta e o dano qualquer redução na produção, a qual pode gerar reduções no retorno financeiro, denominada de perda. A função de dano relaciona dano (D) com injúria (I) através da equação:  $D = f(I)$ . Obter dados para estabelecer a função de dano é o objetivo da fase experimental de um projeto de pesquisa que visa a determinação dos prejuízos causados por um patógeno. Injúria, nesse contexto pode ser traduzida por incidência ou severidade da doença. Ensaio que contém parcelas com plantas sadias e parcelas com plantas doentes, estas exibindo diferentes níveis de injúria, são geralmente empregados para o estabelecimento da função de dano. Deste modo, obtém-se um conjunto de variáveis independentes (níveis da doença) que pode ser relacionado com um conjunto de variáveis dependentes (níveis de dano) (BERGAMIN FILHO et al., 1996).

Diferentes modelos matemáticos podem ser utilizados para estimar danos à níveis local, regional ou nacional, sendo geralmente abastecidos com dados de injúria e gerando dados de produção ou dano (BERGAMIN FILHO et al., 1996). Segundo Teng e Johnson (1988, apud BERGAMIN FILHO et al., 1996), há muitos tipos de modelo para relacionar injúria com dano: Modelos de ponto crítico, de múltiplos pontos, integrais, de superfície resposta e sinecológicos.

No modelo de ponto crítico é possível identificar um estágio de desenvolvimento específico da planta no qual a intensidade da doença está altamente correlacionada com o dano futuro, sendo que uma só variável independente reflete toda a pandemia. Já o modelo de múltiplos pontos relaciona dano com variáveis derivadas de avaliações sucessivas do progresso da doença durante o ciclo da planta, como por exemplo, a severidade em diferentes estágios de desenvolvimento (BERGAMIN FILHO et al., 1996).

As equações de função de dano subsidiam o cálculo do Limiar de Dano Econômico (LDE) (EMBRAPA, 2023). O conceito de LDE pode ser definido como a menor densidade populacional que causa dano econômico (STERN, 1959), ou então, o nível de ataque do organismo nocivo no qual o benefício do controle se iguala ao seu custo (MUNFORD; NORTON, 1984).

O LDE deve ser calculado anualmente e para cada situação em função das variações dos preços da cultura e custo de aplicação (EMBRAPA, 2023),

sendo um critério racional para aplicação de fungicidas (BOHATCHUK et al., 2008).

Com base no manejo integrado de doenças, levando em consideração o LDE, as aplicações de fungicidas devem ser realizadas no limiar de ação (LA), pois a doença não deve exceder o LDE (EMBRAPA 2023). O fungicida deve ser aplicado antes que o LDE seja excedido para atingir alta eficácia do controle químico, uma vez que tanto a implementação do controle quanto a ação do fungicida levam tempo. O LA leva em consideração o tempo entre o registro da severidade da doença e o momento em que o fungicida pode realmente ser aplicado, o que depende, por exemplo, da compra do ingrediente ativo, das condições climáticas para pulverização, dentre outros fatores (DE ROSSI et al., 2022).

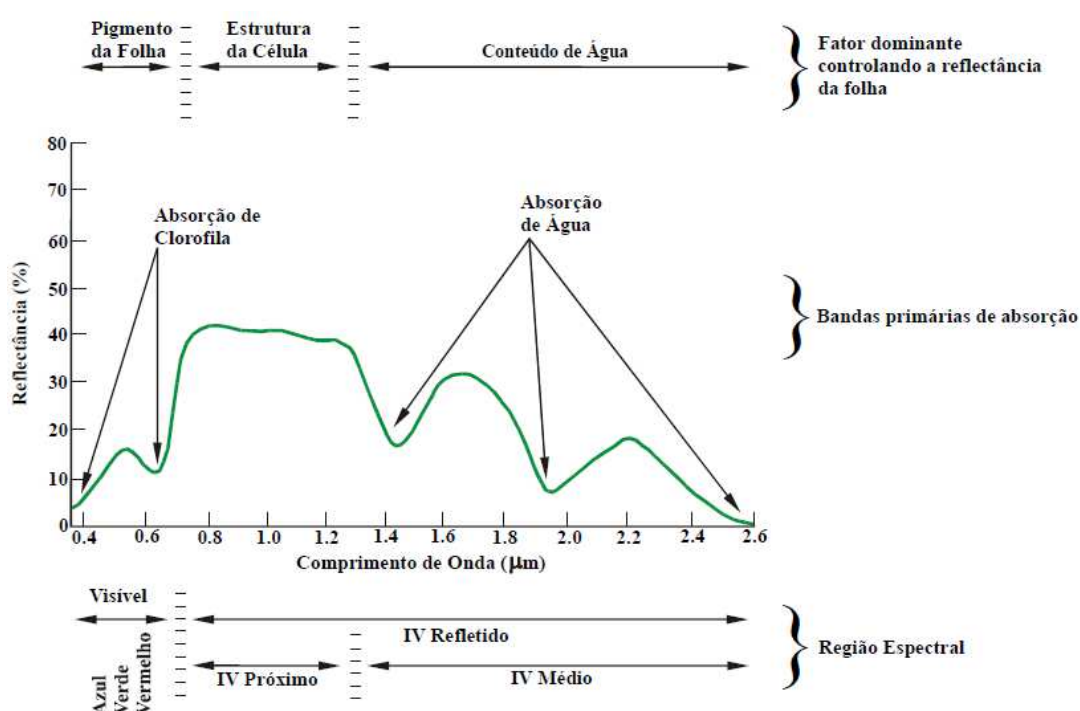
No milho, avaliações de doenças no estágio de grãos pastosos têm similaridade com o modelo de múltiplos pontos, havendo alta correlação com a produtividade comparando à outras épocas de avaliação (FANTIN et al., 2004; BRITO et al., 2008). Vários trabalhos têm relatado uma correlação negativa entre a produtividade do milho e a severidade da doença nas condições brasileiras (COTA et al., 2010). Análises de regressão entre rendimento de grãos de milho e número de lesões de cercosporiose geraram trinta equações lineares de função de dano (REIS et al., 2007). Avaliando diferentes híbridos de milho, concluiu-se que severidades de até 10% de doenças como a mancha branca, cercosporiose, ferrugens e mancha de turcicum no estágio de grãos pastosos, resultam em redução de 20% ou mais na produtividade (FANTIN et al., 2010). Baixas severidades de cercosporiose podem acarretar reduções de 4% na produtividade e altas severidades podem causar reduções de até 25% (FANTIN et al., 2008). Para mancha de bipolaris ainda carecem trabalhos de relação injúria-dano.

Para a comparação de trabalhos de produtividade do milho com e sem o uso de fungicidas para o controle de diferentes doenças, há a necessidade do uso da avaliação de múltiplos pontos para obtenção da AACPD, em vista da inadequação do uso da avaliação baseada no modelo de “ponto crítico” para este tipo de ensaio (FANTIN, 2010).

## 2.7 SENSORIAMENTO REMOTO

Segundo West et al. (2003, apud BERGAMIN FILHO, 2018) o

sensoriamento remoto é um conjunto de técnicas para obter dados de um objeto sem que haja contato físico com ele. Os tecidos das plantas transmitem, absorvem e refletem radiações, sendo que haverá variações de acordo com a espécie, níveis de doença etc. Folhas saudáveis têm baixa reflectância na região do visível (400-700 nm) e na região do infravermelho curto (1200-2400 nm) e alta reflectância na região do infravermelho próximo (700-1200 nm) (WEST et al., 2003). O infravermelho médio fica na faixa de 1300-3000 nm (VETORAZZI, 1992). A clorofila “a” tem maior absorção na banda do vermelho e a clorofila “b” na banda do azul, sendo os pigmentos que mais influenciam a reflectância (MOREIRA, 2005). Ou seja, folhas saudáveis têm baixa reflectância na região do visível, pois os pigmentos são fortemente absorvidos, alta reflectância no infravermelho devido à estrutura lacunosa das células e baixa reflectância na região do infravermelho médio devido à absorção de proteínas, águas, etc (Figura 1) (HATFIELD; PINTER JUNIOR, 1993).



**Figura 1** – Curva de reflectância de uma folha verde.

Fonte: Adaptado de KEYWORTH et al., 2009.

Em outras palavras, os tecidos saudáveis refletem o infravermelho com maior intensidade do que os tecidos doentes (CANTERI, 1998). Sendo assim, sistemas de detecção e quantificação de doenças podem se basear em medidas do espectro em diferentes comprimentos de onda (WEST et al., 2003).

Filmes coloridos infravermelhos e, mais recentemente, câmeras digitais capazes de captar diferentes comprimentos de onda podem ser utilizados na avaliação de doenças por permitirem a distinção entre tecidos saudáveis e doentes (BERGAMIN FILHO, 2018). Estresses abióticos ou maturação podem provocar modificações no espectro semelhantes às doenças. Sendo assim, não se exige as avaliações da doença *in loco*. Segundo Sugiura et al. (2016, apud BERGAMIN FILHO, 2018), a utilização de sensores de radiação em veículos aéreos não tripulados (VANT), drones, deverá ampliar o uso dessa tecnologia na detecção e na quantificação de doenças de plantas.

Diferentes fatores interferem nos espectros, como a quantidade de clorofila, posição do sol e das folhas, textura da superfície, doenças, estágio da planta e etc (CANTERI et al., 1996).

Os índices de vegetação foram concebidos para otimizar a interpretação dos dados de reflectância. O *Normalized Difference Vegetation Index* (NDVI), índice de vegetação por diferença normalizada, é um dos índices mais estudados para diferentes finalidades (ROUSE et al., 1974), o qual é calculado pela seguinte equação:

$$\text{NDVI} = \frac{\text{IVP} - \text{V}}{\text{IVP} + \text{V}}$$

IVP = Reflectância no infravermelho próximo

V = Reflectância na banda do vermelho

O NDVI pode ser utilizado para fins distintos, como por exemplo: avaliar diferentes épocas de dessecação (VIAN et al., 2018), quantificar níveis de doenças (UEBEL, 2015), níveis de nitrogênio, matéria seca, biomassa da parte aérea e rendimento de grãos (TURRA, 2016; SOUZA et al., 2009; REZNICK, 2017; RISSINI et al., 2015), realizar a estimativa da produtividade e determinação de zonas de manejo (ARAÚJO et al. 2005), avaliação da cobertura foliar e matéria seca de plantas daninhas (MEROTTO Jr et al. 2012).

*Normalized Difference Red Edge* (NDRE) é a diferença normalizada da borda do vermelho, um índice utilizado para avaliar o teor de clorofila nas plantas (BARNES et al., 2000):

$$\text{NDRE} = \frac{\text{IVP} - \text{VL}}{\text{IVP} + \text{VL}}$$

IVP = Reflectância no infravermelho próximo

VL = Reflectância no limite do vermelho

Por exemplo, o NDRE pode ser utilizado correlacionar genótipos com o conteúdo de nitrogênio das folhas, altura de plantas, índices de sanidade, desenvolvimento e produtividade (SANTANA et al., 2021; FLORES et al., 2020; CARVALHO, 2021).

*Visible Atmospherically Resistant Index* (VARI) é o índice de vegetação resistente à atmosfera na região do visível, utilizando a banda do verde, baseado na variabilidade de vigor e estresse da planta (GITELSON et al., 2002):

$$\text{VARI}_{\text{green}} = \frac{\text{Vd} - \text{V}}{\text{Vd} + \text{V} + \text{A}}$$

Vd = Reflectância na banda do verde

V = Reflectância na banda do vermelho

A = Reflectância na banda do azul

Por exemplo, o VARI pode ser correlacionado com a fração verde da vegetação para detecção da transição fisiológica na fenologia da cultura (VIÑA et al., 2004) e com o índice de área foliar (IAF) (HASAN et al., 2019).

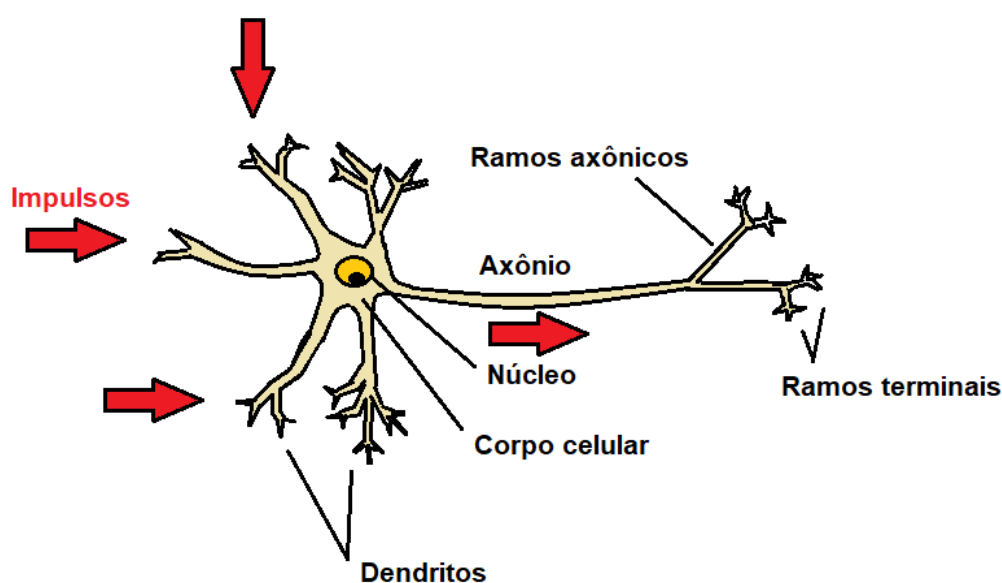
Com base na informação de que índices de vegetação otimizam a interpretação dos dados de reflectância e de que os tecidos sadios refletem o infravermelho com maior intensidade do que os tecidos doentes (CANTERI, 1998), os índices de vegetação podem ser utilizados para a detecção de doenças.

## 2.8 REDES NEURAS CONVOLUCIONAIS

As redes neurais artificiais (RNA) são instrumentos computacionais que proporcionam a resolução de problemas de diferentes áreas do conhecimento, sendo um campo multidisciplinar, envolvendo neurofisiologia, psicologia, física, computação e engenharia (DE CASTRO SILVA, 2001). A rede neural é um processador constituído de unidades simples amplamente distribuídas

paralelamente, armazenando informações e tornando-as disponíveis. Essas redes são baseadas no cérebro biológico em sua conexão entre os neurônios (peso sináptico), processo de aprendizagem e armazenamento de conhecimento (HAYKIN, 2008), ou seja, as redes neurais artificiais são inspiradas na cognição humana ou biologia neural (DE CASTRO SILVA, 2001). Segundo Haykin (2008), o neurônio artificial é uma simplificação matemática do manuseio de informação dos neurônios biológicos, os quais são unidades de processamento do sistema nervoso (HAYKIN, 2008, apud SIQUEIRA, 2009).

O neurônio biológico é formado por dendritos, que coletam sinais, corpo celular, que recebe as entradas e processa o sinal gerando uma resposta, axônio, que propaga a resposta pela sinapse até suas terminações (Figura 2) (TETTEROO, 2018). O cérebro biológico consegue organizar seus neurônios e realizar processamentos complexos, tais como reconhecimento de padrões, percepção e coordenação motora, como, por exemplo, a visão humana distinguindo rostos conhecidos ou não (HAYKIN, 2008).

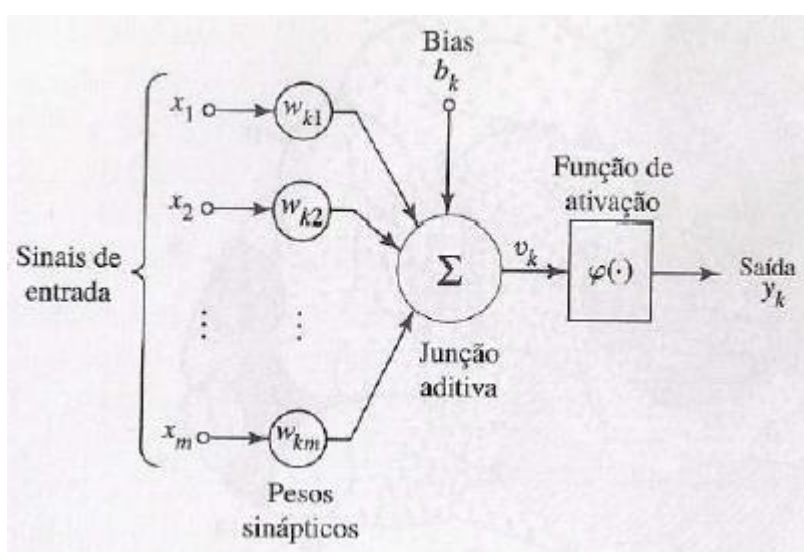


**Figura 2** – Representação de neurônio biológico.

Fonte: Adaptado de TETTEROO, 2018.

McCulloch & Pitts (1943) criaram a primeira estrutura de RNA, e Hebb (1949) sugeriu que os neurônios funcionam como uma rede com ativação de células. Na década de 1950 e 1960, Rosenblatt desenvolveu o modelo Perceptron, onde no neurônio artificial, dentro do modelo computacional, os dendritos são como

os sinais de entrada ( $x_1, x_2$  etc), que multiplicados por seus respectivos pesos ( $w_{k1}, w_{k2}$  etc) juntamente ao valor de bias ( $b_k$ ), a entrada de polarização que alteram esse valor de entrada (+1), chegam até uma unidade somadora, estrutura semelhante ao corpo celular que realiza a soma ponderada das entradas. Em seguida o sinal é enviado para a função de ativação através da saída ( $u$ ), a função de ativação simula a função do axônio  $\phi(\cdot)$ , o qual terá a saída ( $y_k$ ) em sua terminação (Figura 3) (HAYKIN, 2008). Apesar dessas semelhanças, os neurônios artificiais ainda têm menos conexões que os neurônios biológicos (COPPIN, 2013).



**Figura 3** – Composição de neurônio artificial.

Fonte: HAYKIN, 2008.

Traduzindo matematicamente o neurônio, temos a seguinte equação (Figura 4) (HAYKIN, 2008):

$$y_k = f(u_k) = \varphi \left( \sum_{j=1}^m w_{kj} x_j + b_k \right)$$

**Figura 4** – Equação de neurônio artificial.

Fonte: HAYKIN, 2008.

Considerando o exemplo hipotético a seguir (Figura 5), entradas com os valores  $x_1 = 2$ ;  $x_2 = 6$  e com os pesos  $w_1 = 0,4$  e  $w_2 = 0,1$ ; adicionando as *bias*, teremos o somatório  $\Sigma$ . O valor de saída é  $u = 1,4$ , que ao chegar na função de

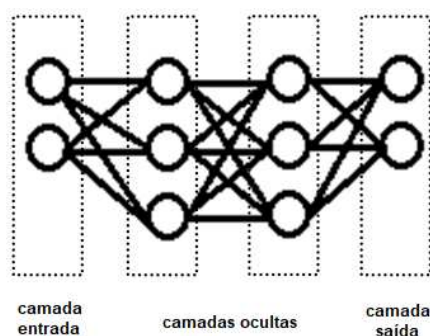
ativação  $\phi(.)$  será avaliado (se  $\Sigma \leq 0$  é 0 e se  $\Sigma \geq 0$  é 1), resultando em  $y = 1$ . Ou seja, se a soma exceder o limiar há a ativação da saída, caso contrário a saída permanece desativada (BRAGA et al., 2011).

Entradas	x1	2
	x2	6
Pesos	w1	0,4
	w2	0,1
Bias	b	
Junção somadora	$\Sigma$	
Saída	u	1,4
Função de ativação	$\phi(.)$	$\Sigma \geq 0$
Resultado de saída	1	

**Figura 5** – Exemplo hipotético de neurônio artificial.

Fonte: Adaptado de BRAGA et al, 2011.

Assim como redes neurais biológicas, em RNAs com múltiplas camadas ocultas de neurônios (Figura 6), as saídas provenientes dos somatórios ( $\Sigma$ ) se propagam através das camadas até chegarem à camada de saída (DSA, 2018).

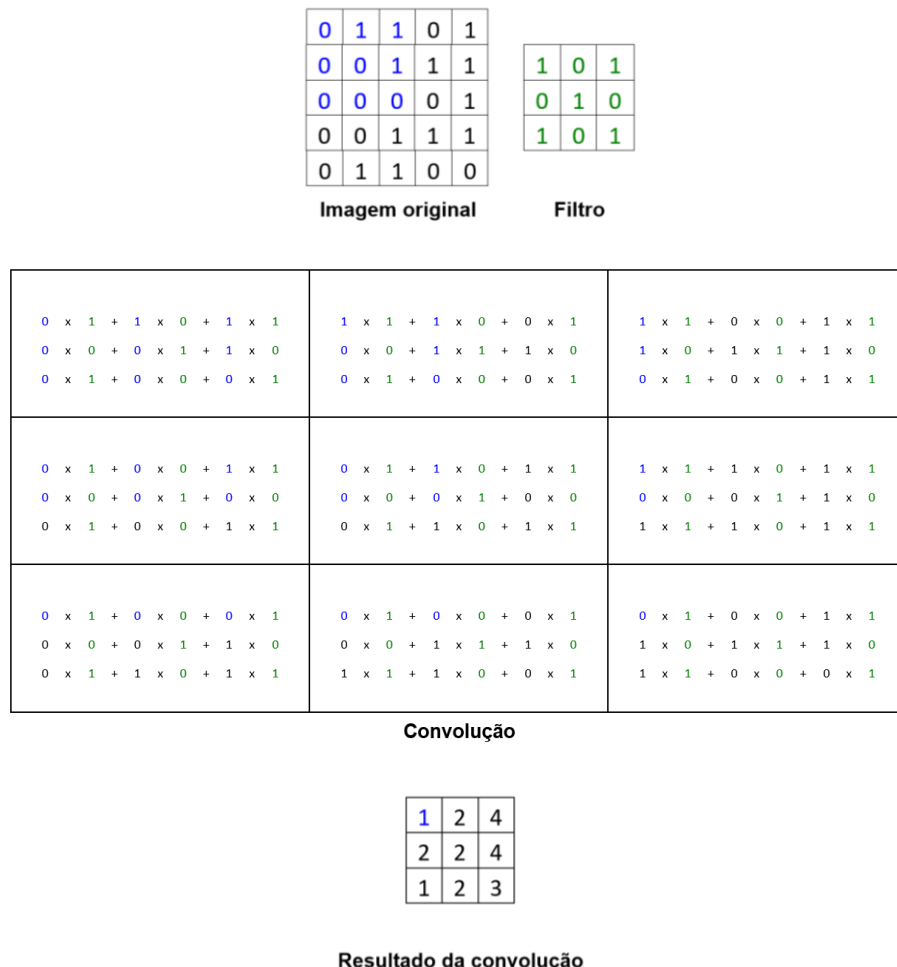


**Figura 6** – Redes neurais multicamadas.

Fonte: Adaptado de DSA, 2018.

A forma de agrupamento dessas camadas e seu aprendizado constituem a arquitetura das RNAs. As Redes Neurais Convolucionais - RNC (*Convolutional Neural Network* - CNN) são um desses tipos de arquitetura, as quais

utilizam mapas de convolução como grupos de pesos compartilhados entre os neurônios presentes nas camadas de convolução. A convolução consiste em uma operação matemática entre duas funções  $f$  e  $g$ , resultando em uma terceira, a função modificada de  $f$ . Em outras palavras, é o somatório da multiplicação de cada componente da imagem pelos componentes do filtro (*kernel*), reduzindo a imagem original às dimensões do filtro (Figura 7). No processamento de imagens, uma imagem é uma função bidimensional, então a convolução é útil para a detecção de bordas, suavização, extração de atributos, dentre outras funções, existindo diferentes *kernels* para cada uma delas, que servirão para selecionar os *pixels* mais importantes (PARKER, 2010). Sendo assim, as Redes Neurais Convolucionais executam filtros em imagens estabelecendo uma relação de vizinhança entre os *pixels* da imagem durante o processamento, assim como nos processos biológicos, como um pré-processamento para depois dar entrada às RNAs (VARGAS et al., 2016).



**Figura 7** – Exemplo de convolução de imagem.

Fonte: Adaptado de PARKER, 2010.

Os resultados dessas camadas de convolução são processados nas ReLUs (*Rectified Linear Units*), neurônios com função de ativação definida de não-linearidade, aplicados na saída de cada camada convolucional, tirando os valores negativos (Figura 8) (KRIZHEVSKY, 2012).

3	-3	0	1	2	-1
2	2	-2	2	2	5
1	2	3	1	12	3
1	2	4	2	2	4
2	2	4	2	-3	4
1	2	3	1	4	5


3	0	0	1	2	0
2	2	0	2	2	5
1	2	3	1	12	3
1	2	4	2	2	4
2	2	4	2	0	4
1	2	3	1	4	5

Resultado da convolução
ReLU

**Figura 8** – Aplicação das ReLUs (*Rectified Linear Units*).

Fonte: Adaptado de KRIZHEVSKY, 2012.

Depois de aplicada a função ReLU, faz-se a aplicação das camadas de *pooling*, com a função *max pooling*, que computam o valor máximo de diferentes regiões do mapa de atributos, deixando apenas os valores máximos e eliminando o restante, diminuindo a dimensão da representação dos dados (*downsampling*), conseqüentemente aumentando a eficiência da computação para as camadas seguintes, criando variâncias e invariâncias entre as imagens (Figura 9) (LECUN, 2015). O *pooling* também pode ser feito com as funções de soma ou média (BIANCHI, 2020). Em seguida, na etapa de *flattening*, que consiste na transformação da matriz em um vetor, possibilita sua entrada na Rede Neural Artificial (Figura 9) (JEONG, 2019).

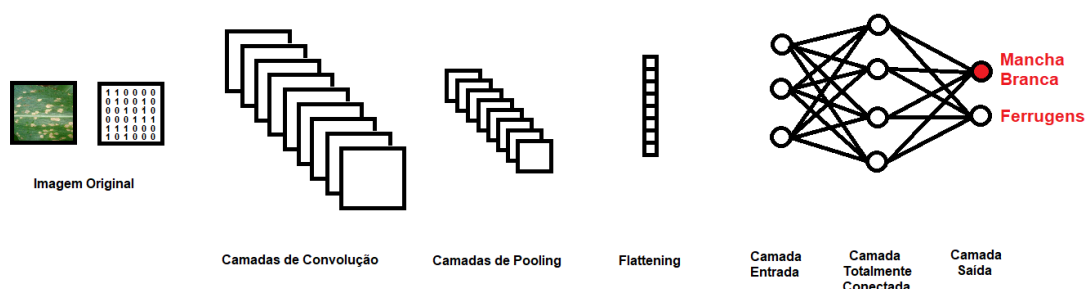


**Figura 9** – Etapas de *Max Pooling* e *Flattening*.

Fonte: Adaptado de LECUN, 2015.

Após as entradas na Rede Neural, há a camada densa, ou totalmente conectada, onde deve-se informar a dimensão de saída e a função de ativação a ser utilizada (Figura 10). A função *softmax* é muito utilizada na camada de

saída da RNC, pois produz uma distribuição das probabilidades para cada classe de imagem durante uma classificação, trabalhando com múltiplas classes (BIANCHI, 2020).



**Figura 10** – Visão geral da RNC (Redes Neurais Convolucionais).

Fonte: O próprio autor.

O reconhecimento de padrões é um processo complexo para computadores, mas simples aos seres humanos (VON ZUBEN, 2003). Os atributos extraídos das imagens são os padrões que servirão de base para o reconhecimento de outras imagens, almejando que este seja independente do tamanho, posição e outras variantes possíveis destas imagens (KHOTANZAD; LU, 1989).

Existem diferentes etapas para o reconhecimento de padrões: iniciando pela captura de imagens à campo, processamento abrangendo segmentação da imagem e extração de características importantes da mesma, treinamento com base nos atributos gerados na fase anterior e, resultados/classificação (KHOTANZAD; LU, 1989)

Redes Neurais Convolucionais foram eficientes em diferenciar espigas de trigo saudáveis de espigas com sintomas de Fusarium, com 75% de precisão (JIN et al., 2018). Utilizando uma RNC e um banco de 83.260 imagens de doenças de trigo, foi alcançada uma precisão de 96,5% na identificação das doenças (LIN et al., 2018). Utilizando 12.332 imagens, uma arquitetura RNC denominada de *DenseNet* apresentou 98,06% de acurácia na identificação de cercospora, mancha de turcicum e ferrugem comum, doenças importantes da cultura do milho (WAHEED et al., 2020). Com base no banco de imagens de problemas fitossanitários importantes para diferentes culturas da Embrapa, foi configurada uma rede neural com vários ciclos de treinamento, a fim de analisar a quantidade de

ciclos necessários para a melhor classificação. A programação foi de 250 épocas de avaliação, porém ciclos de treinamento com número de 75 épocas já foram suficientes para manter os níveis de acertos acima de 85%, com alta acuracidade, evidenciando que as RNCs são eficientes na identificação desses problemas (SILVA; SCHIMIGUEL, 2020). Um modelo de redes neurais convolucionais apresentou 90,1% de precisão na identificação de doenças nas culturas do tomate, milho e batata (SAEED et al., 2021). Ao gerar um modelo único de RNC para identificar doenças de múltiplas culturas, como trigo, cevada, milho, arroz e colza, foi obtida uma precisão balanceada de 93% (PICON et al., 2019). As RNCs também são utilizadas para inúmeras outras finalidades. Por exemplo, em usinas de carvão para fornecimento de energia, quanto mais pura a matéria prima, maior a liberação térmica e menor a descarga de poluentes. Sendo assim, a separação, peneiramento, classificação, dentre outras etapas de triagem são processos imprescindíveis, porém manuais e ineficientes. Assim, um estudo construiu um modelo de aprendizagem com uma rede neural convolucional para distinguir as imagens de carvão, onde 30 épocas foram suficientes para um reconhecimento de 82,5% de acuracidade (PU et al., 2019).

### 3 ARTIGO A: RELAÇÃO INJÚRIA-DANO PARA MANCHAS FOLIARES DO MILHO

#### 3.1 RESUMO

A elaboração de modelos matemáticos para estimar danos a partir de dados de injúria é de extrema importância para a predição de epidemias posteriores e tomada de decisão. Esse trabalho teve como objetivo estabelecer a relação injúria-dano para mancha foliares do milho (mancha branca, mancha de turcicum e mancha de bipolaris), gerando equações de funções de dano, subsidiando o cálculo do Limiar de Dano Econômico (LDE). Foram instalados quatro experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), no município de Londrina, PR, na safrinha de 2022. Os híbridos utilizados foram o AG 8780, AG 9021, AG 9025 e Fórmula VIP. O delineamento experimental utilizado foi blocos ao acaso com oito tratamentos e quatro repetições. Os tratamentos consistiram na aplicação dos fungicidas Prothioconazol + Trifloxistrobina + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>), na dose de produto comercial de 500 mL.ha<sup>-1</sup> do produto comercial em diferentes estádios fenológicos da cultura: T1 - testemunha; T2 - V6, V10, R2, R2+14; T3 - V6, V10, R2; T4 - V6, V10; T5 - V6; T6 - V10, R2, R2+14; T7 - R2, R2+14; T8 - R2+14. A quantificação da severidade das doenças foi realizada semanalmente utilizando-se escalas diagramáticas, sendo que os valores foram utilizados para o cálculo da área abaixo da curva de progresso da doença (AACPD) por integração trapezoidal. A colheita foi mensurada nas duas linhas centrais de cada parcela, estimando a produtividade (kg.ha<sup>-1</sup>), sendo corrigida para 13% de umidade. Os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5% de probabilidade. A relação entre AACPD e produtividade foi analisada por regressão linear. O LDE foi calculado através da equação  $ID = [Cc/(Pp \times Cd)] \times Ec$ . Foi calculada a produtividade em função das aplicações através de regressão linear. A contribuição desse estudo consiste nas equações de dano propostas e nos altos coeficientes de determinação obtidos para a relação da AACPD de mancha de bipolaris com o dano, atingindo valores de 84, 68, 82 e 81% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente. Para a relação da AACPD de manchas foliares com o dano, foram obtidos valores de 87, 71, 88 e 92% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente. Considerando a média dos híbridos, para mancha de bipolaris, o Limiar de Ação (LA) obtido ficou entre 1,23 e 1,54%, enquanto para mancha de turcicum entre 0,75 e 0,94% e para mancha branca entre 0,53 e 0,67%.

Palavras-chave: equação de dano; limiar de dano econômico; limiar de ação

## INJURY-DAMAGE RELATION FOR LEAF SPOTS IN CORN

### 3.2 ABSTRACT

The development of mathematical models to estimate damage based on injury data is extremely important for predict subsequent epidemics and for decision making. This study aimed to establish the injury-damage relation for leaf spots in corn (maize white spot (MWS), northern corn leaf blight (NCLB) and southern corn leaf blight (SCLB)), and to generate damage function equations, supporting the calculation of the Economic Damage Threshold (EDT). Four experiments were carried out at the School Farm of the State University of Londrina (UEL), in Londrina, PR, Brazil, in the second season 2022. The hybrids used were AG 8780, AG 9021, AG 9025 and F6rmula VIP. The experimental design used was randomized blocks with eight treatments and four replications. The treatments consisted of applying the fungicides Prothioconazole + Trifloxystrobin + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>) at a dose of 500 mL.ha<sup>-1</sup> of the commercial product at different phenological stages of the crop: T1 - control; T2 - V6, V10, R2, R2+14; T3 - V6, V10, R2; T4 - V6, V10; T5 - V6; T6 - V10, R2, R2+14; T7 - R2, R2+14; T8 - R2+14. Quantification of disease severity was carried out weekly using diagrammatic scales, and the values were used to calculate the area under the disease progress curve (AUDPC) by trapezoidal integration. The yield was measured in the two central lines of each plot, estimating productivity (kg.ha<sup>-1</sup>), adjusted for 13% humidity. The data were subjected to analysis of variance using the F test and differences between means, when significant, were compared using the Scott Knott test, at a 5% probability level. The relation between AUDPC and productivity was analyzed using linear regression. The EDT was calculated using the equation  $ID = [Cc/(Pp \times Cd)] \times Ec$ . Productivity was calculated depending on applications using linear regression. The contribution of this study consists of the proposed damage equations and the high coefficients of determination obtained for the relation between the AUDPC of SCLB and the damage, reaching values of 84, 68, 82 and 81% for the hybrids AG 8780, AG 9021, AG 9025 and FORMULA VIP, respectively. For the relation between the AUDPC of leaf spots and the damage, values of 87, 71, 88 and 92% were obtained for the hybrids AG 8780, AG 9021, AG 9025 and FORMULA VIP, respectively. Considering the average of the hybrids, for SCLB, the Action Threshold (AT) obtained was between 1,23 and 1,54%, while for NCLB it was between 0,75 and 0,94% and for MWS it was between 0,53 and 0,67%.

Keywords: damage equation; economic damage threshold; action threshold

### 3.3 INTRODUÇÃO

O milho (*Zea mays* L.) é um dos cereais cultivados mais importantes no Brasil, representando 38,85% da produção de grãos do País. Na safra 2023/2024 houve decréscimo de 12,3% na produção em relação à safra anterior, alcançando 115,697 milhões de toneladas (CONAB, 2024).

A ocorrência de doenças, plantas invasoras e pragas afetam significativamente o potencial produtivo da planta de milho (ÁVILA; PANIZZI, 1995; CHOCOROSQUI; PANIZZI, 2004; ROZA-GOMES, 2011). Dentre as principais doenças foliares na cultura do milho estão a cercosporiose, mancha branca, ferrugem polissora, ferrugem comum, ferrugem tropical, mancha de turcicum, antracnose e mancha de bipolaris (EMBRAPA, 2021).

As perdas acarretadas por mancha branca estão relacionadas à suscetibilidade do hospedeiro, ao seu estágio de desenvolvimento na infecção e às condições ambientais favoráveis ao desenvolvimento da doença (PEREIRA et al., 2005). A partir do estágio R5 (grão farináceo duro), um aumento de 1% na severidade resulta em uma redução de 0,23% na produtividade e de 0,16% no peso dos grãos (CARSON, 2005). As perdas causadas pela mancha de turcicum podem exceder 40% da produção de grãos, sendo considerada limitante para a produção em algumas partes do mundo (COTA et al., 2013). A mancha de bipolaris é mais nociva em regiões de clima temperado e tropicais quentes e úmidas, nas quais tem sido relatadas perdas de produção superiores a 70% (COSTA et al., 2018)

Dentre as medidas de manejo de doenças na cultura do milho, estão a época de plantio adequada, utilização de sementes de boa qualidade e tratadas com fungicidas, rotação de culturas, adubação, população adequada, controle de pragas e de plantas daninhas e colheita no período adequado. O manejo integrado visa reduzir o inóculo na lavoura e dar longevidade à resistência genética das cultivares comerciais (CASELA et al., 2006).

Diferentes aspectos devem ser observados para a tomada de decisão sobre a aplicação de fungicidas, de modo a se obter maior eficiência e melhor relação custo/benefício na utilização dessa estratégia de manejo de doenças na cultura do milho, evitando o uso inadequado da ferramenta: Histórico de doenças em níveis regionais e de propriedade; aplicação de fungicidas x resistência genética dos cultivares; aplicação de fungicidas x produtividade; aplicação de fungicidas x

ocorrência de doenças; características dos fungicidas; época de aplicação de fungicidas na cultura do milho e disponibilidade de equipamentos para aplicação (COSTA; COTA, 2009).

A quantificação dos danos é imprescindível para a definição de estratégias de controle. Segundo Zadoks (1985, apud BERGAMIN FILHO et al., 1996) qualquer agente que cause dano à uma lavoura é um organismo nocivo, sendo que a injúria é qualquer sintoma na planta e o dano qualquer redução na produção, a qual pode gerar redução no retorno financeiro, denominada de perda. A função de dano relaciona dano (D) com injúria (I) através da equação:  $D = f(I)$ . Obter dados para estabelecer a função de dano é o objetivo da fase experimental de um projeto de pesquisa que visa a determinação dos prejuízos causados por um patógeno (BERGAMIN FILHO et al., 2018).

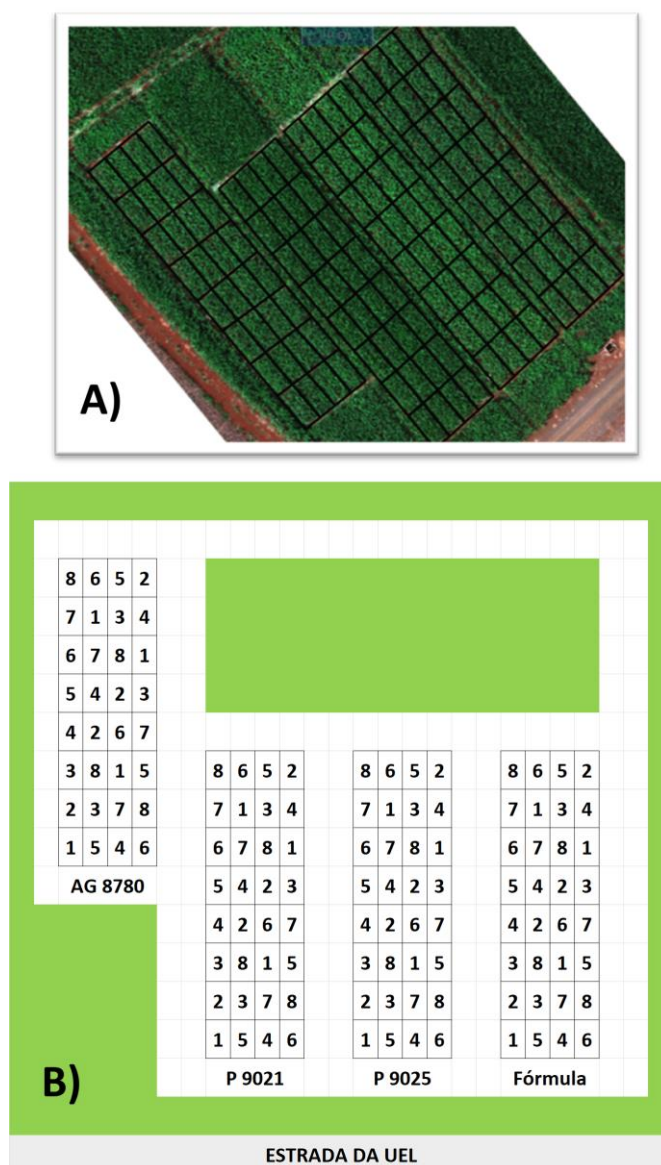
Essas equações de função de dano subsidiam o cálculo do Limiar de Dano Econômico (LDE) (EMBRAPA, 2023). O conceito de LDE pode ser definido como a menor densidade populacional que causa dano econômico (STERN, 1959), ou então, o nível de ataque do organismo nocivo no qual o benefício do controle se iguala ao seu custo (MUNFORD; NORTON, 1984).

Esse trabalho teve como objetivo estabelecer a relação injúria-dano para mancha foliares do milho (mancha branca, mancha de turcicum e mancha de bipolaris), gerando equações de funções de dano, subsidiando o cálculo do Limiar de Dano Econômico (LDE).

### 3.4 MATERIAL E MÉTODOS

#### 3.4.1 Localização dos Experimentos

Foram instalados quatro experimentos (Figura 11) na Fazenda Escola da Universidade Estadual de Londrina (UEL), na altitude de 564 m, no município de Londrina, PR, na safinha 2022. O solo é classificado como Latossolo Vermelho Distroférico (EMBRAPA, 2018). De acordo com Köppen-Geiger, o clima é do tipo Cfa – subtropical úmido, apresentando temperatura média no mês mais frio abaixo de 18 °C e temperatura média no mês mais quente acima de 22 °C (CAVIGLIONE et al., 2000).



**Figura 11** – Imagem aérea com as delimitações das parcelas (A) e croqui dos experimentos com tratamentos e códigos dos híbridos (B).

Fonte: O próprio autor.

### 3.4.2 Instalação dos Experimentos e Delineamento Experimental

Os detalhes em relação à instalação dos experimentos estão descritos na Tabela 1.

**Tabela 1 – Época e ano de condução, data de semeadura, híbrido, data da aplicação de fungicidas e estágio de desenvolvimento da cultura. Londrina – PR.**

Época e Ano de condução	Localidade	Data de semeadura	Híbrido	Data da aplicação de fungicidas e ED <sup>a</sup>			
				23/03/2022	06/04/2022	20/04/2022	04/05/2022
Safrinha 2022	Londrina	18/02/2022	AG 8780	V6	V9	R1	R3
			AG 9021	V7	V11	R2	R4
			AG 9025	V6	V10	R2	R3
			FÓRMULA VIP	V6	V9	R1	R3

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V6, seis folhas desenroladas; V7, sete folhas desenroladas; V9, nove folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

Para fins de simplificação da descrição dos tratamentos, os estádios de desenvolvimento da cultura nas aplicações de fungicidas serão citados da seguinte forma: aplicação em 23/03/2022 (V6, seis folhas desenroladas); aplicação em 06/04/2022 (V10, dez folhas desenroladas); aplicação em 20/04/2022 (R2, bolha d'água); aplicação em 04/05/2022 (R2+14, quatorze dias após bolha d'água).

Para cada um dos experimentos citados, foi utilizado um híbrido de milho. Em relação às características, os híbridos utilizados foram: AG 8780 com ciclo precoce, suscetível à mancha branca e tolerante à mancha de turcicum, AG 9021 com ciclo hiperprecoce, moderadamente suscetível à mancha branca e à mancha de turcicum, AG 9025 com ciclo superprecoce, moderadamente suscetível à mancha branca e à mancha de turcicum, e Fórmula VIP com ciclo precoce, moderadamente suscetível à mancha branca e à mancha de turcicum (AGRO BAYER, 2024; SYNGENTA, 2024). Não há informações quanto à suscetibilidade dos híbridos à mancha de bipolaris.

Para todos os híbridos foi utilizado o espaçamento de 0,50 m entre linhas, com 3 sementes por metro linear, contando com uma população de 60 mil plantas ha<sup>-1</sup>. O delineamento experimental utilizado foi blocos ao acaso com oito tratamentos e quatro repetições. As parcelas eram de 3 m de largura por 7 m de comprimento, totalizando 21 m<sup>2</sup>, compostas por seis linhas de semeadura.

### 3.4.3 Adubação e Manutenção Fitossanitária

A adubação de base foi de 280 kg.ha<sup>-1</sup> com o formulado 12-15-15, realizada no dia da semeadura de acordo com as recomendações para a cultura (EMBRAPA, 2021). Posteriormente foi realizada uma adubação nitrogenada por

cobertura de 100 kg.ha<sup>-1</sup> de ureia no estágio de V3 da cultura. O controle das pragas cigarrinha-do-milho e percevejo-barriga-verde foi realizado com os inseticidas Imidacloprido + Beta-Ciflutrina (100 + 12,5 g i.a. L<sup>-1</sup>) a 1000 mL.ha<sup>-1</sup> nos dias 3, 10 e 17 de março de 2022. O controle de plantas daninhas foi realizado com o herbicida Tembotriona (420 g i.a. L<sup>-1</sup>) a 240 mL.ha<sup>-1</sup> e o sequencial do herbicida Atrazina (500 g i.a. L<sup>-1</sup>) a 3000 mL.ha<sup>-1</sup> no dia 10 de março de 2022.

#### 3.4.4 Tratamentos

Em relação aos tratamentos do experimento, foram utilizados os fungicidas Protioconazol + Trifloxistrobina + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>), aplicados na dose de produto comercial de 500 mL.ha<sup>-1</sup> em diferentes estádios fenológicos da cultura (Tabela 2).

**Tabela 2** – Tratamentos, estádios de desenvolvimento das plantas e número de aplicações dos fungicidas para controle de doenças fúngicas na cultura do milho. Londrina – PR.

Tratamento	ED <sup>a</sup>	Nº de aplicações
T1	-	-
T2	V6/ V10/ R2/ R2+14	4
T3	V6/ V10/ R2	3
T4	V6/ V10	2
T5	V6	1
T6	V10/ R2/ R2+14	3
T7	R2/ R2+14	2
T8	R2+14	1

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

Esta formulação de fungicidas foi escolhida por possuir elevada eficácia no controle de doenças do milho (CUSTODIO et al., 2020), com a finalidade de gerar gradientes entre as parcelas, possibilitando as análises posteriores.


As aplicações foram realizadas com pulverizador costal de pressão constante, propelido por CO<sub>2</sub> pressurizado, utilizando seis pontas de pulverização do tipo jato plano de dupla saída modelo 110.015, espaçados a cada 0,4 m. A pressão de trabalho foi de 2,5 bar, volume de pulverização de 150 L.ha<sup>-1</sup>.

### 3.4.5 Condições Climáticas


Os dados de volume de precipitação, temperaturas máximas e mínimas, e a umidade relativa foram obtidos da Estação Meteorológica da Universidade Estadual de Londrina, referentes ao município de Londrina - PR, no período de condução dos experimentos (ANEXO A).

### 3.4.6 Avaliação da Severidade das Doenças

A ocorrência das doenças nos experimentos foi natural. A quantificação da severidade das doenças foi realizada utilizando as escalas diagramáticas da mancha branca proposta por Capucho et al. (2010) (Figura 12), da mancha de turcicum proposta por Vieira et al. (2013) (Figura 13) e da cercosporiose proposta por Ward et al. (1997) (Figura 14) adaptada para a avaliação da mancha de *bipolaris*, devido à falta dessa escala na literatura.

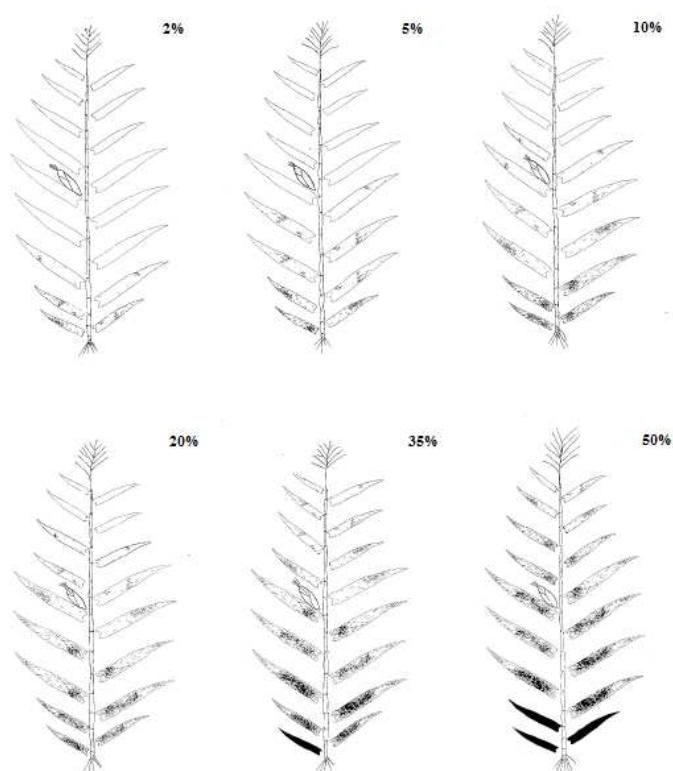


**Figura 12** – Escala diagramática da mancha branca.  
Fonte: Capucho et al., (2010).



**Figura 13** – Escala diagramática da mancha de turcicum.

Fonte: Vieira et al., (2013).



**Figura 14** – Escala diagramática da cercosporiose, utilizada para avaliar mancha de bipolaris.

Fonte: Ward et al., (1997).

A partir do surgimento dos primeiros sintomas e gradiente entre os tratamentos, foram avaliadas semanalmente as quatro linhas centrais das parcelas considerando a severidade média da doença nas folhas, sendo que as avaliações

seguiram até a senescência das plantas (Tabela 3).

**Tabela 3** – Época e ano de condução, híbrido, datas das avaliações e estádios de desenvolvimento das plantas de milho. Londrina – PR.

Época e Ano	Híbrido	Data da avaliação e ED <sup>a</sup>						
		07/04/2022	14/04/2022	21/04/2022	28/04/2022	06/05/2022	13/05/2022	20/05/2022
Safrinha 2022	AG 8780	V9	V10	R1	R2	R3	R3	R4
	AG 9021	V11	VT	R2	R3	R4	R4	R5
	AG 9025	V10	V12	R2	R2	R3	R3	R4
	FÓRMULA VIP	V9	V10	R1	R2	R3	R3	R4

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V9, nove folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; V12, doze folhas desenroladas; VT, pendoamento; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso; R5, grão dente.

### 3.4.7 Área Abaixo da Curva de Progresso da Doença

Os valores de severidade média de cada doença foram utilizados para o cálculo da área abaixo da curva de progresso da doença (AACPD) por integração trapezoidal (SHANER; FINNEY, 1987), através da equação:

$$AACPD = \sum_{i=1}^{n-1} [(X_i + X_{i+1})]/2 (t_{i+1} - t_i)$$

X = Severidade média da doença por parcela

N = Número de avaliações

$t_{i+1} - t_i$  = Intervalo entre duas avaliações

Para este cálculo foi utilizado o programa estatístico Scout, baseado na arquitetura ARM (*Agriculture Research Manager*) (GDM, 2025). Para obter a AACPD de manchas foliares, foi considerado o patossistema múltiplo, calculando a média entre a AACPD das doenças.

### 3.4.8 Produtividade

A colheita foi realizada em 14/07/2022, mensurada manualmente nas duas linhas centrais de cada parcela, cada uma medindo 5 m de comprimento, totalizando 2,5 m<sup>2</sup> por parcela, posteriormente estimando-se a produtividade (kg.ha<sup>-1</sup>), corrigida para 13% de umidade.

### 3.4.9 Relação entre AACPD e Produtividade

Através de regressões lineares buscou-se mensurar a relação entre as avaliações de severidade em cada avaliação e a AACPD de cada doença e do patossistema múltiplo com a produtividade.

As equações de dano foram estimadas através da análise de regressão:  $y = a + bx$ . Onde “y” é a produtividade estimada e “x” o somatório de severidade das doenças, representada pela severidade nos diferentes tratamentos dos experimentos. O coeficiente de regressão “b”, ou coeficiente de dano (Cd), representa o quanto varia a média de “y” para o aumento de 1 unidade de “x”. Também foram obtidos os coeficientes de determinação ( $R^2$ ) que demonstram o quão forte é a relação entre as variáveis dependente e independente.

### 3.4.10 Limiar de Dano Econômico (LDE) e Limiar de Ação (LA)

O LDE foi determinado usando como base de cálculo a equação de Munford e Norton (1984), modificada para doenças foliares (REIS et al., 2001), aplicada para doenças:  $ID = [Cc / (Pp \times Cd)] \times Ec$ ; na qual, ID = intensidade de doença; Cc = custo do controle dos fungicidas; Pp = preço da tonelada do produto; Ec = eficiência dos fungicidas a serem utilizados; Cd = coeficiente de dano.

Para o cálculo do “Cc” foram consideradas 3 sc/ha/aplicação de fungicida (COSTA et al., 2012a), sendo convertido pelo valor de saca de milho, R\$ 126/ha/aplicação (NOTÍCIAS AGRICOLAS, 2023). O valor utilizado de “Pp” foi de R\$ 42,00/sc de 60 kg, convertido para R\$ 700/tonelada, considerando a cotação para Londrina em 02 de outubro de 2023 (NOTÍCIAS AGRICOLAS, 2023). O valor utilizado de “Ec” foi de 83% (CUSTODIO et al., 2020). Para fins de cálculo, foram considerados os valores de “Cd” das equações de dano originais em  $kg \cdot ha^{-1}$ , transformados para a unidade de toneladas, abrangendo cada avaliação de severidade e as diferentes doenças avaliadas.

Para determinar o LA, foi proposta uma redução de 20% do valor de LDE obtido (CARMONA et al., 2014; DE ROSSI et al., 2022).

### 3.4.11 Produtividade em Função das Aplicações de Fungicidas

Para obtenção do incremento de produtividade ( $\text{kg}\cdot\text{ha}^{-1}$ ) em função do número de aplicações no início do ciclo, foi realizada a regressão linear entre a produtividade dos tratamentos (T2, T6, T7 e T8) e o número de aplicações, pela equação “ $y=a+bx$ ”.

Para obtenção do incremento de produtividade ( $\text{kg}\cdot\text{ha}^{-1}$ ) em função do número de aplicações no final do ciclo, foi realizada a regressão linear entre a produtividade dos tratamentos (T1, T5, T4 e T3) e o número de aplicações, pela equação “ $y=a+bx$ ”.

Para obtenção da redução de produtividade ( $\text{kg}\cdot\text{ha}^{-1}$ ) em função do número de dias no atraso das aplicações, foi realizada a regressão linear entre a produtividade dos tratamentos (T2, T6, T7 e T8) e os dias que se iniciaram as aplicações para cada tratamento, pela equação “ $y=a+bx$ ”.

### 3.4.12 Análise dos Dados

Todos os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5% de probabilidade, utilizando-se o programa SASM-Agri (CANTERI et al., 2001).

A relação entre a AACPD e produtividade foram analisadas por regressão linear, utilizando o programa Microsoft Office Excel®.

## 3.5 RESULTADOS E DISCUSSÃO

### 3.5.1 Severidade e Área Abaixo da Curva de Progresso da Doença (AACPD)

#### 3.5.1.1 Mancha de Bipolaris

Para todos os híbridos, os primeiros sintomas de mancha de bipolaris foram visualizados no estágio de V9 a V11 (Apêndices A, B, C e D). Nas avaliações seguintes a severidade aumentou progressivamente até o estágio R3, estando os sintomas localizados nas folhas inferiores à inserção da espiga, no baixeiro (Figura 15).



**Figura 15** – Sintomas de mancha de bipolaris em folhas do estágio V11 de planta de milho do híbrido AG 9021.

**Fonte:** O próprio autor.

Para a mancha de bipolaris, é importante observar principalmente os sintomas nas folhas inferiores da planta de milho, as quais ficam estressadas pelas lesões nas folhas, sendo que os sintomas não são normalmente encontrados nas folhas da espiga ou acima (CALVERT; MARCUS, 2012).

O híbrido AG 9021 obteve um comportamento mais suscetível à mancha de bipolaris em relação aos demais, porém nenhum dos híbridos estudados apresentou tolerância à essa doença. Para o híbrido AG 8780, os tratamentos 2, 3 e 4, que contemplaram as duas aplicações iniciais de fungicidas, nos estádios V6 e V10, proporcionaram as menores AACPD para mancha de bipolaris, já para os híbridos AG 9021, AG 9025 e FÓRMULA VIP os tratamentos 2, 3, 4 e 5, que contemplaram a primeira aplicação no estágio V6, proporcionaram as menores AACPD (Tabela 4).

**Tabela 4** –Área abaixo da curva de progresso da doença (AACPD) para mancha de bipolaris em híbridos de milho (*Zea mays* L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR.

Tratamento <sup>a</sup>	AACPD*			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
1-Testemunha	291,375 a	735,000 a	373,625 a	207,375 a
2-V6/ V10/ R2/ R2+14	38,500 e	114,625 c	43,750 c	31,500 c
3-V6/ V10/ R2	50,750 e	113,750 c	77,000 c	32,375 c
4-V6/ V10	31,125 e	110,250 c	67,375 c	25,375 c
5-V6	78,750 d	141,750 c	98,000 c	30,625 c
6-V10/ R2/ R2+14	141,750 c	670,250 b	273,000 b	176,750 b
7- R2/ R2+14	264,250 b	700,875 b	367,500 a	218,750 a
8-R2+14	291,375 b	693,000 b	364,000 a	224,875 a
C.V. (%)	10,77	5,74	14,65	20,64

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

Sendo assim, a aplicação no estágio V6 foi a mais eficiente para o controle dessa doença, porém quando esta é acrescida de pelo menos uma segunda aplicação em V10, houve menor severidade em uma maior gama de híbridos. A mancha de bipolaris tem ganhado relevância nas últimas safras, com os primeiros sintomas sendo observados no estágio V6, com maior ocorrência e severidade comparadas à outras doenças foliares, ocasionando a redução da produtividade (FITOSSANIDADE TROPICAL, 2024). O melhoramento de plantas com foco em maior produtividade, juntamente à falta de rotação de culturas, culmina na suscetibilidade às doenças. Esta situação, leva à ocorrência da doença cada vez mais cedo no ciclo e de forma mais agressiva, sendo que essas folhas doentes abaixo da espiga servirão de fonte de inóculo para as folhas superiores, demandando a recomendação da aplicação de fungicidas mais cedo, aproximadamente no estágio V4 (FUNDAÇÃO ABC, 2023).

### 3.5.1.2 Mancha de Turcicum

Para os híbridos AG 9021, AG 9025 e FÓRMULA VIP, os primeiros sintomas de mancha de turcicum começaram a ser avaliados no estágio de V9 a V11 (Apêndices E, F e G). Nas avaliações seguintes a severidade aumentou progressivamente até o estágio R3, estando localizada no terço inferior e

principalmente no terço médio das plantas (Figura 16).



**Figura 16** – Sintomas de mancha de turcicum em folhas do estágio V10 de planta de milho do híbrido AG 9025.

Fonte: O próprio autor.

Não foram observados sintomas de mancha de turcicum no híbrido AG 8780, uma vez que o mesmo possui tolerância à essa doença (AGRO BAYER, 2024).

Geralmente, a mancha de turcicum tem início durante o estágio vegetativo das plantas (V8) e término no estágio reprodutivo de grão dente (R5) (CUSTODIO et al., 2019).

Para os híbridos AG 9025 e FÓRMULA VIP, os tratamentos 2, 3 e 4, que contemplam duas aplicações nos estádios V6 e V10, proporcionaram as menores AACPD para mancha de turcicum, enquanto para o híbrido AG 9021, os tratamentos 2, 3, 4 e 5, que contemplam a aplicação com início no estágio V6, proporcionaram as menores AACPD (Tabela 5).

**Tabela 5** – Área abaixo da curva de progresso da doença (AACPD) para mancha de turcicum em híbridos de milho (*Zea mays* L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR.

Tratamento <sup>a</sup>	AACPD*		
	AG 9021	AG 9025	FÓRMULA VIP
1-Testemunha	282,625 a	543,375 a	392,125 a
2-V6/ V10/ R2/ R2+14	78,750 b	108,500 d	14,000 d
3-V6/ V10/ R2	51,625 b	150,500 d	20,375 d
4-V6/ V10	68,250 b	149,625 d	27,250 d
5-V6	65,625 b	282,625 c	117,375 c
6-V10/ R2/ R2+14	289,625 a	350,875 b	137,375 c
7- R2/ R2+14	282,625 a	505,750 a	294,500 b
8-R2+14	266,000 a	513,625 a	311,250 b
C.V. (%)	19,55	13,79	20,34

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

Sendo assim, as aplicações nos estádios V6 e V10 foram as mais eficientes para o controle desta doença. Segundo Moterle & Santos (2019), o tratamento com aplicações nos estágios V8 + Pré-florescimento da safrinha de milho com os fungicidas trifloxistrobina + tebuconazol, resultaram em menor severidade de mancha de turcicum, quando comparado aos tratamentos com aplicações isoladas nos estádios de V8 ou de pré-florescimento. Resultados semelhantes foram obtidos anteriormente com os fungicidas epoxiconazol + piraclostrobina (SILVA et al., 2016).

### 3.5.1.3 Mancha Branca

Para todos os híbridos, os primeiros sintomas de mancha branca começaram a ser avaliados no estádio de R2 a R4 (Apêndices H, I, J e K). Nas avaliações seguintes, a severidade aumentou progressivamente até o estádio R5, estando localizada no terço médio e superior das plantas (Figura 17).



**Figura 17** – Sintomas de mancha branca em folha do estágio R3 de planta de milho do híbrido FÓRMULA VIP.

**Fonte:** O próprio autor.

Geralmente, a mancha branca tem início no meio da estação de cultivo, durante o estágio vegetativo de pré-pendoamento das plantas (V11) ou antes e término no final da estação de cultivo no estágio reprodutivo de grão dente (R5) (CUSTODIO et al., 2019).

Para os híbridos AG 8780 e AG 9025, os tratamentos 2, 3, 4 e 6, que contemplam duas ou mais aplicações de fungicidas iniciando nos estádios V6 ou V10, proporcionaram as menores AACPD para mancha branca. Enquanto para o híbrido AG 9021, os tratamentos 2 e 3, que contemplam três ou mais aplicações de fungicidas iniciando nos estádios V6, proporcionaram as menores AACPD. Para o híbrido FÓRMULA VIP, os tratamentos 2, 3, 4 e 5, que contemplam aplicações de fungicidas com início no estágio V6, proporcionaram as menores AACPD (Tabela 6).

**Tabela 6** – Área abaixo da curva de progresso da doença (AACPD) para mancha branca em híbridos de milho (*Zea mays* L.) com tratamentos de fungicidas em diferentes épocas e número de aplicações. Safrinha 2022, Londrina – PR.

Tratamento <sup>a</sup>	AACPD*			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
1-Testemunha	267,750 a	123,375 a	84,000 a	138,250 a
2-V6/ V10/ R2/ R2+14	1,750 d	5,250 d	0,0000 c	54,250 b
3-V6/ V10/ R2	8,750 d	9,625 d	6,1250 c	57,750 b
4-V6/ V10	14,000 d	24,500 c	0,0000 c	68,250 b
5-V6	85,625 c	42,875 c	40,250 b	57,750 b
6-V10/ R2/ R2+14	26,500 d	22,750 c	4,3750 c	99,750 a
7- R2/ R2+14	142,750 b	70,875 b	52,500 b	122,500 a
8-R2+14	143,000 b	71,750 b	83,125 a	124,250 a
C.V. (%)	35,2	31,04	41,63	23,88

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

Sendo assim, as aplicações de fungicidas nos estádios V6 e V10 foram as mais importantes para o controle esta doença, porém quando são acrescidas de pelo menos uma terceira aplicação de fungicida após R2, obteve-se menor severidade em uma maior gama de híbridos. Resultados semelhantes foram obtidos por Borth et al (2021), onde aplicações de fungicidas nos estádios V4 + V8 + VT resultaram em menores severidades de mancha branca quando comparadas às aplicações em V4 + V8 e às aplicações isoladas em V4 ou V8, considerando diferentes híbridos de milho e localidades. Em contrapartida, apenas 6% dos agricultores normalmente realizam três aplicações de fungicidas na cultura do milho (COTA et al., 2018).

### 3.5.2 Relação Injúria-Dano

Com base nos resultados da área abaixo da curva de progresso da doença (AACPD) e da produtividade de cada híbrido (Apêndice L), foram estabelecidas as relações injúria-dano, obtendo-se as equações de função de dano para cada doença (Tabela 7). Os maiores coeficientes de determinação para mancha de bipolaris foram de 84 e 82% para os híbridos AG 8780 e AG 9025, para mancha de turcicum de 86 e 87% para os híbridos AG 9025 e FÓRMULA VIP e, para mancha branca de 88 e 91% para os híbridos AG 9025 e FÓRMULA VIP. As

maiores correlações para manchas foliares, considerando o patossistema múltiplo, foram de 88 e 92% para os híbridos AG 9025 e FÓRMULA VIP (Tabela 7).

**Tabela 7** – Equações de função de dano e coeficientes de determinação para doenças em diferentes híbridos de milho (*Zea mays* L.). Safrinha 2022, Londrina – PR.

Híbrido	Equação de função de dano e coeficiente de determinação			
	Doença			Patossistema Múltiplo
	AACPD Mancha de Bipolaris	AACPD Mancha de Turcicum	AACPD Mancha Branca	AACPD Manchas Foliares
AG 8780	$y = -8,3394x + 9206,4$	-	$y = -9,1908x + 8802,6$	$y = -9,1365x + 9082,1$
	$R^2 = 0,8405$		$R^2 = 0,7515$	$R^2 = 0,8743$
AG 9021	$y = -2,9152x + 10538$	$y = -23,921x + 10452$	$y = -7,6058x + 10660$	$y = -6,0996x + 10623$
	$R^2 = 0,682$	$R^2 = 0,7664$	$R^2 = 0,6356$	$R^2 = 0,7107$
AG 9025	$y = -5,741x + 7332,8$	$y = -24,274x + 6958,9$	$y = -4,9689x + 7756,4$	$y = -7,4897x + 7555,1$
	$R^2 = 0,8202$	$R^2 = 0,8624$	$R^2 = 0,8837$	$R^2 = 0,8894$
FÓRMULA VIP	$y = -8,516x + 10374$	$y = -24,25x + 11556$	$y = -5,7918x + 10317$	$y = -9,5013x + 10547$
	$R^2 = 0,818$	$R^2 = 0,8787$	$R^2 = 0,9186$	$R^2 = 0,9213$

Outros autores também obtiveram equações de dano com altas correlações entre doenças e a produtividade para diferentes híbridos na cultura do milho, envolvendo mancha de turcicum, ferrugem polissora e principalmente para cercospora e mancha branca (BRASIL; CARVALHO, 1998; BRITO et al., 2007; BRITO et al., 2008; BRITO et al., 2013; FANTIN et al., 2004; FANTIN et al., 2008; FANTIN et al., 2010; REIS et al., 2007). Para mancha de turcicum, Bernini et al (2020) encontraram correlação de 48% com a produtividade no milho segunda safra, possivelmente por ter ocorrido tardiamente e ter competido com outras doenças, as quais ocuparam em pouco tempo extensas áreas de tecido foliar. Existem também diversas raças deste fungo, que podem levar à diferentes tipos de reação nas plantas (WHITE, 2000) ou diferenças de agressividade entre isolados (SASSE, 2008). Para mancha de bipolaris ainda carecem estudos de relação injúria-dano.

Geralmente, os trabalhos têm desenvolvido equações de dano para doenças específicas, e poucos têm contemplado o patossistema múltiplo. Na cultura do milho, Fantin et al. (2004) obteve alta correlação ( $r = -0,94$ ) entre a AACPD total, a qual abrange a mancha branca e a cercosporiose, com a produtividade. Outro

exemplo de escassez de trabalhos com patossistema múltiplos se encontra na cultura do trigo (BOHATCHUK et al., 2008; RETMAN et al., 2014).

Levando em consideração a ocorrência de mancha de bipolaris no terço inferior, da mancha de turcicum principalmente no terço médio e da mancha branca no terço médio e superior das plantas, é possível inferir que todas as doenças impactaram direta ou indiretamente no potencial produtivo da cultura. Doenças como a mancha de bipolaris, com desenvolvimento em estádios vegetativos, podem acarretar a desuniformidade da lavoura e baixo índice de área foliar (FUNDAÇÃO ABC, 2023). Segundo Allison & Watson et al. (1986, apud FANCELLI; DOURADO NETO, 2000), sobre as funções das folhas em relação à planta de milho, o enchimento de grãos está diretamente relacionado ao terço superior, o crescimento de panículas e espigas ao terço médio e o desenvolvimento de raízes ao terço inferior.

Ainda segundo Bernini et al (2020) e Fantin & Duarte (2009), empresas produtoras de híbridos de milho podem estar priorizando o potencial produtivo dos cultivares, em detrimento da resistência múltipla às doenças foliares.

### 3.5.3 Limiar de Dano Econômico (LDE) e Limiar de Ação (LA)

Com base nos resultados de severidade e produtividade de cada híbrido, foi estabelecida a relação injúria-dano, possibilitando determinar as equações de função de dano, coeficientes de determinação, coeficientes de dano, LDE e LA para cada doença, época de avaliação e híbrido. De uma maneira geral, para mancha de bipolaris, a média geral do LA para os híbridos ficou entre 1,23 e 1,54%, enquanto para mancha de turcicum entre 0,75 a 0,94% e para mancha branca entre 0,53 a 0,67% (Tabela 8).

**Tabela 8** – Equações de função de dano, coeficientes de determinação, Limiar de Dano Econômico (LDE) e Limiar de Ação (LA) em relação aos estádios de desenvolvimento na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Híbrido	Doença	ED <sup>a</sup>	Equação	R <sup>2</sup>	Cd	LDE (%)	LA (%)
AG 8780	M.Bipolaris	V9	y = -244,89x + 9448,5	R <sup>2</sup> = 0,7214	244,89	0,61	0,49
AG 8780	M.Bipolaris	V10	y = -119,5x + 9212,2	R <sup>2</sup> = 0,8446	119,5	1,25	1,00
AG 8780	M.Bipolaris	R1	y = -69,653x + 9054,5	R <sup>2</sup> = 0,8159	69,653	2,14	1,72
AG 8780	M.Branca	R2	y = -979,01x + 8438	R <sup>2</sup> = 0,6565	979,01	0,15	0,12
AG 8780	M.Branca	R3	y = -226,29x + 8688,6	R <sup>2</sup> = 0,7795	226,29	0,66	0,53
AG 8780	M.Branca	R3	y = -142,61x + 8803	R <sup>2</sup> = 0,7206	142,61	1,05	0,84
AG 8780	M.Branca	R4	y = -135,31x + 8901,9	R <sup>2</sup> = 0,6913	135,31	1,10	0,88
AG 9021	M.Bipolaris	V11	y = -74,361x + 10535	R <sup>2</sup> = 0,6592	74,361	2,01	1,61
AG 9021	M.Bipolaris	VT	y = -63,104x + 10532	R <sup>2</sup> = 0,6827	63,104	2,37	1,89
AG 9021	M.Bipolaris	R2	y = -57,203x + 10539	R <sup>2</sup> = 0,6844	57,203	2,61	2,09
AG 9021	M.Bipolaris	R3	y = -55,48x + 10541	R <sup>2</sup> = 0,6882	55,48	2,69	2,15
AG 9021	M.Turcicum.	V11	y = -191,57x + 10558	R <sup>2</sup> = 0,6005	191,57	0,78	0,62
AG 9021	M.Turcicum	VT	y = -166,38x + 10586	R <sup>2</sup> = 0,5959	166,38	0,90	0,72
AG 9021	M.Turcicum	R2	y = -148,13x + 10690	R <sup>2</sup> = 0,6461	148,13	1,01	0,81
AG 9021	M.Turcicum	R3	y = -141,03x + 10753	R <sup>2</sup> = 0,6847	141,03	1,06	0,85
AG 9021	M.Branca	R4	y = -1082,2x + 10053	R <sup>2</sup> = 0,7648	1082,2	0,14	0,11
AG 9021	M.Branca	R4	y = -309,11x + 10483	R <sup>2</sup> = 0,7935	309,11	0,48	0,39
AG 9021	M.Branca	R5	y = -204,79x + 10412	R <sup>2</sup> = 0,6785	204,79	0,73	0,58
AG 9025	M.Bipolaris	V10	y = -166,33x + 7370,4	R <sup>2</sup> = 0,7657	166,33	0,90	0,72
AG 9025	M.Bipolaris	V12	y = -133,49x + 7348,3	R <sup>2</sup> = 0,7847	133,49	1,12	0,90
AG 9025	M.Bipolaris	R2	y = -106,03x + 7304,8	R <sup>2</sup> = 0,8358	106,03	1,41	1,13
AG 9025	M.Bipolaris	R2	y = -98,684x + 7313,4	R <sup>2</sup> = 0,8579	98,684	1,51	1,21
AG 9025	M.Turcicum	V10	y = -139,97x + 7686,9	R <sup>2</sup> = 0,6606	139,97	1,07	0,85
AG 9025	M.Turcicum	V12	y = -114,09x + 7775	R <sup>2</sup> = 0,8721	114,09	1,31	1,05
AG 9025	M.Turcicum	R2	y = -87,661x + 7678	R <sup>2</sup> = 0,8978	87,661	1,70	1,36
AG 9025	M.Turcicum	R2	y = -85,821x + 7696,7	R <sup>2</sup> = 0,8863	85,821	1,74	1,39
AG 9025	M.Branca	R3	y = -1089,8x + 6819,6	R <sup>2</sup> = 0,8915	1089,8	0,14	0,11
AG 9025	M.Branca	R3	y = -321,62x + 6922,4	R <sup>2</sup> = 0,8537	321,62	0,46	0,37
AG 9025	M.Branca	R4	y = -204,94x + 6990,3	R <sup>2</sup> = 0,8247	204,94	0,73	0,58
FÓRMULA VIP	M.Bipolaris	V9	y = -183,74x + 10410	R <sup>2</sup> = 0,7335	183,74	0,81	0,65
FÓRMULA VIP	M.Bipolaris	V10	y = -123,73x + 10390	R <sup>2</sup> = 0,8188	123,73	1,21	0,97
FÓRMULA VIP	M.Bipolaris	R1	y = -80,79x + 10307	R <sup>2</sup> = 0,8361	80,79	1,85	1,48
FÓRMULA VIP	M.Turcicum	V9	y = -532,88x + 12113	R <sup>2</sup> = 0,8686	532,88	0,28	0,22
FÓRMULA VIP	M.Turcicum	V10	y = -337,85x + 11540	R <sup>2</sup> = 0,8815	337,85	0,44	0,35
FÓRMULA VIP	M.Turcicum	R1	y = -237,73x + 11260	R <sup>2</sup> = 0,833	237,73	0,63	0,50
FÓRMULA VIP	M.Branca	R2	y = -471,38x + 9939,9	R <sup>2</sup> = 0,7653	471,38	0,32	0,25
FÓRMULA VIP	M.Branca	R3	y = -116,74x + 10219	R <sup>2</sup> = 0,9151	116,74	1,28	1,02
FÓRMULA VIP	M.Branca	R3	y = -99,556x + 10328	R <sup>2</sup> = 0,8985	99,556	1,50	1,20
FÓRMULA VIP	M.Branca	R4	y = -89,626x + 10413	R <sup>2</sup> = 0,8864	89,626	1,67	1,33
	M.Bipolaris					<b>1,54</b>	<b>1,23</b>
Média dos híbridos	M.Turcicum					<b>0,94</b>	<b>0,75</b>
	M.Branca					<b>0,67</b>	<b>0,53</b>

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V9, nove folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; V12, doze folhas desenroladas; VT, pendoamento; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso; R5, grão dente.

De Rossi et al. (2022) obtiveram resultados semelhantes para a mancha de turcicum, e concluíram que a aplicação de fungicidas deve ser feita entre 0,88 e 1,09% para essa doença, ou seja, entre o limiar de ação (LA) e o limiar de dano econômico (LDE). Assim como relatado por estes mesmos autores, à primeira vista, os valores de LDE e LA registrados nesse trabalho também podem ser considerados muito baixos para a recomendação de aplicação de fungicidas no campo. Porém, sabe-se que a severidade da mancha de turcicum e outras doenças aumentam quando as condições climáticas são favoráveis.

O princípio de manejo integrado de doenças fundamentado no LDE, sugere que a aplicação de fungicidas seja realizada no limiar de ação (LA). Assim, a medida de controle deve ser implementada de modo a evitar que a doença ultrapasse o LDE, sendo que este não é fixo e deve ser calculado anualmente para cada situação em função das variações dos preços da cultura, dos fungicidas, dos custos das aplicações e da eficiência dos fungicidas (REIS; CASA, 2008). Desse modo, o LDE é uma ferramenta de gestão e critério adicional para a tomada de decisões sobre intervenções com fungicidas, podendo ser alterado de acordo com as mudanças nos parâmetros da equação (DE ROSSI et al., 2022). Outros fatores também devem ser considerados na tomada de decisão, como o histórico de doenças no campo, clima e suscetibilidade do híbrido (MUNKVOLD, 2007; SMITH, 2015).

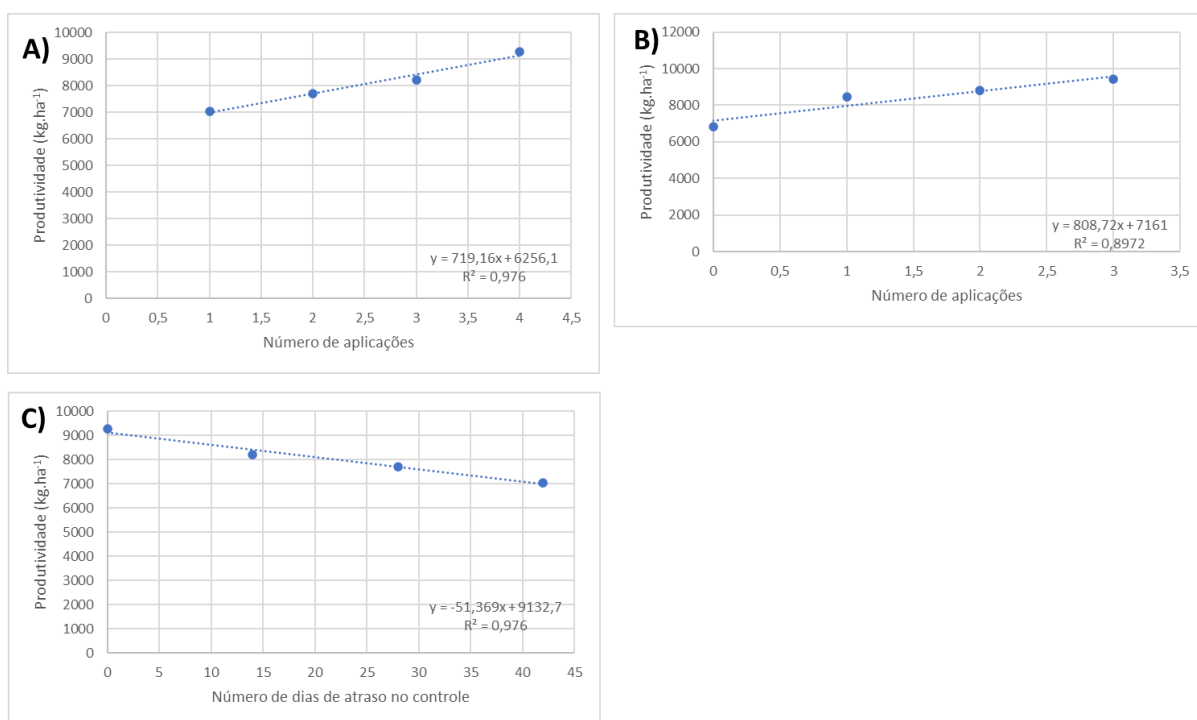
Os híbridos do presente estudo possuem suscetibilidade moderada às doenças relatadas, com exceção à escassez de informações sobre mancha de bipolaris e em relação à tolerância do material AG 8780 à mancha de turcicum (AGRO BAYER, 2024; SYNGENTA, 2024). Segundo Munkvold (2007, apud DE ROSSI, 2022), híbridos moderadamente resistentes ou resistentes não devem ser tratados com fungicidas, pois é improvável que haja benefício econômico de uma aplicação. Por outro lado, é recomendada a sua utilização em híbridos moderadamente suscetíveis a suscetíveis.

Apesar de cada doença ocorrer preferencialmente em determinados estádios fenológicos (CUSTODIO et al., 2019), o LDE não deve ser excedido durante nenhum período de crescimento da cultura (CARMONA et al., 2014). Portanto, é preciso analisar diversos fatores para que o benefício do controle das doenças com fungicidas seja superior ao custo da sua utilização (PAUL et al., 2011;

COSTA et al., 2012a, 2012b; MALLOWA et al., 2015; TEDFORD et al., 2017; ESKERS et al., 2018; COTA et al., 2018).

### 3.5.4 Produtividade em Função das Aplicações de Fungicidas

Sobre a relação da produtividade com o número de aplicações de fungicidas e o atraso no controle, podemos fazer diferentes inferências. Analisando a média de todos os híbridos, para cada aplicação atrasada houve perda de produtividade de 719,16 kg/ha/aplicação (Figura 18A), sendo que para cada aplicação a menos no final do ciclo, houve perda de produtividade de 808,72 kg/ha/aplicação (Figura 18B). Para cada dia de atraso no início do controle, houve perda de produtividade de 51,36 kg/ha/dia de atraso (Figura 18C). Ou seja, devido à ocorrência de doenças tanto no período vegetativo quanto no final do ciclo, nos diferentes extratos da planta, todas as épocas de aplicação interferiram nos valores de produtividade.



**Figura 18** – Relação entre produtividade e o número de aplicações de fungicidas no início do ciclo (Figura A), no final do ciclo (Figura B) e relação entre produtividade e o atraso no início do controle (Figura C), na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Segundo observado por Wise et al (2019), aplicações em V6 geraram ganhos de 127,4 kg/ha em relação à testemunha sem aplicações, enquanto aplicações no pendoamento (VT) proporcionaram ganhos de 376,8 kg/ha e a combinação de ambas as aplicações (V6 + VT) resultou em incrementos de 493,9 kg/ha, levando em consideração o plantio de verão dos Estados Unidos, região do *Corn Belt*, de clima temperado, onde a ferrugem polissora é relevante. Esses autores enfatizaram que a menor resposta de rendimento observada com aplicações de fungicidas em V6 foi atribuída ao fato de que essas aplicações ocorrem muito cedo para reduzir a severidade da cercosporiose e ferrugens. Também salientaram que o início dessas doenças geralmente ocorre nos estados vegetativos posteriores (V16) e que poucas doenças foliares importantes estão presentes nos estágios vegetativos iniciais. Outros autores constataram que independente do híbrido, o fungicida azoxistrobina + ciproconazol nos estádios V8, VT ou R1, aumentaram em média a produtividade em 18, 30 e 21%, respectivamente, caracterizando o pendoamento como a melhor época de aplicação (ROSA et al., 2017). No entanto, em anos/locais em que a doença se desenvolve no início da estação de crescimento (por exemplo, durante as fases vegetativas do milho) como por exemplo no extremo sul dos EUA, pode ser observada uma resposta maior à aplicação em V6 (WISE et al., 2019). Por exemplo, Robinson e colaboradores (2016), ao analisarem o efeito de fungicidas no controle de mancha de turcicum e cercosporiose, obtiveram de 768 a 809 kg/ha à mais em relação à testemunha sem fungicidas, realizando uma aplicação no estágio V5 ou duas aplicações em V5 + R1, enquanto uma aplicação isolada no estágio R1 resultou em um incremento de 526 kg/ha em relação à testemunha, evidenciando a importância da aplicação no início do período vegetativo. Além disso, esse momento de aplicação é mais barato para os agricultores, pois pode ser feito utilizando equipamentos agrícolas comuns. Assim, uma pulverização mais precoce pode ser mais interessante, mesmo que isso leve à um menor rendimento em algumas situações (TESTA et al., 2015).

### 3.6 CONCLUSÕES

Apesar da mancha de bipolaris ter se tornado a doença mais severa e mais frequente nas últimas safras em todo o Brasil, ocasionando a redução da produtividade, ainda carece de estudos, sobretudo de relação injúria-dano. Sendo

assim, trabalhos que abordem a relação dessa doença com a produtividade em diferentes híbridos, incluindo novos entrantes no mercado de sementes, tem relevância para a cadeia produtiva do milho segunda safra. Portanto, a contribuição desse estudo consiste nas equações de dano propostas e nos altos coeficientes de determinação obtidos para a relação da AACPD de mancha de bipolaris com o dano, atingindo valores de 84, 68, 82 e 81% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente.

Para mancha de turcicum e mancha branca, embora haja alguns trabalhos de relação injúria-dano na literatura, é preciso atualizar essa área do conhecimento frente à diversidade de híbridos, bem como incluir os resultados obtidos nessas manchas junto aos da mancha de bipolaris na composição dos resultados de complexo de manchas foliares, uma vez que não há estudos nesse sentido. Desta forma, o presente estudo obteve equações de dano e altos coeficientes de determinação para a relação da AACPD de mancha de turcicum com o dano, atingindo valores de 76, 86 e 87% para os híbridos AG 9021, AG 9025 e FÓRMULA VIP, respectivamente. Para a mancha branca, esses valores foram de 75, 63, 88 e 91% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente.

Ao longo dos anos, a maioria dos autores têm desenvolvido equações de dano para doenças específicas. Em contrapartida, as doenças foliares dificilmente ocorrem isoladamente no campo, em virtude da dificuldade em se obter materiais com elevados níveis de tolerância à diferentes doenças, simultaneamente. Portanto, poucos estudos têm contemplado o patossistema múltiplo na cultura do milho e nenhum abordado o complexo de manchas foliares com a inclusão de mancha de bipolaris, justificando a necessidade de informações mais ajustadas à realidade do cenário de doenças frente à variabilidade e atualidade. Sendo assim, o presente estudo obteve equações de dano e altos coeficientes de determinação para a relação da AACPD de manchas foliares com o dano, com valores de 87, 71, 88 e 92% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente.

Neste estudo, abordamos a severidade de mancha de bipolaris, mancha de turcicum e mancha branca em diferentes estádios de desenvolvimento da cultura e a sua relação com o rendimento de diferentes híbridos de milho semeados na segunda safra, subsidiando a determinação do LDE e LA como

critérios para a aplicação de fungicidas. Estes limiares não têm valores fixos e devem ser calculados anualmente para cada situação, sendo assim, considerando a média dos híbridos, para mancha de bipolaris, o LA obtido ficou entre 1,23 e 1,54%, enquanto para mancha de turcicum entre 0,75 e 0,94% e para mancha branca entre 0,53 e 0,67%, sugerindo que a intervenção com fungicidas deve ocorrer preventivamente ou na detecção dos primeiros sintomas, para que o benefício do controle das doenças com fungicidas seja superior ao custo da sua utilização.

Sobre a relação da produtividade com o número de aplicações de fungicidas e o atraso no controle, para cada aplicação atrasada houve perda de produtividade de 719,16 kg/ha/aplicação, sendo que para cada aplicação a menos no final do ciclo, houve perda de produtividade de 808,72 kg/ha/aplicação. Para cada dia de atraso no início do controle, houve perda de produtividade de 51,36 kg/ha/dia de atraso. Ou seja, devido à ocorrência de doenças tanto no período vegetativo quanto no final do ciclo, nos diferentes extratos da planta, todas as épocas de aplicação interferiram na produtividade.

Programas de aplicações de fungicidas iniciados precocemente no período vegetativo, estágio de V6, seguido de aplicações em V10 e R2, oferecem controle para um maior espectro de doenças em diferentes híbridos. O manejo preventivo de doenças na cultura do milho é extremamente importante para a manutenção do potencial produtivo da cultura e, conseqüentemente, da rentabilidade, em virtude das fortes relações injúria-dano e dos baixos limiares de ação observados.

## 4 ARTIGO B: ÍNDICES DE VEGETAÇÃO COMO MÉTODOS DE DETECÇÃO E PREDIÇÃO DE DANOS CAUSADOS POR MANCHAS FOLIARES DO MILHO

### 4.1 RESUMO

Os tecidos sadios refletem o infravermelho com maior intensidade do que os tecidos doentes, sendo assim, sistemas de detecção e quantificação de doenças podem se basear em medidas de reflectância, com as quais, os índices de vegetação podem ser calculados, facilitando sua interpretação. Neste contexto, o objetivo deste estudo foi verificar o potencial uso de índices de vegetação como métodos de detecção e predição de danos causados por mancha foliares do milho (mancha branca, mancha de turcicum e mancha de bipolaris). Foram instalados quatro experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), no município de Londrina, PR, na safra de 2022. Os híbridos de milho utilizados foram o AG 8780, AG 9021, AG 9025 e Fórmula VIP, cada material representando um experimento. O delineamento experimental utilizado foi blocos ao acaso com oito tratamentos e quatro repetições. Os tratamentos consistiram na aplicação dos fungicidas Prothioconazol + Trifloxistrobina + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>) na dose de 500 mL.ha<sup>-1</sup> do produto comercial em diferentes estádios fenológicos do milho: T1 - testemunha; T2 - V6, V10, R2, R2+14; T3 - V6, V10, R2; T4 - V6, V10; T5 - V6; T6 - V10, R2, R2+14; T7 - R2, R2+14; T8 - R2+14. As capturas de dados foram realizadas com um sensor *Micasense-MX* acoplado a um drone DJI Inspire 2 nas mesmas datas de avaliação de severidade. Os cálculos dos índices de vegetação foram realizados através dos softwares *Agisoft* e *ArcGIS PRO*. Também foi utilizado o radiômetro *GreenSeeker* para avaliações em pranchas (1,5 x 1,0 m) cobertas com folhas de milho. Com os índices e bandas foram calculadas as áreas abaixo da curva de progresso do NDVI, NQAB, NQAF, NDRE, VARI e NIR (AACPN<sub>NDVI</sub>, AACPN<sub>NQAB</sub>, AACPN<sub>NQAF</sub>, AACPN<sub>NDRE</sub>, AACPV<sub>VARI</sub> e NIR). Os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5% de probabilidade. O NDVI proporcionou a maior correlação com a mancha de bipolaris, considerando maior gama de híbridos na cultura do milho. Para o híbrido AG 8780, a relação entre AACPN do NDVI e a AACPD de mancha de bipolaris atingiu 67%, e para o híbrido AG 9025 de 84%. Para a AACPD de manchas foliares, a AACPN do índice NDVI foi a que obteve melhor correlação na maioria dos híbridos, com valores de 70, 58, 70 e 72% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente. Para a cultura do milho segunda safra, os índices de vegetação VARI e NDVI foram os que apresentaram as melhores correlações com a produtividade, para a maioria dos híbridos. No híbrido AG 8780, houve boa relação entre a produtividade e a AACPN dos índices NDVI, NQAF e VARI, com 82, 50 e 52%, respectivamente. Para o híbrido AG 9021, a melhor relação ocorreu com o índice VARI, com 56%, enquanto para o híbrido AG 9025, foram os índices NDVI e VARI, com R<sup>2</sup> de 76 e 70%, respectivamente e, para o híbrido FÓRMULA VIP, a região NIR, com 54%.

Palavras-chave: sensoriamento remoto; NDVI; reflectancia

## VEGETATION INDEXES AS METHODS FOR DETECTION AND PREDICTION OF DAMAGE CAUSED BY LEAF SPOTS IN CORN

### 4.2 ABSTRACT

Healthy tissues reflect infrared with greater intensity than diseased tissues, therefore, disease detection and quantification systems can be based on reflectance measurements, with which vegetation indices can be calculated, facilitating their interpretation. In this context, the objective was to verify the potential use of vegetation indexes as methods for detection and prediction of damage caused by leaf spots in corn (maize white spot (MWS), northern corn leaf blight (NCLB) and southern corn leaf blight (SCLB)). Four experiments were settled at the School Farm of the State University of Londrina (UEL), in the city of Londrina, PR, in the corn second season 2022. The corn hybrids used were AG 8780, AG 9021, AG 9025 and Fórmula VIP, each material representing one experiment. The experimental design used was randomized blocks with eight treatments and four replications. Treatments consisted of the application of the fungicides Prothioconazole + Trifloxystrobin + Bixafen ( $175 + 150 + 125 \text{ g a.i. L}^{-1}$ ) at a dose of  $500 \text{ mL.ha}^{-1}$  of the commercial product at different phenological stages of the crop: T1 - control; T2 - V6, V10, R2, R2+14; T3 - V6, V10, R2; T4 - V6, V10; T5 - V6; T6 - V10, R2, R2+14; T7 - R2, R2+14; T8 - R2+14. The captures were taken with a Micasense-MX sensor coupled to a DJI Inspire 2 drone on the same severity assessment dates. Vegetation indices calculations were carried out using Agisoft and ArcGIS PRO software. The GreenSeeker radiometer was also used for assessments on boards ( $1,5 \times 1,0 \text{ m}$ ) covered with corn leaves. With the indices and bands, the areas under the progress curve of NDVI, NQAB, NQAF, NDRE, VARI e NIR ( $\text{AUPC}_{\text{NDVI}}$ ,  $\text{AUPC}_{\text{NQAB}}$ ,  $\text{AUPC}_{\text{NQAF}}$ ,  $\text{AUPC}_{\text{NDRE}}$ ,  $\text{AUPC}_{\text{VARI}}$  e NIR) were calculated. The data were subjected to analysis of variance using the F test and differences between means, when significant, were compared using the Scott Knott test, at a 5% probability level. The relations between the AUPC of vegetation index, AUDPC and productivity were analyzed by linear regression. NDVI provided the highest correlation with SCLB, considering a wider range of hybrids in corn crops. For hybrid AG 8780, the relation between AACPC of NDVI and AUDPC of SCLB reached 67%, and for hybrid AG 9025 it was 84%. For AUDPC of leaf spots, the AACPC of the NDVI index was the one that obtained the best correlation in most hybrids, with values of 70, 58, 70 and 72% for hybrids AG 8780, AG 9021, AG 9025 and FORMULA VIP, respectively. For second-crop corn, the vegetation indexes VARI and NDVI were the ones that presented the best correlations with productivity, for most hybrids. In the AG 8780 hybrid, there was a good relation between productivity and the AACPC of the NDVI, NQAF and VARI indexes, with 82, 50 and 52%, respectively. For the AG 9021 hybrid, the best relation occurred with the VARI index, with 56%, while for the AG 9025 hybrid, it was the NDVI and VARI indexes, with  $R^2$  of 76 and 70%, respectively and, for the FÓRMULA VIP hybrid, the NIR region, with 54%.

Keywords: remote sensing; NDVI; reflectance

### 4.3 INTRODUÇÃO

O milho (*Zea mays* L.) é uma das culturas mais importantes no Brasil, sendo que o Paraná é o segundo estado brasileiro com maior produção (CONAB, 2024). Danos causados por doenças nessa cultura podem exceder 70% (COSTA et al., 2018).

Dentre as principais doenças foliares na cultura do milho estão a cercosporiose, mancha branca, ferrugem polissora, ferrugem comum, ferrugem tropical, mancha de turcicum, antracnose e mancha de bipolaris (EMBRAPA, 2021).

A quantificação de doenças é uma etapa crucial nos estudos epidemiológicos e para avaliação de estratégias de controle e, para que erros sejam minimizados. O método utilizado na quantificação deve fornecer resultados acurados e precisos. As escalas diagramáticas se constituíram na principal ferramenta de avaliação de severidade para muitas doenças (BERGAMIN FILHO et al., 2018). A eficiência dessas escalas depende da capacidade individual dos avaliadores, havendo a necessidade de treinamento, pois frequentemente a visão humana superestima a doença (SHERWOOD et al., 1983; BERGAMIN FILHO et al., 2018). As escalas diagramáticas utilizadas na fitopatometria possuem problemas relacionados ao nível de experiência do avaliador, que acarretam a subjetividade nas avaliações (VALE et al., 2004).

Os tecidos sadios refletem o infravermelho com maior intensidade do que os tecidos doentes (CANTERI, 1998). Sendo assim, sistemas de detecção e quantificação de doenças podem se basear em medidas do espectro em diferentes comprimentos de onda (WEST et al., 2003). Filmes coloridos infravermelhos e, mais recentemente, câmeras digitais capazes de captar diferentes comprimentos de onda podem ser utilizados na avaliação de doenças por permitirem a distinção entre tecidos sadios e sintomáticos (BERGAMIN FILHO, 2018). Os índices de vegetação foram concebidos para otimizar a interpretação dos dados de reflectância.

Segundo Sugiura et al. (2016, apud BERGAMIN FILHO, 2018), a utilização de sensores de radiação em veículos aéreos não tripulados (VANT), drones, deverá ampliar o uso dessa tecnologia na detecção e na quantificação de doenças de plantas.

Esse trabalho teve como objetivo verificar o potencial uso de índices de vegetação como método de detecção e predição de danos causados por

manchas foliares do milho.

#### 4.4 MATERIAL E MÉTODOS

##### 4.4.1 Localização dos Experimentos

Foram instalados quatro experimentos na cultura do milho na Fazenda Escola da Universidade Estadual de Londrina (UEL), na altitude de 564 m, no município de Londrina, PR. O solo é classificado como Latossolo Vermelho Distroférico (EMBRAPA, 2018). De acordo com Köppen-Geiger, o clima é do tipo Cfa – subtropical úmido, apresentando temperatura média no mês mais frio abaixo de 18 °C e temperatura média no mês mais quente acima de 22 °C (CAVIGLIONE et al., 2000).

##### 4.4.2 Instalação dos Experimentos e Delineamento Experimental

Os detalhes em relação à instalação dos experimentos estão descritos na Tabela 9.

**Tabela 9** – Época e ano de condução, data de semeadura, híbrido, data da aplicação de fungicidas e estágio de desenvolvimento da cultura. Londrina – PR.

Época e Ano de condução	Localidade	Data de semeadura	Híbrido	Data da aplicação de fungicidas e ED <sup>a</sup>			
				23/03/2022	06/04/2022	20/04/2022	04/05/2022
Safrinha 2022	Londrina	18/02/2022	AG 8780	V6	V9	R1	R3
			AG 9021	V7	V11	R2	R4
			AG 9025	V6	V10	R2	R3
			FÓRMULA VIP	V6	V9	R1	R3

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V6, seis folhas desenroladas; V7, sete folhas desenroladas; V9, nove folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

Para fins de simplificação da descrição dos tratamentos, os estádios de desenvolvimento da cultura nas aplicações serão citados da seguinte forma: aplicação em 23/03/2022 (V6, seis folhas desenroladas); aplicação em 06/04/2022 (V10, dez folhas desenroladas); aplicação em 20/04/2022 (R2, bolha d'água); aplicação em 04/05/2022 (R2+14, quatorze dias após bolha d'água).

Para cada um dos experimentos citados, foi utilizado um híbrido de

milho. Em relação às características, os híbridos utilizados foram: AG 8780 com ciclo precoce, suscetível à mancha branca e tolerante à mancha de turcicum, AG 9021 com ciclo hiperprecoce, moderadamente suscetível à mancha branca e à mancha de turcicum, AG 9025 com ciclo superprecoce, moderadamente suscetível à mancha branca e à mancha de turcicum, e Fórmula VIP com ciclo precoce, moderadamente suscetível à mancha branca e à mancha de turcicum (AGRO BAYER, 2024; SYNGENTA, 2024). Não há informações quanto à suscetibilidade dos híbridos à mancha de bipolaris.

Para todos os híbridos de milho foi utilizado o espaçamento de 0,50 m entre linhas, com 3 sementes por metro linear, contando com população de 60 mil plantas ha<sup>-1</sup>. O delineamento experimental utilizado foi blocos ao acaso com oito tratamentos e quatro repetições. As parcelas foram de 3 m de largura e 7 m de comprimento, totalizando 21 m<sup>2</sup>, compostas por seis linhas de semeadura.

#### 4.4.3 Adubação e Manutenção Fitossanitária

Em relação à cultura do milho, a adubação de base foi de 280 kg.ha<sup>-1</sup> com o formulado 12-15-15, realizada no dia da semeadura de acordo com as recomendações para a cultura (EMBRAPA, 2021). Posteriormente foi realizada uma adubação nitrogenada por cobertura de 100 kg.ha<sup>-1</sup> de ureia no estágio de V3 da cultura. O controle das pragas cigarrinha-do-milho e percevejo-barriga-verde foi realizado com os inseticidas Imidacloprido + Beta-Ciflutrina (100 + 12,5 g i.a. L<sup>-1</sup>) a 1000 mL.ha<sup>-1</sup> nos dias 3, 10 e 17 de março de 2022. O controle de plantas daninhas foi realizado com o herbicida Tembotriona (420 g i.a. L<sup>-1</sup>) a 240 mL.ha<sup>-1</sup> e o sequencial com o herbicida Atrazina (500 g i.a. L<sup>-1</sup>) a 3000 mL.ha<sup>-1</sup> no dia 10 de março de 2022.

#### 4.4.4 Tratamentos

Em relação aos tratamentos nos experimentos de milho, foram utilizados os fungicidas Protioconazol + Trifloxistrobina + Bixafen (175 + 150 + 125 g i.a. L<sup>-1</sup>), aplicados na dose de produto comercial de 500 mL.ha<sup>-1</sup> em diferentes estádios fenológicos da cultura (Tabela 10).

**Tabela 10** – Tratamentos, estádios de desenvolvimento da planta e número de aplicações dos fungicidas para controle de doenças fúngicas na cultura do milho. Londrina – PR.

Tratamento	ED <sup>a</sup>	Nº de aplicações
T1	-	-
T2	V6/ V10/ R2/ R2+14	4
T3	V6/ V10/ R2	3
T4	V6/ V10	2
T5	V6	1
T6	V10/ R2/ R2+14	3
T7	R2/ R2+14	2
T8	R2+14	1

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

Esta formulação de fungicidas foi escolhida por possuir elevada eficácia no controle de doenças do milho (CUSTODIO et al., 2020), com a finalidade de gerar gradientes entre as parcelas, possibilitando as análises posteriores.

As aplicações de fungicidas foram realizadas com pulverizador costal de pressão constante, propelido por CO<sub>2</sub> pressurizado, utilizando seis pontas de pulverização do tipo jato plano de dupla saída modelo 110.015, espaçados a cada 0,4 m. A pressão de trabalho foi de 2,5 bar, com volume de pulverização de 150 L.ha<sup>-1</sup>.

#### 4.4.5 Condições Climáticas

Os dados de volume de precipitação, temperaturas máximas e mínimas, e a umidade relativa foram obtidos da Estação Meteorológica da Universidade Estadual de Londrina, referentes ao município de Londrina - PR, no período de condução dos experimentos (ANEXO A).

#### 4.4.6 Captura dos Dados com Sensor Acoplado à VANT

As capturas foram realizadas com sensor *Micasense-MX* (Figura 19) acoplado à um *VANT DJI Inspire 2* (Figura 20). A resolução do sensor foi de 1280 x 960 (1.2 MP por banda EO). As bandas espectrais foram azul, verde, vermelho, limite do vermelho e infravermelho próximo (IVP) e saída RGB e o obturador global

foi alinhado com todas as bandas. O equipamento possui GSD (Ground Sample Distance) de 2,05 cm/pixel. Foi utilizado o equipamento da empresa ALVAZ (Londrina, Paraná), que também deu o suporte para os voos.



**Figura 19** – Sensor *Micasense-MX* utilizado para captura dos dados.

Fonte: O próprio autor.



**Figura 20** – Equipamento *VANT DJI Inspire 2* utilizado para realização dos voos.

Fonte: O próprio autor.

A altura de voo foi de 30 m, devido à uma limitação de segurança. Os voos para obtenção das reflectâncias e mosaicos foram realizados entre às 08:00 e 10:00 da manhã, juntamente à cada avaliação de severidade de mancha branca, mancha de turcicum e mancha de bipolaris para a cultura do milho (Tabela 11).

**Tabela 11** – Época e ano de condução, híbrido, data da captura de dados com sensor e estágio de desenvolvimento das plantas de milho. Londrina – PR.

Época e Ano	Híbrido	Data da captura com sensor e ED <sup>a</sup>						
		07/04/2022	14/04/2022	21/04/2022	28/04/2022	06/05/2022	13/05/2022	20/05/2022
Safrinha 2022	AG 8780	V9	V10	R1	R2	R3	R3	R4
	AG 9021	V11	VT	R2	R3	R4	R4	R5
	AG 9025	V10	V12	R2	R2	R3	R3	R4
	FÓRMULA VIP	V9	V10	R1	R2	R3	R3	R4

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005): V9, nove folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; V12, doze folhas desenroladas; VT, pendoamento; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso; R5, grão dente.

Correções para exclusões de “imagens de fundo” contendo solo, divisões das parcelas, extração de dados de reflectância e cálculos de índices de vegetação foram realizadas através dos softwares *Agisoft* e *ArcGIS PRO*. Essas ferramentas também foram utilizadas no processamento, integração, exibição, criação de mapas, análises e geração de modelos 2D e 3D, automatização de análises, calibração automática de câmeras.

Os índices obtidos foram o NDVI (*Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge*), NQAB (Índice de Biomassa), NQAF (Índice de Fotossíntese), NQAE (Índice de Estresse Vegetal), VARI (*Visible Atmospherically Resistant Index*). Também foram obtidos os dados da banda NIR (*Near-Infrared*). Os índices NQAB, NQAF e NQAE foram desenvolvidos pela ALVAZ e não tiveram as equações cedidas.

#### 4.4.7 Captura dos Dados com Radiômetro

As capturas foram realizadas com radiômetro *GreenSeeker Hand Held Model 505* (Figura 21), pertencente ao Departamento de Agronomia da Universidade Estadual de Londrina, com reflectância no comprimento de onda de 600 nm e 770 nm para obtenção dos dados de NDVI.



**Figura 21** – Equipamento radiômetro *GreenSeeker Hand Held Model 505*.

Fonte: O próprio autor.


Tratando-se de uma nova metodologia proposta, sem precedentes na literatura, foram destacadas folhas saudáveis de milho (0% de severidade) e com sintomas de mancha branca (5-10% de severidade), mancha de turcicum (5% de severidade) e mancha de bipolaris (3-5% de severidade), sendo posteriormente dispostas em pranchas de 1,5 m por 1,0 m para a realização das leituras (Figuras 22

e 23). O sensor foi posicionado à aproximadamente 60 cm da prancha (OLKAHOMA STATE UNIVERSITY, 2017), com a finalidade de simular o dossel de plantas. As leituras foram realizadas em quatro passadas no percurso de 1,5 m por prancha, resultando em 6 metros lineares, simulando parcelas de ensaios à campo, que usualmente possuem este comprimento para a cultura do milho.



**Figura 22** – Prancha coberta com folhas de milho com sintomas de mancha branca para a leitura.

Fonte: O próprio autor.



**Figura 23** – Recortes das pranchas de folhas saudias, folhas com sintomas de mancha de bipolaris, de mancha de turcicum e de mancha branca.

Fonte: O próprio autor.

Os índices obtidos foram o NDVI (*Normalized Difference Vegetation Index*) e VI (Índice customizado do equipamento). São mencionados neste artigo como NDVI\_R e VI\_R, respectivamente, para distingui-los dos índices obtidos

através dos voos de VANT.

#### 4.4.8 Área Abaixo da Curva de Progresso dos Índices de Vegetação e NIR

Com os dados dos índices de vegetação e NIR, foram calculadas as áreas abaixo da curva de progresso (AACP) para NDVI, NDRE, NQAB, NQAF, VARI, NIR e, NDVI\_R e VI\_R (AACP<sub>NDVI</sub>, AACP<sub>NDRE</sub>, AACP<sub>NQAB</sub>, AACP<sub>NQAF</sub>, AACP<sub>VARI</sub>, AACP<sub>NIR</sub>, AACP<sub>NDVI\_R</sub> e AACP<sub>VI\_R</sub>) por integração trapezoidal (SHANER; FINNEY, 1987), através da equação:

$$AACP = \sum_{i=1}^{n-1} [(X_i + X_{i+1})]/2 (t_{i+1} - t_i)$$

X = Índices de vegetação e NIR.

N = Número de avaliações

$t_{i+1} - t_i$  = Intervalo entre duas avaliações

Os cálculos foram realizados no programa estatístico Scout, baseado na arquitetura ARM (*Agriculture Research Manager*) (GDM, 2025).

#### 4.4.9 Relação Injúria-Dano-Índices de Vegetação e NIR

Através de regressões lineares, buscou-se mensurar a relação entre as avaliações de severidade (artigos não publicados) com os índices de vegetação e NIR em cada avaliação. Também buscou-se mensurar a relação entre os índices de vegetação e NIR obtidos em cada avaliação com a produtividade. Por fim, também foi mensurada a relação entre as AACP dos índices de vegetação e NIR com a AACPD de cada doença, com o patossistema múltiplo (artigos não publicados) e com a produtividade.

As equações de dano foram estimadas através da análise de regressão:  $y = a + bx$ . Onde “y” é a produtividade estimada ou a severidade e “x” o somatório de severidade das doenças ou índices de vegetação, representado pelos níveis observados nos diferentes tratamentos experimentais. O coeficiente de regressão “b”, ou coeficiente de dano (Cd), representa o quanto varia a média de “y” para o aumento de uma unidade de “x”. Também foram obtidos os coeficientes de

determinação ( $R^2$ ) que demonstram o quão forte é a relação entre as variáveis dependente e independente.

#### 4.4.10 Análise dos Dados

Todos os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5% de probabilidade, utilizando o programa SASM-Agri (CANTERI et al., 2001).


Todas as relações foram analisadas por regressão linear, utilizando o programa Microsoft Office Excel®.

### 4.5 RESULTADOS E DISCUSSÃO

#### 4.5.1 Cultura do Milho


##### 4.5.1.1 Resposta de Índices de Vegetação e NIR às Aplicações de Fungicidas

É possível observar diferenças entre os híbridos ao longo do ciclo da cultura, devido às suas diferentes estaturas, arquiteturas, texturas foliares e suscetibilidades a acamamento (Figura 24). O acamamento no material AG 9025 foi mais acentuado à partir do estágio R3 (Figura 24E). Por outro lado, não foi possível detectar ou distinguir a olho nu gradientes entre as parcelas, podendo ser uma limitação do método de captura com câmera RGB.



**Figura 24** – Imagens aéreas da cultura do milho (*Zea mays* L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR.

O índice de fotossíntese (NQAF) também possibilitou capturar diferenças entre os diferentes híbridos ao longo do ciclo da cultura. Porém, assim como a imagem aérea, dificilmente se observa gradiente entre as parcelas através da imagem gerada (Figura 25). Esse índice mostra o armazenamento de energia gerada pela fotossíntese, ou seja, o potencial que a planta tem para gasto energético (potencial produtivo) (ALVAZ, 2024).



**Figura 25** – Índice de fotossíntese (NQAF) na cultura do milho (*Zea mays* L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR.

Os índices de biomassa (NQAB) e de estresse vegetal (NQAE), calculados a partir das reflectâncias, também indicam essa mesma tendência (Anexos B e C). O NQAB serve para mensurar a massa verde relativa na lavoura, independente de suas possíveis causas agrônômicas, como por exemplo: área foliar, teor de nitrogênio e outros. O NQAE indica se a planta apresenta condição adequada ou não para seu desenvolvimento naquele estágio fenológico, e se existe ou não algum estresse aparente nas plantas (ALVAZ, 2024).

De uma maneira geral, na cultura do milho, em relação à utilização das AACPs dos índices de vegetação para a diferenciação de severidade entre os tratamentos com a aplicação de fungicidas, nos híbridos AG 9021, AG 9025 e FÓRMULA VIP, não houve diferença estatística. Apenas no híbrido AG 8780, os tratamentos 2, 3 e 6, que contemplam pelo menos três aplicações de fungicidas no ciclo, iniciando nos estádios V6 e V10, diferiram estatisticamente dos demais em relação à AACP do índice de vegetação VARI (Apêndices M, N, O e P).

O comportamento de um híbrido de milho pode diferir de outro em relação à diversos fatores, como: potencial de rendimento, nível de tecnologia, época de plantio, ciclo, região edafoclimática, finalidade, textura e cor do grão, estatura e arquitetura da planta, resistência ao acamamento e suscetibilidade à doenças (CRUZ; PEREIRA, 2009). Em virtude das diferenças de arquitetura e estatura dos híbridos e comportamento frente às doenças, a distribuição (dossel superior vs inferior) de diferentes lesões específicas, também podem influenciar os sinais capturados pelo sensoriamento remoto multiespectral baseado em VANTs. Isto cria campos de visão e perspectivas opostos e afetam a relação entre os índices de vegetação e a avaliação visual de severidade (MORETA, 2023).

Ainda sobre os resultados de Moreta (2023), a correlação entre as avaliações visuais de severidade de mancha de turcicum e mancha de helmintosporium causada por *Bipolaris zeicola* e os índices multiespectrais provenientes de VANT, sugerem que a força de seu relacionamento dependia da capacidade de discriminar visualmente os tipos distintos de doenças que coocorreram na mesma parcela. A sobreposição de diferentes sintomas de doenças e padrões de lesões nos híbridos prejudicou, até certo ponto, a detecção e percepção visual de um avaliador experiente para obter avaliações precisas de cada doença. Além disso, até o momento não se sabe ao certo qual é o impacto de infecções mistas nas propriedades ópticas das plantas (MAHLEIN, 2016).

#### 4.5.1.2 Relação Injúria-Índices de Vegetação e NIR

##### 4.5.1.2.1 Mancha de Bipolaris

Em relação ao modelo de ponto crítico para mancha de bipolaris, os índices que melhor correlacionaram com a severidade para o híbrido AG 9021, foram o NQAB e NDRE, no estágio de V11, com  $R^2$  de 0,54 e 0,47, respectivamente. Para o híbrido AG 9025, os melhores índices foram o NDVI, NQAB, NQAF e NDRE, no estágio de R2, com  $R^2$  de 0,71; 0,76; 0,74 e 0,75, respectivamente (Apêndices Q, R, S e T). No modelo integral, para o híbrido AG 8780, a relação entre AACP do NDVI e a AACPD de mancha de bipolaris apresentou  $R^2$  de 0,67, sendo que para o híbrido AG 9025, essa relação com a AACP dos índices NDVI, NQAB, NQAF, NDRE e VARI, foram  $R^2$  de 0,84; 0,75; 0,83; 0,78 e 0,62, respectivamente (Tabela 12).

**Tabela 12** – Equações de função de severidade para mancha de bipolaris e coeficientes de determinação para a AACPD dos índices de vegetação e NIR, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Índice de vegetação	Equação de função de severidade e coeficiente de determinação			
	AACPD Mancha de Bipolaris			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
AACPD <sub>NDVI</sub>	$y = -0,0009x + 35,914$	$y = 2E-05x + 37,05$	$y = -0,0016x + 34,161$	$y = -0,0004x + 36,165$
	$R^2 = 0,6783$	$R^2 = 0,0034$	$R^2 = 0,8494$	$R^2 = 0,0554$
AACPD <sub>NQAB</sub>	$y = -0,0088x + 197,46$	$y = 0,0031x + 214,84$	$y = -0,0099x + 176,81$	$y = 0,0013x + 209,03$
	$R^2 = 0,3123$	$R^2 = 0,3581$	$R^2 = 0,7517$	$R^2 = 0,0037$
AACPD <sub>NQAF</sub>	$y = -0,0015x + 132,17$	$y = 0,0003x + 134,31$	$y = -0,002x + 128,96$	$y = -9E-05x + 133,51$
	$R^2 = 0,46$	$R^2 = 0,2742$	$R^2 = 0,8346$	$R^2 = 0,0011$
AACPD <sub>NDRE</sub>	$y = -0,0013x + 19,744$	$y = 0,0003x + 21,844$	$y = -0,0017x + 16,748$	$y = 6E-05x + 21,221$
	$R^2 = 0,3755$	$R^2 = 0,3541$	$R^2 = 0,7841$	$R^2 = 0,0006$
AACPD <sub>VARI</sub>	$y = -0,0017x + 23,074$	$y = -0,0005x + 23,412$	$y = -0,0029x + 16,392$	$y = -0,0011x + 22,046$
	$R^2 = 0,4102$	$R^2 = 0,3817$	$R^2 = 0,6262$	$R^2 = 0,1008$
AACPD <sub>NIR</sub>	$y = -18,109x + 602927$	$y = -4,8428x + 617661$	$y = 0,3152x + 610343$	$y = -22,803x + 634506$
	$R^2 = 0,2264$	$R^2 = 0,2784$	$R^2 = 0,0002$	$R^2 = 0,2214$

A mancha de bipolaris (*Bipolaris maydis*) tem ganhado maior relevância nas últimas safras, com maior ocorrência comparadas à outras doenças foliares (FITOSSANIDADE TROPICAL, 2024). As lesões dessa doença podem ser comumente confundidas com lesões causadas por outros fungos, principalmente a cercosporiose do milho, sendo que nesse caso, a distinção entre os sintomas pode ser feita observando-se os detalhes nas bordas e o tamanho das lesões (COSTA et al., 2014). Devido à escassez de trabalhos de sensoriamento remoto para mancha de bipolaris, podemos nos basear em trabalhos de cercosporiose, devido à similaridade das lesões. Para Uebel (2015), a relação do NDVI com a AACPD de cercosporiose, resultou em correlações com  $R^2$  de 0,64 a 0,68 para o híbrido P30F53, de 0,87 a 0,90 para FÓRMULA e de 0,62 a 0,70 para 2B587. Outros autores, utilizando os sensores WorldView 2 e Quickbird, identificaram que 608 nm e 660 nm nas bandas amarela e vermelha, região do visível, foram as melhores para discriminar todas as categorias de infecção de cercosporiose no milho (DHAU et al., 2017). Outros resultados mostraram que a região visível do limite do vermelho e NIR, foram as melhores regiões espectrais para discriminar diferentes infecções de

cercosporiose (SIBANDA et al., 2019). Apesar de não haver trabalhos com NDVI, NDRE, VARI e NIR em mancha de bipolaris causada por *Bipolaris maydis*, outros índices de vegetação, denominados *Renormalized Difference Vegetation Index* (RDVI), *Optimized Soil-Adjusted Vegetation Index* (OSAVI), *Modified Chlorophyll Absorption in Reflectance Index* (MCARI1 e MCARI2) apresentaram boa correlação com a severidade da mancha causada por *Bipolaris zeicola* na cultura do milho nos Estados Unidos, na safra 2018 (MORETA, 2023).

#### 4.5.1.2.2 Mancha de Turcicum

Para mancha de turcicum, no híbrido AG 9025, os índices que melhor correlacionaram com a severidade de doença no modelo de ponto crítico, foram o NDVI, NQAB, NQAF e NDRE, no estágio de R2, com R<sup>2</sup> de 0,75; 0,67; 0,66 e 0,67, respectivamente (Apêndices Q, R, S e T). No modelo integral, o híbrido AG 9025 apresentou boa correlação entre a AACPD de mancha de turcicum e AACPD dos índices NDVI, NQAB, NQAF, NDRE e VARI, com R<sup>2</sup> de 0,88; 0,64; 0,76; 0,69 e 0,69, respectivamente (Tabela 13).

**Tabela 13** – Equações de função de severidade para mancha de turcicum e coeficientes de determinação para a AACPDs dos índices de vegetação e NIR, na cultura do milho (*Zea mays* L.) Safrinha 2022. Londrina – PR.

Índice de vegetação	Equação de função de severidade e coeficiente de determinação		
	AACPD Mancha de Turcicum		
	AG 9021	AG 9025	FÓRMULA VIP
AACPD <sub>NDVI</sub>	$y = 8E-05x + 37,043$	$y = -0,0013x + 34,267$	$y = -0,0018x + 36,28$
	R <sup>2</sup> = 0,0098	R <sup>2</sup> = 0,8815	R <sup>2</sup> = 0,1553
AACPD <sub>NQAB</sub>	$y = 0,0085x + 214,66$	$y = -0,0076x + 177,23$	$y = -0,0048x + 209,61$
	R <sup>2</sup> = 0,3559	R <sup>2</sup> = 0,6422	R <sup>2</sup> = 0,0068
AACPD <sub>NQAF</sub>	$y = 0,0008x + 134,29$	$y = -0,0016x + 129,06$	$y = -0,0013x + 133,62$
	R <sup>2</sup> = 0,2794	R <sup>2</sup> = 0,7658	R <sup>2</sup> = 0,0349
AACPD <sub>NDRE</sub>	$y = 0,0009x + 21,825$	$y = -0,0013x + 16,827$	$y = -0,0008x + 21,304$
	R <sup>2</sup> = 0,352	R <sup>2</sup> = 0,6922	R <sup>2</sup> = 0,0151
AACPD <sub>VARI</sub>	$y = -0,0013x + 23,419$	$y = -0,0025x + 16,613$	$y = -0,0045x + 22,325$
	R <sup>2</sup> = 0,3119	R <sup>2</sup> = 0,6918	R <sup>2</sup> = 0,2252
AACPD <sub>NIR</sub>	$y = -13,361x + 617849$	$y = 2,9117x + 609697$	$y = -76,594x + 638614$
	R <sup>2</sup> = 0,3046	R <sup>2</sup> = 0,0233	R <sup>2</sup> = 0,3602

Assim como no presente trabalho, outros autores obtiveram diferentes correlações para cada híbrido estudado. Para Uebel (2015), a relação do NDVI com a AACPD de mancha de turcicum, resultou em correlações com  $R^2$  de 0,44 a 0,59 para o híbrido DKB390, de 0,62 a 0,69 para P30F53 e  $R^2$  de 0,35 a 0,71 para 2B587. Outros índices de vegetação, além dos citados no presente trabalho, também podem ser utilizados para a detecção da mancha de turcicum no milho. Por exemplo, Moreta (2023) concluiu que os índices de vegetação, denominados RDVI, OSAVI, MCARI1 e MCARI2, também apresentaram boa correlação com a severidade de mancha de turcicum na cultura do milho, na safra de 2019. Além da utilização dos índices de vegetação de maneira isolada, outros pesquisadores demonstraram que um modelo específico, construído pela fusão dos índices de vegetação *Transformed Chlorophyll Absorption in Reflectance Index* (TCARI1), *Photochemical Reflectance Index* (PRI515), *Normalized Phaeophytinization Index* (NPQI) e *Water Index* (WI) e características de plantas (*plant traits*), extraídos de dados hiperespectrais multiangulares, pode ser utilizado para monitorar efetivamente a mancha de turcicum inicial (GUO et al., 2024). Carecem trabalhos na literatura com os índices NDRE, VARI e NIR para a mancha de turcicum do milho.

#### 4.5.1.2.3 Mancha Branca

Para mancha branca, no híbrido AG 8780, os índices que melhor correlacionaram com a severidade de doença no modelo de ponto crítico, foram o NDVI e VARI, nos estádios de R2 e R3, com  $R^2$  de 0,74 e 0,84, respectivamente. Para o híbrido AG 9021, o índice que melhor correlacionou com a severidade de doença, foi o VARI, no estádio de R4, com  $R^2$  de 0,59. Para o híbrido AG 9025, todos os índices tiveram boa correlação com a severidade dessa doença, porém, com destaque para o NDVI e VARI, no estádio de R3, com  $R^2$  de 0,80 e 0,90, respectivamente (Apêndices Q, R, S e T). No modelo integral, houve boa correlação entre a AACPD e AACP do índice NDVI para os híbridos AG 8780 e AG 9025, com  $R^2$  de 0,60 e 0,78, respectivamente e, VARI para os híbridos AG 8780, AG 9021 e AG 9025, com  $R^2$  de 0,61; 0,52 e 0,85, respectivamente (Tabela 14).

**Tabela 14** – Equações de função de severidade para mancha branca e coeficientes de determinação para a AACPD dos índices de vegetação e NIR, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Índice de vegetação	Equação de função de severidade e coeficiente de determinação			
	AACPD Mancha Branca			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
AACPD <sub>NDVI</sub>	$y = -0,001x + 35,87$	$y = 8E-05x + 37,054$	$y = -0,0062x + 34,046$	$y = -0,0005x + 36,201$
	$R^2 = 0,6058$	$R^2 = 0,001$	$R^2 = 0,7889$	$R^2 = 0,2262$
AACPD <sub>NQAB</sub>	$y = -0,0057x + 196,69$	$y = 0,0222x + 215,1$	$y = -0,0238x + 175,56$	$y = -0,0021x + 209,53$
	$R^2 = 0,0952$	$R^2 = 0,2978$	$R^2 = 0,2582$	$R^2 = 0,0243$
AACPD <sub>NQAF</sub>	$y = -0,0012x + 132,05$	$y = 0,0022x + 134,32$	$y = -0,0059x + 128,74$	$y = -0,0004x + 133,57$
	$R^2 = 0,2083$	$R^2 = 0,2629$	$R^2 = 0,4261$	$R^2 = 0,0699$
AACPD <sub>NDRE</sub>	$y = -0,0009x + 19,633$	$y = 0,0026x + 21,866$	$y = -0,0044x + 16,55$	$y = -0,0003x + 21,28$
	$R^2 = 0,1335$	$R^2 = 0,3328$	$R^2 = 0,3245$	$R^2 = 0,0393$
AACPD <sub>VARI</sub>	$y = -0,0025x + 23,04$	$y = -0,005x + 23,418$	$y = -0,0138x + 16,261$	$y = -0,0014x + 22,139$
	$R^2 = 0,6198$	$R^2 = 0,5259$	$R^2 = 0,8513$	$R^2 = 0,373$
AACPD <sub>NIR</sub>	$y = -27,419x + 602694$	$y = -42,396x + 617502$	$y = 4,6539x + 610488$	$y = -18,408x + 634719$
	$R^2 = 0,382$	$R^2 = 0,3738$	$R^2 = 0,0024$	$R^2 = 0,3813$

Em híbridos diferentes dos utilizados nesse trabalho, Uebel (2015), observou que a relação do NDVI com a AACPD de mancha branca, resultou em correlações com  $R^2$  de 0,50 a 0,56 para o híbrido DKB390, de 0,61 a 0,76 para P30F53 e de 0,64 a 0,76 para 2B587. Diferentemente dos resultados obtidos para o híbrido FÓRMULA (Tabela 14), Uebel (2015) encontrou uma correlação mais alta para este mesmo híbrido, com  $R^2$  de 0,79 a 0,88. Outros autores, também encontraram uma boa relação do NDVI com essa e outras doenças, evidenciando superioridade em relação ao índice de reflectância de antocianina (ARI), ao índice de reflectância fotoquímica (PRI) e ao índice de reflectância de carotenoides (CRI) (NKUNA et al., 2024).

#### 4.5.1.2.4 Manchas Foliares

Para manchas foliares, considerando o patossistema múltiplo, o índice NDVI foi o que obteve melhor correlação com a maioria dos híbridos, com valores de  $R^2$  de 0,58 a 0,72 (Tabela 15).

**Tabela 15** – Equações de função de severidade para manchas foliares e coeficientes de determinação para a AACPD dos índices de vegetação e NIR, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Índice de vegetação	Equação de função de severidade e coeficiente de determinação			
	AACPD Manchas Foliares			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
AACPD <sub>NDVI</sub>	$y = -0,001x + 35,901$	$y = -0,0006x + 35,912$	$y = -0,0008x + 35,943$	$y = -0,0011x + 35,924$
	$R^2 = 0,7083$	$R^2 = 0,5859$	$R^2 = 0,7008$	$R^2 = 0,72$
AACPD <sub>NQAB</sub>	$y = -0,008x + 197,14$	$y = -0,0079x + 197,87$	$y = -0,0084x + 197,8$	$y = -0,0116x + 197,64$
	$R^2 = 0,2234$	$R^2 = 0,4935$	$R^2 = 0,345$	$R^2 = 0,3773$
AACPD <sub>NQAF</sub>	$y = -0,0014x + 132,12$	$y = -0,0012x + 132,21$	$y = -0,0014x + 132,22$	$y = -0,0019x + 132,19$
	$R^2 = 0,3706$	$R^2 = 0,6059$	$R^2 = 0,4808$	$R^2 = 0,526$
AACPD <sub>NDRE</sub>	$y = -0,0012x + 19,698$	$y = -0,0012x + 19,796$	$y = -0,0012x + 19,789$	$y = -0,0017x + 19,768$
	$R^2 = 0,2802$	$R^2 = 0,549$	$R^2 = 0,3981$	$R^2 = 0,4401$
AACPD <sub>VARI</sub>	$y = -0,0021x + 23,074$	$y = -0,0009x + 23,011$	$y = -0,0016x + 23,134$	$y = -0,002x + 23,079$
	$R^2 = 0,5285$	$R^2 = 0,2044$	$R^2 = 0,438$	$R^2 = 0,3938$
AACPD <sub>NIR</sub>	$y = -22,957x + 603023$	$y = -7,6115x + 601926$	$y = -18,299x + 603790$	$y = -20,736x + 602907$
	$R^2 = 0,3153$	$R^2 = 0,0772$	$R^2 = 0,2785$	$R^2 = 0,2065$

Geralmente, os trabalhos têm abordado a relação de doenças específicas com os índices de vegetação, e poucos têm contemplado o patossistema múltiplo. Diferentemente dos resultados obtidos no presente estudo, Moreta (2023) encontrou uma fraca correlação ( $r = -0,17$ ) entre o NDVI e a AACPD do patossistema múltiplo, composto por doenças causadas pelas espécies de fungos *Bipolaris zeizola*, *Exserohilum turcicum* e *Colletotrichum graminicola* em experimentos no ano de 2019, sendo que para os experimentos de 2018 não houve correlação significativa. Segundo o autor, esta relação foi fraca mesmo após a remoção do ruído de fundo do solo.

#### 4.5.1.3 Avaliação da Prancha com Folhas Destacadas de Milho

Em relação à utilização do NDVI<sub>R</sub> e VI<sub>R</sub> para a detecção de doenças no milho, apenas as capturas em prancha de mancha de bipolaris diferiram estatisticamente da captura em folha sadia (Tabela 16).

**Tabela 16** – Índices de vegetação obtidos por radiômetro, nos tratamentos com diferentes pranchas de doenças, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Tratamento	Índice de vegetação*		
	Doença	NDVI_R	VI_R
Mancha de Bipolaris	0,621261 a	0,238331 a	
Mancha Branca	0,698358 b	0,181041 b	
Mancha de Turcicum	0,738129 b	0,151732 b	
Folhas Sadias	0,717821 b	0,163881 b	
C.V. (%)	7,65	21,03	

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

Apesar da leitura com o radiômetro ter sido realizada no início da ocorrência de doenças, ainda em baixa severidade, a mancha de bipolaris proporcionou maior amarelecimento foliar que a mancha de turcicum e a mancha branca, sendo esse o fator responsável pela diferenciação estatística do NDVI\_R e VI\_R do tratamento “Mancha de Bipolaris” em relação aos demais.

É preciso salientar que os índices são equações com diferentes composições das bandas espectrais, com reflectâncias no infravermelho próximo, limite do vermelho, vermelho, verde, azul e etc. Sendo assim, alterações em diferentes comprimentos de onda, também gerarão alterações nos índices. Dados gerados pelo *Centro Internacional de Mejoramiento de Maíz y Trigo* (CIMMYT) em 11 ensaios de rendimento de milho, sob estresse de calor e seca, indicaram que usar dados de 62 bandas leva à uma maior precisão de predição comparado à índices de vegetação individuais (AGUATE et al 2017). Outros resultados mostraram que as bandas do limite do vermelho de 705 e 710 nm foram as mais valiosas na detecção da cercosporiose para os sensores multiespectrais Sentinel-2 e RapidEye, respectivamente, e, que para os sensores WorldView 2 e Quickbird, os respectivos 608 nm e 660 nm nas bandas amarela e vermelha foram identificados como os mais valiosos para discriminar todas as categorias de infecção (DHAU et al., 2017).

Os índices de vegetação também têm tido boa correlação com outras doenças na cultura do milho, como por exemplo, a ferrugem polissora (LENG et al., 2012; MENG et al., 2020; LI et al.; SPURLOCK et al., 2020). Para a mancha de asfalto do milho, uma nova doença, causada pelo fungo *Phyllachora maydis*, ainda em expansão na América Latina, foi encontrada forte relação entre a área sob a curva de progresso da doença da doença (AACPD) e três índices vegetativos (RDVI, MCARI1 e MCARI2) (LOLADZE et al., 2019). Os índices de vegetação

também têm sido amplamente utilizados em etapas de segmentação de modelos de *deep learning* para identificação de doenças (BENAÏSSA et al., 2024; CHEN et al., 2023).

Por outro lado, os índices de vegetação não são indicadores diretos, nem exclusivos, da severidade da doença, pois eles também estão relacionados ao vigor, biomassa, conteúdo de pigmento, conteúdo de água, dentre outros fatores (BOCK et al., 2020).

#### 4.5.1.4 Relação Dano-Índices de Vegetação e NIR

Na cultura do milho, os índices que melhor correlacionaram com a produtividade do híbrido AG 8780 no modelo de ponto crítico, foram o NDVI, NQAF, NDRE e VARI, nos estádios de R3, R2, R2 e R3, com  $R^2$  de 0,90; 0,67; 0,59 e 0,75, respectivamente. Para o híbrido AG 9021, esse índice foi o VARI, no estádio de R4, com  $R^2$  de 0,55. Para o híbrido AG 9025, foram o NDVI, NQAB, NQAF, NDRE e VARI, no estádio de R3, com  $R^2$  de 0,78; 0,66; 0,68; 0,64 e 0,85, respectivamente. Para o FÓRMULA VIP, foram o VARI e NIR, no estádio de R3, com  $R^2$  de 0,62 e 0,54, respectivamente (Apêndices U, V, X e W).

No modelo integral, para o híbrido AG 8780, houve boa relação entre a produtividade e a AACP do índice NDVI, NQAF e VARI, com  $R^2$  de 0,82; 0,50 e 0,52, respectivamente. Para o híbrido AG 9021, a melhor relação ocorreu com o índice VARI, com  $R^2$  de 0,56, enquanto que para o híbrido AG 9025, foram os índices NDVI e VARI, com  $R^2$  de 0,76 e 0,70, respectivamente. Para o híbrido FÓRMULA VIP, a região NIR, com  $R^2$  de 0,54 (Tabela 17).

**Tabela 17** – Equações de função de dano e coeficientes de determinação para a AACPs dos índices de vegetação e NIR, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.

Índice de vegetação	Equação de função de dano e coeficiente de determinação			
	Híbrido			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
AACP <sub>NDVI</sub>	$y = 7455,4x - 258769$	$y = 1282,4x - 38179$	$y = 3275,3x - 104689$	$y = 3160,6x - 104790$
	$R^2 = 0,828$	$R^2 = 0,0131$	$R^2 = 0,7612$	$R^2 = 0,3068$
AACP <sub>NQAB</sub>	$y = 353,11x - 61272$	$y = -287,18x + 71409$	$y = 333,97x - 52227$	$y = 132,53x - 18358$
	$R^2 = 0,3723$	$R^2 = 0,1821$	$R^2 = 0,359$	$R^2 = 0,088$
AACP <sub>NQAF</sub>	$y = 2950,4x - 381300$	$y = -2398,5x + 331764$	$y = 2027,5x - 254473$	$y = 1391,1x - 176338$
	$R^2 = 0,5092$	$R^2 = 0,1463$	$R^2 = 0,496$	$R^2 = 0,1447$
AACP <sub>NDRE</sub>	$y = 2696,2x - 44709$	$y = -2753,8x + 69891$	$y = 2147,4x - 29080$	$y = 1226,5x - 16671$
	$R^2 = 0,4153$	$R^2 = 0,2077$	$R^2 = 0,4097$	$R^2 = 0,1062$
AACP <sub>VARI</sub>	$y = 2471,3x - 48405$	$y = 2986,1x - 59893$	$y = 1472,3x - 17116$	$y = 1712,7x - 28168$
	$R^2 = 0,5293$	$R^2 = 0,567$	$R^2 = 0,7079$	$R^2 = 0,4025$
AACP <sub>NIR</sub>	$y = 0,1372x - 74370$	$y = 0,2364x - 136156$	$y = -0,0329x + 26247$	$y = 0,1493x - 84925$
	$R^2 = 0,3297$	$R^2 = 0,3598$	$R^2 = 0,0141$	$R^2 = 0,5422$

Ou seja, para a cultura do milho, o VARI foi o índice de vegetação apresentou boa correlação para a maioria dos híbridos, simultaneamente. O NDVI também obteve boas correlações para dois híbridos. O índice VARI apresentou correlação significativa ( $r = 0,99$ ) com o rendimento de grãos (COSWOSK et al., 2024). O índice de área foliar (IAF) é uma variável importante para modelagem climática, estimativas de produção primária, previsão de rendimento agrícola e muitos outros estudos diversos (GITELSON et al., 2003). Muitos outros trabalhos encontraram alta correlação entre o VARI e IAF ou nitrogênio nas folhas (BALLESTEROS et al., 2021; QIAO et al., 2022; SHAO et al., 2021; MAGALHÃES; ROSSI, 2024; RODENE et al., 2022). NDVI e VARI provenientes de sensoriamento remoto por VANTs, contribuíram para o modelo de estimativa do IAF calculado no campo (GUOMIN et al., 2020).

Vian et al. (2018), analisando a relação do NDVI com a produtividade, utilizando o radiômetro GreenSeeker em diferentes estádios fenológicos, obtiveram o coeficiente de determinação mais alto no estádio de V8,  $R^2 = 0,83$ . Para Uebel (2015), a relação do NDVI com a produtividade resultou em correlações com  $R^2$  de 0,35 a 0,49 para o híbrido DKB390, de 0,34 a 0,47 para

P30F53, de 0,70 a 0,77 para FÓRMULA e de 0,13 a 0,28 para 2B587. Por outro lado, segundo trabalho conduzido por Clarindo et al (2022), o NDVI relacionado com a biomassa, juntamente a outros parâmetros, estimou equivocadamente a produtividade potencial com valor 18% maior do que a produtividade real. Outros autores verificaram que para cada resteva, as classes de potencial produtivo baixo, médio, alto e muito alto foram indicadas, respectivamente, pelos seguintes valores de NDVI: 0,13; 0,45; 0,68 e 0,80, em milho (GROHS et al., 2009). Por outro lado, outro autor, abordando índices diferentes dos estudados no presente trabalho, objetivando avaliar a relação da produtividade com os valores médios de sete índices de vegetação, calculados através de bandas multiespectrais capturadas pelos instrumentos de imagem Sentinel-2A e Sentinel-2B, concluiu que os índices *Pan Normalized Difference Vegetation Index* (PRENDVI) e *Green-Red Normalized Difference Vegetation Index* (GRENDVI), foram os mais recomendados para estimar a produtividade de grãos em milho (HENRIQUES, et al., 2021).

#### 4.6 CONCLUSÕES

Em virtude da insuficiência de trabalhos de sensoriamento remoto abordando a mais abrangente e recente problemática no cenário de doenças da cultura do milho no Brasil, inexistem informações sobre a utilização dos índices de vegetação NDVI, NDRE, VARI e NIR na detecção da mancha de *bipolaris* causada por *Bipolaris maydis*, bem como na predição de seus danos. Estudos semelhantes foram realizados em doenças causadas por fungos desse mesmo gênero, espécie *Bipolaris zeicola*, nos Estados Unidos, verificando a utilização de outros índices de vegetação. Porém, por não serem resultados transferíveis para as condições tropicais, também não refletem a realidade do milho segunda safra no Brasil.

Haja visto essa lacuna de dados, a contribuição desse artigo constitui-se em correlacionar a severidade dessa doença em questão com os índices de vegetação. O NDVI proporcionou a maior correlação, considerando maior gama de híbridos na cultura do milho, sendo que para o híbrido AG 8780, a relação entre AACPD do NDVI e a AACPD de mancha de *bipolaris* atingiu 67%, e para o híbrido AG 9025 de 84%.

Para mancha de turcicum e mancha branca, carecem trabalhos na literatura com os índices NDRE, VARI e NIR, sendo preciso gerar mais informações

frente à diversidade de híbridos e notoriedade desses índices, bem como incluir os resultados obtidos nessas manchas junto aos da mancha de *bipolaris* na composição dos resultados de complexo de manchas foliares, uma vez que não há estudos nesse sentido. O híbrido AG 9025 foi o único que apresentou boa correlação entre a AACPD de mancha de turcicum e AACPD dos índices, com valores de 88, 64, 76, 69 e 69% para NDVI, NQAB, NQAF, NDRE e VARI, respectivamente. Para mancha branca, houve boa correlação entre a AACPD e AACPD do índice NDVI para os híbridos AG 8780 e AG 9025, com 60 e 78%, respectivamente e, VARI para os híbridos AG 8780, AG 9021 e AG 9025, com 61, 52 e 85% respectivamente.

Geralmente, estudos relacionados ao uso do sensoriamento remoto na detecção de doenças, não contemplam o patossistema múltiplo, nem mesmo consideram a presença da mancha de *bipolaris* nesse complexo de doenças. Por este motivo, a escassez de informações justifica a realização dessa pesquisa, onde para manchas foliares, considerando o patossistema múltiplo, a AACPD do índice NDVI foi o que obteve melhor correlação com a maioria dos híbridos, com valores de 70, 58, 70 e 72% para os híbridos AG 8780, AG 9021, AG 9025 e FÓRMULA VIP, respectivamente.

Apesar de existirem trabalhos na literatura relacionando a produtividade aos índices de vegetação testados, não há resultados onde esses mesmos parâmetros são influenciados pelo complexo de manchas foliares do presente estudo. Para a cultura do milho segunda safra, o VARI foi o índice de vegetação que apresentou a melhor correlação com a produtividade, para a maioria dos híbridos, simultaneamente. O NDVI também obteve boas correlações para dois híbridos. No híbrido AG 8780, houve boa relação entre a produtividade e a AACPD dos índices NDVI, NQAF e VARI, com 82, 50 e 52%, respectivamente. Para o híbrido AG 9021, a melhor relação ocorreu com o índice VARI, com 56%, enquanto para o híbrido AG 9025, foram os índices NDVI e VARI, com  $R^2$  de 76 e 70%, respectivamente. Para o híbrido FÓRMULA VIP, a região NIR, com 54%.

## 5 ARTIGO C: REDES NEURAIS CONVOLUCIONAIS COMO MÉTODOS DE DETECÇÃO DE MANCHAS FOLIARES DO MILHO

### 5.1 RESUMO

As redes neurais convolucionais (RNC) são arquiteturas de aprendizagem profunda que proporcionam a resolução de problemas de diferentes áreas do conhecimento. Neste contexto, objetivou-se verificar o potencial uso de redes convolucionais para a detecção de manchas foliares do milho (mancha branca, mancha de turcicum e mancha de bipolaris). As folhas de plantas de milho foram coletadas em experimentos conduzidos na Fazenda Escola da Universidade Estadual de Londrina (UEL), no município de Londrina, PR, na safrinha de 2022. Os híbridos desses experimentos foram o AG 8780, AG 9021, AG 9025 e Fórmula VIP. Foram destacadas de plantas de milho, folhas saudias de milho, folhas com mancha branca, mancha de turcicum e mancha de bipolaris, e fotografadas em ambiente com luminosidade artificial utilizando câmera de 12 MP de celular *smartphone*, marca Iphone, modelo X. As imagens tiveram o fundo removido através da ferramenta online *Pixlr Remove BG* e divididas horizontalmente em três partes pela ferramenta online *Pinetools Bulk split image*, resultando em 955 imagens de mancha branca, 67 de mancha de turcicum, 733 de mancha de bipolaris e 365 de folhas saudias, totalizando 2.120 imagens. As arquiteturas de RNC utilizadas foram a VGG16, MobileNetV2 e um Modelo Manual. Cada modelo foi treinado com batch de tamanho 32 por 10 épocas. Para as condições desses experimentos em questão, a VGG16 foi a arquitetura de CNN que obteve a maior acurácia na detecção de manchas foliares na cultura do milho segunda safra, atingindo 96,76% na etapa de treinamento e de 84,67% na etapa de validação. As demais CNNs obtiveram menores acurácias, onde a MobileNetV2 e o Modelo Manual, na etapa de treinamento obtiveram acurácia de 89,15 e 71,52%, respectivamente, e na etapa de validação atingiram acurácia de 81,13 e 75%, respectivamente.

Palavras-chave: VGG16; inteligência artificial; aprendizagem profunda

## CONVOLUTIONAL NEURAL NETWORKS AS METHODS FOR DETECTION OF LEAF SPOTS IN CORN

### 5.2 ABSTRACT

Convolutional neural networks (CNN) are deep learning architectures that provide problem solving in different areas of knowledge. In this context, the objective was to verify the potential use of convolutional networks for the detection of leaf spots in corn (maize white spot (MWS), northern corn leaf blight (NCLB) and southern corn leaf blight (SCLB)). The leaves of corn plants were collected in experiments conducted at the Fazenda Escola da Universidade Estadual de Londrina (UEL), in the city of Londrina, PR, second season 2022. The hybrids in these experiments were AG 8780, AG 9021, AG 9025 and Fórmula VIP. Were detached from corn plants, healthy corn leaves, leaves with MWS, NCLB and SCLB and photographed in a studio with artificial light, using a smartphone camera with 12 MP, iPhone brand, model X. The images had the background removed using the online tool Pixlr Remove BG and divided horizontally into three parts using the online tool Pinetools Bulk split image, resulting in 955 images of MWS, 67 of NCLB, 733 of SCLB and 365 of healthy leaves, totaling 2.120 images. The CNN architectures used were VGG16, MobileNetV2 and a Manual Model. Each model was trained with batch size 32 for 10 epochs. For the conditions of these experiments in question, VGG16 was the CNN architecture that obtained the highest accuracy in detecting leaf spots in the second corn crop, reaching 96,76% in the training stage and 84,67% in the validation stage. The other CNNs obtained lower accuracies, where MobileNetV2 and the Manual Model, in the training stage, obtained accuracies of 89,15 and 71,52%, respectively, and in the validation stage, reached accuracies of 81,13 and 75%, respectively.

Keywords: VGG16; artificial intelligence; deep learning

### 5.3 INTRODUÇÃO

O milho (*Zea mays* L.) é uma das culturas mais importantes no Brasil, representando 38,85% da produção de grãos do País. Na safra total 2023/2024 houve decréscimo de 12,3% na produção em relação à safra anterior, alcançando 115,697 milhões de toneladas (CONAB, 2024).

A ocorrência de doenças, plantas invasoras e pragas afetam significativamente o potencial produtivo da planta de milho (ÁVILA; PANIZZI, 1995; CHOCOROSQUI; PANIZZI, 2004; ROZA-GOMES, 2011). Dentre as principais doenças foliares na cultura do milho estão a cercosporiose, mancha branca, ferrugem polissora, ferrugem comum, ferrugem tropical, mancha de turcicum, antracnose e mancha de bipolaris (EMBRAPA, 2021).

A diagnose se refere à identificação de uma doença e do seu agente causal com base nos sintomas e sinais. Essa constatação de uma possível doença é realizada na lavoura, geralmente pelo produtor, técnico ou fitopatologista pela observação das plantas afetadas. Este reconhecimento não deve ser confundido com a identificação do agente causal da doença, no entanto esta etapa preliminar é fundamental para nortear procedimentos posteriores. A correta diagnose e o conhecimento da epidemiologia da doença são pré-requisitos indispensáveis para definir as medidas para o seu manejo (BERGAMIN FILHO et al., 2018).

Atualmente, os métodos de diagnóstico precoce envolvem a combinação das avaliações visuais com métodos mais atuais. Essa mudança se deu pelos avanços tecnológicos e redução nos custos na aquisição de imagens à campo, possibilitando a introdução de diferentes métodos de diagnóstico de doenças baseados na classificação de imagens (STRANGE et al., 2005).

A inteligência computacional tem sido utilizada na identificação de padrões, reduzindo o número de identificações de rotina utilizadas por especialistas de diferentes áreas, sendo que a técnica de aprendizagem profunda (AP) tem sido aplicada na classificação de imagens (MARQUES et al., 2018). As redes neurais convolucionais (RNC) são arquiteturas de aprendizagem profunda que proporcionam a resolução de problemas de diferentes áreas do conhecimento (DE CASTRO SILVA, 2001).

Neste contexto, objetivou-se verificar o potencial uso de redes neurais convolucionais para a detecção de manchas foliares do milho (mancha

branca, mancha de turcicum e mancha de mancha de bipolaris).

## 5.4 MATERIAL E MÉTODOS

### 5.4.1 Coleta de Folhas Doentes e Sadias de Plantas de Milho

Foram coletadas folhas doentes e sadias de plantas de milho em quatro experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), na altitude de 564 m, no município de Londrina, PR (Figura 26). As folhas de milho foram coletadas de plantas dos híbridos AG 8780, AG 9021, AG 9025 e Fórmula VIP.



**Figura 26** – Folhas de milho do híbrido AG 9021 com sintomas de mancha branca, coletadas em experimentos na Fazenda Escola da Universidade Estadual de Londrina (UEL), Londrina, PR.

**Fonte:** O próprio autor.

### 5.4.2 Registros Fotográficos das Folhas

A captura de imagens foi realizada utilizando câmera de celular de 12 MP *smartphone*, marca Iphone, modelo X, Câmeras de 12 MP com lentes grande-angular e teleobjetiva. A lente grande-angular possuía abertura de  $f/1.8$ , e a teleobjetiva, abertura de  $f/2.4$ . Além disso, a câmera possuía sensor de retroiluminação, foco automático com *Focus Pixels*, captura de ampla tonalidade de cores para fotos e *Live Photos*, mapeamento de tom local aprimorado, e estabilização automática de imagem.

As folhas foram levadas para ambiente com luminosidade artificial, sendo estendidas e posicionadas sobre mesa circular com um raio de 0,75 m e,

quando necessário, foram utilizadas fitas adesivas para auxiliar na fixação do tecido na mesa (Figura 27). A câmera foi posicionada em frente à mesa à aproximadamente 1 m de distância, sendo que a área de abrangência da captura foi delimitada pelas dimensões do círculo dela, no sentido vertical das folhas.

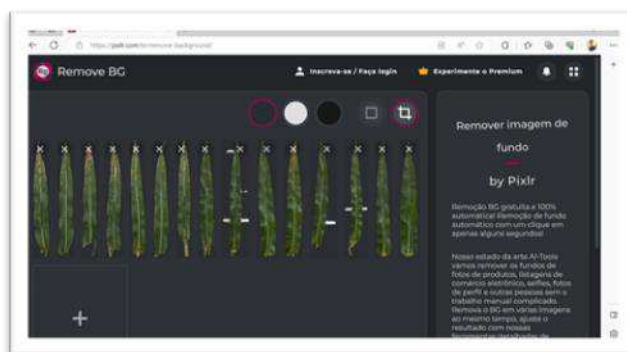


**Figura 27** – Fixação de folha de planta de milho em mesa para os registros fotográficos.

Fonte: O próprio autor.

#### 5.4.3 Tratamento das Imagens

As fotografias tiveram o fundo removido através da ferramenta online *Pixlr Remove BG* (PIXLR, 2023) (Figura 28). Esta ferramenta permite o upload em lotes de imagens, facilitando o processo para trabalhar com elevado número de arquivos e, disponibiliza o download em formato compactado.



**Figura 28** – Ferramenta *Pixlr Remove BG* para remoção de fundo de imagem.

Fonte: O próprio autor.

As imagens foram divididas horizontalmente em três partes pela ferramenta online *Pinetools Bulk split image* (PINETOOLS, 2023) (Figura 29). Este procedimento teve o objetivo de facilitar o aprendizado computacional, visto que a severidade é variável de acordo com a região da folha e, também para aumentar a quantidade de imagens a serem utilizadas no processo. Esta ferramenta também permite o upload em lotes de imagens, otimizando o tratamento.



**Figura 29** – Imagens de folhas de milho do híbrido AG 9021 com sintomas de mancha branca após a divisão utilizando a ferramenta *Pinetools Bulk split image*.

**Fonte:** O próprio autor.

O tratamento de imagens resultou em 2.120 imagens, organizadas em quatro classes diferentes (Tabela 18).

**Tabela 18** – Número de imagens após tratamento. Londrina – PR.

	Classe				Total
	Mancha Branca	Mancha de Turcicum	Mancha de Bipolaris	Folhas Sadias	
<b>Número de imagens</b>	955	67	733	365	2.120

#### 5.4.4 Treinamento da Rede Neural Convolutacional (RNC)

Foram testadas três arquiteturas de RNCs diferentes, com a finalidade de analisar seus respectivos comportamentos em relação ao problema proposto:

- **Modelo Manual:** Criado especialmente para essa situação, contendo poucos parâmetros. O modelo começa ajustando o tamanho e a escala das imagens de entrada. Depois, ele usa várias camadas de convolução para extrair características importantes das imagens, seguidas por camadas de *pooling* para reduzir a

informação e tornar o modelo mais robusto. As camadas *flatten* e *dense* combinam essas características aprendidas para produzir uma probabilidade para cada classe possível na camada de saída.

Detalhamento do Modelo Manual:

```
model = tf.keras.Sequential()
model.add(Resizing(img_height, img_width))
model.add(Rescaling(1./255))

model.add(tf.keras.layers.InputLayer(input_shape=[img_width,
img_height], batch_size=batch_size))

model.add(tf.keras.layers.Conv2D(16, kernel_size=10,
activation='relu'))
model.add(tf.keras.layers.MaxPooling2D(3))

model.add(tf.keras.layers.Conv2D(32, kernel_size=8,
activation='relu'))
model.add(tf.keras.layers.MaxPooling2D(2))

model.add(tf.keras.layers.Conv2D(32, kernel_size=6,
activation='relu'))
model.add(tf.keras.layers.MaxPooling2D(2))

model.add(tf.keras.layers.Flatten())
model.add(tf.keras.layers.Dense(50, activation='relu'))
model.add(tf.keras.layers.Dense(20, activation='relu'))
model.add(tf.keras.layers.Dense(num_classes, activation='softmax'))
```

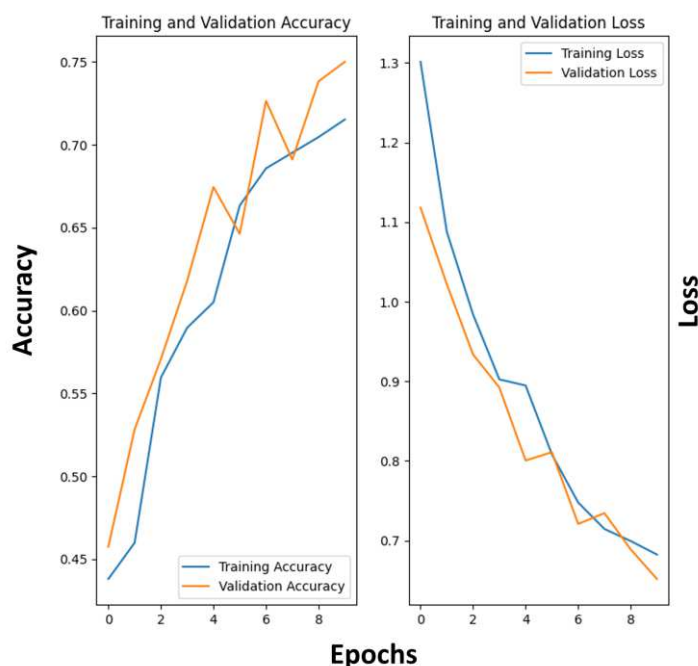
- **VGG16**: Modelo pré-treinado na ImageNet, com arquitetura amplamente utilizada para tarefas de visão computacional, conhecida por sua profundidade contendo 16 camadas e desempenho competitivo em competições de reconhecimento de imagens;

- **MobileNetV2:** Modelo pré-treinado na ImageNet, contendo arquitetura para eficiência em termos de uso de recursos computacionais, em aplicações de visão computacional e aprendizado profundo móvel.

Cada modelo foi treinado com batch de tamanho 32 por 10 épocas. Os *datasets* não tiveram aumento de dados. Os resultados foram expressos em *accuracy* e *val\_accuracy* em escala de 0 a 1, sendo transformados em percentuais através da multiplicação por 100, para fins de discussão. *Accuracy* é a precisão de acertos nos dados de treinamento e *val\_accuracy* é a precisão de acertos nos dados de validação. O algoritmo foi configurado para destinar 20% dos dados coletados para validação.

## 5.5 RESULTADOS E DISCUSSÃO

Em relação à precisão de acertos nos dados de treinamento e validação para o Modelo Manual, na etapa de treinamento foi obtida acurácia de 71,52% e perda de 68,23%, sendo que na etapa de validação foi obtida uma acurácia de 75% e perda de 65,16% (Figura 30).



**Figura 30** – Precisão de acertos nos dados de treinamento e validação para o Modelo Manual.

Epoch 10/10 53/53 [=====] - 3s 46ms/step - loss: 0.6823 - accuracy: 0.7152 - val\_loss: 0.6516 - val\_accuracy: 0.7500

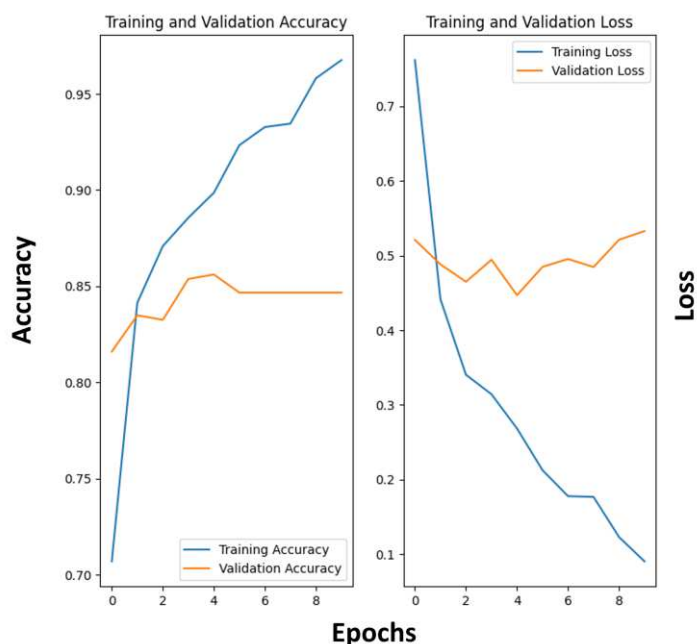
Fonte: O próprio autor.

Zeng et al (2022) obtiveram 95,4% de precisão com o modelo otimizado (LDSNet) para identificação de doenças foliares na cultura do milho, com precisão melhor que as redes pesadas existentes, como AlexNet, VGG16, VGG19 e ResNet50, e redes leves, como DenseNet121, GoogleNet, MobileNet (V1, V2 e V3-large), ShuffleNetV2 e GhostNet. A AlexNet contém 8 camadas, sendo 5 camadas de convolução, 3 camadas de *max-pooling*, 2 camadas normalizadas, 2 camadas totalmente conectadas e 1 camada SoftMax. A rede, exceto a última camada, é dividida em duas cópias, cada uma executada em uma GPU, sendo que esta foi a primeira arquitetura que usou GPU para aumentar o desempenho do treinamento (KRIZHEVSKY et al., 2012). O VGG-19 é uma rede neural convolucional profunda com 19 camadas de peso, compreendendo 16 camadas convolucionais e 3 camadas totalmente conectadas, sendo que o ReLU (Rectified Linear Unit) é usado como a função de ativação para as camadas convolucionais e totalmente conectadas, com a finalidade de introduzir não linearidade (SIMONYAN; ZISSERMAN, 2015). ResNet-50 é uma rede neural convolucional com 50 camadas de profundidade, consistindo em vários blocos de construção conhecidos como blocos residuais. Cada bloco residual contém várias camadas convolucionais com

normalização em lote e ativações ReLU (HE et al., 2015). DenseNet é uma rede neural convolucional que utiliza conexões densas entre camadas, por meio de Blocos Densos, onde são conectadas todas as camadas, com tamanhos de mapa de características correspondentes, diretamente umas com as outras (HUANG et al., 2017). GoogleNet é uma rede neural convolucional com 22 camadas de profundidade, treinada no conjunto de dados ImageNet, capaz de classificar objetos em 1.000 categorias (SZEGEDY et al. 2017). ShuffleNet v2 é uma rede neural convolucional otimizada para uma métrica direta (velocidade) em vez de métricas indiretas como FLOPs (MA et al., 2018). A GhostNet é uma CNN construída com módulos Ghost, que visam gerar mais recursos usando menos parâmetros, permitindo maior eficiência (HAN et al., 2020).

Uma nova abordagem de *deep learning* chamada MaizeNet é proposta por Masood et al (2023) para localizar e classificar os vários tipos de infecções de folhas de milho, obtendo precisão média de 97,89% junto com o valor mAP de 0,94. Sibiya et al (2019), utilizaram a estrutura do Neuroph Studio (NEUROPH, 2025) para construir uma CNN profunda mais facilitada, por meio da qual as extrações de recursos de convolução e agrupamento foram incorporadas na biblioteca Neuroph. A precisão geral desse novo modelo foi de 92,85%, provando sua viabilidade no reconhecimento da cercosporiose, mancha de turcicum e ferrugem comum na cultura do milho, a partir de folhas sadias. Sun et al (2020) desenvolveram um método com Resnet-101 para detecção da mancha de turcicum, alcançando 91,83% de precisão, sendo melhor do que outros modelos de detecção baseados em Resnet-101.

Em relação à precisão de acertos nos dados de treinamento e validação para o VGG16, na etapa de treinamento foi obtida acurácia de 96,76% e perda de 9,05%, sendo que na etapa de validação foi obtida uma acurácia de 84,67% e perda de 53,27% (Figura 31).



**Figura 31** – Precisão de acertos nos dados de treinamento e validação para o VGG16.

Epoch 10/10 53/53 [=====] - 7s 126ms/step - loss: 0.0905 - accuracy: 0.9676 - val\_loss: 0.5327 - val\_accuracy: 0.8467

Fonte: O próprio autor.


Estes valores indicam *overfitting*, o qual ocorre quando um modelo não consegue generalizar bem de dados antigos para novos dados, fazendo com que o modelo tenha um bom desempenho nos dados de treinamento, mas atue mal nos dados de validação (XIA et al., 2023). Em geral, isso pode acontecer com base em três motivos: aprendizado de ruído de dados de treinamento, complexidade de hipóteses e múltiplas etapas de comparação que aparecem em algoritmos indutivos. O aumento de dados pode ser uma das ferramentas para mitigar o *overfitting* (XIA et al., 2023).

Benaissa et al. (2024) atingiram 92,39% de precisão com modelos construídos utilizando o conjunto de dados de milho PlantVillage, com aplicação de várias técnicas de pré-processamento e extraíndo características através da VGG16 por meio de aprendizagem de transferência. O conjunto de dados PlantVillage é uma coleção ou repositório de imagens de folhas de plantas que são usadas para desenvolver algoritmos que identificam doenças de plantas (BRUNO et al., 2022). O aprendizado por transferência é uma técnica de aprendizado de máquina na qual o conhecimento adquirido em uma tarefa ou conjunto de dados é utilizado para melhorar o desempenho do modelo em outra tarefa relacionada e/ou em um

conjunto de dados diferente (IBM, 2024).

Existem outros modelos com alta precisão comparados ao VGG19. Por exemplo, Syarief & Setiawan (2020), testaram sete modelos de CNN na classificação de cercosporiose, mancha de turcicum e ferrugem comum do milho: AlexNet, VGG16, VGG19, GoogleNet, Inception-V3, ResNet50 e ResNet101. Com base nos resultados desses testes, a melhor classificação foi obtida com a AlexNet, atingindo a precisão de 93,5% (SYARIEF; SETIAWAN, 2020).

Em relação à precisão de acertos nos dados de treinamento e validação para o MobileNetV2, na etapa de treinamento foi obtida acurácia de 89,15% e perda de 28,50%, sendo que na etapa de validação foi obtida acurácia de 81,13% e perda de 56,64% (Figura 32).



**Figura 32** – Precisão de acertos nos dados de treinamento e validação para o MobileNetV2.

Epoch 10/10 53/53 [=====] - 3s 60ms/step - loss: 0.2850 - accuracy: 0.8915 - val\_loss: 0.5664 - val\_accuracy: 0.8113

Fonte: O próprio autor.

Nan et al. (2023), visando avaliar o potencial da câmera RGB-D sincronizada com informações de profundidade para classificação de doenças foliares de milho, verificaram que dentre os modelos de pós-segmentação, Resnet50 e MobilenetV2 mostraram precisão semelhantes e foram melhores do que os modelos VGG16 e Efficientnet-B3. Neste mesmo trabalho, o modelo MobilenetV2

apresentou um desempenho melhor do que os outros três em termos de tamanho e tempo de previsão de imagem única. Concepcion et al. (2021), analisando um conjunto de dados com 583 imagens, contendo folhas de milho senescentes, sadias e doentes, concluíram que o modelo MobileNetV2-GQPSO-RNN fornece detecção confiável de doenças e avaliação quantitativa na superfície da folha de milho na fenotipagem em campo.

Li et al. (2023), propondo um método baseado em aprendizado profundo para identificação de doenças do milho, concluíram que, quando testado em conjuntos de dados coletados em campo com um fundo complexo, o modelo MDCDenseNet superou os modelos DenseNet121, ResNet50, MobileNetV2 e NASNetMobile com precisão de 98,84%.

## 5.6 CONCLUSÕES

Com o aumento crescente da incidência de manchas foliares no cenário atual da cultura do milho no Brasil, sobretudo da mancha de bipolaris nesse complexo, e com a carência de estudos de redes neurais convolucionais voltados para essa realidade, a contribuição do presente trabalho está na validação das diferentes arquiteturas testadas na detecção das manchas foliares (mancha branca, mancha de turcicum e mancha de bipolaris). Sendo assim, para as condições desses experimentos em questão, a VGG16 foi a arquitetura de CNN que obteve a maior acurácia na detecção de manchas foliares na cultura do milho segunda safra, atingindo 96,76% na etapa de treinamento e de 84,67% na etapa de validação.

As demais CNNs obtiveram menores acurácias, onde a MobileNetV2 e o Modelo Manual, na etapa de treinamento obtiveram acurácia de 89,15 e 71,52%, respectivamente, e na etapa de validação atingiram acurácia de 81,13 e 75%, respectivamente.

Como não foram aplicados aumento de dados nessa metodologia, há a possibilidade de se atingir resultados ainda melhores em trabalhos posteriores.

## 6 CONSIDERAÇÕES FINAIS

A mancha de *bipolaris* se tornou a doença mais severa e mais frequente no atual cenário de doenças da cultura do milho no Brasil, ocasionando a redução da produtividade. Por este motivo, é de relevância para a cadeia produtiva do milho segunda safra, trabalhos que abordem a relação da produtividade com essa doença juntamente à outras no complexo de manchas foliares em diferentes híbridos, uma vez que as doenças foliares dificilmente ocorrem isoladamente no campo.

Portanto, a principal contribuição na relação injúria-dano consiste nas equações de dano propostas e nos altos coeficientes de determinação obtidos para a relação do dano com a AACPD de mancha de *bipolaris* e AACPD do complexo de manchas foliares.

Abordamos a severidade de mancha de *bipolaris*, mancha de *turcicum* e mancha branca em diferentes estádios de desenvolvimento da cultura e a sua relação com o rendimento de diferentes híbridos de milho semeados na segunda safra, subsidiando a determinação do LDE e LA como critérios para a aplicação de fungicidas. Em posse desses limiares, concluímos que essas aplicações devem ocorrer preventivamente ou na detecção dos primeiros sintomas, para que o benefício do controle das doenças com fungicidas seja superior ao custo da sua utilização.

Preenchemos a lacuna de informações de sensoriamento remoto a respeito da mais importante doença da atualidade na cultura do milho, a mancha de *bipolaris*, bem como do complexo de manchas foliares da qual ela faz parte, contribuindo com os resultados onde o NDVI foi o índice de vegetação com maior correlação com as doenças avaliadas e o VARI e NDVI com maior correlação com a produtividade dos híbridos estudados.

Com a carência de estudos de redes neurais convolucionais voltados para essa realidade das manchas foliares no milho segunda safra do Brasil, contribuímos na validação das arquiteturas VGG16, MobileNetV2 e Modelo Manual na detecção das manchas foliares. Sendo assim, para as condições desses experimentos em questão, a VGG16 foi a arquitetura de CNN que obteve a maior acurácia na detecção de manchas foliares na cultura do milho segunda safra.

## REFERÊNCIAS

- ABE, K.; WATABE, S.; EMORI, Y.; WATANABE, M.; ARAI, S. An ice nucleation active gene of *Erwinia ananas*: sequence similarity to those of *Pseudomonas* species and regions required for ice nucleation activity. **FEBS Letters**, Chichester, v. 258, n. 2, p. 297-300, 1989.
- AGRIOS, G. N. **Plant pathology**. 5. ed. New York: Academic Press, 2004. 922 p.
- AGROBAYER. Produtos recomendados. 2024. **Sementes Agroceres**. Disponível em: <https://www.agro.bayer.com.br/marcas/agroceres>. Acesso em 18 de novembro de 2024.
- AGUATE, F. M.; TRASCHEL, S.; PÉREZ, L. G.; BURGUEÑO, J.; CROSSA, J.; BALZARINI, M.; GOUACHE, D.; BOGARD, M.; DE LOS CAMPOS, G. Use of Hyperspectral Image Data Outperforms Vegetation Indices in Prediction of Maize Yield. **Crop Science**, v. 57, p. 2517-2524, 2017.
- ALVAZ. Índices de fotossíntese, biomassa e estresse vegetal. 2024. **Serviços e negócios**. Disponível em: <https://produtos.alvaz.com>. Acesso em 20 de novembro de 2024.
- AMIN, N.; NASRUDDIN, A.; DALHA, L. Isolation, Identification and in-vitro screening of fungal endophytes against pathogen of maize leaf blight, *Helminthosporium maydis*. **The 21st National Congress of the Indonesian Phytopathology Society**, 2012.
- ARAÚJO, J. C.; VETTORAZZI, C. A.; MOLIN, J. P. Estimativa da produtividade e determinação de zonas de manejo, em culturas de grãos, por meio de videografia aérea multiespectral. **Acta Sci. Agron.**, v. 27, n. 3, p. 437-447, 2005.
- ÁVILA, C. J.; PANIZZI, A. R. Occurrence and damage by *Dichelops* (*Neodichelops*) *melacanthus* (Dallas) (Heteroptera: Pentatomidae) on corn. **Anais da Sociedade Entomológica do Brasil**, Piracicaba, 1995, v. 24, n. 1, p. 193-194.
- BALLESTEROS, R.; MORENO, M. A.; BARROSO, F.; GONZÁLES-GÓMEZ, L.; ORTEGA, J. F. Assessment of Maize Growth and Development with High- and Medium-Resolution Remote Sensing Products. **Agronomy**, v. 11, n. 940, p. 1-15, 2021.
- BALMER, E.; PEREIRA, O.A.P. Doenças do milho. In: PATERNIANI, E.; VIEGAS, G.P. **Melhoramento e produção de milho**. Campinas: Fundação Cargil, 1987. v. 2, p. 595-634.
- BARNES, E. M., CLARKE, T. R., RICHARDS, S. E., CLAIZZI, P. D., HABERLAND, M., KOSTRZEWSKI, P., WALLER, P., CHOI, C.; RILEY, E.; THOMPSON, T.; LASCANO, R. J.; LI, H.; MORAN, M. S. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In: **5th International Conference on Precision Agriculture**, 5., Madison, WI, 2000.

BASHIR, K. A.; SIJAM, K.; AHMAD, K. Evaluation of resistance in response to infection of southern corn leaf blight disease and determination of secondary metabolites produced during the interaction. **Journal of Applied Science & Environmental Sustainability**, n. 3, p. 1-17, 2017.

BENAISSA, S.; NAJOU, M.; JBARI, A. Deep learning and vegetation indices based approach for leaf diseases classification in RGB images. **Procedia Computer Science**, v. 236, p. 202-208, 2024.

BERGAMIM FILHO, A.; AMORIM, L.; REZENDE, J. A. M. **Manual de Fitopatologia: Princípios e conceitos**. 5 ed. São Paulo: Agronômica Ceres, 2018, Vol. 1.

BERGAMIM FILHO, A.; AMORIM, L. **Doenças de Plantas Tropicais: Epidemiologia e Controle Econômico**. 1 ed. São Paulo: Agronômica Ceres, 1996.

BERNINI, C. S.; ARRUDA, J. M.; MOURA, L. C.; BARELLI, M. A. A.; SILVA, V. P.; AZEVEDO, R. F.; SANTOS, F. A. S.; FIGUEIREDO, Z. N. Avaliação da resistência de cultivares de milho quanto à *Exserohilum turcicum* agente causal da queima de turcicum na região do sudoeste do Mato Grosso. **Agrárias: Pesquisa e Inovação nas Ciências que Alimentam o Mundo IV**, c. 2, p. 14-22, 2020.

BIANCHI, A. L. Arquiteturas de Redes Neurais Convolucionais para reconhecimento de imagens. 2020. **Viceri Tecnologia**. Disponível em: <https://www.viceri.com.br/insights/arquiteturas-de-redes-neurais-convolucionais-para-reconhecimento-de-imagens>. Acesso em 21 de Junho de 2021.

BOCK, C. H.; PARKER, P. E.; COOK, A. Z.; GOTTWALD, T. R. Characteristics of the Perception of Different Severity Measures of Citrus Canker and the Relationships Between the Various Symptom Types. **Plant Disease**, v. 92, n. 6, p. 927-939, 2020.

BOHATCHUK, B.; CASA, R. T.; BOGO, A.; KUHNEM P. R. J.; REIS, E. M.; MOREIRA, E. N. Modelo de ponto crítico para estimar danos de doenças foliares do trigo em patossistema múltiplo. **Tropical Plant Pathology**, n. 5, p. 363-369, 2008.

BOMFETI, C. A.; MEIRELLES, W. F.; SOUZAPACCOLA, E. A.; CASELA, C. R.; FERREIRA, A. S.; MARRIEL, I. E.; PACCOLA-MEIRELLES, L. D. Avaliação de produtos químicos comerciais, *in vitro* e *in vivo*, no controle da doença foliar, mancha branca do milho, causada por *Pantoea ananatis*. **Summa Phytopathologica**, Botucatu, v. 33, n. 1, p. 63-67, 2007.

BOMFETI, C. A.; SOUZA-PACCOLA, E. A.; MASSOLA JUNIOR, N. S.; MARRIEL, I. E.; MEIRELLES, W. F.; CASELA, C. R.; PACCOLA-MEIRELLES, L. D. Localization of *Pantoea ananatis* inside lesions of maize white spot disease using transmission electron microscopy and molecular techniques. **Tropical Plant Pathology**, Brasília, v. 33, n. 1, p. 63-66, 2008.

BORTH, M. R.; PADUAN, F. N.; ALVES, K. A.; MATSUMOTO, L. S.; DUARTE, E. R.; PEDRINHO, D. R.; SUGUIMOTO, H. H.; BERTOLINI, E.; ZAWADZKI, F.; SAUER, A. V. Épocas de aplicação de azoxistrobina + mancozebe no controle de mancha branca do milho. **Research, Society and Development**, v. 10, n. 2, p. 1-13, 2021.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes Neurais**

**Artificiais: Teoria e Aplicações.** 2. ed. Rio de Janeiro: LTC, 2011.

BRITO, A. H.; PINHO, R. G. V.; POZZA, E. A.; PEREIRA, J. L. A. R.; MARIA FILHO, E. M. Efeito da cercosporiose no rendimento de híbridos comerciais de milho. **Fitopatologia Brasileira**, v. 32, n. 6, p. 1-8, 2007.

BRITO, A. H.; PINHO, R. G. V.; SOUZA FILHO, A. X.; ALTOÉ, T. F. Avaliação da severidade da Cercosporiose e rendimento de grãos em híbridos comerciais de milho. **Revista Brasileira de Milho e Sorgo**, v. 7, p. 19-31, 2008.

BRITO, A. H.; PINHO, R. G. V.; PEREIRA, J. L. A. R.; BALESTRE, M. Controle químico da Cercosporiose, Mancha-Branca e dos Grãos Ardidos em milho. **Revista Ceres Viçosa**, v. 60, n. 5, p. 629-635, 2013.

BRUNO, A.; MORONI, D.; DAINELLI, R.; ROCCHI, L.; MORELLI, S.; FERRARI, E.; TOSCANO, P.; MARTINELLI, M. Improving plant disease classification by adaptive minimal ensembling. 2022. **Frontiers in Artificial Intelligence**. Disponível em: <https://www.frontiersin.org/journals/artificial-intelligence/articles/10.3389/frai.2022.868926/full>. Acesso em 26 de março de 2025.

CALVERT, O. H.; MARCUS, S. Z. Ear-rotting potential of *Helminthosporium maydis* Race T in corn. *Phytopathology*, n. 63, p. 769-72, 2012.

CAMARA, J. N.; KOEFENDER, J.; GOLLE, D. P.; FLORES, E. F.; BORTOLOTTO, R. P.; SCHOFFEL, A.; DEUNER, C. C. Aplicação Preventiva e curativa de fungicidas para controle da mancha de turcicum em milho. **Holos**, Ano 35, v. 2, p. 1-10, 2019.

CANTERI, M. G.; DALLA PRIA M.; AMORIM L.; BERGAMIN FILHO, A. Uso de radiômetro de múltiplo espectro na avaliação de fungicidas para controle de ferrugem do feijoeiro. In: CONGRESSO BRASILEIRO DE FITOPATOLOGIA, 29, 1996, Campo Grande. **Resumos**. Brasília: Sociedade Brasileira de Fitopatologia, 1996. p. 350.

CANTERI, M. G. **Uso de medidas da área foliar sadia e reflectância no manejo da mancha angular do feijoeiro**. 1998. 81 p. Tese. (Doutorado em Agronomia – Escola Superior de Agricultura “Luiz de Queiroz”, da Universidade de São Paulo, SP.

CANTERI, M. G.; ALTHAUS, R. A.; VIRGENS FILHO, J. S., GIGLIOTI, E. A., GODOY, C. V. SASM – AGRI. Sistema para análise e separação de medias em experimentos agrícolas pelos métodos Scott Knott, Tukey e Duncan. **Revista Brasileira de Agrocomputação**, v. 1, n. 2, p. 18-24. 2001.

CAPUCHO, A. S et al. Desenvolvimento de Metodologia para Avaliação da Mancha Branca do Milho. Ministério da Agricultura, Pecuária e Abastecimento, Sete Lagoas, 2010. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/876549/1/bol26.pdf>. Acesso em: 17 de Outubro de 2023

CARMONA, M. A.; VIOTTI, G.; SAUTUA, F. Tizón del maíz: cuantificación de daño y propuesta de umbral. **Actas 3º Congreso argentino de fitopatología**, p. 260, 2014.

CARSON, M. L. Yield loss potential of *Phaeosphaeria* leaf spot of maize caused by

*Phaeosphaeria maydis* in the United States. **Plant Disease**, v. 89, n. 9, p. 986-988, 2005.

CARSON, M. L. Response of a maize synthetic to selection for components of partial resistance to *Exserohilum turcicum*. **Plant Disease**, v. 90, p. 910-914, 2006.

CARVALHO, R. S. **ÍNDICES DE VEGETAÇÃO E PRODUTIVIDADE DE CULTIVARES DE TRIGO SUBMETIDAS À DIFERENTES ÉPOCAS DE SEMEADURA**. Trabalho de Conclusão de Curso (Agronomia) – Universidade Estadual do Rio Grande do Sul, p. 1-51, 2021.

CASELA, C.R.; FERREIRA, A.S.; PINTO, N.F.J.A. Doenças na cultura do milho. **Circular Técnica Embrapa**, n. 83, p. 1-6, 2006.

CAVIGLIONE, J. H.; CARAMORI, P. H.; KIIHL, L. R. B; OLIVEIRA, D. **Cartas Climáticas do Paraná**. Londrina: IAPAR, 1 CD-ROM, 2000.

CHEN, S.; ZHANG, K.; WU, S.; TANG, Z.; ZHAO, Y.; SUN, Y.; SHI, Z. A Weakly Supervised Approach for Disease Segmentation of Maize Northern Leaf Blight from UAV Images. **Drones**, v. 7, n. 173, p. 1-20, 2023.

CHOCOROSQUI, V. R.; PANIZZI, A. R. Impact of cultivation systems on *Dichelops melacanthus* (Dallas) (Heteroptera: Pentatomidae) population and damage and its chemical control on wheat. **Neotropical Entomology**, Londrina, v. 33, n. 4, p. 487-492, 2004.

CONAB. Grãos - Safra 2022/23 12º Levantamento. **Acompanhamento da safra brasileira**. v.10, n. 12, p. 1-110, 2023.

CONAB. Grãos - Safra 2024/25 3º Levantamento. **Acompanhamento da safra brasileira**. v.12, n. 3, p. 1-105, 2024.

CONCEPCION, R.; DADIOS, E.; ALEJANDRINO, J.; MENDIGORIA, C. H.; AQUINO, H.; ALAJAS, O. J. Diseased Surface Assessment of Maize Cercospora Leaf Spot Using Hybrid Gaussian Quantum-Behaved Particle Swarm and Recurrent Neural Network. **IEEE International IOT - Electronics and Mechatronics Conference**, p. 1-6, 2021.

COPPIN, B. **Inteligência Artificial**. Rio de Janeiro: LTC, 2013.

COSTA, R. V.; COTA, L. V. Controle químico de doenças na cultura do milho: aspectos a serem considerados na tomada de decisão sobre aplicação. **Circular Técnica Embrapa**, n. 125, p. 1-11, 2009.

COSTA, R. V.; COTA, L. V.; SILVA, D. D.; LANZA, F. E. Recomendações para o controle químico da mancha branca do milho. **Circular Técnica Embrapa**, n. 167, p. 1-6, 2011.

COSTA, R. V.; COTA, L. V.; SILVA, D. D.; MEIRELLES, W. F.; LANZA, F. E. Viabilidade técnica e econômica da aplicação de estrobilurinas em milho. **Tropical Plant Pathology**, v. 37, n. 4, p. 346-354, 2012a.

COSTA, R. V.; COTA, L. V.; SILVA, D. D.; LANZA, F. E.; FIGUEIREDO, J. E. F. Eficiência de fungicidas para o controle de mancha branca do milho. **Revista Brasileira de Milho e Sorgo**, v. 11, n. 3, p. 291-301, 2012b.

COSTA, R. V.; SILVA, D. D.; COTA, L. V. Mancha-de-bipolaris-do milho. Sete Lagoas: Embrapa Milho e Sorgo, 2014. (Embrapa Milho e Sorgo. Circular Técnica, 207).

COSTA, R. V.; COTA, L. V.; SILVA, D. D.; CAMPOS, L. J. M.; ALMEIDA, R. E. M.; BERNARDES, F. P.; PEREIRA, L. A. O. A. Reação de Híbridos Comerciais de Milho à Mancha-de-bipolaris em Diferentes Épocas de Semeadura. Sete Lagoas: Embrapa Milho e Sorgo, 2018. (Embrapa Milho e Sorgo. Circular Técnica, 238).

COSWOSK, G. G.; GONÇALVES, V. M. L.; DE LIMA, V. J.; DE SOUZA, G. A. R.; AMARAL JUNIOR, A. T.; PEREIRA, M. G.; OLIVEIRA, E. C.; LEITE, J. T.; KAMPHORST, S. H.; OLIVEIRA, U. A.; CREVELARI, J. A.; SANTOS, K. D.; MARQUES, F. C. R. Utilizing Visible Band Vegetation Indices from Unmanned. **Remote Sensing**, v. 16, n. 3015, p. 1-28, 2024.

Aerial Vehicle Images for Maize Phenotyping

COTA, L. V. SILVA, D. D., COSTA, R. V. Helminthosporiose causada por *Exserohilum turcicum* na cultura do milho. **Circular Técnica Embrapa**, n. 195, p. 1-8, 2013.

COTA, L. V.; CAPUCHO, A. S.; ZAMBOLIM, L.; DUARTE, H. S. S.; PARREIRA, D. F.; FERREIRA, P. A.; LANZA, F. E.; COSTA, R. V.; CASELA, C. R.; SILVA, D. D. Desenvolvimento de metodologia para avaliação da mancha branca do milho. **Boletim de Pesquisa e Desenvolvimento Embrapa**, n. 26, p. 7-26, 2010.

CRUZ, J. C.; PEREIRA, I. A. Milho: como escolher a cultivar certa entre tantas alternativas. **DBO Agrotecnologia**, p. 12-17, 2009.

CUSTODIO, A. A. P.; UTIAMADA, C. M.; MADALOSSO, T.; YADA, I. F. U. Eficiência de fungicidas no controle da mancha branca do milho – Segunda safra 2018 e 2019. **Boletim Técnico - IAPAR**, n. 94, p. 11-34, 2019.

CUSTODIO, A. A. P.; UTIAMADA, C. M.; MADALOSSO, T.; CAMPOS, H. D.; SILVA, D. D.; COSTA, R. V.; YADA, I. F. U. Eficiência de fungicidas no controle múltiplo de doenças foliares do milho: segunda safra 2020. **Boletim Técnico - IAPAR**, n. 97, p. 1-46, 2020.

DE CASTRO SILVA, F. C. C.; DE CASTRO, M. C. F. **Redes Neurais Artificiais**. Porto Alegre, RS: Pontifícia Universidade Católica do Rio Grande do Sul, 2001.

DE ROSSI, R. L.; GUERRA, F. A.; PLAZAS, M. C.; VULETIC, E. E.; BRÜCHER, E.; GUERRA, G. D.; REIS, E. M. Crop damage, economic losses, and the economic damage threshold for northern corn leaf blight. **Crop Protection**, n. 154, p. 1-10, 2022.

DHAU, I.; ADAM, E.; MUTANGA, O.; AYISI, K.; ABDEL-RAHMAN, M.; OBINDI, J.; MASOCHA, M. Testing the capability of spectral resolution of the new multispectral sensors on detecting the severity of grey leaf spot disease in maize crop. **Geocarto**

**International**, p. 1-30, 2017.

DIDVANIA, S.; SHAH, R.; JOHN, K. S. A. New disease of bell pepper (*Capsicum annuum* var. *grossum*) caused by *Drechslera bicolor*, its pathophysiology, efficacy of fungicides and botanicals. **Plant Pathology Journal**, n. 11, p. 68-72, 2012.

DSA. Deep learning Book. 2021. **Data Science Academy**. Disponível em: <<http://deeplearningbook.com.br/capitulos/>>. Acesso em: 27 de Junho de 2021.

EMBRAPA. Estádios de desenvolvimento do milho. 2005. **Agência Embrapa de Informação Tecnológica**. Disponível em: <<https://www.embrapa.br/en/busca-de-publicacoes/-/publicacao/489400/estadios-de-desenvolvimento-do-milho>>. Acesso em 17 de Outubro de 2023.

EMBRAPA. Ferrugem da folha - Documentos Online Nº 64. 2006. **Agência Embrapa de Informação Tecnológica**. Disponível em: <[http://www.cnpt.embrapa.br/biblio/do/p\\_do64\\_2.htm](http://www.cnpt.embrapa.br/biblio/do/p_do64_2.htm)>. Acesso em: 01 de agosto de 2023.

EMBRAPA. Sistema Brasileiro de Classificação de Solos. 5. ed., rev. e ampl. – Brasília, DF: **Embrapa**, 2018.

EMBRAPA. Arvore do conhecimento Milho – Adubação Mineral. 2021. **Agência Embrapa de Informação Tecnológica**. Disponível em: <[https://www.agencia.cnptia.embrapa.br/gestor/milho/arvore/CONTAG01\\_47\\_168200511159.html](https://www.agencia.cnptia.embrapa.br/gestor/milho/arvore/CONTAG01_47_168200511159.html)> Acesso em 21 de Junho de 2021.

EMBRAPA. Controle das doenças de órgãos aéreos. Sistemas de Produção de Trigo. 2023. **Agência Embrapa de Informação Tecnológica**. Disponível em: <<http://www.cnpt.embrapa.br/publicacoes/sist-prod/trigo-sul02/trigo7-3.htm>>. Acesso em: 02 de setembro de 2023.

ELENA, K.; ALIVIZATOS, A. S.; VARVERI, C. New plant pathogens reported in Greece, 1990-2007. **Hellenic Protection Journal**, v. 01, n. 01, p. 1-25, 2008.

ELLIOT, C. H.; JENKINS, M. T. *Helminthosporium turcicum* leaf blight of corn. **Phytopathology**, v. 36, p. 660-666, 1946.

ESKERS, P. D.; SHAH, D. A.; BRADLEY, C. A.; CONLEY, S. P.; PAUL, P. A.; ROBERTSON, A. E. Perceptions of Midwestern Crop Advisors and Growers on foliar Fungicide Adoption and Use in Maize. **Disease Control and Pest Management**, n. 108, p. 1078-1088, 2018.

ESTEVES, M. C. F. **Reações a *Exserohilum turcicum* (Pass.) Leonard & Suggs em milho (*Zea mays* L.) e variabilidade do patógeno**. Dissertação (Mestrado em Fitopatologia) – Escola Superior de Agricultura “Luiz de Queiróz”, Universidade de São Paulo, p. 1-64, 1989.

FANCELLI, A. L.; DOURATO NETO, D. Produção de milho. **Guaíba: Agropecuária**, 2000. 360p.

FANTIN, G. M.; COLLETTI, M. P. B.; COUTINHO, A. S. V. A. Desenvolvimento de

lesões da mancha de *Phaeosphaeria maydis* em cultivares de milho em casa de vegetação. In: CONGRESSO PAULISTA DE FITOPATOLOGIA, 25, 2002. **Summa Phytopathologica**. Botucatu-SP: Grupo Paulista de Fitopatologia, 2002, v. 28, p. 75.

FANTIN, G. M., DUDIENAS, C.; CASTRO, J. L.; SAWAZAKI, E.; DUARTE, A. P. Avaliação da severidade das manchas de *Phaeosphaeria* e de *Cercospora* do milho em cultivo de safrinha. **Revista de Agricultura**, v. 79, n. 1, p. 135-154, 2004.

FANTIN, G. M.; DUARTE, A. P.; DUDIENAS, C.; GALLO, P. B.; RAMOS JUNIOR, E. U.; CRUZ, F. A.; RAMOS, V. J.; FREITAS, R. S.; DENUCCI, S.; TICELLI, M. Efeito da mancha de cercospora na produtividade do milho safrinha, no estado de São Paulo. **Revista Brasileira de Milho e Sorgo**, v. 7, n. 3, p. 231-250, 2008.

FANTIN, G.M.; DUARTE, A. Manejo de doenças na cultura do milho safrinha. **Campinas: Instituto Agrônomo**, SP. 2009. 99p.

FANTIN, G.M.; DUARTE, A.P.; DUDIENAS, C. Quantificação de danos causados por diferentes níveis de severidade de doenças foliares à produtividade do milho. In: CONGRESSO NACIONAL DE MILHO E SORGO, 28, Goiânia, 2010. Trabalhos e palestras. Goiânia: ABMS, 2010. 8p.

FERNANDES, F. T.; OLIVEIRA, E. **Principais doenças da cultura do milho**. Sete Lagoas: Embrapa/ CNPMS, 1997. 80p. (Circular Técnica, 26).

FERNANDES, F.T.; OLIVEIRA, E. **Principais doenças na cultura do milho**. Sete Lagoas: EMBRAPA/CNPMS, 2000. 80p

FERNANDES, J. M. C; PICININI, E. C. Controlando as doenças de trigo na hora certa. Passo Fundo: Embrapa Trigo, 1999. 3p.html. (Embrapa Trigo. Comunicado Técnico Online, 22). Disponível: [http://www.cnpt.embrapa.br/biblio/p\\_co22.htm](http://www.cnpt.embrapa.br/biblio/p_co22.htm). Acesso em: 16 de Junho de 2021.

FITOSSANIDADE TROPICAL. Controle analisado. 2024. **Revista Cultivar**. Disponível em: <https://www.fitossanidadetropical.org.br/images/rft/novidades/2024/controle-analisado.pdf>. Acesso em 18 de novembro de 2024.

FIGUEIREDO, J. E. F.; COSTA, G. M. C.; PACCOLA-MEIRELLES, L. D.; RAMOS, T. C. D. A.; LANZA, F. E.; CORREA, C. L. Diagnóstico molecular de *Pantoea ananatis*. In: CONGRESSO NACIONAL DE MILHO E SORGO, 29., 2012, Águas de Lindóia. **Anais...** Sete Lagoas: Embrapa Milho e Sorgo, 2012. p.75-81. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/65559/1/Diagnostico-molecular.pdf>. Acesso em: 13 de Julho de 2021.

FLORES, M. S.; PASCHOALETE, W. M.; BAIO, F. H. R.; CAMPOS, C. N. S.; PANTALEÃO, A. A.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.; TEODORO, P. E. Relação entre índices de vegetação e desempenho agrônomo de variedades de milho sob diferentes doses de nitrogênio. **Bioscience Journal**, v. 36, n. 5, p. 1638-1644, 2020.

FUNDAÇÃO ABC. Impacto das doenças na produtividade do Milho. 2023. **Notícias Agrícolas**. Disponível em: <https://fundacaoabc.org/2023/11/30/impacto-das->

doencas-na-produtividade-do-milho. Acesso em 18 de novembro de 2024.

GARCIA, M. R. **CARACTERIZAÇÃO ESPECTRO-TEMPORAL DE CULTIVARES DE TRIGO POR MEIO DE ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA – NDVI DE SENSORES TERRESTRES**. Dissertação (Mestrado em Engenharia Agrícola, área de concentração em Engenharia de Sistemas Biológicos e Agroindustriais) – Universidade Estadual do Oeste do Paraná, p. 1-87, 2015.

GDM. GDM Information. 2025. **GDM Solutions**. Disponível em: <https://gdmdata.com/About%20Us/GDM%20Information>. Acesso em 27 de março de 2025.

GENET J. L.; JAWORSKA, G.; GEDDENS, R.; SHEPERD, C. Effect of temperature on the curative and anti-sporulant action of cymoxanil for control of *Phytophthora infestans*. In: WORKSHOP OF AN EUROPEAN NETWORK FOR DEVELOPMENT OF AN INTEGRATED CONTROL STRATEGY OF POTATO LATE BLIGHT, 5, 2000, Munich, p. 107-117.

GITELSON, A. A., KAUFMAN, Y. J., STARK, R., RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sens. Environ**, v. 80, p. 76–87, 2002.

GITELSON, A. A., VIÑA, A.; ARKEBAUER, T. J.; RUNDQUIST, D.; KEYDAN, G.; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, p. 1-4, 2003.

GONÇALVES, R. M.; FIGUEIREDO, J. E. F.; PEDRO, E. S.; MEIRELLES, W. F.; LEITE JUNIOR, R. P.; SAVER, A. V.; PACCOLA-MEIRELLES, L. D. Etiology of Phaeosphaeria leaf spot disease of maize. **Journal of Plant Pathology**, v. 95, n. 3, p. 559-569, 2013.

GUO, A.; HUANG, W.; WANG, K.; QIAN, B.; CHENG, X. Early Monitoring of Maize Northern Leaf Blight Using Vegetation Indices and Plant Traits from Multiangle Hyperspectral Data. **Agriculture**, v. 14, n. 1311, p. 1-18, 2024.

HAN, K.; WANG, Y.; TIAN, Q.; GUO, J.; XU, C.; XU, C. GhostNet: More Features from Cheap Operations. 2020. **Cornell University**. Disponível em: <https://arxiv.org/abs/1911.11907>. Acesso em 26 de março de 2025.

HASAN, U.; SAWUT, M.; CHEN, S. Estimating the leaf area index of winter wheat based on unmanned aerial vehicle RGB-Image Parameters. **Sustainability**, v. 11, n. 6829, p. 1-11, 2019.

HATFIELD, J. L.; PINTER JUNIOR, P. J. Remote sensing for crop protection. **Crop Protection**, v. 12, n. 6, p. 403-413, 1993.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Porto Alegre: Editora Bookman, 2008.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep Residual Learning for Image Recognition. 2015. **Cornell University**. Disponível em: <https://arxiv.org/abs/1512.03385>. Acesso em 26 de março de 2025.

HEBB, D. – **The Organization of Behavior**. New York: Wiley, 1949.

HENNINGS, P. V. Fungi S. Paulenses II. Puttermans collect: **Hedwigia**, Dresden, v. 41, p. 295-311, 1902.

HUANG, G.; LIU, Z.; VAN DER MAATEN, L.; WEINBERGER, K. Q. Densely Connected Convolutional Networks. 2017. **Computer Vision Foundation**. Disponível em: [https://openaccess.thecvf.com/content\\_cvpr\\_2017/papers/Huang\\_Densely\\_Connected\\_Convolutional\\_CVPR\\_2017\\_paper.pdf](https://openaccess.thecvf.com/content_cvpr_2017/papers/Huang_Densely_Connected_Convolutional_CVPR_2017_paper.pdf). Acesso em 26 de março de 2025.

IBM. O que é aprendizado por transferência. 2024. **IBM Think**. Disponível em: <https://www.ibm.com/br-pt/think/topics/transfer-learning>. Acesso em 26 de março de 2025.

JEONG, J. The Most Intuitive and Easiest Guide for Convolutional Neural Network. **Towards data science**. 2019. Disponível em: <https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>. Acesso em 21 de Junho de 2021.

JIN, X.; JIE, L.; WANG, S.; QI, H. J.; LI, S. W. Classifying wheat hyperspectral pixels of healthy heads and Fusarium head blight disease using a deep neural network in the wild field. **Remote Sensing**, v. 10, n. 395. P. 1-20, 2018.

JULIATTI, F. C.; SOUZA, R. M. EFEITO DE ÉPOCAS DE PLANTIO NA SEVERIDADE DE DOENÇAS FOLIARES E PRODUTIVIDADE DE HÍBRIDOS DE MILHO. **Bioscience Journal**, v. 21, n. 1, p. 103-112, 2005.

JULIATTI, F. C.; BELOTI, I. F.; JULIATTI, B. C. M.; CRATO, F. F. EFICÁCIA DA ASSOCIAÇÃO DE FUNGICIDAS E ANTIBIÓTICOS NO MANEJO DA MANCHA BRANCA DO MILHO E SEU EFEITO NA PRODUTIVIDADE. **Bioscience Journal**, v. 30, n. 6, p. 1622-1630, 2014.

KEYWORTH, S.; JARMAN, M.; MEDCALF, K. Assessing the extent and severity of erosion on the upland organic soils of Scotland using earth observation – A GIFTSS Implementation Test – Final report. **Environment Systems**, p. 3-85, 2009.

KHOTANZAD, A.; LU, J. H. Object Recognition Using a Neural Network and Invariant Zernike Features, Computer Vision and Pattern Recognition, Proceedings CVPR'89. **IEEE Computer Society Conference**, p. 200-205, 1989.

KIMATI, H.; AMORIM, L.; REZENDE, J. A. M.; BERGAMIN FILHO, A.; CAMARGO, L. E. A. (ed.). Manual de fitopatologia: doenças das plantas cultivadas. 4. ed. São Paulo: **Agronômica Ceres**, 2005. v.2 663 p. il. color.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. 2012. **Advances in neural information processing systems**. Disponível em: <https://papers.nips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>. Acesso em 05 de Julho de 2021.

KUTAWA, A. B.; AHMAD, K. H.; ALI, A.; HUSSEIN, M. Z.; WAHAB, M. A. A.; SIJAM,

K. State of the art on southern corn leaf blight disease incited by *Cochliobolus heterostrophus*: detection, pathogenic variability and novel control measures. **Bulg. J. Agric. Sci.**, v. 27, n. 1, p. 147–155, 2021.

LEACH, C. M.; FULLERTON, R. A.; YOUNG, K. Northern leaf blight of maize in New Zealand: relationship of *Drechslera turcica* airspora to factors influencing sporulation, conidium development, and chlamydospore formation. **Phytopathology**, v. 67, p. 629-636, 1977.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**, v. 521, n. 7553, p. 436, 2015.

LENG, W.F.; LI, G.Z.; MA, Z.H. Distribution and molecular detection of corn rust in China. **China Plant Protection**, v. 12, n. 12, p. 18-20, 2012.

LEVY, Y.; COHEN, Y. Sporulation of *Helminthosporium turcicum* on sweet corn: effects of light and sugars. **Physiological Plant Pathology**, London, v. 18, p. 17-25, 1981.

LEVY, Y. The overwintering of *Exserohilum turcicum* in Israel. **Phytoparasitica**, Bet Dagan, v. 12, p. 177-182, 1984.

LEVY, Y.; PATAKY, J. K. Epidemiology of northern leaf blight on sweet corn. **Phytoparasitica**, Bet Dagan, v. 20, p. 53-66, 1992.

LEVY, Y. Inoculum survival of *Exserohilum turcicum* on corn between and during growing periods. **Canadian Journal of Plant Pathology**, Ottawa, v. 17, p. 144-146, 1995.

LI, X.H.; ZHANG, K.Y.; LI, L.F.; ZHANG, S.M.; LUO, Y.; MA, Z.H. Correlation between *Puccinia polysora* Underw. spore number and disease index and meteorological factors. **Acta Phytopathologica Sinica**, v. 49, n. 3, p. 362-369, 2019.

LI, E.; WANG, L.; XIE, Q.; GAO, R.; SU, Z.; LI, Y. A novel deep learning method for maize disease identification based on small sample-size and complex background datasets. **Ecological Informatics**, v. 75, n. 102011, 2023.

LIN, Z.; MU, S.; HUANG, F.; MATEEN, K. A.; WANG, M.; GAO, W.; JIA, J. A unified matrix-based convolutional neural network for fine-grained image classification of wheat leaf diseases. **IEEE Access**, v. 7, p. 11570-11590, 2019.

LOLADZE, A.; RODRIGUES JR, F. A.; TOLEDO, F.; VICENTE, F. S.; GÉRARD, B.; BODDUPALLI, M. P. Application of Remote Sensing for Phenotyping Tar Spot Complex Resistance in Maize. **Frontiers in Plant Science**, v. 10, n. 552, p. 1-10, 2019.

LU, J.; HU, J.; ZHAO, G.; MEI, F.; ZHANG, C. An in-flied automatic wheat disease diagnosis system. **Computer and Electronics in Agriculture**, v. 142, p. 369-379, 2017.

MA, N.; ZHANG, X.; ZHENG, H.; SUN, J. ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design. 2018. **Cornell University**. Disponível em:

<https://arxiv.org/abs/1807.11164>. Acesso em 26 de março de 2025.

MAGALHÃES, P. C.; DURÃES, F. O. M.; CARNEIRO, N. P.; PAIVA, E. Fisiologia do Milho. **Circular técnica – Embrapa**, n. 22, p. 1-23, 2002.

MAHLEIN, A. K. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. **Plant Disease**, v. 100, n. 2, p. 241-251, 2016.

MALLOWA, S. O.; ESKER, P. D.; PAUL, P. A.; BRADLEY, C. A.; CHAPARA, V. R.; CONLEY, S. P.; ROBERTSON, A. E. Effect of maize hybrid and foliar fungicides on yield under low foliar disease severity conditions. **Phytopathology**, v. 105, p. 1080-1089, 2015.

MANERBA, F. C. **Controle químico da mancha branca do milho**. 2010. 32f. Dissertação (Mestrado em Fitopatologia) – Faculdade de Agronomia, Universidade Federal de Lavras, Lavras, 2010.

MARCHIONATTO, J. B. Directivas en la lucha contra las enfermedades de las plantas. **Revista Argentina de Agronomía**, v.16, p. 29-32, 1949.

MARGARET, T. M.; Effectively managing northern corn leaf blight. **Phytopathology**, v. 21, p. 221-234, 2013.

MARQUES, A. C. R. R.; RAIMUNDO M. M.; CAVALHEIRO, E. M. B.; SALLES, L. F. P.; LYRA, C.; VON ZUBEN, F. J. Ant genera identification using an ensemble of convolutional neural networks. PLOS ONE, 2018. **Public Library of Science (PLoS)**, v. 13, n. 1, p. e0192011, 2018.

MARTINS, M. C.; GUERZONI, R. A.; CÂMARA, G. M. S.; MATTIAZZI, P.; LOURENÇO, S. A.; AMORIM, L. Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. *Fitopatologia Brasileira*, v. 29, p. 179-184, 2004.

MASOOD, M.; NAWAZ, M.; NAZIR, T.; JAVED, A.; ALKANHEL, R.; ELMANNAI, H.; DHAHBI, S.; BOUROUIS, S. MaizeNet: A Deep Learning Approach for Effective Recognition of Maize Plant Leaf Diseases. **IEEE Access**, v. 11, p. 52862-52876, 2023.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MENG, W.; JIA, M.; LILI, F.; KEHE, F.; CHUANJIN, Y.; JINXIN, G.; YAGIAN, L.; JIE, C. Biological control of southern corn leaf blight by *Trichoderma atroviride* SG3403. **Biocontrol Science & Technology**, v. 25, n. 10, p. 1133-1146, 2015.

MENG, R.; LV, Z.; YAN, J.; CHEN, G.; ZHAO, F.; ZENG, L.; XU, B. Development of Spectral Disease Indices for Southern Corn Rust Detection and Severity Classification. **Remote Sensing**, v. 12, n. 3233, p. 1-16, 2020.

MEROTTO JR. A.; BREDEMEIER, C.; VIDAL, R. A.; GOULART, I. C. G. R.; BORTOLI, E. D.; ANDERSON, N. L. Reflectance indices as a diagnostic tool for

weed control performed by multipurpose equipment in precision agriculture. **Planta Daninha**, v. 30, n. 2, p. 437-447, 2012.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3. ed. Viçosa: Editora UFV, 2005. 320 p.

MORETA, D. E. M. **NORTHERN LEAF BLIGHT RESISTANCE IN MAIZE: BENEFITS, COSTS, AND HIGH-THROUGHPUT PHENOTYPING**. Tese (Doutorado) – Cornell University, p. 1-169, 2023.

MOTERLE, L. M.; SANTOS, R. F. Época de aplicação de fungicida na cultura do milho segunda safra. **Colloquium Agrariae**, v. 15, n. 2, p. 61-71, 2019.

MUNFORD, J. D.; NORTON, G. A. Economics of decision making in pest management. **Annual Review of Entomology**, v. 29, p. 157-174, 1984.

MUNKVOLD, G. P. Fungicides on Hybrid Corn: Yield Impact of Foliar Disease Control. **Illinois Crop Protection Technology Conference**, p. 29–33, 2007.

MUNKVOLD, G. P.; WHITE, D. G. Compendium of corn diseases. 4rd. ed. St. Paul: American Phytopathological Society, 2016.

NAN, F.; SONG, Y.; YU, X.; NIE, C.; LIU, Y.; BAI, Y.; ZOU, D.; WANG, C.; YIN, D.; YANG, W.; JIN, X. A novel method for maize leaf disease classification using the RGB-D post-segmentation image data. **Frontiers in Plant Science**, v. 1, p. 1-14, 2023.

NEUROPH. Java Neural Network Framework. **Neuroph**. Disponível em: <https://neuroph.sourceforge.net/>. Acesso em 26 de março de 2025.

NKUNA, B. L.; CHIRIMA, J. G.; NEWETE, S. W.; NYAMUGAMA, A.; VAN DER WALT, A. J. Developing models to detect maize diseases using spectral vegetation indices derived from spectral signatures. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 27, p. 597-603, 2024.

NOTÍCIAS AGRÍCOLAS. 2023. **Milho - Mercado Físico**. Disponível em: <https://www.noticiasagricolas.com.br/cotacoes/milho/milho-mercado-fisico-sindicatos-e-cooperativas/2023-10-02>. Acesso em 02 de outubro de 2023.

OKLAHOMA STATE UNIVERSITY. 2017. Using the GreenSeeker Handheld Sensor and Sensor-Based Nitrogen Rate Calculator. **Fact Sheets**. Disponível em: <https://extension.okstate.edu/fact-sheets/using-the-greenseeker-handheld-sensor-and-sensor-based-nitrogen-rate-calculator.html>. Acesso em 21 de março de 2025.

PACCOLA-MEIRELLES, L. D.; FERREIRA, A. S.; MEIRELLES, W. F.; MARRIEL, I. E.; CASELA, C. R. Detection of a bacterium associated with a leaf spot disease of maize in Brazil. **Journal of Phytopathology**, Berlin, v. 149, n. 5, p. 275-279, 2001

PARKER, J. R. **Algorithms for image processing and computer vision**. Indianapolis: Wiley Publishing, 2010. Disponível em: [http://www.manalhelal.com/Books/crol/Algorithms%20for%20Image%20Processing%20and%20Computer%20Vision\\_2011.pdf](http://www.manalhelal.com/Books/crol/Algorithms%20for%20Image%20Processing%20and%20Computer%20Vision_2011.pdf). Acesso em 16 de Junho de 2021.

PAUL, P. A.; MADDEN, L. V.; BRADLEY, C. A.; ROBERTSON, A. E.; MUNKVOLD, G. P.; SHANER, G.; WISE, K. A.; MALVICK, D. K.; ALLEN, T. W.; GRYBAUSKAS, A.; VINCELLI, P.; ESKER, P. Meta-analysis of yield response of hybrid field corn to foliar fungicides in the U.S. Corn Belt. **Phytopathology**, v. 101, n. 9, p. 1122-1132, 2011.

PEREIRA, O. A. P. Doença do milho. In: KIMATI, H.; AMORIM, L.; BERGAMIN FILHO, A.; CAMARGO, L.E.A.; REZENDE, J.A.M. (Ed.) Manual de Fitopatologia. 3. ed. São Paulo: Agronômica Ceres, 1997. v. 2, p. 538-555.

PEREIRA, O. A. P.; CARVALHO, R. V.; CAMARGO, L. E. A. Doenças do milho (*Zea mays* L.). In: KIMATI, H.; AMORIM, L.; REZENDE, J. A. M.; BERGAMIN FILHO, A.; CAMARGO, L. E. A. (Eds.). **Manual de fitopatologia: doenças das plantas cultivadas**. 4. ed. São Paulo: Ceres, 2005. v. 2, p. 477-488.

PICON, A.; SEITZ, M.; ALVAREZ-GILA, A.; MOHNKE, P.; ORTIZ-BARREDO, A.; ECHAZARRA, J. Crop conditional Convolutional Neural Networks for massive multi-crop plant disease classification over cell phone acquired images taken on real field conditions. **Computers and Electronics in Agriculture**, v. 167, n. 105093, p. 1-10, 2019.

PINETOOLS. 2023. Bulk split image online. **Images**. Disponível em: <https://pinetools.com/bulk-batch-split-image>. Acesso em 13 de Julho de 2021.

PINTO, N. F. J. A. Controle químico de doenças foliares em milho. 2004. **Revista Brasileira de Milho e Sorgo**, v. 3, n. 1, p. 134-138. Disponível em: <http://rbms.cnpms.embrapa.br/index.php/ojs/article/viewFile/96/97>. Acesso em 13 de Julho de 2021.

PIXLR. 2023. Remova o BG com o removedor de plano de fundo. **Remove BG**. Disponível em: <https://pixlr.com/br/remove-background>. Acesso em 9 de janeiro de 2023.

PU, Y.; APEL, D. B.; SZMIGIEL, A.; CHEN, J. Image Recognition of Coal and Coal Gangue Using a Convolutional Neural Network and Transfer Learning. **Energies**, v. 12, n. 1735, p. 2-11, 2019.

RANE, M. S.; PAYAK, M. M.; RENFRO, B. L. A. Phaeosphaeria leaf spot of maize. **Indian Phytopathology Society Bulletin**, v. 03, p. 6-10, 1965.

REIS, E.M., CASA, R.T.; MEDEIROS, C.A. Diagnose, patometria e controle de doenças de cereais de inverno. Londrina. ES Comunicação S/C Ltda. 2001. 94p.

REIS, E. M.; CASA, R. T.; BRESOLIN, A. C. R. **Manual de diagnose e controle de doenças do milho**. 2 ed. Lages, SC: Graphel. 2004.

REIS, E. M.; SANTOS, J. A. P.; BLUM, M. M. C. Critical-Point yield model to estimate yield damage caused by *Cercospora zea-maydis* in corn. **Fitopatol. Bras**, v. 32, n. 2, p. 110-113, 2007.

REZNICK, J. P. K. **PRODUTIVIDADE, QUALIDADE INDUSTRIAL E NUTRICIONAL NA CULTURA DO TRIGO**. Dissertação (Mestrado em Ciência do Solo) –

Universidade Federal do Paraná, p. 1-64, 2017.

RISSINI, A. L. L.; KAWAKAMI, J.; GENÚ, A. M. Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, v. 39, p. 1703-1713, 2015.

ROBINSON, K.; KALEBICH, C.; FELLOWS G. M.; CARDOSO, F. C. Effects of foliar fungicide application on the growing corn plant. **Journal of Animal Science**, n. 94, p. 198-198, 2016.

ROLIM, G. S.; JÚNIOR, M. J. P.; FANTIN, G. M.; BRUNINI, O.; DUARTE, A. P.; DUDIENAS, C. Modelo agrometeorológico regional para a estimativa da severidade da mancha de *Phaeosphaeria* em milho safrinha no estado de São Paulo, Brasil. **Bragantia**, Campinas, v. 66, n. 4, p.721-728, 2007.

ROSA, W. B.; DUARTE JÚNIOR, J. B.; QUEIROZ, S. B.; PEREGO, I.; MATTEI, E. Desempenho agrônômico de cinco híbridos de milho submetidos à aplicação de fungicida em diferentes estádios fenológicos. **Revista Engenharia na Agricultura**, v. 25, n. 05, p. 428-435, 2017.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and retrieval in the brain. **Psychological Review**, v. 65, p. 386-408, 1958.

ROUSE, W.; HAAS, R. H.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERT. Third Earth Resources Technology Satellite-1 Symposium-Volume I: **Technical Presentations**. NASA SP-351, published by NASA, Washington, D.C., 1974, p.309.

ROZA-GOMES, M. F. et al. Injúrias de quatro espécies de percevejos pentatomídeos em plântulas de milho. **Ciência Rural**, Santa Maria, v. 41, n. 7, p. 1-5, 2011.

SAEED, F.; KHAN, M. A.; SHARIF, M.; MITTAL, M.; GOYAL, L. M.; ROY, S. Deep neural network features fusion and selection based on PLS regression with an application for crops diseases classification. **Applied Soft Computing**, v. 103, n. 107164, p. 1-11, 2021.

SANTANA, D. C.; FLORES, M. S.; COTRIM, M. F.; RODRIGUES, E. V.; SANTOS, A.; TEODORO, L. P. R.; BAIO, F. H. R.; SILVA JUNIOR, C. A.; TEODORO, P. E. Genotype x trait and canonical correlations for spectral and agronomic traits in corn. **Agronomy Journal**, v. 113, p. 1197-1204, 2021.

SASSE, S. **CARACTERIZAÇÃO DE VARIEDADES LOCAIS DE MILHO PROCEDENTES DE ANCHIETA – SC QUANTO À RESISTÊNCIA A EXSEROHILUM TURCICUM**. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, p. 1-88, 2008.

SAWAZAKI, E.; DUDIENAS, C.; PATERNIANI, M. E. A. G. Z.; GALVÃO, J. C. C.; CASTRO, J. L.; PEREIRA, J. Reação de cultivares de milho à mancha de *Phaeosphaeria* no estado de São Paulo. **Pesquisa Agropecuária Brasileira**, Brasília, v. 32, n. 6, p. 585-589, 1997.

SHANER, G.; FINNEY, R. F. The effects of nitrogen fertilization on the expression of show-midwing in knox wheat. **Phytopathology**, v. 67, p. 1051-1055, 1987.

SHERWOOD, R.T.; BERG, C.C.; HOOVER, M.R. & ZEIDERS, K.E. Illusions in visual assessments of Stagonospora leaf spot of orchardgrass. **Phytopathology**; 73: 173-177. 1983.

SIBANDA, M.; MUTANGA, O.; DUBE, T.; OBINDI, J.; MAFONGOYA, P. L. Usability, strength and practicality of the upcoming hyperspectral in detecting maize gray leafy spot in relation to sentinel-2 msi, venus and landsat 8 oli spectral band-settings. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, p. 1015-1022, 2019.

SIBIYA, M.; SUMBWANYAMBE, M. A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks. **AgriEngineering**, v. 1, p. 119-131, 2019.

SILVA, M. J.; SCHMIGUEL, J. IDENTIFICAÇÃO DE DOENÇAS EM PLANTAS POR MEIO DE PROCESSAMENTO DE IMAGENS: Redes Neurais Convolucionais como Auxílio à Agricultura. **Revista Ubiquidade**, v. 3, n. 1, p. 91-111, 2020.

SIMONYAN, K.; ZISSERMAN, A. VERY DEEP CONVOLUTIONAL NETWORKS

FOR LARGE-SCALE IMAGE RECOGNITION. 2015. **University of Oxford**. Disponível em: <https://www.robots.ox.ac.uk/~vgg/publications/2015/Simonyan15/simonyan15.pdf>. Acesso em 26 de março de 2025.

SIQUEIRA, H. V. **Previsão de series de vazões com redes neurais artificiais e modelos lineares ajustados por algoritmos bio-inspirados**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas, p. 1-156, 2009.

SILVA, A. G.; FRANCISCHINI, R.; TEIXEIRA, I. R.; GOULART, M. M. P. Aplicação de fungicida em híbridos de milho na safra de verão na região Central do Brasil. **Magistra**, v. 28, n. 3/4, p. 379-389, 2016.

SMITH, D. Corn Diseases 2015 and Should I Spray Fungicide? **University of Wisconsin Extension**. Disponível em: <http://fyi.uwex.edu/fieldcroppathology/2015/07/13/corn-diseases-of-2015-and-should-i-spray/>. Acesso em 18 de novembro de 2024.

SOUZA, E. G.; ROCHA, T.; OPAZO-URIBE, M. A.; NOBREGA, L. H. P. Índices de vegetação no milho em função da hora do dia e da taxa de nitrogênio aplicada. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, (Suplemento), p.865–872, 2009.

SOUZA, L. T.; PEREIRA, J. L. A. R.; SOUZA, T. T. Avaliação da produtividade de milho e controle de doenças foliares. **Revista Agrogeoambiental**, Pouso Alegre, v. 7, n. 3, p. 31-37, 2015.

SPURLOCK, T.N.; STARK, C.R.; BAILEY, J.D.; TOLBERT, A.C.; HOYLE, R.C.

Detection, spread and economic impact of southern rust in Arkansas corn fields using remote sensing and spatial analysis technologies. In: Ford V, Kelley J, McKinney N, editors. **Corn and grain sorghum research studies**. Arkansas: University of Arkansas System; 2020. p. 22–33.

SREENIVAS, A.; MAHESHWARI, M.; JAIN, S.; CHOUDHARY, S.; VADIVU, G. Indian Sign Language Communicator Using Convolutional Neural Network. **International Journal of Advanced Science and Technology**, v. 29, n. 3, p. 11015-11031, 2020.

STERN, V. M.; SMITH, R. F.; BOSCH, V. D.; HAGEN, K. S. The integrated control concept. **Hilgardia**, v. 28, p. 81-101, 1959.

STRANGE, R. N.; SCOTT, P. R. Plant disease: A threat to global food security. *Annual Review of Phytopathology*. **Annual Reviews**, v. 43, n. 1, p. 83–116, 2005.

SUN, J.; YANG, Y.; HE, X.; WU, X. Northern Maize Leaf Blight Detection Under Complex Field Environment Based on Deep Learning. **IEEE Access**, v. 8, p. 33679-33688, 2020.

SYARIEF, M.; SETIAWAN, W. Convolutional neural network for maize leaf disease image classification. **TELKOMNIKA Telecommunication, Computing, Electronics and Control**, V. 18, N. 3, P. 1376-1381, 2020.

SYNGENTA. Rentabilidade com tecnologia e genética. 2024. **Sementes de milho**. Disponível em: <https://portal.syngenta.com.br/sementes/nk-milho/formula>. Acesso em 18 de novembro de 2024.

SZEGEDY, C.; LIU, W.; JIA.; SERMANET. P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions. 2017. **Cornell University**. Disponível em: <https://arxiv.org/abs/1409.4842>. Acesso em 26 de março de 2025.

TEDFORD, E. C.; KRISS, A. B.; GEATER, C.; SAINI, M.; BATTLES, B.; SMELSER, R. B.; FITHIAN, W. A. Plot size can influence yield benefits from fungicides on corn. **Crop Protection**, n. 91, p. 66-73, 2017.

TESTA, G.; REYNERI, A.; BLANDINO, M. Foliar Fungicide Application to Maize: Yield and Grain Hardness Enhancement in Different Environmental Conditions. **Crop Science**, v. 55, p. 1782-1790, 2015.

TETTEROO, Jonathan. **Exploring Convolutional Neural Networks on the p-VEX architecture**. 2018. Thesis (Master of Science in Computer Engineering) – Delft University of Technology, The Netherlands, 2018.

TURGEON, B. G.; BAKER, S. E. Genetic and genomic dissection of the *Cochliobolus heterostrophus* Tox1 locus controlling biosynthesis of the polyketide virulence factor T-toxin. **Advances in Genetics**, v 57, p. 219-261, 2007.

TURRA, M. A. **MANEJO DO NITROGÊNIO EM CULTIVARES DE TRIGO BASEADO NO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI)**. Dissertação (Mestrado em Fitotecnia Ênfase Fisiologia e Manejo Vegetal) –

Universidade Federal do Rio Grande do Sul, p. 1-91, 2016.

UEBEL, J. D. **Avaliação de fungicidas no controle de doenças foliares, grãos ardidos e efeito no NDVI (Índice de Vegetação por Diferença Normalizada) em híbridos de milho.** 119 f. Dissertação de Mestrado – Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, Brasília, 2015. Disponível em: <[http://www.repositorio.unb.br/bitstream/10482/19019/1/2015\\_JulianoDanielUebel.pdf](http://www.repositorio.unb.br/bitstream/10482/19019/1/2015_JulianoDanielUebel.pdf)>. Acesso em 14 de Julho de 2021.

USDA. Grain: World Market and Trade. 2024. **Global Market Analysis.** Disponível em: <https://www.fas.usda.gov/data/production/commodity/0440000>. Acesso em 08 de março de 2025.

VALE, F.X.R. et al. **Epidemiologia aplicada ao manejo de doenças de plantas.** Belo Horizonte: Perfil, 2004. 531 p.

VARGAS, A. C. G; PAES, A. V. C. N.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: **Proceedings of the XXIX Conference on Graphics, Patterns and Images.** 2016. p. 1-4.

VETTORAZZI, C. A. **Sensoriamento remoto orbital.** Piracicaba: ESALQ, Série didática do Departamento de Engenharia Rural, 1992. 129p.

VIAN, A. L.; BREDEMEIER, C.; DA SILVA, P. R. F.; SANTI, A. L; GIORDANO, C. P. S.; SANTOS, F. L. Limites críticos de NDVI para estimativa do potencial produtivo do milho. **Revista Brasileira de Milho e Sorgo**, v. 17, n. 1, p. 91-100, 2018.

VIEIRA, R. A.; MESQUINI, R. M.; HATA, C. N.; TESSMANN, D. J.; SCAPIN, C. A. A new diagrammatic scale for the assessment of northern corn leaf blight. **Cropprotv.** v.56, p. 55-57, 2013.

VIÑA, A.; GITELSON, A. A.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B.; SCHEPERS, J. Monitoring Maize (*Zea mays* L.) Phenology with Remote Sensing. **Agronomy Journal**, v. 96, p. 1139-1147, 2004.

VON ZUBEN, F. J; DE CASTRO, L.N. RNAs, Classificação de Padrões e Motivação Geométrica, Notas de aula da disciplina Redes Neurais, **School of Electrical and Computer Engineering.** Campinas-SP, UNICAMP, 2003.

XIA, Z. Overfitting of CNN model in cifar-10: Problem and solutions. 2023. **New York University Shanghai.** Disponível: [https://www.researchgate.net/publication/378435489\\_Overfitting\\_of\\_CNN\\_model\\_in\\_cifar-10\\_Problem\\_and\\_solutions](https://www.researchgate.net/publication/378435489_Overfitting_of_CNN_model_in_cifar-10_Problem_and_solutions). Acesso em 26 de março de 2025.

WAHEED, A.; GOYAL, M.; GUPTA, D.; KHANNA, A.; HASSANIEN, E. An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. **Computers and Electronics in Agriculture**, v. 175, n. 105456, p. 1-11, 2020.

WARD, J. M. J. LAING, M. D.; RIJKENBERG, F. H. J. Frequency and Timing of

Fungicide Applications for the Control of Gray Leaf Spot in Maize. **Plant Disease**, v. 81, n. 1, p. 41-48, 1997.

WEST, J.S.; BRAVO, C.; OBERTI, R.; LEMAIRE, D.; MOSHOU, D.; MCCARTNEY, H.A. The potential of optical canopy measurements for targeted control of field crop diseases. **Annual Review Phytopathology**, v. 41, p. 593–614, 2003.

WHETZEL, H. H. The terminology of phytopathology. Proceedings the International **Congress of Plant Sciences**, v. 2, p. 1204-1215, 1929.

WHITE, D. G. **Compendium of corn diseases**. 3th ed. St. Paul: American Phytopathological Society, 2000. 78 p.

WISE, K.; SMITH, D.; FREIJE, A.; MUELLER, D. S.; KANDEL, Y.; ALLEN, T.; BRADLEY, C. A.; BYAMUKAMA, E.; CHILVERS, M.; FASKE, T.; FRISKOP, A.; HOLLIER, C.; JACKSON-ZIEMS, T. A.; KELLY, H.; KEMERAIT, B.; PRICE, P.; ROBERTSON, A.; TENUTA, A. Meta-analysis of yield response of foliar fungicide-treated hybrid corn in the United States and Ontario, Canada. **Plos One**, p. 1-15, 2019.

ZADOKS, J. C.; CHANG, T. T.; KONZAK, C. D. A decimal code for the growth stages of cereals. **Weed research**, v. 14, p.415-421, 1974.

ZENG, W.; LI, H.; HU, G.; LIANG, D. Lightweight dense-scale network (LDSNet) for corn leaf disease identification. **Computers and Electronics in Agriculture**, v. 197, n. 106943, 2022.

## APÊNDICES

**Apêndice A** – Avaliações de severidade de mancha de bipolaris causada por *Bipolaris maydis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 8780. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Bipolaris*		
	V9 <sup>a</sup>	V10 <sup>a</sup>	R1 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022
1-Testemunha	10,5 a	20,75 a	31,25 a
2-V6/ V10/ R2/ R2+14	2,5 b	2,75 e	3,0 e
3-V6/ V10/ R2	3,5 b	3,5 e	4,0 e
4-V6/ V10	2,0 b	2,5 e	2,75 e
5-V6	3,0 b	5,5 d	8,5 d
6-V10/ R2/ R2+14	9,0 a	10,0 c	11,5 c
7- R2/ R2+14	8,0 a	18,25 b	31,0 a
8-R2+14	8,5 a	17,25 b	28,0 b
C.V. (%)	31,63	13,69	10

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V9, nove folhas desenroladas; V10, dez folhas desenroladas; VT, pendoamento; R1, florescimento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice B** – Avaliações de severidade de mancha de bipolaris causada por *Bipolaris maydis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Bipolaris*			
	V11 <sup>a</sup>	VT <sup>a</sup>	R2 <sup>a</sup>	R3 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022	28/04/2022
1-Testemunha	29,25 a	33,5 a	37,50 a	38,75 a
2-V6/ V10/ R2/ R2+14	5,00 b	5,25 b	5,75 b	5,75 c
3-V6/ V10/ R2	4,75 b	5,00 b	5,75 b	6,25 c
4-V6/ V10	5,25 b	5,25 b	5,25 b	5,25 c
5-V6	4,50 b	6,25 b	7,75 b	8,00 c
6-V10/ R2/ R2+14	27,25 a	31,00 a	33,75 a	34,75 b
7- R2/ R2+14	26,25 a	32,25 a	36,25 a	37,00 a
8-R2+14	26,00 a	32,25 a	35,25 a	37,00 a
C.V. (%)	14,8	6,17	10,22	7,33

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; VT, pendoamento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R3, grão leitoso.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice C** – Avaliações de severidade de mancha de bipolaris causada por *Bipolaris maydis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Bipolaris*			
	V10 <sup>a</sup>	V12 <sup>a</sup>	R2 <sup>a</sup>	R2 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022	28/04/2022
1-Testemunha	13,00 a	15,25 a	20,25 a	22,75 a
2-V6/ V10/ R2/ R2+14	1,75 b	2,00 c	2,25 c	2,25 c
3-V6/ V10/ R2	3,50 b	3,50 c	3,75 c	4,00 c
4-V6/ V10	2,75 b	3,25 c	3,25 c	3,50 c
5-V6	3,25 b	4,50 c	5,00 c	5,75 c
6-V10/ R2/ R2+14	10,50 a	12,00 b	14,25 b	15,00 b
7- R2/ R2+14	13,00 a	16,00 a	19,25 a	21,50 a
8-R2+14	11,50 a	16,00 a	20,00 a	20,50 a
C.V. (%)	28,63	17,55	15,78	14,1

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; V12, doze folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

**Apêndice D** – Avaliações de severidade de mancha de bipolaris causada por *Bipolaris maydis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Bipolaris*		
	V9 <sup>a</sup>	V10 <sup>a</sup>	R1 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022
1-Testemunha	9,50 a	14,5 a	23,25 a
2-V6/ V10/ R2/ R2+14	2,00 b	2,25 c	2,50 c
3-V6/ V10/ R2	2,25 b	2,25 c	2,50 c
4-V6/ V10	1,25 b	2,00 c	2,00 c
5-V6	1,75 b	2,25 c	2,50 c
6-V10/ R2/ R2+14	10,25 a	12,25 b	15,75 b
7- R2/ R2+14	8,25 a	15,50 a	23,25 a
8-R2+14	10,25 a	15,25 a	21,50 a
C.V. (%)	33,09	21,51	18,64

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V9, nove folhas desenroladas; V10, dez folhas desenroladas; R1, florescimento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

**Apêndice E** – Avaliações de severidade de mancha de turcicum causada por *Exserohilum turcicum* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Turcicum*			
	V11 <sup>a</sup>	VT <sup>a</sup>	R2 <sup>a</sup>	R3 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022	28/04/2022
1-Testemunha	10,00 a	12,25 a	15,00 a	16,25 a
2-V6/ V10/ R2/ R2+14	2,25 b	3,00 b	4,75 b	4,75 b
3-V6/ V10/ R2	1,50 b	2,25 b	2,75 b	3,25 b
4-V6/ V10	3,00 b	3,00 b	3,25 b	4,00 b
5-V6	2,25 b	2,75 b	3,50 b	4,00 b
6-V10/ R2/ R2+14	11,75 a	13,25 a	14,50 a	15,50 a
7- R2/ R2+14	10,25 a	12,25 a	15,00 a	16,00 a
8-R2+14	9,75 a	11,0 a	14,00 a	16,25 a
C.V. (%)	29,02	22,33	22,27	12,68

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; V11, onze folhas desenroladas; VT, pendoamento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R3, grão leitoso.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice F** – Avaliações de severidade de mancha de turcicum causada por *Exserohilum turcicum* em tratamentos com diferentes épocas e números de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Turcicum*			
	V10 <sup>a</sup>	V12 <sup>a</sup>	R2 <sup>a</sup>	R2 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022	28/04/2022
1-Testemunha	16,50 a	23,75 a	30,25 a	30,75 a
2-V6/ V10/ R2/ R2+14	4,50 b	5,00 d	5,50 c	5,50 c
3-V6/ V10/ R2	6,50 b	6,75 d	7,50 c	8,00 c
4-V6/ V10	6,25 b	6,75 d	7,50 c	8,00 c
5-V6	6,50 b	11,75 c	16,50 b	17,75 b
6-V10/ R2/ R2+14	16,50 a	16,50 b	16,75 b	17,25 b
7- R2/ R2+14	15,75 a	21,75 a	28,25 a	28,75 a
8-R2+14	16,00 a	22,50 a	28,25 a	29,25 a
C.V. (%)	24,71	15,07	15,36	14,75

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; V12, doze folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice G** – Avaliações de severidade de mancha de turcicum causada *Exserohilum turcicum* em tratamentos com diferentes épocas e números de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha de Turcicum*		
	V9 <sup>a</sup>	V10 <sup>a</sup>	R1 <sup>a</sup>
	07/04/2022	14/04/2022	21/04/2022
1-Testemunha	7,75 a	9,25 a	13,25 a
2-V6/ V10/ R2/ R2+14	3,25 b	3,75 b	4,75 b
3-V6/ V10/ R2	3,25 b	4,00 b	5,25 b
4-V6/ V10	4,50 b	4,75 b	5,50 b
5-V6	4,50 b	4,25 b	4,75 b
6-V10/ R2/ R2+14	6,25 a	7,25 a	7,75 b
7- R2/ R2+14	5,50 a	9,25 a	11,25 a
8-R2+14	6,25 a	9,00 a	11,25 a
C.V. (%)	35,92	23,21	28,59

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V9, nove folhas desenroladas; V10, dez folhas desenroladas; R1, florescimento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice H** – Avaliações de severidade de mancha branca causada por *Pantonea ananatis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 8780. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha Branca*			
	R2 <sup>a</sup>	R3 <sup>a</sup>	R3 <sup>a</sup>	R4 <sup>a</sup>
	28/04/2022	06/05/2022	13/05/2022	20/05/2022
1-Testemunha	2,0 a	10,25 a	17 a	18,25 a
2-V6/ V10/ R2/ R2+14	0,0 b	0,0 c	0,0 c	0,5 c
3-V6/ V10/ R2	0,0 b	0,0 c	0,5 c	1,5 c
4-V6/ V10	0,0 b	0,0 c	1,0 c	2,0 c
5-V6	0,0 b	1,5 c	6,25 b	8,75 b
6-V10/ R2/ R2+14	0,0 b	0,5 c	2,0 c	2,5 c
7- R2/ R2+14	0,0 b	5,5 b	9,5 b	10,0 b
8-R2+14	1,5 a	6,25 b	8,25 b	9,25 b
C.V. (%)	84,57	49,2	40,79	36,43

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; VT, pendoamento; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R3, grão leitoso; R4, grão pastoso.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice I** – Avaliações de severidade de mancha branca causada por *Pantonea ananatis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha Branca*		
	R4 <sup>a</sup>	R4 <sup>a</sup>	R5 <sup>a</sup>
	06/05/2022	13/05/2022	20/05/2022
1-Testemunha	2,25 a	9,50 a	14,00 a
2-V6/ V10/ R2/ R2+14	0,00 b	0,50 c	0,50 c
3-V6/ V10/ R2	0,00 b	0,75 c	1,25 c
4-V6/ V10	0,00 b	2,00 c	3,00 c
5-V6	0,50 b	2,75 c	6,25 b
6-V10/ R2/ R2+14	0,00 b	2,00 c	2,50 c
7- R2/ R2+14	0,75 b	6,00 b	7,50 b
8-R2+14	1,75 a	6,00 b	6,75 b
C.V. (%)	73,65	41,37	33,95

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R4, grão pastoso; R5, grão dente.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

**Apêndice J** – Avaliações de severidade de mancha branca causada por *Pantonea ananatis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Severidade de Mancha Branca*		
	R3 <sup>a</sup>	R3 <sup>a</sup>	R4 <sup>a</sup>
	06/05/2022	13/05/2022	20/05/2022
1-Testemunha	2,00 a	5,75 a	10,50 a
2-V6/ V10/ R2/ R2+14	0,00 b	0,00 c	0,00 c
3-V6/ V10/ R2	0,00 b	0,25 c	1,25 c
4-V6/ V10	0,00 b	0,00 c	0,00 c
5-V6	0,50 b	2,50 b	6,00 b
6-V10/ R2/ R2+14	0,00 b	0,25 c	0,75 c
7- R2/ R2+14	0,75 b	4,25 a	5,75 b
8-R2+14	1,75 a	6,50 a	9,00 a
C.V. (%)	100,29	56,53	38,73

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R3, grão leitoso; R4, grão pastoso.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott ( $P < 0,05$ ).

**Apêndice K – Avaliações de severidade de mancha branca causada por *Pantonea ananatis* em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.**

Tratamento <sup>a</sup>	Severidade de Mancha Branca*			
	R2 <sup>a</sup>	R3 <sup>a</sup>	R3 <sup>a</sup>	R4 <sup>a</sup>
	28/04/2022	06/05/2022	13/05/2022	20/05/2022
1-Testemunha	3,75 a	17,50 a	22,50 a	28,25 a
2-V6/ V10/ R2/ R2+14	0,00 c	0,00 d	1,25 d	1,50 d
3-V6/ V10/ R2	0,00 c	0,50 d	1,25 d	2,25 d
4-V6/ V10	0,00 c	0,25 d	1,50 d	4,25 d
5-V6	0,00 c	3,75 c	7,25 c	11,00 c
6-V10/ R2/ R2+14	0,25 c	6,75 b	7,75 c	9,00 c
7- R2/ R2+14	2,25 b	14,50 a	16,00 b	18,50 b
8-R2+14	3,50 a	15,25 a	16,75 b	18,75 b
C.V. (%)	39,66	26,25	22,66	20,58

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água; R3, grão leitoso; R4, grão pastoso.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice L – Produtividade em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.). Safrinha 2022. Londrina – PR.**

Tratamento <sup>a</sup>	Produtividade (kg.ha <sup>-1</sup> )*			
	AG 8780	AG 9021	AG 9025	FÓRMULA VIP
1-Testemunha	6732,3475 a	7877,290 a	4459,1725 a	8253,3525 a
2-V6/ V10/ R2/ R2+14	9198,5775 e	10297,847 d	6993,1850 d	10582,0375 d
3-V6/ V10/ R2	9185,6400 e	11082,365 e	6937,8075 d	10430,3500 d
4-V6/ V10	8604,6725 d	9745,392 c	6934,0400 d	9934,3675 c
5-V6	8196,6700 c	9541,800 c	6577,2475 c	9495,0475 c
6-V10/ R2/ R2+14	7930,8175 c	9298,152 c	6464,4350 c	9153,2000 b
7- R2/ R2+14	7596,0100 b	8964,557 b	5489,4250 b	8724,6075 b
8-R2+14	6633,0850 a	7936,625 a	5252,5975 b	8350,3975 a
C.V. (%)	3,27	4,17	3,36	3,7

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice M – Área abaixo da curva de progresso dos índices de vegetação e regiões espectrais em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 8780. Safrinha 2022. Londrina – PR.**

Tratamento <sup>a</sup>	Índices de vegetação*					
	AACP <sub>NDVI</sub>	AACP <sub>NQAB</sub>	AACP <sub>NQAF</sub>	AACP <sub>NDRE</sub>	AACP <sub>VARI</sub>	AACP <sub>NIR</sub>
1-Testemunha	35,645957 a	195,459368 a	131,784174 a	19,421206 a	22,547589 a	598179,507294 a
2-V6/ V10/ R2/ R2+14	35,925776 a	198,167653 a	132,209762 a	19,800635 a	23,148909 b	607535,420983 a
3-V6/ V10/ R2	35,930379 a	197,284705 a	132,140087 a	19,710716 a	23,202943 b	601283,596327 a
4-V6/ V10	35,746789 a	195,108520 a	131,842697 a	19,429774 a	22,830105 a	601211,272365 a
5-V6	35,861821 a	198,973046 a	132,336105 a	19,952845 a	22,545803 a	594730,446121 a
6-V10/ R2/ R2+14	35,825158 a	194,605187 a	131,795836 a	19,356107 a	23,137706 b	604399,083806 a
7- R2/ R2+14	35,711584 a	195,632371 a	131,844035 a	19,457298 a	22,580415 a	597802,539813 a
8-R2+14	35,617649 a	194,402840 a	131,673568 a	19,294046 a	22,632997 a	597486,264715 a
C.V. (%)	0,95	2,93	0,58	3,94	1,46	1,16

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice N – Área abaixo da curva de progresso dos índices de vegetação e regiões espectrais em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.**

Tratamento <sup>a</sup>	Índices de vegetação*					
	AACP <sub>NDVI</sub>	AACP <sub>NQAB</sub>	AACP <sub>NQAF</sub>	AACP <sub>NDRE</sub>	AACP <sub>VARI</sub>	AACP <sub>NIR</sub>
1-Testemunha	37,059033 a	217,376213 a	134,555006 a	22,136503 a	22,793255 a	612977,954089 a
2-V6/ V10/ R2/ R2+14	37,123508 a	216,246800 a	134,439378 a	21,982138 a	23,396701 a	614816,494782 a
3-V6/ V10/ R2	37,021127 a	215,236732 a	134,308595 a	21,864076 a	23,322788 a	616347,751491 a
4-V6/ V10	37,108751 a	215,523977 a	134,413821 a	21,947386 a	23,556990 a	620481,910204 a
5-V6	36,954651 a	213,907087 a	134,211896 a	21,757530 a	23,076318 a	616521,905994 a
6-V10/ R2/ R2+14	37,005914 a	215,144566 a	134,315882 a	21,873203 a	23,165922 a	617199,469840 a
7- R2/ R2+14	37,239513 a	219,275559 a	134,778393 a	22,341520 a	23,361021 a	614561,615790 a
8-R2+14	36,947670 a	216,294158 a	134,395067 a	21,991396 a	22,816186 a	611377,721740 a
C.V. (%)	0,98	2,23	0,44	2,63	3,81	1,19

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice O** – Área abaixo da curva de progresso dos índices de vegetação e regiões espectrais em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Índices de vegetação*					
	AACP <sub>NDVI</sub>	AACP <sub>NQAB</sub>	AACP <sub>NQAF</sub>	AACP <sub>NDRE</sub>	AACP <sub>VARI</sub>	AACP <sub>NIR</sub>
1-Testemunha	33,65045 a	174,5922 a	128,4548 a	16,36249 a	15,33888 a	612351,6 a
2-V6/ V10/ R2/ R2+14	34,06164 a	176,3307 a	128,8559 a	16,66539 a	16,31465 a	614200,8 a
3-V6/ V10/ R2	34,00696 a	175,7134 a	128,7325 a	16,55587 a	16,08482 a	604647,1 a
4-V6/ V10	34,14393 a	177,0574 a	128,9917 a	16,78919 a	16,15884 a	608206,6 a
5-V6	33,92958 a	175,7307 a	128,7026 a	16,54979 a	15,99704 a	613588,6 a
6-V10/ R2/ R2+14	33,90047 a	172,8456 a	128,3185 a	16,14381 a	16,17988 a	612644,9 a
7- R2/ R2+14	33,53844 a	172,6146 a	128,0953 a	16,02098 a	15,55204 a	612073,3 a
8-R2+14	33,46433 a	173,187 a	128,163 a	16,11214 a	14,73486 a	607449 a
C.V. (%)	1,18	1,78	0,42	2,87	5,92	1,90

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice P** – Área abaixo da curva de progresso dos índices de vegetação e regiões espectrais em tratamentos com diferentes épocas e número de aplicações de fungicidas, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.

Tratamento <sup>a</sup>	Índices de vegetação*					
	AACP <sub>NDVI</sub>	AACP <sub>NQAB</sub>	AACP <sub>NQAF</sub>	AACP <sub>NDRE</sub>	AACP <sub>VARI</sub>	AACP <sub>NIR</sub>
1-Testemunha	35,848230 a	207,125214 a	133,180090 a	20,957745 a	21,325803 a	628891,967715 a
2-V6/ V10/ R2/ R2+14	36,367226 a	212,328893 a	133,890317 a	21,606906 a	22,427776 a	641980,371055 a
3-V6/ V10/ R2	36,190932 a	209,580780 a	133,539241 a	21,258375 a	22,123449 a	632929,172304 a
4-V6/ V10	36,074871 a	207,582334 a	133,343687 a	21,058208 a	21,924116 a	629789,322485 a
5-V6	36,000680 a	207,072444 a	133,272077 a	20,997807 a	21,587377 a	630354,453390 a
6-V10/ R2/ R2+14	36,088357 a	208,760342 a	133,461120 a	21,192527 a	21,985483 a	632036,836461 a
7- R2/ R2+14	36,250533 a	211,821041 a	133,800121 a	21,543951 a	21,913274 a	629304,449126 a
8-R2+14	36,129141 a	209,167771 a	133,479706 a	21,209211 a	22,029095 a	628270,130551 a
C.V. (%)	1,12	3,01	0,56	3,56	3,29	1,08

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das aplicações de fungicidas e avaliações: V6, seis folhas desenroladas; V10, dez folhas desenroladas; R2, bolha d'água; R2+14, quatorze dias após bolha d'água.

\*Médias seguidas de mesma letra na coluna não diferem estatisticamente entre si pelo teste de Scott Knott (P<0,05).

**Apêndice Q – Equações de função de severidade e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido AG 8780. Safrinha 2022. Londrina – PR.**

ED <sup>a</sup>	DN <sup>b</sup>	Equação de função de severidade e coeficiente de determinação					
		NDVI	NQAB	NQAF	NDRE	VARI	NIR
V9	MBI	$y = -5E-05x + 0,8945$ $R^2 = 0,0174$	$y = -0,0031x + 5,3457$ $R^2 = 0,1885$	$y = -0,0003x + 3,1771$ $R^2 = 0,1459$	$y = -0,0003x + 0,558$ $R^2 = 0,1669$	$y = 0,0003x + 0,6216$ $R^2 = 0,0282$	$y = 23,532x + 13633$ $R^2 = 0,4621$
V10	MBI	$y = -0,0001x + 0,9014$ $R^2 = 0,3773$	$y = -0,0019x + 5,7512$ $R^2 = 0,0908$	$y = -0,0002x + 3,2075$ $R^2 = 0,1218$	$y = -0,0002x + 0,5949$ $R^2 = 0,0816$	$y = -0,0003x + 0,633$ $R^2 = 0,2062$	$y = -8,5869x + 15582$ $R^2 = 0,1336$
R1	MBI	$y = -9E-05x + 0,8731$ $R^2 = 0,1079$	$y = -0,0018x + 4,8044$ $R^2 = 0,1403$	$y = -0,0002x + 3,1188$ $R^2 = 0,1604$	$y = -0,0002x + 0,4955$ $R^2 = 0,157$	$y = -8E-05x + 0,579$ $R^2 = 0,0109$	$y = -4,1161x + 16039$ $R^2 = 0,1445$
R2	MBR	$y = -0,0038x + 0,818$ $R^2 = 0,7421$	$y = -0,0266x + 4,3402$ $R^2 = 0,2723$	$y = -0,0053x + 3,0492$ $R^2 = 0,4719$	$y = -0,0045x + 0,4345$ $R^2 = 0,3608$	$y = -0,0048x + 0,4878$ $R^2 = 0,3406$	$y = -77,361x + 14849$ $R^2 = 0,2958$
R3	MBR	$y = -0,0004x + 0,8114$ $R^2 = 0,1974$	$y = -0,0033x + 4,2046$ $R^2 = 0,1029$	$y = -0,0008x + 3,0282$ $R^2 = 0,2107$	$y = -0,0006x + 0,4134$ $R^2 = 0,172$	$y = -0,0009x + 0,4922$ $R^2 = 0,2225$	$y = -16,657x + 15063$ $R^2 = 0,3719$
R3	MBR	$y = -0,0007x + 0,7858$ $R^2 = 0,7341$	$y = -0,0016x + 3,9398$ $R^2 = 0,0577$	$y = -0,0005x + 2,9834$ $R^2 = 0,1806$	$y = -0,0003x + 0,3728$ $R^2 = 0,0828$	$y = -0,0022x + 0,483$ $R^2 = 0,8413$	$y = -15,831x + 11775$ $R^2 = 0,5236$
R4	MBR	$y = -0,0006x + 0,7402$ $R^2 = 0,3713$	$y = -0,0011x + 3,595$ $R^2 = 0,0257$	$y = -0,0005x + 2,9122$ $R^2 = 0,1041$	$y = -0,0003x + 0,3116$ $R^2 = 0,056$	$y = -0,0011x + 0,4592$ $R^2 = 0,4403$	$y = -4,4537x + 12494$ $R^2 = 0,0609$

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V9, nove folhas desenroladas; V10, dez folhas desenroladas; VT, pendoamento; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

<sup>b</sup>DN – Doenças: MBI, Mancha de Bipolaris; MTU, Mancha de Turcicum; MBR, Mancha Branca.

**Apêndice R – Equações de função de severidade e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.**

ED <sup>a</sup>	DN <sup>b</sup>	Equação de função de severidade e coeficiente de determinação					
		NDVI	NQAB	NQAF	NDRE	VARI	NIR
V11	MBI	$y = 4E-05x + 0,9158$ $R^2 = 0,0929$	$y = 0,0036x + 5,6776$ $R^2 = 0,5491$	$y = 0,0003x + 3,2095$ $R^2 = 0,4212$	$y = 0,0003x + 0,5901$ $R^2 = 0,4767$	$y = -3,5942x + 13767$ $R^2 = 0,2937$	$y = -0,0002x + 0,6745$ $R^2 = 0,1749$
VT	MBI	$y = 3E-05x + 0,9168$ $R^2 = 0,0455$	$y = 0,0028x + 6,268$ $R^2 = 0,4037$	$y = 0,0002x + 3,2436$ $R^2 = 0,3589$	$y = 0,0002x + 0,6363$ $R^2 = 0,4228$	$y = -0,0002x + 0,637$ $R^2 = 0,2632$	$y = -2,4221x + 15682$ $R^2 = 0,1212$
R2	MBI	$y = 2E-05x + 0,8898$ $R^2 = 0,0156$	$y = 0,002x + 5,1694$ $R^2 = 0,4143$	$y = 0,0002x + 3,1584$ $R^2 = 0,3006$	$y = 0,0002x + 0,5369$ $R^2 = 0,3841$	$y = -2E-05x + 0,5913$ $R^2 = 0,003$	$y = -1,9322x + 15983$ $R^2 = 0,0528$
R3	MBI	$y = 7E-06x + 0,8496$ $R^2 = 0,0018$	$y = 0,0009x + 4,7857$ $R^2 = 0,219$	$y = 0,0001x + 3,1084$ $R^2 = 0,2053$	$y = 0,0001x + 0,4923$ $R^2 = 0,2732$	$y = -0,0002x + 0,4971$ $R^2 = 0,3312$	$y = -2,5865x + 14613$ $R^2 = 0,3041$
V11	MTU	$y = 7E-05x + 0,916$ $R^2 = 0,0385$	$y = 0,0084x + 5,6824$ $R^2 = 0,4042$	$y = 0,0006x + 3,2099$ $R^2 = 0,2878$	$y = 0,0007x + 0,5906$ $R^2 = 0,3375$	$y = -0,0004x + 0,6741$ $R^2 = 0,1076$	$y = -7,6708x + 13758$ $R^2 = 0,1836$
VT	MTU	$y = 8E-05x + 0,9167$ $R^2 = 0,0522$	$y = 0,0073x + 6,2659$ $R^2 = 0,3491$	$y = 0,0004x + 3,2435$ $R^2 = 0,3218$	$y = 0,0006x + 0,6361$ $R^2 = 0,3715$	$y = -0,0006x + 0,6371$ $R^2 = 0,2261$	$y = -6,0251x + 15681$ $R^2 = 0,0942$
R2	MTU	$y = 8E-05x + 0,8896$ $R^2 = 0,0334$	$y = 0,0056x + 5,16$ $R^2 = 0,4642$	$y = 0,0005x + 3,1576$ $R^2 = 0,3463$	$y = 0,0006x + 0,536$ $R^2 = 0,43$	$y = 2E-05x + 0,5906$ $R^2 = 0,0003$	$y = -5,8266x + 15996$ $R^2 = 0,0675$
R3	MTU	$y = 4E-05x + 0,8494$ $R^2 = 0,0076$	$y = 0,0025x + 4,7808$ $R^2 = 0,2474$	$y = 0,0003x + 3,1078$ $R^2 = 0,2337$	$y = 0,0003x + 0,4917$ $R^2 = 0,3017$	$y = -0,0005x + 0,4974$ $R^2 = 0,274$	$y = -6,6315x + 14623$ $R^2 = 0,3078$
R4	MBR	$y = -0,001x + 0,8483$ $R^2 = 0,0886$	$y = 0,0077x + 4,6486$ $R^2 = 0,0365$	$y = 0,001x + 3,0915$ $R^2 = 0,032$	$y = 0,0014x + 0,4733$ $R^2 = 0,0699$	$y = -0,0082x + 0,5087$ $R^2 = 0,5987$	$y = -36,952x + 15182$ $R^2 = 0,0712$
R4	MBR	$y = -0,0003x + 0,8195$ $R^2 = 0,0931$	$y = 0,0027x + 4,3407$ $R^2 = 0,1048$	$y = 0,0004x + 3,048$ $R^2 = 0,0893$	$y = 0,0005x + 0,4332$ $R^2 = 0,1815$	$y = -0,0027x + 0,4742$ $R^2 = 0,4642$	$y = -23,183x + 11581$ $R^2 = 0,3863$
R5	MBR	$y = 0,0004x + 0,7802$ $R^2 = 0,1713$	$y = 0,0051x + 3,9553$ $R^2 = 0,3641$	$y = 0,001x + 2,9809$ $R^2 = 0,4084$	$y = 0,0009x + 0,3721$ $R^2 = 0,437$	$y = -0,0007x + 0,4485$ $R^2 = 0,0978$	$y = -3,2944x + 12350$ $R^2 = 0,0245$

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V10, dez folhas desenroladas; V11, onze folhas desenroladas; VT, pendoamento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso; R5, grão dente.

<sup>b</sup>DN – Doenças: MBI, Mancha de Bipolaris; MTU, Mancha de Turcicum; MBR, Mancha Branca.

**Apêndice S – Equações de função de severidade e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.**

ED <sup>a</sup>	DN <sup>b</sup>	Equação de função de severidade e coeficiente de determinação					
		NDVI	NQAB	NQAF	NDRE	VARI	NIR
V10	MBI	$y = -0,0001x + 0,8892$ $R^2 = 0,0652$	$y = 0,0006x + 4,9113$ $R^2 = 0,0063$	$y = -4E-05x + 3,1365$ $R^2 = 0,0018$	$y = 2E-05x + 0,5102$ $R^2 = 0,0006$	$y = -0,0004x + 0,6617$ $R^2 = 0,0303$	$y = 8,1416x + 13585$ $R^2 = 0,1111$
V12	MBI	$y = -0,0002x + 0,8931$ $R^2 = 0,452$	$y = -0,0033x + 5,2077$ $R^2 = 0,1554$	$y = -0,0004x + 3,1635$ $R^2 = 0,1856$	$y = -0,0004x + 0,542$ $R^2 = 0,1455$	$y = -0,0005x + 0,6673$ $R^2 = 0,3713$	$y = 1,9745x + 15954$ $R^2 = 0,0082$
R2	MBI	$y = -0,0003x + 0,8519$ $R^2 = 0,7114$	$y = -0,0036x + 4,3122$ $R^2 = 0,4834$	$y = -0,0005x + 3,0546$ $R^2 = 0,5245$	$y = -0,0005x + 0,4296$ $R^2 = 0,4675$	$y = -0,0004x + 0,5496$ $R^2 = 0,2858$	$y = -1,307x + 16406$ $R^2 = 0,0134$
R2	MBI	$y = -0,0006x + 0,7682$ $R^2 = 0,5928$	$y = -0,0048x + 3,854$ $R^2 = 0,7633$	$y = -0,0009x + 2,9648$ $R^2 = 0,7444$	$y = -0,0008x + 0,3582$ $R^2 = 0,7573$	$y = -0,0007x + 0,3877$ $R^2 = 0,3263$	$y = 6,3298x + 14481$ $R^2 = 0,1625$
V10	MTU	$y = -0,0002x + 0,8901$ $R^2 = 0,1352$	$y = -0,0005x + 4,9214$ $R^2 = 0,0074$	$y = -0,0002x + 3,138$ $R^2 = 0,044$	$y = -0,0001x + 0,5115$ $R^2 = 0,02$	$y = -0,0004x + 0,6637$ $R^2 = 0,0508$	$y = 5,2879x + 13587$ $R^2 = 0,0571$
V12	MTU	$y = -0,0002x + 0,8937$ $R^2 = 0,4578$	$y = -0,002x + 5,2056$ $R^2 = 0,0819$	$y = -0,0002x + 3,1636$ $R^2 = 0,1154$	$y = -0,0002x + 0,5418$ $R^2 = 0,0772$	$y = -0,0005x + 0,6695$ $R^2 = 0,4989$	$y = 1,0808x + 15956$ $R^2 = 0,0038$
R2	MTU	$y = -0,0002x + 0,8528$ $R^2 = 0,7592$	$y = -0,0021x + 4,3105$ $R^2 = 0,273$	$y = -0,0003x + 3,0546$ $R^2 = 0,3282$	$y = -0,0003x + 0,4294$ $R^2 = 0,2634$	$y = -0,0004x + 0,5525$ $R^2 = 0,4733$	$y = -0,0894x + 16393$ $R^2 = 1E-04$
R2	MTU	$y = -0,0005x + 0,7701$ $R^2 = 0,5713$	$y = -0,0039x + 3,8672$ $R^2 = 0,6783$	$y = -0,0008x + 2,9674$ $R^2 = 0,6667$	$y = -0,0007x + 0,3604$ $R^2 = 0,6704$	$y = -0,0006x + 0,3909$ $R^2 = 0,3638$	$y = 5,7177x + 14452$ $R^2 = 0,1811$
R3	MBR	$y = -0,0112x + 0,743$ $R^2 = 0,6691$	$y = -0,0458x + 3,6732$ $R^2 = 0,4926$	$y = -0,0104x + 2,9265$ $R^2 = 0,5164$	$y = -0,0079x + 0,3254$ $R^2 = 0,4729$	$y = -0,023x + 0,3334$ $R^2 = 0,9011$	$y = -56,574x + 14454$ $R^2 = 0,0972$
R3	MBR	$y = -0,0034x + 0,7294$ $R^2 = 0,8025$	$y = -0,0148x + 3,5181$ $R^2 = 0,5901$	$y = -0,0036x + 2,8952$ $R^2 = 0,6279$	$y = -0,0028x + 0,2978$ $R^2 = 0,5813$	$y = -0,0073x + 0,3123$ $R^2 = 0,7115$	$y = -1,6323x + 11130$ $R^2 = 0,0008$
R4	MBR	$y = -0,0023x + 0,6576$ $R^2 = 0,7094$	$y = -0,0072x + 3,2348$ $R^2 = 0,5067$	$y = -0,002x + 2,8202$ $R^2 = 0,5395$	$y = -0,0015x + 0,2406$ $R^2 = 0,4953$	$y = -0,0028x + 0,2378$ $R^2 = 0,529$	$y = 3,345x + 11743$ $R^2 = 0,0117$

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V10, dez folhas desenroladas; V12, doze folhas desenroladas; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

<sup>b</sup>DN – Doenças: MBI, Mancha de Bipolaris; MTU, Mancha de Turicum; MBR, Mancha Branca.

**Apêndice T – Equações de função de severidade e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.**

ED <sup>a</sup>	DN <sup>b</sup>	Equação de função de severidade e coeficiente de determinação					
		NDVI	NQAB	NQAF	NDRE	VARI	NIR
V9	MBI	$y = 0,0002x + 0,8828$ $R^2 = 0,1852$	$y = 0,0069x + 5,1653$ $R^2 = 0,3862$	$y = 0,0006x + 3,1579$ $R^2 = 0,3196$	$y = 0,0007x + 0,539$ $R^2 = 0,352$	$y = 0,0005x + 0,6204$ $R^2 = 0,1139$	$y = -5,6068x + 13276$ $R^2 = 0,1149$
V10	MBI	$y = 1E-05x + 0,8985$ $R^2 = 0,0021$	$y = 0,0017x + 5,915$ $R^2 = 0,0398$	$y = 0,0001x + 3,2166$ $R^2 = 0,0317$	$y = 0,0002x + 0,6086$ $R^2 = 0,0431$	$y = -0,0002x + 0,6307$ $R^2 = 0,0741$	$y = -6,9466x + 15859$ $R^2 = 0,1123$
R1	MBI	$y = -8E-05x + 0,8823$ $R^2 = 0,055$	$y = 0,0003x + 5,1215$ $R^2 = 0,0035$	$y = -3E-05x + 3,1498$ $R^2 = 0,0028$	$y = 4E-06x + 0,5302$ $R^2 = 4E-05$	$y = -0,0001x + 0,605$ $R^2 = 0,0153$	$y = -8,6483x + 16413$ $R^2 = 0,2372$
V9	MTU	$y = 6E-05x + 0,8839$ $R^2 = 0,0017$	$y = 0,0095x + 5,1572$ $R^2 = 0,1202$	$y = 0,0007x + 3,1579$ $R^2 = 0,0688$	$y = 0,0009x + 0,5384$ $R^2 = 0,0988$	$y = -0,0003x + 0,6246$ $R^2 = 0,0088$	$y = -28,225x + 13385$ $R^2 = 0,4809$
V10	MTU	$y = -4E-05x + 0,8989$ $R^2 = 0,0022$	$y = 0,0029x + 5,9111$ $R^2 = 0,0149$	$y = 0,0002x + 3,2165$ $R^2 = 0,0092$	$y = 0,0003x + 0,6082$ $R^2 = 0,0167$	$y = -0,0008x + 0,6338$ $R^2 = 0,1151$	$y = -27,212x + 15976$ $R^2 = 0,2373$
R1	MTU	$y = -0,0004x + 0,8843$ $R^2 = 0,1544$	$y = -0,0014x + 5,136$ $R^2 = 0,008$	$y = -0,0004x + 3,1523$ $R^2 = 0,0504$	$y = -0,0003x + 0,5323$ $R^2 = 0,0253$	$y = -0,0008x + 0,6097$ $R^2 = 0,067$	$y = -23,344x + 16501$ $R^2 = 0,2103$
R2	MBR	$y = -0,0007x + 0,8323$ $R^2 = 0,0775$	$y = -0,004x + 4,7576$ $R^2 = 0,0172$	$y = -0,0007x + 3,0987$ $R^2 = 0,0324$	$y = -0,0005x + 0,4878$ $R^2 = 0,021$	$y = -0,0017x + 0,4746$ $R^2 = 0,1091$	$y = -25,503x + 15273$ $R^2 = 0,098$
R3	MBR	$y = -0,0004x + 0,8238$ $R^2 = 0,366$	$y = -0,0016x + 4,6042$ $R^2 = 0,0564$	$y = -0,0003x + 3,0769$ $R^2 = 0,0933$	$y = -0,0002x + 0,4659$ $R^2 = 0,0504$	$y = -0,0011x + 0,4617$ $R^2 = 0,5583$	$y = -15,518x + 15552$ $R^2 = 0,4903$
R3	MBR	$y = -0,0004x + 0,7957$ $R^2 = 0,2554$	$y = -0,0021x + 4,2772$ $R^2 = 0,1548$	$y = -0,0004x + 3,0309$ $R^2 = 0,1849$	$y = -0,0003x + 0,4226$ $R^2 = 0,162$	$y = -0,0008x + 0,4178$ $R^2 = 0,2489$	$y = -2,7157x + 12210$ $R^2 = 0,0395$
R4	MBR	$y = -0,0003x + 0,7533$ $R^2 = 0,181$	$y = -0,0007x + 3,9198$ $R^2 = 0,0252$	$y = -0,0002x + 2,9666$ $R^2 = 0,0632$	$y = -0,0001x + 0,3652$ $R^2 = 0,0359$	$y = -0,0009x + 0,3775$ $R^2 = 0,2658$	$y = -4,6377x + 12948$ $R^2 = 0,0791$

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V9, nove folhas desenroladas; V10, dez folhas desenroladas; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

<sup>b</sup>DN – Doenças: MBI, Mancha de Bipolaris; MTU, Mancha de Turicum; MBR, Mancha Branca.

### Apêndice U – Equações de função de dano e coeficientes de determinação para os índices de vegetação na cultura do milho (*Zea mays* L.), híbrido AG 8780. Safrinha 2022. Londrina – PR.

ED <sup>a</sup>	Equação de função de dano e coeficiente de determinação					
	NDVI	NQAB	NQAF	NDRE	VARI	NIR
V9	y = 397068x - 347050 R <sup>2</sup> = 0,3173	y = 19113x - 93810 R <sup>2</sup> = 0,2311	y = 202765x - 635872 R <sup>2</sup> = 0,2358	y = 162138x - 82160 R <sup>2</sup> = 0,1857	y = 45301x - 20243 R <sup>2</sup> = 0,107	y = -3,5897x + 57444 R <sup>2</sup> = 0,1858
V10	y = 658777x - 585135 R <sup>2</sup> = 0,7016	y = 8638,3x - 41506 R <sup>2</sup> = 0,1755	y = 140372x - 442016 R <sup>2</sup> = 0,2376	y = 93379x - 47391 R <sup>2</sup> = 0,1623	y = 103678x - 57297 R <sup>2</sup> = 0,288	y = 2,4942x - 30639 R <sup>2</sup> = 0,203
R1	y = 140329x - 114314 R <sup>2</sup> = 0,2758	y = 8317,4x - 31722 R <sup>2</sup> = 0,2795	y = 70151x - 210521 R <sup>2</sup> = 0,3096	y = 67405x - 25141 R <sup>2</sup> = 0,2959	y = 27700x - 7995,6 R <sup>2</sup> = 0,0724	y = 3,6541x - 50371 R <sup>2</sup> = 0,2632
R2	y = 236078x - 184706 R <sup>2</sup> = 0,7586	y = 17330x - 67007 R <sup>2</sup> = 0,5336	y = 128095x - 382272 R <sup>2</sup> = 0,679	y = 123638x - 45463 R <sup>2</sup> = 0,5919	y = 88265x - 34865 R <sup>2</sup> = 0,3585	y = 88265x - 34865 R <sup>2</sup> = 0,3585
R3	y = 162159x - 123375 R <sup>2</sup> = 0,2948	y = 12411x - 44049 R <sup>2</sup> = 0,2552	y = 93424x - 274684 R <sup>2</sup> = 0,355	y = 93207x - 30343 R <sup>2</sup> = 0,3232	y = 64315x - 23466 R <sup>2</sup> = 0,2491	y = 6,0315x - 82541 R <sup>2</sup> = 0,4132
R3	y = 185989x - 137381 R <sup>2</sup> = 0,9092	y = 14660x - 49616 R <sup>2</sup> = 0,3493	y = 99375x - 288180 R <sup>2</sup> = 0,5242	y = 93767x - 26779 R <sup>2</sup> = 0,3851	y = 61969x - 21175 R <sup>2</sup> = 0,7596	y = 4,5166x - 44778 R <sup>2</sup> = 0,346
R4	y = 137921x - 93573 R <sup>2</sup> = 0,595	y = 13374x - 39972 R <sup>2</sup> = 0,3163	y = 74519x - 208777 R <sup>2</sup> = 0,4387	y = 78648x - 16343 R <sup>2</sup> = 0,3703	y = 60849x - 19482 R <sup>2</sup> = 0,3972	y = 0,5701x + 903,28 R <sup>2</sup> = 0,004

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V9, nove folhas desenroladas; V10, dez folhas desenroladas; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

### Apêndice V – Equações de função de dano e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido AG 9021. Safrinha 2022. Londrina – PR.

ED <sup>a</sup>	Equação de função de dano e coeficiente de determinação					
	NDVI	NQAB	NQAF	NDRE	VARI	NIR
V11	y = -262808x + 250189 R <sup>2</sup> = 0,1491	y = -12645x + 81867 R <sup>2</sup> = 0,4543	y = -146967x + 481625 R <sup>2</sup> = 0,3906	y = -129906x + 86658 R <sup>2</sup> = 0,4204	y = 108660x - 63660 R <sup>2</sup> = 0,2209	y = 4,9959x - 59150 R <sup>2</sup> = 0,1309
VT	y = -32298x + 38971 R <sup>2</sup> = 0,0028	y = -9014,7x + 66317 R <sup>2</sup> = 0,2648	y = -129666x + 430345 R <sup>2</sup> = 0,2277	y = -122971x + 88089 R <sup>2</sup> = 0,2904	y = 112696x - 61960 R <sup>2</sup> = 0,425	y = 5,1303x - 70876 R <sup>2</sup> = 0,2184
R2	y = 58191x - 42462 R <sup>2</sup> = 0,0177	y = -9378,7x + 58213 R <sup>2</sup> = 0,1736	y = -77860x + 255529 R <sup>2</sup> = 0,1187	y = -90131x + 58116 R <sup>2</sup> = 0,1796	y = 73288x - 33955 R <sup>2</sup> = 0,1759	y = 1,4792x - 14240 R <sup>2</sup> = 0,0324
R3	y = 40716x - 25257 R <sup>2</sup> = 0,0095	y = -10064x + 57705 R <sup>2</sup> = 0,0846	y = -88298x + 284020 R <sup>2</sup> = 0,103	y = -106845x + 62235 R <sup>2</sup> = 0,1489	y = 106103x - 42855 R <sup>2</sup> = 0,4263	y = 7,5785x - 100977 R <sup>2</sup> = 0,2825
R4	y = 100217x - 75602 R <sup>2</sup> = 0,0786	y = -5038,8x + 32792 R <sup>2</sup> = 0,0268	y = -44513x + 146983 R <sup>2</sup> = 0,0367	y = -63428x + 39423 R <sup>2</sup> = 0,0721	y = 87856x - 34880 R <sup>2</sup> = 0,5593	y = 3,2428x - 39810 R <sup>2</sup> = 0,1316
R4	y = 116273x - 85800 R <sup>2</sup> = 0,1406	y = -3903x + 26324 R <sup>2</sup> = 0,0089	y = -27767x + 94016 R <sup>2</sup> = 0,01	y = -60164x + 35514 R <sup>2</sup> = 0,0394	y = 54439x - 15925 R <sup>2</sup> = 0,3955	y = 4,4452x - 41759 R <sup>2</sup> = 0,2283
R5	y = -91547x + 80974 R <sup>2</sup> = 0,1429	y = -13211x + 61950 R <sup>2</sup> = 0,2041	y = -85314x + 264089 R <sup>2</sup> = 0,2749	y = -96148x + 45570 R <sup>2</sup> = 0,2763	y = 34536x - 6014,8 R <sup>2</sup> = 0,107	y = 1,4257x - 8239,9 R <sup>2</sup> = 0,0146

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V11, onze folhas desenroladas; VT, pendoamento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso; R5, grão dente.

**Apêndice X – Equações de função de dano e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido AG 9025. Safrinha 2022. Londrina – PR.**

ED <sup>a</sup>	Equação de função de dano e coeficiente de determinação					
	NDVI	NQAB	NQAF	NDRE	VARI	NIR
V10	$y = 79316x - 64311$ $R^2 = 0,0453$	$y = -11331x + 61835$ $R^2 = 0,1736$	$y = -65705x + 212207$ $R^2 = 0,0855$	$y = -85058x + 49544$ $R^2 = 0,1513$	$y = 29451x - 13269$ $R^2 = 0,102$	$y = -2,1596x + 35606$ $R^2 = 0,077$
V12	$y = 205311x - 176795$ $R^2 = 0,2167$	$y = 78,625x + 5731,4$ $R^2 = 2E-05$	$y = 9946x - 25293$ $R^2 = 0,0031$	$y = -1105,9x + 6734,3$ $R^2 = 5E-05$	$y = 145933x - 90580$ $R^2 = 0,6284$	$y = -0,611x + 15897$ $R^2 = 0,0078$
R2	$y = 287339x - 237779$ $R^2 = 0,6478$	$y = 8841,9x - 31644$ $R^2 = 0,1522$	$y = 68160x - 201654$ $R^2 = 0,1951$	$y = 58668x - 18735$ $R^2 = 0,1435$	$y = 119979x - 59247$ $R^2 = 0,6487$	$y = -1,5041x + 30793$ $R^2 = 0,0214$
R2	$y = 98872x - 69151$ $R^2 = 0,4679$	$y = 13554x - 45324$ $R^2 = 0,4912$	$y = 69015x - 197718$ $R^2 = 0,4838$	$y = 78942x - 21373$ $R^2 = 0,4775$	$y = 57403x - 15629$ $R^2 = 0,4502$	$y = -2,1029x + 36749$ $R^2 = 0,0961$
R3	$y = 74870x - 48968$ $R^2 = 0,788$	$y = 14408x - 46371$ $R^2 = 0,6642$	$y = 65887x - 186251$ $R^2 = 0,6819$	$y = 80524x - 19662$ $R^2 = 0,6459$	$y = 43943x - 7877,8$ $R^2 = 0,8529$	$y = 1,9655x - 22202$ $R^2 = 0,0955$
R3	$y = 72671x - 46277$ $R^2 = 0,6104$	$y = 12834x - 38547$ $R^2 = 0,5074$	$y = 55163x - 153086$ $R^2 = 0,5228$	$y = 66715x - 13275$ $R^2 = 0,4954$	$y = 27825x - 2055,9$ $R^2 = 0,4768$	$y = -0,254x + 8964,2$ $R^2 = 0,0019$
R4	$y = 68766x - 38437$ $R^2 = 0,6683$	$y = 16080x - 45397$ $R^2 = 0,5149$	$y = 62098x - 168485$ $R^2 = 0,5401$	$y = 77703x - 12088$ $R^2 = 0,504$	$y = 38510x - 2577,7$ $R^2 = 0,4191$	$y = -1,2946x + 21359$ $R^2 = 0,0314$

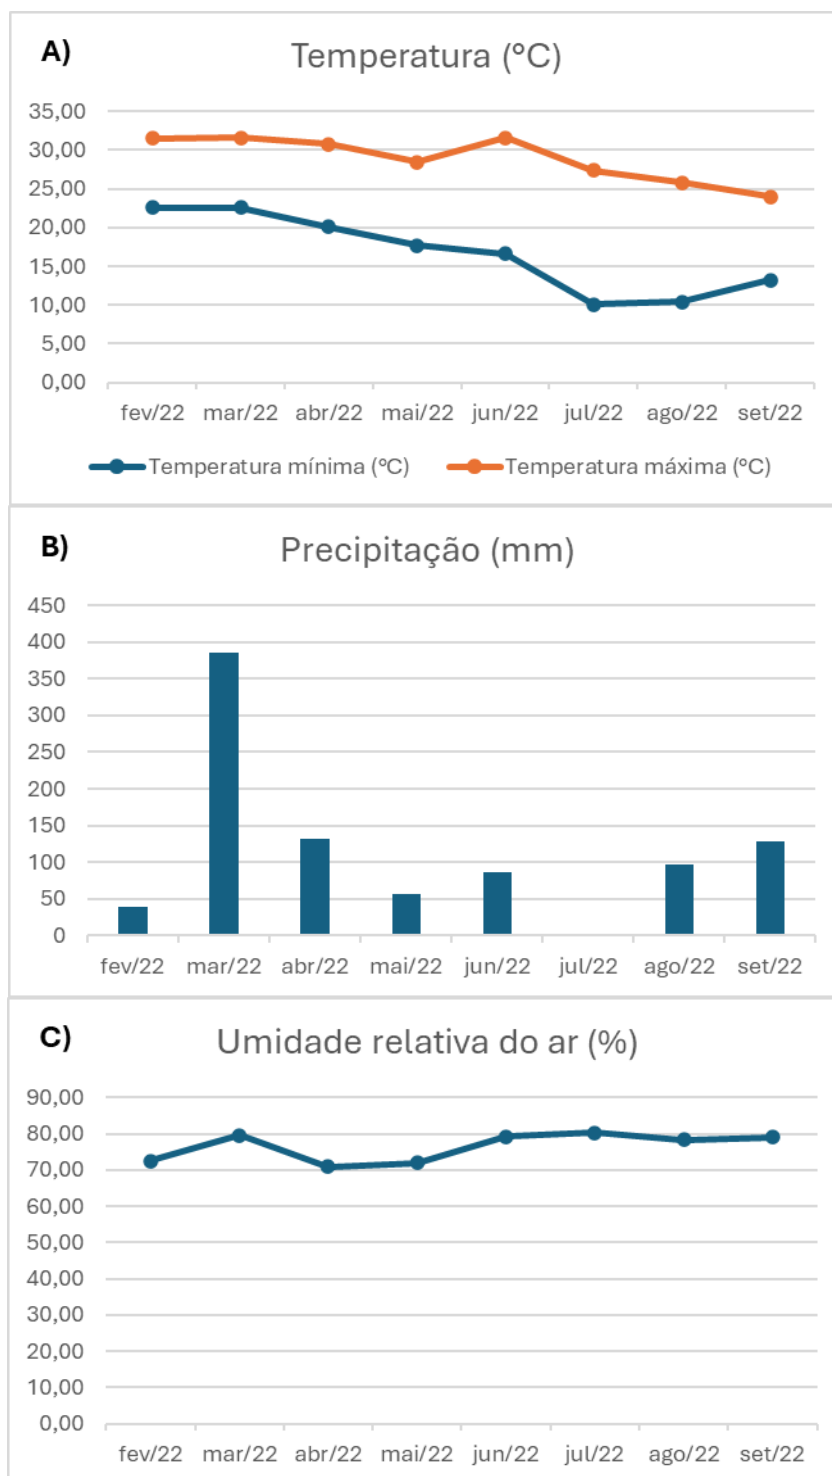
<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V10, dez folhas desenroladas; V12, doze folhas desenroladas; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

**Apêndice W – Equações de função de dano e coeficientes de determinação para os índices de vegetação, na cultura do milho (*Zea mays* L.), híbrido FÓRMULA VIP. Safrinha 2022. Londrina – PR.**


ED <sup>a</sup>	Equação de função de dano e coeficiente de determinação					
	NDVI	NQAB	NQAF	NDRE	VARI	NIR
V9	$y = -57399x + 60119$ $R^2 = 0,023$	$y = -6790,8x + 44707$ $R^2 = 0,123$	$y = -50606x + 169359$ $R^2 = 0,0706$	$y = -54459x + 38937$ $R^2 = 0,0903$	$y = -10720x + 16044$ $R^2 = 0,0045$	$y = 7,0458x - 83951$ $R^2 = 0,2951$
V10	$y = 120475x - 98900$ $R^2 = 0,0866$	$y = 2518,8x - 5569,8$ $R^2 = 0,0268$	$y = 39263x - 116969$ $R^2 = 0,0382$	$y = 29610x - 8692,7$ $R^2 = 0,0271$	$y = 67854x - 33300$ $R^2 = 0,1895$	$y = 3,441x - 45004$ $R^2 = 0,2854$
R1	$y = 155032x - 127279$ $R^2 = 0,3069$	$y = 5646,9x - 19576$ $R^2 = 0,1078$	$y = 71009x - 214274$ $R^2 = 0,1838$	$y = 60826x - 22885$ $R^2 = 0,1411$	$y = 33130x - 10629$ $R^2 = 0,1441$	$y = 3,4174x - 46391$ $R^2 = 0,4376$
R2	$y = 96631x - 70972$ $R^2 = 0,2145$	$y = 5631,3x - 17399$ $R^2 = 0,0999$	$y = 50005x - 145539$ $R^2 = 0,1264$	$y = 46004x - 13047$ $R^2 = 0,1007$	$y = 54760x - 16511$ $R^2 = 0,2707$	$y = 3,6137x - 45715$ $R^2 = 0,2986$
R3	$y = 137921x - 103872$ $R^2 = 0,4909$	$y = 7697,7x - 25987$ $R^2 = 0,1778$	$y = 64784x - 189841$ $R^2 = 0,2246$	$y = 58104x - 17622$ $R^2 = 0,1651$	$y = 66120x - 20634$ $R^2 = 0,6268$	$y = 4,0559x - 53250$ $R^2 = 0,5426$
R3	$y = 86338x - 59048$ $R^2 = 0,307$	$y = 10100x - 33636$ $R^2 = 0,251$	$y = 62389x - 179504$ $R^2 = 0,2643$	$y = 69328x - 19724$ $R^2 = 0,2504$	$y = 35302x - 5130$ $R^2 = 0,2526$	$y = 1,588x - 9983,9$ $R^2 = 0,0391$
R4	$y = 59066x - 34914$ $R^2 = 0,1919$	$y = 5402,2x - 11764$ $R^2 = 0,0603$	$y = 35522x - 95922$ $R^2 = 0,0948$	$y = 35921x - 3695,2$ $R^2 = 0,0691$	$y = 29539x - 1493$ $R^2 = 0,2381$	$y = 2,38x - 21325$ $R^2 = 0,1452$

<sup>a</sup>Estádio de desenvolvimento das plantas de milho (EMBRAPA, 2005) no momento das avaliações: V9, nove folhas desenroladas; V10, dez folhas desenroladas; R1, florescimento; R2, bolha d'água; R3, grão leitoso; R4, grão pastoso.

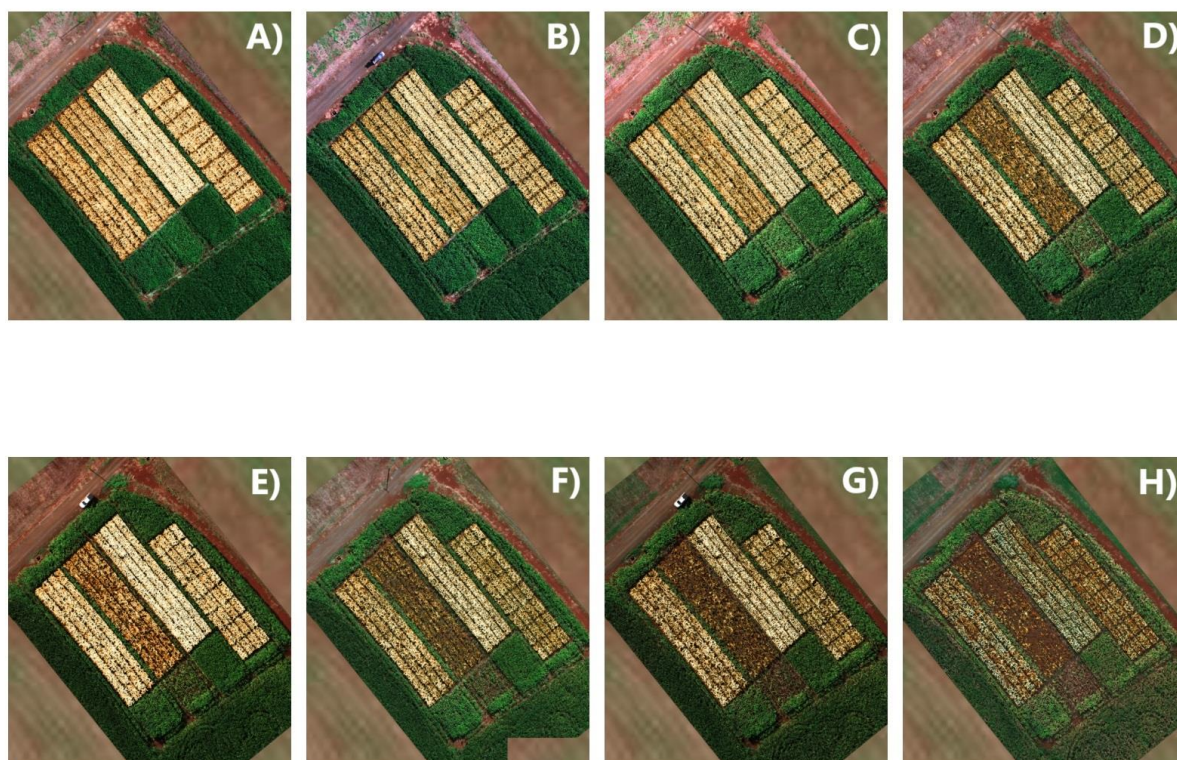
## ANEXOS



**Anexo A** – Temperaturas máximas e mínimas, precipitação e umidade relativa do ar no período de fevereiro a setembro de 2022. Londrina – PR.



**Anexo B** – Índice de Biomassa (NQAB) na cultura do milho (*Zea mays* L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR.



**Anexo C – Índice de Estresse Vegetal (NQAE) na cultura do milho (*Zea mays* L.) em diferentes datas de captura: A em 07/04/2022; B em 14/04/2022; C em 21/04/2022; D em 28/04/2022; E em 06/05/2022; F em 13/05/2022; G em 20/05/2022; H em 26/05/2022. Safrinha 2022. Londrina – PR.**