

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CAMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

JOSÉ DONIZETE DE QUEIROZ OTONE

**RESPOSTA HIPERSPECTRAL DA CULTURA DA SOJA EM FUNÇÃO  
DA SEVERIDADE DA MANCHA ALVO (*Corynespora cassicola*)**

CHAPADÃO DO SUL – MS

2023

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CAMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

JOSÉ DONIZETE DE QUEIROZ OTONE

**RESPOSTA HIPERSPECTRAL DA CULTURA DA SOJA EM FUNÇÃO  
DA SEVERIDADE DA MANCHA ALVO (*Corynespora cassicola*)**

Orientador: Prof. Dr. Fábio Henrique Rojo Baio

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul, como parte dos requisitos para obtenção do título de Mestre em Agronomia, área de concentração: Produção Vegetal.

CHAPADÃO DO SUL – MS

2023



Serviço Público Federal  
Ministério da Educação  
Fundação Universidade Federal de Mato Grosso do Sul



## PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

### CERTIFICADO DE APROVAÇÃO

**DISCENTE:** José Donizete de Queiroz Otone

**ORIENTADOR:** Dr. Fabio Henrique Rojo Baio

**TÍTULO:** Resposta hiperspectral da cultura da soja em função da severidade da mancha alva (*Corynespora cassiicola*).

#### AVALIADORES:

Prof. Dr. Fabio Henrique Rojo Baio

Prof. Dr. Gustavo de Faria Theodoro

Prof. Rafael Ferreira Barreto

Chapadão do Sul, 12 de dezembro de 2023.

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Fabio Henrique Rojo Baio, Professor do Magisterio Superior**, em 12/12/2023, às 15:40, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Rafael Ferreira Barreto, Professor do Magisterio Superior**, em 12/12/2023, às 15:43, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Gustavo de Faria Theodoro, Professor do Magisterio Superior**, em 12/12/2023, às 16:32, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufms.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4533508** e o código CRC **C35D7826**.

## AGRADECIMENTOS

Agradeço primeiramente a Deus por sempre estar comigo e ser a base de todas as conquistas.

Agradeço aos meus pais, irmã, cunhado e familiares pelo carinho e apoio, e em especial a minha esposa e filho que sempre me apoiaram e deram forças para chegar a este objetivo.

Ao Prof. Dr. Fábio H. R. Baio pelo suporte e orientação, bem como, aos membros da banca pelo aceite e suas contribuições.

A instituição UFMS, campus Chapadão do Sul e aos professores da Pós-graduação, que contribuíram para o meu conhecimento.

A todo time da Desafios Agro, em especial a equipe de fitopatologia, liderada pelo Pesquisador Alfredo Ricieri Dias, apoiando na condução e desenvolvimento deste trabalho.

E a todos que de alguma forma contribuíram para realização deste trabalho.

**RESUMO:** No contexto atual da agricultura, a eficácia produtiva é fundamental para os agricultores, mas doenças, como a mancha alvo, continuam a prejudicar a produtividade da soja. O sensoriamento remoto, especialmente o sensoriamento hiperspectral, pode detectar essas doenças, mas tem desvantagens, como custo e complexidade. Os objetivos deste trabalho foram: identificar a variável de entrada (Bandas, Índices de vegetação e Reflectância) mais apropriado para as métricas trabalhadas (Classificação correta, Kappa e F-score) e identificar se há relação entre as bandas espectrais e índices de vegetação com os níveis de severidade da mancha alvo, produtividade e massa de grãos. O experimento foi realizado na safra 2022/23 em uma fazenda em Costa Rica/MS/BR, conduzido com diferentes tratamentos fungicidas, para se obter diferentes níveis de severidade da doença. Foram usados espectrorradiômetro e imagem de aeronave remotamente pilotada para coletar dados espectrais das folhas. Os dados foram submetidos a análises de aprendizado de máquina usando diferentes algoritmos. Os algoritmos RF (Floresta aleatória) e SVM (Máquina de vetor suporte) apresentaram melhor desempenho na classificação dos níveis de severidade da mancha alvo, utilizando reflectância. A análise multivariada mostrou que folhas saudáveis se destacam em comprimentos de onda específicos, enquanto as folhas doentes mostraram diferentes padrões espectrais. A detecção de doenças usando sensores hiperspectrais permitiu uma aquisição detalhada de informações. O estudo demonstrou que o sensoriamento remoto, especialmente sensores hiperspectrais e técnicas de aprendizado de máquina podem ser eficaz na detecção precoce e no monitoramento da mancha alvo em lavouras de soja, permitindo uma ação rápida para o controle e prevenção de perdas de produtividade.

**Palavras-chave:** *Glycine max*. Sensoriamento remoto. Agricultura de Precisão.

**The hyperspectral response of soybean crops in relation to the severity of target spot (*Corynespora cassiicola*).**

**ABSTRACT:** In the current context of agriculture, productive efficiency is fundamental for farmers, but diseases, such as target spot, continue to harm soybean productivity. Remote sensing, especially hyperspectral sensing, can detect these diseases, but it has disadvantages such as cost and complexity. The objectives of this work were: to identify the input variable (Bands, Vegetation Indices and Reflectance) most appropriate for the metrics worked on (Correct Classification, Kappa and F-score) and to identify whether there is a relationship between the spectral bands and vegetation indices with target stain severity levels, yield and

grain mass. The experiment was carried out in the 2022/23 harvest on a farm in Costa Rica/MS/BR, conducted with different fungicide treatments, to obtain different levels of disease severity. A spectroradiometer and remotely piloted aircraft imaging were used to collect spectral data from the leaves. The data was subjected to machine learning analysis using different algorithms. The RF (Random Forest) and SVM (Support Vector Machine) algorithms showed better performance in classifying the severity levels of the target spot, using reflectance. Multivariate analysis showed that healthy leaves stood out at specific wavelengths, while diseased leaves showed different spectral patterns. Disease detection using hyperspectral sensors has enabled detailed information acquisition. The study demonstrated that remote sensing, especially hyperspectral sensors and machine learning techniques can be effective in early detection and monitoring of target spot in soybean crops, allowing rapid action to control and prevent productivity losses.

**Keywords:** *Glycine max*. Remote Sensing. Precision Agriculture.

**SUMÁRIO**

INTRODUÇÃO .....	8
MATERIAL E MÉTODOS .....	9
RESULTADOS E DISCUSSÃO .....	15
CONCLUSÕES.....	22
REFERÊNCIAS.....	23

## INTRODUÇÃO

No contexto atual da agricultura, a ampliação da produtividade assume um papel decisivo e está fundamentalmente associada aos avanços tecnológicos e às estratégias de gestão agrícola implementadas pelos agricultores. Entretanto, mesmo diante da eficácia das tecnologias contemporâneas e da vigilância contínua da sanidade das culturas, as plantações de soja continuam a ser regularmente afetadas por enfermidades foliares (ARANTES et al., 2019), que resultam em uma diminuição da produtividade.

Uma das doenças que acomete a cultura da soja é a mancha alvo (*Corynespora cassiicola*), que em função da utilização de cultivares sensíveis e perda da sensibilidade a fungicidas registrados, apresentou importância relevante após 2010, sendo relatadas perdas de até 24% em alguns estudos recentes (MOLINA et al., 2019). Outro aspecto de grande importância para essa doença é a sua ampla gama de hospedeiro (DIXON et al., 2009), como o algodoeiro (*Gossypium hirsutum*) que é muito relevante por fazer parte do sistema de produção de muitas fazendas.

Como consequência dos efeitos de estresses de natureza biótica e abiótica, as plantas têm modificações de natureza biofísica e bioquímica, tais como a diminuição de sua biomassa e a alteração da coloração das folhas, que podem ser prontamente identificados por intermédio de técnicas de sensoriamento remoto aplicadas à faixa de espectro luz visível (VIS), infravermelho próximo (NIR), infravermelho de ondas curtas (SWIR) (BAJWA, RUPE E MASON, 2017). A identificação precoce de doenças nas culturas oferece um tempo adequado para conter potenciais epidemias e minimizar perdas de produtividade. Diante disso, profissionais em agricultura de precisão persistem na busca por soluções inovadoras e econômicas que abordem de maneira fácil e eficaz a detecção de doenças (SHAHI et al., 2023).

As aeronaves remotamente pilotadas (ARP) são muito utilizadas por possibilitar transportar sensores capazes de adquirir informações do espectro eletromagnético nos comprimentos de VIS, NIR e SWIR, também chamados de imagens multiespectral (TANG E SHAO, 2015). Devido aos avanços na tecnologia, sensores cada vez menores, leves e mais baratos tornaram-se disponíveis para aplicações de sensoriamento remoto por ARP. Anderson e Gaston (2013) e Colomina e Molina (2014) fornecem introduções detalhadas a vários sistemas de sensoriamento remoto com ARP.

Uma técnica de imagem mais sofisticada, denominada imagem hiperspectral, emprega dados de reflectância coletados em uma vasta faixa espectral, tipicamente entre 350 e 2500 nm, com o propósito de reconstruir uma representação espacial da folha da planta sob análise



mediante procedimentos de processamento de imagem altamente especializados. Embora seja uma abordagem extremamente informativa, que possibilita a detecção de uma gama mais ampla de doenças de plantas em comparação com a imagem R (Red), G (Green) e B (Blue), apresenta algumas desvantagens, incluindo custos elevados, complexidade, maiores períodos de aquisição de dados e uma análise de dados intrincada, sobretudo em situações em que respostas rápidas ou a avaliação extensiva de grandes áreas são necessárias (FARBER *et al.*, 2019).

Utilizar técnicas de aprendizagem de máquinas aliadas ao sensoriamento remoto possibilita avanços tecnológicos no meio agrícola no monitoramento da lavoura, especialmente em aspectos fitossanitários. Koc *et al.* (2022) recomendam o processamento de dados de sensoriamento utilizando aprendizagem de máquina na classificação rápida de doenças.

Questiona-se se é possível diagnosticar presença da mancha alvo nas folhas da cultura da soja utilizando técnicas de sensoriamento remoto por sensores hiperespectral e multiespectral e analisar a relação dessas características espectrais com a fenologia da produtividade da cultura. Dessa forma, os objetivos deste trabalho foram: identificar a variável de entrada (Bandas, Índices de vegetação e Reflectância) mais apropriado para as métricas trabalhadas e por fim, identificar se há relação entre as bandas espectrais e índices de vegetação com os níveis de severidade da mancha alvo, produtividade e peso de grãos.

## **MATERIAL E MÉTODOS**

O estudo foi conduzido no ano agrícola 2022/2023, na Fazenda Nova França (município Costa Rica – MS/Br), cujas coordenadas geográficas são 53°06'40,09'' de longitude oeste, 18°16'06,01'' de latitude sul (Figura 1). O clima da região segundo Koppen, é do tipo Aw, classificado como tropical úmido, com estação chuvosa no verão e seca no inverno. O solo é classificado como Latossolo Vermelho Distrófico com textura muito argilosa (Santos *et al.*, 2018).

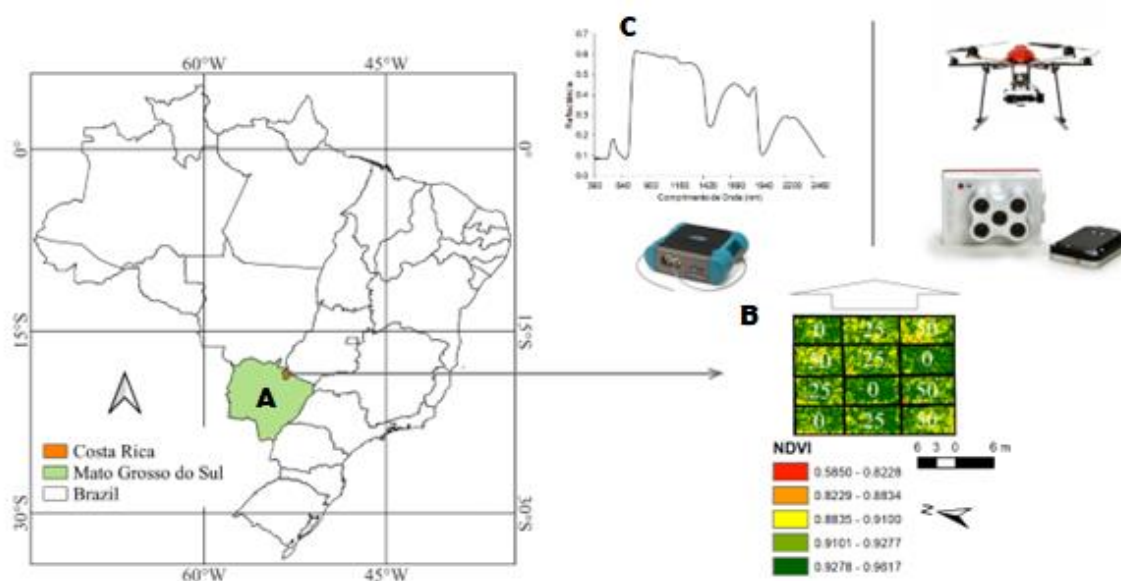


Figura 1. Localização de Costa Rica (A), projeto de parcela experimental (B) e equipamentos utilizados para obter as imagens (C).

A Figura 2 apresenta as condições climáticas do experimento ao longo do ciclo da cultura da soja. Foi observada uma temperatura média ao longo do ciclo de 21,39 °C e pluviosidade total de 1011,5 mm. Houve uma incidência maior de chuvas próximo aos 40 dias após a emergência das plantas e temperaturas amenas favorecendo a incidência da doença. Essa condição ambiental foi desejada para propiciar as condições de variabilidade nos tratamentos.

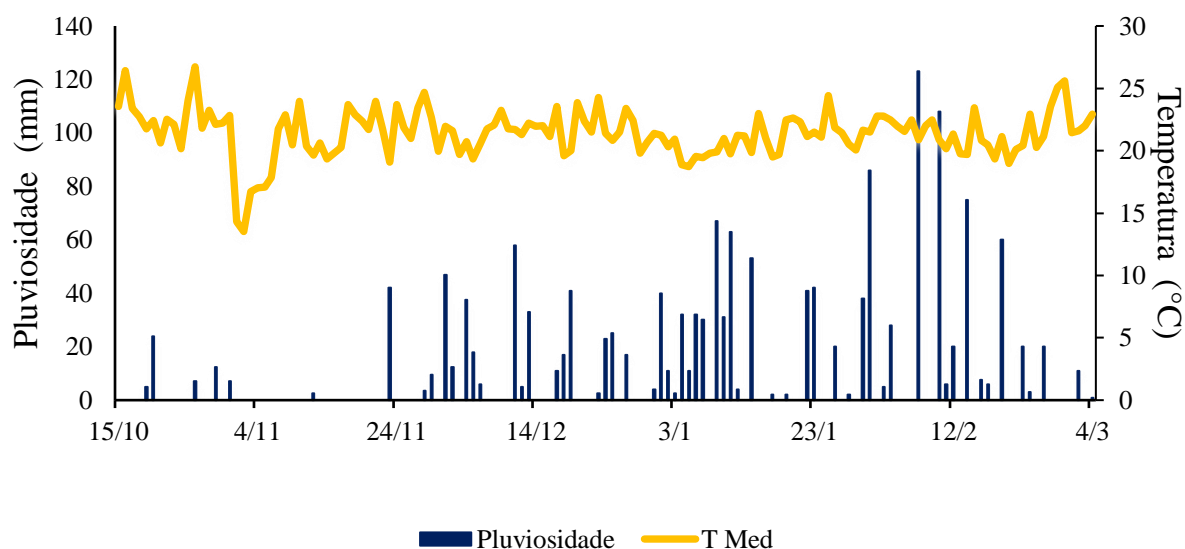


Figura 2. Condições pluviométricas e de temperatura média durante a condução do experimento.

Os dados obtidos através da análise química do solo na camada de 0-20 cm estão apresentados na Tabela 1. A adubação em conjunto com a semeadura foi realizada com 171 kg ha<sup>-1</sup> de 06-35-06 (N-P-K), também foi realizada aplicação de 83 kg ha<sup>-1</sup> de Cloreto de Potássio a lanço, antecedendo a semeadura. A semeadura foi realizada no dia 15 de outubro de 2022, utilizando a cultivar de soja M 5947 IPRO, contendo a tecnologia INTACTA RR2 PRO e apresentando maturidade relativa de 5.9, sendo assim, considerada super precoce (empresa 3Tentos).

Tabela 1. Resultados médios da análise química do solo.

pH	H+Al	Ca	Mg	Al	CTC	B	Cu	Fe	Mn	Zn	K	P	MO	Argila	V	m
cmolc dm <sup>-3</sup>					mg dm <sup>-3</sup>							g dm <sup>-3</sup>	%			
5,3	4,6	5,5	1,7	0,05	12,0	0,33	1,4	45,0	16,6	5,2	97,0	37,4	36,1	67	60,2	0,8

pH CaCl<sub>2</sub>; H + Al: Acidez potencial; Ca: Cálcio; Mg: Magnésio; Al: Alumínio; CTC: Capacidade de troca de cátions; B: Boro; Cu: Cobre; Fe: Ferro; Mn: Manganês; Zn: Zinco; K: Potássio; P: Fósforo (Mehlich); MO: Matéria Orgânica; Argila: Quantidade de argila; V: Saturação de base; m: Saturação por alumínio.

A semeadura da soja foi realizada posteriormente ao cultivo de algodoeiro (*Gossypium hirsutum* L.) na área, com população inicial de 377.774 plantas ha<sup>-1</sup>. A emergência das plântulas ocorreu no dia 20 de outubro de 2022. Durante a condução do experimento foram realizados todos os tratos culturais e manejo fitossanitário, em função do monitoramento e de acordo com as recomendações para a cultura, exceto a aplicação de fungicidas que foi realizada conforme os tratamentos (SEIXAS et al., 2020).

As parcelas foram constituídas por sete fileiras de soja, espaçadas em 0,45 m entre si, e com comprimento de 5,5 m, resultando em 17,3 m<sup>2</sup> de área total por parcela. A área útil utilizada para a coleta amostral foi composta por 4,0 m de comprimento da parcela das duas linhas centrais, totalizando 3,6 m<sup>2</sup>.

O delineamento experimental utilizado foi o de esquema fatorial 6 (algoritmos de aprendizagem de máquina) x 3 (severidade da doença) para as análises de inteligência artificial por aprendizado de máquina. Foram instaladas quatro parcelas experimentais por tratamento, as quais foram tratadas com diferentes fungicidas, induzindo aos diferentes níveis de severidade da doença: (1) 50% de área foliar com sintomas causados pela doença. Para se obter este nível de severidade, não houve aplicação de fungicidas Godoy et al. (2022); (2) 25% de área foliar lesionada, onde a redução da severidade foi assegurada pela aplicação de Piraclostrobina + Fluxapiraxade (116,55+58,45 g de ingrediente ativo por ha<sup>-1</sup>); e (3) folhas sadias, sem sintomas da doença, obtidas através da pulverização de Azoxistrobina + Protioconazol + Mancozeb (75+1050+75 g de ingrediente ativo por ha<sup>-1</sup>). Tais pulverizações foram realizadas com

intervalos de 15 dias tendo início aos 30 dias após a emergência (DAE), somando 3 aplicações no decorrer do ciclo da cultura.

No dia 18/01/2023, aos 88 dias após a emergência, estando a cultura em estágio fenológico R5.5 (Enchimento de grãos - 76 a 100% de granação - em um dos quatro nós superiores na haste principal), foram realizadas as coletas de folhas nas parcelas dos diferentes tratamentos. Foram obtidos 100 folíolos saudáveis, 100 folíolos com 25% de severidade e 100 folíolos com 50% de severidade, com base na escala diagramática elaborada por Soares et al. (2009). Estas amostras foram identificadas e transportadas em uma caixa de isopor do campo até o laboratório para que a turgescência dos folíolos fosse mantida.




Figura 3. Folhas saudáveis (A), com 25% de severidade de mancha alva (B) e 50% de severidade de mancha alva (C).

As análises por sensor hiperspectral de cada amostra de folha de soja foram realizadas no laboratório da Universidade Federal do Mato Grosso do Sul (Campus de Chapadão do Sul), utilizando o espectrorradiômetro FieldSpec 3 Jr da Analytical Spectral Devices (Boulder, EUA). Este equipamento tem a capacidade de realizar aferições espectrais em uma ampla faixa de 350 a 2500 nm. As leituras são registradas com um intervalo de 1,4 nm na faixa de 50 a 1050 nm e de 2 nm na faixa de 1000 a 2500 nm. As amostras foram mensuradas aplicando-se o leitor opcional ASD Plant Probe. Uma das principais vantagens desse opcional é que a leitura espectral não é afetada pela luminosidade do ambiente. Através da recomendação de Jensen (2009), os picos de leituras espectrais relacionadas com as principais características fisiológicas vegetais estão descritos na Tabela 2.

Tabela 2. Centro da banda espectral em função da característica vegetal.

Centro da banda espectral (nm)	Característica fisiológica vegetal
370	Fototropismo
420	a-caroteno
425	b-caroteno
430	Absorção de clorofila
440	a-caroteno
445	xantofila
445	Síntese de clorofila
450	b-caroteno
453	Clorofila b
470	a-caroteno
475	Clorofila b
480	a-caroteno
650	Síntese de clorofila
960	Absorção de clorofila
1100	Absorção de clorofila
1400	Absorção de água
1930	Absorção de água
2200	Pico de Al-OH , Mg-OH e CO <sub>3</sub>

Foram extraídas as bandas espectrais das repetições em cada tratamento, com o intuito de avaliar a melhor caracterização da doença em relação às características espectrais (se por bandas espectrais, Índices de Vegetação [IV], ou pelas reflectâncias diretas do sensor) e características fenológicas. A definição das bandas espectrais foi realizada baseada nos picos de reflectância do espectro eletromagnético na identificação das características fisiológicas vegetais (Tabela2).

O cálculo das bandas espectrais foi conduzido de acordo com a metodologia descrita por Silva Junior et al. (2018), utilizando os valores obtidos ao calcular a diferença entre os valores de reflectância no ponto de menor inflexão e no ponto de maior alcance subsequente. Os intervalos das bandas trabalhadas estão descritos na Tabela 3.

Tabela 3. Intervalos do espectro eletromagnético em cada banda trabalhada.

Banda (n)	Intervalo espectral (nm)
B1	390-420
B2	435-470
B3	480-550
B4	555-670
B5	680-750
B6	755-970
B7	1070-1120
B8	1270-1430
B9	1460-1650
B10	1850-1930
B11	2130-2460

No dia 20/01/2023, aos 90 dias após a emergência das plantas (90 DAE), estando a cultura em estágio reprodutivo R5.5, foram adquiridas as imagens espectrais por uma aeronave remotamente pilotada (ARP) utilizada como plataforma aérea para o sensor multiespectral. Foi utilizado a ARP XFly X800 equipada com uma câmera multiespectral Micasense, modelo Red-edge MX com 1280 x 960 pixels de resolução e com resolução espacial na cena correspondente a 0,06 m (em cada uma das bandas). O sistema mapeou imagens nas bandas do azul (B) (centro de 475 nm, largura de banda de 20 nm), verde (G) (centro de 560 nm, largura de banda de 20 nm), vermelho (R) (centro de 668 nm, largura de banda de 10 nm), borda do vermelho (RE) (centro de 717 nm, largura de banda de 10 nm), e infra-vermelho próximo (NIR) (centro de 840 nm, 40 nm de largura de banda). O sobrevoo foi realizado a 60 m de altitude local. As imagens foram ortoretificadas utilizando o programa Pix4D. Foi realizada a correção radiométrica baseada em um alvo reflexivo padrão. A manipulação dos mapas e a extração dos Índices de Vegetação foi realizada a partir das respectivas parcelas utilizando o programa de SIG ArcGis versão 10.5. As caracterizações destes Índices de Vegetação estão apresentadas na Tabela 4.

Tabela 4. Índices de vegetação calculados a partir dos valores de reflectância nas bandas espectrais do Red (668 nm), Green (560 nm), Red Edge (717 nm), Nir (840 nm) e Blue (475 nm) coletados pela câmera multiespectral.

Abreviação	Índice de vegetação	Equação	Referência
NDVI	Índice de vegetação de diferença normalizada	$\frac{(Nir - R)}{(Nir + R)}$	(ROUSE et al., 1974)
NDRE	Índice de borda vermelha de diferença normalizada	$\frac{(Nir - RE)}{(Nir + RE)}$	(GITELSON e MERZLYAK, 1994)
SAVI	Índice de Vegetação Ajustado ao Solo	$(1 + 0,5) \times \frac{(Nir - R)}{(Nir + R + 0,5)}$	(HUETE, 1988)
GNDVI	Índice de vegetação de diferença normalizada verde	$\frac{(Nir - G)}{(Nir + G)}$	(GITELSON e MERZLYAK, 1996)
EVI	Índice de Vegetação Aprimorado	$\frac{(Nir - R)}{((Nir + (6 \times R) - (7,5 \times B) + 1))}$	(HUETE, 1988)
MCCI	Índice modificado de conteúdo de clorofila da copa	$\frac{NDRE}{NDVI}$	(PERRY et al., 2018)

Nir: reflectância no infravermelho próximo; R: reflectância no vermelho; RE: reflectância de borda vermelha; G: reflectância no verde; B: reflectância no azul.

No dia 22/02/2023 foi realizada a colheita mecanizada do experimento utilizado como base de dados. Foi colhida a área amostral de 7,2 m<sup>2</sup> central de cada parcela. Foi utilizada uma colhedora adaptada para parcelas experimentais Massey Ferguson MF220. A partir dos grãos provenientes foi realizada a mensuração da umidade (%), peso de mil grãos e, também a

produtividade da área útil. A umidade foi corrigida a 13% e a massa de grãos extrapolada por hectare.

Através da semeadura utilizando uma cultivar de ciclo precoce, pôde-se isolar o fator mancha alvo sem a presença de outras doenças. Os dados obtidos através da reflectância, bandas e índices de vegetação foram submetidos a análise de aprendizado de máquina (Tabela 5). Sendo os parâmetros ajustados de acordo com as configurações padrão do software Weka 3.8.5.

Tabela 5. Modelos de aprendizado de máquina utilizados na classificação

<b>Sigla</b>	<b>Modelo de aprendizagem de máquinas</b>	<b>Referência</b>
ANN	Redes neurais artificiais	(EGMONT-PETERSEN, RIDDER, DE E HANDELS, 2002)
J48	Árvores de decisão J48	(QUINLAN, 1993)
LR	Regressão logística	(ŠTEPANOVSÝ et al., 2017)
DT	REPTree	(SNOUSY et al., 2011)
RF	Floresta aleatória	(BELGIU e DRĂGUȚ, 2016)
Rt	Random Tree	(KALMEGH, 2015)
SVM	Máquina de vetor suporte	(NALEPA e KAWULOK, 2019)

A eficácia do modelo de aprendizado de máquina foi avaliada utilizando métricas de desempenho, incluindo a taxa de classificações corretas (CC), o F-score e o coeficiente Kappa. A performance dos modelos foi então submetida a uma análise de variância para investigar se existiam diferenças significativas entre as variáveis e os modelos de aprendizado de máquina, bem como para avaliar a interação entre eles.

Os dados obtidos foram submetidos à análise de variância e ao se obter diferenças significativas, boxplots foram criados para se visualizar as médias, agrupadas de acordo com o teste de Scott-Knott (SCOTT e KNOTT, 1974), com um nível de significância de 5%. Todas as bandas, índices de vegetação e dados de produtividade obtidos em parcelas com folhas sadias e com níveis de 25 e 50% de severidade foram submetidos a análise multivariada através do teste de variáveis canônicas. O agrupamento das médias por Scott-Knott e análise multivariada de variáveis canônicas foram realizadas utilizando o software Rbio (BHERING, 2017), enquanto os boxplots foram formados através da utilização dos pacotes ggplot2 e ExpDes.pt do software R.

## RESULTADOS E DISCUSSÃO

Os níveis de severidade de doença apresentaram curvas hiperespectrais distintas entre si (Figura 3). É notável que na região do visível a maior reflectância ocorreu nas folhas com maior nível de severidade (50%), enquanto que a menor reflectância foi nas folhas sadias,

especialmente nos comprimentos de onda 508-700 nm correspondentes também entre as bandas B3, B4 e B5. Na região NIR a severidade de 50% apresentou baixas reflectâncias entre os comprimentos de onda 725-794 nm elevando sua reflectância a partir desse ponto até as bandas do infravermelho de ondas curtas (SWIR), sendo bem representado pela banda B6, B7 e B8. O nível de severidade de 25% apresentou aumento na reflectância entre as bandas 725-1346 nm e ficando intermediário nas faixas do SWIR. As folhas saudias apresentaram reflectância similar ao nível de severidade de 25% entre os comprimentos de onda 725-863 nm e superior ao nível maior da incidência, diminuindo a reflectância a partir desse ponto até o SWIR.

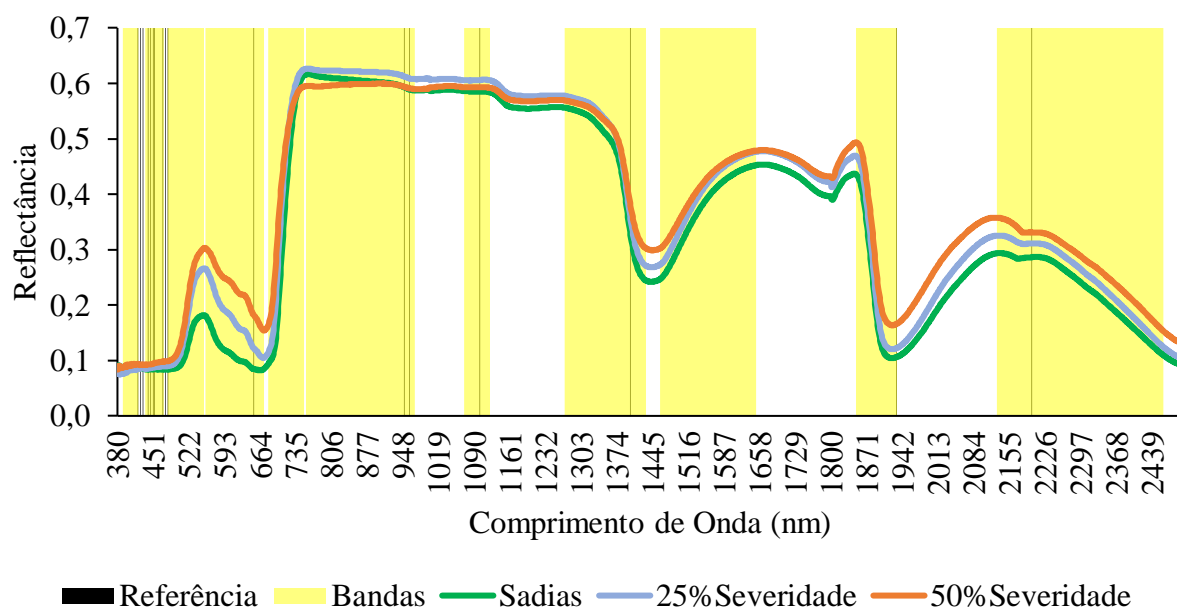


Figura 3. Assinatura espectral para cada nível de severidade de doença macha-alvo na cultura da soja.

O comportamento biofísico e bioquímico do tecido vegetal é alterado devido a presença da doença, que causa modificações na cor dos tecidos, formato das folhas, na taxa de transpiração, morfologia e densidade das folhas resultando em propriedades ópticas modificadas do tecido foliar, ou seja, alterando sua reflectância (MAHLEIN, 2016; WEST et al., 2010). A composição e o conteúdo dos pigmentos são modificados quando as folhas são expostas a patógenos que causam sintomas como o amarelecimento e necrose dos seus tecidos (MAHLEIN, 2016), como é o caso da macha-alvo.

Na faixa do visível (VIS) entre os comprimentos de onda 400-700 nm apresentou menor reflectância devido a absorção da clorofila e outros pigmentos (CHRISTENSON et al., 2014). Assim como apresentado na tabela de referência, em que a região do visível está mais relacionado com os pigmentos fotossintetizantes como a clorofila, antocianina e carotenos. Desta forma, esta faixa é importante como indicativo para a detecção de alterações



na coloração das folhas causadas por doenças e estresse em plantas (ZAHIR et al., 2022). Portanto, a menor reflectância de folhas saudáveis é devido a alta absorção de luz pelos pigmentos para realizar a fotossíntese, e a maior reflectância das folhas das plantas doentes pela doença se deve aos danos causados aos pigmentos, afetando negativamente sua função na planta e alterando sua reflectância nessa faixa (MOREIRA, 2005).

Essa relação se inverte nas bandas ao redor do comprimento de onda NIR (~ 740-770 nm). Na região do visível, quanto maior a severidade da doença, maior será a reflectância, mas, na região NIR, haverá uma maior reflectância nas folhas mais saudáveis (NEGRISOLI et al., 2022). De maneira geral plantas saudáveis apresentam baixa reflectância na região do visível e infravermelho médio e alta reflectância no NIR (AHMED et al., 2020). Tal comportamento foi parcialmente observado nas assinaturas hiperespectrais apresentados na Figura 3, com exceção da faixa de 725-863 nm, a qual apresentou pico de reflectância das folhas saudáveis similar as folhas com nível de 25% de severidade. Assim, (Índices de vegetação) IVs calculados a partir da reflectância dessas faixas do VIS e do NIR podem fornecer estimativas mais precisas da concentração de clorofila, garantindo resultados mais precisos quanto a atividade fotossintética da planta (CHO et al., 2012).

A alteração observada na assinatura espectral no nível de severidade de 25% quando comparada as folhas saudáveis pode fornecer informações precoces quanto a alteração bioquímica da folha causada pela doença, sendo a utilização de sensor hiperespectral importante na implementação de estratégias eficazes para diagnosticar a mancha alvo e prevenir perdas maiores de produtividade na lavoura (ZAHIR et al., 2022).

Na região do SWIR é notável uma expressão maior de reflectância no maior nível de severidade da doença, isso porque essa faixa tem associação com a composição química da folha e com o seu teor de água (CARTER e KNAPP, 2001; JUNGES et al., 2020). Diversos trabalhos relatam o aumento de reflectância na região do SWIR em folhas com maior grau de severidade de doenças como oídio, vírus do enrolamento da folha da videira e ferrugem devido à perda de água pelas lesões (HEIM et al., 2018; JUNGES et al., 2020; KNAUER et al., 2017). Estes autores em estudos realizados com uva também relataram uma mudança entre as assinaturas espectrais médias de bagas destacadas saudáveis e aquelas com infecção grave por oídio devido à maior reflectância das bagas doentes em toda a região SWIR, sendo bem representados pelas bandas B9, B10 e B11.

Segundo a análise de variáveis canônicas (Figura 6A), utilizando as informações de reflectância provenientes do sensor hiperespectral, as folhas saudáveis apresentaram maior correlação positiva com a variabilidade dos IVs NDRE e GNDVI. As folhas com 25% de

severidade apresentaram maior relação de variabilidade mais próximas das bandas 680-750 nm e 1460-1650nm. Folhas com maior severidade de ataque apresentaram maior relação positiva direta com as bandas 435-470 nm, 2130-2460 nm e 1850-1930 nm, assim como foi apresentado pela Figura 3, pela qual se observa elevação dos valores de reflectância na região dessas bandas, segundo a análise da assinatura hiperspectral das folhas de soja.

É notável a relação positiva entre a variabilidade dos dados apresentados pela Figura 6B, quando se analisa o comportamento da reflectância mensurada nas folhas sadias e a produtividade da cultura. Essa relação também é positiva quando se analisa a proximidade dessas variáveis com os vetores SAVI, EVI, 840 nm e peso de grãos. Tanto os dados provenientes do sensor hiper quanto os dados mensurados com o sensor multiespectral apresentaram relação direta e positiva entre a variável produtividade e os níveis de severidade de ataque da doença. Portanto, na outra contraparte, folhas provenientes das plantas com maior severidade apresentaram menor produtividade. A variabilidade dos dados provenientes de folhas com 25% de severidade apresentou proximidade com os comprimentos de onda na região do visível 475 nm, 560 nm, 668 nm, 717 nm.

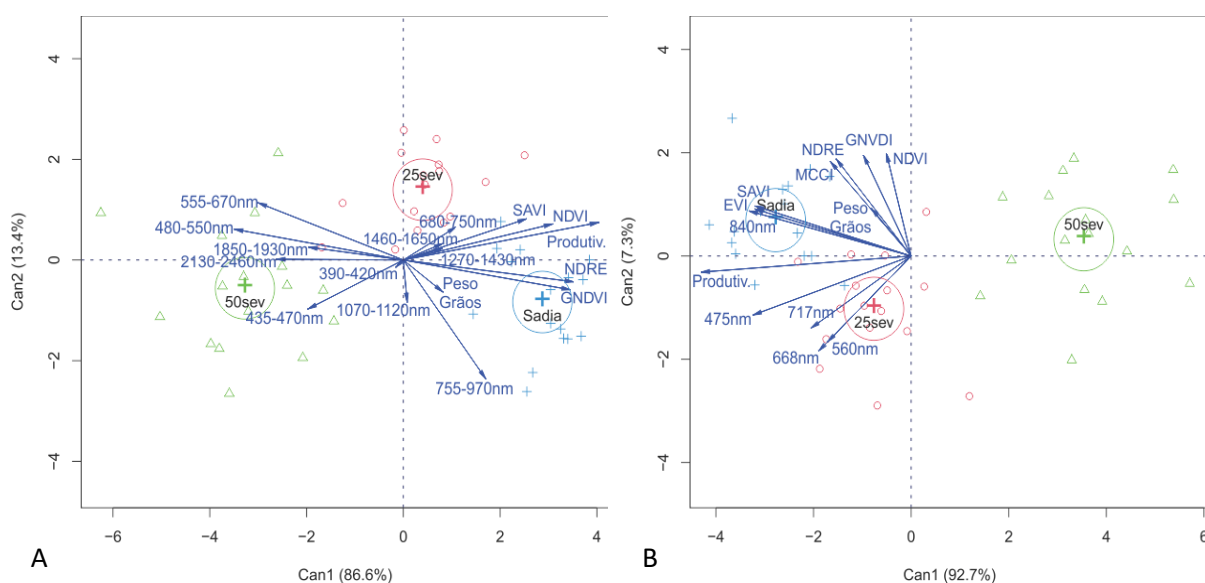


Figura 4. Variáveis canônicas relacionando bandas espectrais baseadas em sensor hiperspectral (A) e índices de vegetação baseados em sensor multiespectral (B) com os níveis de severidade da mancha alvo, produtividade e peso de grãos.

A detecção, identificação e quantificação de doenças de plantas utilizando sensores permitem que haja manejos mais adequados no controle, já que os sensores são sensíveis, precisos e de fácil manuseio para a avaliação de doenças (MAHLEIN et al., 2012). A escolha do tipo de sensor a ser utilizado dependerá dos recursos para a obtenção deles, visto que

sensores multiespectrais são de mais fácil aquisição do ponto de vista econômico. Na análise de variáveis canônicas nota-se que para o sensor multiespectral apresentou resultados com maior relação entre as folhas saudas e o peso de grãos, ambos próximos dos IVs SAVI e EVI, e do comprimento de onda de 840 nm. Assim, a utilização desse sensor com esses IVs apresenta maior sensibilidade para a estimativa de possíveis variações de produtividades em plantas saudas.

De forma geral os níveis de severidade da doença apresentaram diferenças entre si, e as respostas espectrais das suas reflectâncias geraram assinaturas espectrais distintas. Portanto, como próximo passo na sequência de análises, os dados adquiridos por ambos os sensores foram submetidos a análise de aprendizagem de máquina com o intuito de caracterizar o melhor algoritmo na classificação nos níveis de severidade da mancha alvo em soja. Foram utilizados seis algoritmos de ML e três diferentes configurações de entrada, havendo interação significativa entre elas (Tabela 6) para as três métricas de acurácia testadas Classificação correta (CC), F-score e Kappa.

Tabela 6. Resumo da análise de variância para as variáveis Classificação correta (CC), F-score e Kappa.

F.V.	G.L.	CC	Kappa	F-score
VE	2	489,05*	0,1091*	0,1037*
ML	5	423,68*	0,0963*	0,0274*
VE*ML	10	202,02*	0,0454*	0,0116*
Resíduo	162	5,4300	0,0012	0,0007
CV (%)		3,16	5,82	3,14

VE – Variáveis de entrada, ML – aprendizagem de máquinas, CV- coeficiente de variação

Para a métrica classificação correta e kappa (Figura 5) comparando os algoritmos utilizando como entradas as bandas o melhor desempenho foi observado para RL e RNA. Quando utilizado IVs RNA teve a melhor acurácia quando comparado aos demais algoritmos. Utilizando todos os valores de reflectância fornecido pelo sensor RL e SVM apresentaram melhores resultados. Comparando os três inputs dentro dos algoritmos todos tiveram melhor resposta utilizando todas as informações de reflectância do sensor.

Para a métrica Fscore utilizando bandas como input a melhor resposta foi para os algoritmos RF, RL, RNA e SVM. Utilizando IVs como entrada RL e RNA apresentaram melhores respostas. Utilizando todas as informações fornecidas pelo sensor RL e SVM tiveram

melhores resultados. Comparando os três inputs dentro de cada algoritmo J48, RF e RNA foram melhores utilizando as bandas. REPTree e RL tiveram as mesmas respostas utilizando bandas ou reflectância. SVM alcançou melhor acurácia utilizando reflectâncias.

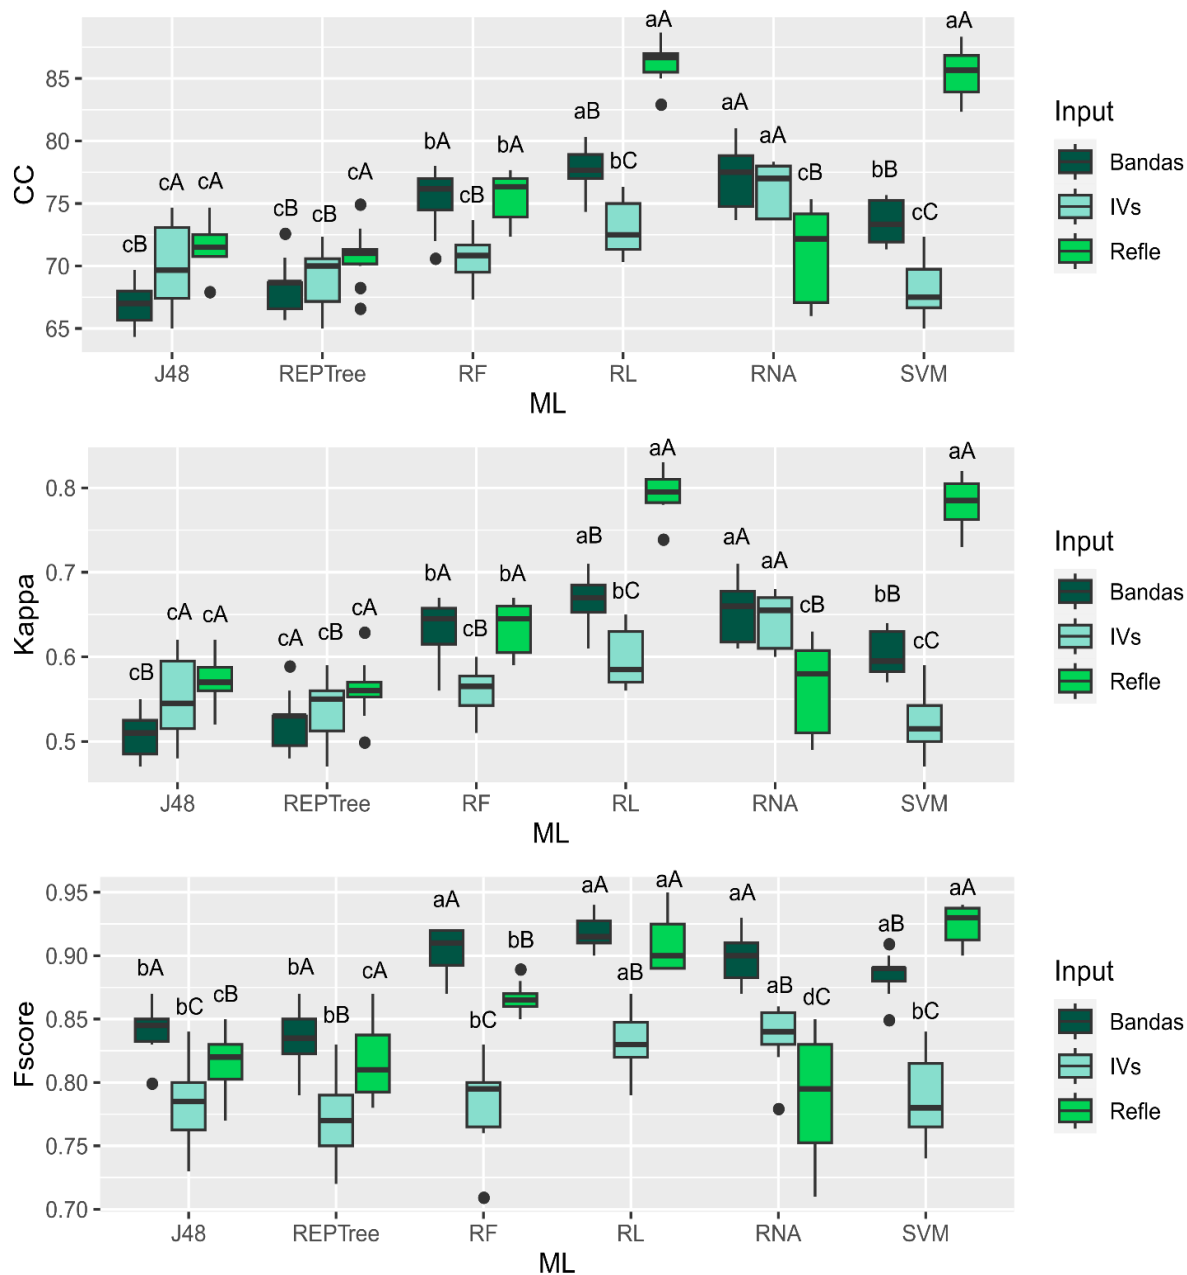


Figura 5. Gráfico de caixa para as métricas de acurácia classificação correta (CC), Kappa e F-score para os modelos de aprendizado de máquinas para as severidades de mancha alvo em soja.

De uma forma geral, os algoritmos que demonstram melhores resultados para as três métricas foram RL e SVM utilizando reflectâncias, ou seja, usando todas as informações da faixa espectral fornecida pelo sensor. Bose et al. (2021) encontram altos valores de acurácia na classificação de folhas doentes e saudáveis com o algoritmo SVM, assim como Kaur et al., (2022), utilizando RL encontram um modelo de detecção de doenças. O SVM tem se mostrado

um algoritmo eficaz em várias tarefas de classificação como na classificação de genótipos de soja quanto ao teor de macronutrientes primários (SANTANA et al., 2023) ou quanto classificar genótipos de soja segundo seus teores industriais de grão (SANTANA et al., 2023) e em ambos os trabalhos utilizar as informações brutas fornecidas pelo sensor garantiu melhor resultado para o algoritmo.

Nos resultados apresentados tanto o uso de RL quanto SVM propõe boa classificação com alta acurácia para identificar níveis de severidade da mancha alvo em soja utilizando toda a faixa de reflectância das plantas. Os dados hiperespectrais possibilitam uma caracterização detalhada do objeto de estudo, permitindo, a assimilação de intervalos espectrais específicos para a detecção de doenças e, em conformidade com as especificações de cada nível de severidade em cada tipo de doença (SILVA et al., 2021).

As plantas sadias e com o nível de 25% de severidade tiveram o mesmo comportamento para o NDVI, pois, quanto se tem este nível de severidade ainda não é possível observar sintomas no terço superior, dificultando a captura de diferenças pela multiespectral.

A utilização de índices de vegetação advindos de cálculos da faixa do VIS/NIR podem ser eficientes no monitoramento agrícola de doenças, podendo detectar alterações na vegetação oriundos do ataque da doença (ARANTES et al., 2019). O Índice de Vegetação por Diferença Normalizada (NDVI) é destaque entre os índices de vegetação utilizados na agricultura no monitoramento da sanidade (GOLHANI et al., 2018). As variações espectrais captadas pelos NDVI são devidas as diferenças na arquitetura da planta provocada pela doença, como, amarelecimento e outros sintomas (BRAVO et al., 2003), tal comportamento pode ter sido similar entre plantas sadias e com o nível de 25% de severidade para ambas terem tido o mesmo comportamento.

A partir dos dados obtidos neste experimento, mensurou-se as perdas causadas pela mancha alvo na cultivar de soja empregada. Plantas com 25% de severidade da doença tiveram redução de aproximadamente 5.9 % na produtividade, enquanto aquelas com 50% de severidade tiveram uma redução de aproximadamente 23.5 % na produtividade de grãos. Estes dados estão em concordância com MOLINA et al. (2018), que estimou uma redução de produtividade de 8 a 42 % em diferentes cultivares que se estavam com 50% de severidade da mancha alvo.

A produtividade é afetada pela doença devido a diminuição da área fotossintética prejudicando a formação e o enchimento de grãos. Dessa forma, a utilização de técnicas de sensoriamento remoto podem ser promissoras na detecção de doenças precocemente no campo permitindo a ação rápida de controle (ARANTES et al., 2019).

Entretanto, através dos dados obtidos neste trabalho, é válido salientar que o uso do sensor multiespectral pode apresentar algumas limitações, visto que a doença se inicia nas folhas mais velhas da cultura. Com isso, dificultai a captura de imagens de folhas que ficaram recentemente doentes e uma diagnose mais precoce, que evitaria perdas. Porém, este fato pode não ocorrer no caso de doenças que manifestam sintomas reflexos, em folhas distantes do local de atuação do patógeno, que pode ser detectada em imagens.

Com os resultados obtidos podemos observar que existe a possibilidade de identificar a presença da doença a campo utilizando as ferramentas demonstradas no texto, porém, é necessário que se faça novos estudos para confirmar a usabilidade e eficácia dos modelos a campo. Também existe a necessidade de se obter informações com outras doenças e demais culturas, trazendo enormes benefícios para a agricultura.

## CONCLUSÕES

A identificação da mancha alvo utilizando sensores multiespectral e hiperspectral é um trabalho complexo e a escolha do sensor está diretamente ligada ao emprego da ferramenta, a disponibilidade de recursos financeiros e o tempo disponível para obtenção dos resultados.

Ao utilizar a multiespectral, podemos ter um custo menor e uma maior agilidade na obtenção dos resultados, porém, em função a dificuldades na identificação precoce da doença. Quando utilizamos sensor hiperspectral podemos obter melhores resultados na identificação da doença, porém, demanda investimento financeiro e tempo para obtenção dos resultados.

Os algoritmos RL e SVM apresentaram melhor desempenho para identificação da mancha alvo. A melhor entrada para os algoritmos de ML foi ao utilizar reflectância como entrada para os algoritmos, obtendo melhor desempenho. Portanto, o uso de reflectância nos algoritmos RL e SVM permite uma classificação precisa da mancha alvo.

Os dados obtidos do sensor hiperspectral e multiespectral apresentaram relação direta e positiva entre a variável produtividade e os níveis de severidade de ataque da doença.

## REFERÊNCIAS

- AHMED, M.; SERAJ, R.; ISLAM, S. M. S. The k-means algorithm: A comprehensive survey and performance evaluation. **Electronics**, v. 9, n. 8, p. 1295, 2020.
- ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138–146, 2013.
- ARANTES, B. H. T.; MARTINS, G. D.; CARVALHO, E. R.; NOGUEIRA, L. C. A. Identificação de ferrugem na soja por meio de imagens de alta resolução espacial. **Revista Brasileira de Geografia Física**, v. 12, n. 03, p. 1003–1016, 2019.
- BAJWA, S. G.; RUPE, J. C.; MASON, J. Soybean disease monitoring with leaf reflectance. **Remote Sensing**, v. 9, n. 2, p. 127, 2017.
- BELGIU, M.; DRĂGUȚ, L. Random Forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BHERING, L. L. Rbio: A tool for biometric and statistical analysis using the R platform. **Crop Breeding and Applied Biotechnology**, v. 17, p. 187–190, 2017.
- BOSE, P.; DUTTA, S.; GOYAL, V.; BANDYOPADHYAY, S. K. Leaf Diseases Detection of Medicinal Plants Based on Support Vector Machine Classification Algorithm. **Journal of Pharmaceutical Research International**, v. 33, n. 42A, p. 111–119, 2021.
- BRAVO, C.; MOSHOU, D.; WEST, J.; MCCARTNEY, A.; RAMON, H. Early disease detection in wheat fields using spectral reflectance. **Biosystems Engineering**, v. 84, n. 2, p. 137–145, 2003.
- CARTER, G. A.; KNAPP, A. K. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. **American journal of botany**, v. 88, n. 4, p. 677–684, 2001.
- CHOU, S.; CHEN, B.; CHEN, J.; WANG, M.; WANG, S.; CROFT, H.; SHI, Q. Estimation of leaf photosynthetic capacity from the photochemical reflectance index and leaf pigments. **Ecological Indicators**, v. 110, p. 105867, 2020.
- CHRISTENSON, B. S.; SCHAPAUGH JR., W. T.; AN, N.; PRICE, K. P.; FRITZ, A. K. Characterizing Changes in Soybean Spectral Response Curves with Breeding Advancements. **Crop Science**, v. 54, n. 4, p. 1585–1597, 1 jul. 2014.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of photogrammetry and remote sensing**, v. 92, p. 79–97, 2014.
- DIXON, L. J.; SCHLUB, R. L.; PERNEZNY, K.; DATNOF, L. E. Host specialization and phylogenetic diversity of *Corynespora cassiicola*. **Phytopathology**, v. 99, p. 1015–1027, 2009.
- EDWARDS MOLINA, J. P.; PAUL, P. A.; AMORIM, L.; SILVA, L. H. C. P.; SIQUERI, F. V.; BORGES, E. P.; CAMPOS, H. D.; VENANCIO, W. S.; MEYER, M. C.; MARTINS, M. C.; BALARDIN, R. S.; CARLIN, V. J.; GRIGOLLI, J. F. J.; BELUF, L. M. D. R.; NUNES

JUNIOR, J.; GODOY, C. V. Efect of target spot on soybean yield and factors affecting this relationship. **Plant Pathology**, v. 68, p.107–115, 2019

EGMONT-PETERSEN, M.; RIDDER, D. DE; HANDELS, H. Image processing with neural networks—a review. **Pattern Recognition**, v. 35, n. 10, p. 2279–2301, 2002.

FARBER, C.; MAHNKE, M.; SANCHEZ, L.; KUROUSKI, D. Advanced spectroscopic techniques for plant disease diagnostics. A review. **TrAC Trends in Analytical Chemistry**, v. 118, p. 43–49, 2019.

GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, v. 148, n. 3, p. 494–500, 1996.

GITELSON, A.; MERZLYAK, M. N. Spectral Reflectance Changes Associated with Autumn Senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. Leaves. Spectral Features and Relation to Chlorophyll Estimation. **Journal of Plant Physiology**, v. 143, n. 3, p. 286–292, 1994.

GODOY, C. V.; UTIAMADA, C. M.; MEYER, M. C.; CAMPOS, H. D.; LOPES, I. de O. N.; TOMEN, A.; FARIAS, A. de; MUHL, A.; SICHOCKI, D.; MOREIRA, E. N.; KONAGESKI, F. T.; BONANI, J. C.; ROY, J. M. T.; NUNES JUNIOR, J.; KUDLAWIEC, K.; BELUFI, L. M. de R.; FANTIN, L. H.; LIMA, L. A. de S.; SILVA, L. H. C. P. da; ARAUJO JUNIOR, I. P.; GOUSSAIN JUNIOR, M. M.; GARBIATE, M. V.; MÜLLER, M. A.; MARTINS, M. C.; TORMEN, N. R.; KONAGESKI, T. F.; MOCHKO, A. C. R. Eficiência de fungicidas para o controle da mancha-alvo, *Corynespora cassiicola*, na cultura da soja, na safra 2021/2022: resultados sumarizados dos ensaios cooperativos. **Circular Técnica**. Londrina, PR. Embrapa Soja, n. 182, p. 1-12, 2022.

GOLHANI, K.; BALASUNDRAM, S. K.; VADAMALAI, G.; PRADHAN, B. A review of neural networks in plant disease detection using hyperspectral data. **Information Processing in Agriculture**, v. 5, n. 3, p. 354–371, 2018.

HEIM, R. H. J.; WRIGHT, I. J.; CHANG, H.; CARNEGIE, A. J.; PEGG, G. S.; LANCASTER, E. K.; FALSTER, D. S.; OLDELAND, J. Detecting myrtle rust (*Austropuccinia psidii*) on lemon myrtle trees using spectral signatures and machine learning. **Plant pathology**, v. 67, n. 5, p. 1114–1121, 2018.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective 2/e**. [s.l.] Pearson Education India, 2009.

JUNGES, A. H.; ALMANÇA, M. A. K.; FAJARDO, T. V. M.; DUCATI, J. R. Leaf hyperspectral reflectance as a potential tool to detect diseases associated with vineyard decline. **Tropical Plant Pathology**, v. 45, n. 5, p. 522–533, 2020.

KALMEGH, S. **Analysis of WEKA Data Mining Algorithm REPTree, Simple Cart and RandomTree for Classification of Indian News** **IJSET-International Journal of Innovative Science, Engineering & Technology**. [s.l.: s.n.]. Disponível em: <www.ijset.com>.



- KAUR, P.; HARNAL, S.; TIWARI, R.; UPADHYAY, S.; BHATIA, S.; MASHAT, A.; ALABDALI, A. M. Recognition of leaf disease using hybrid convolutional neural network by applying feature reduction. **Sensors**, v. 22, n. 2, p. 575, 2022.
- KNAUER, U.; MATROS, A.; PETROVIC, T.; ZANKER, T.; SCOTT, E. S.; SEIFFERT, U. Improved classification accuracy of powdery mildew infection levels of wine grapes by spatial-spectral analysis of hyperspectral images. **Plant Methods**, v. 13, n. 1, p. 1–15, 2017.
- KOC, A.; ODILBEKOV, F.; ALAMRANI, M.; HENRIKSSON, T.; CHAWADE, A. Predicting yellow rust in wheat breeding trials by proximal phenotyping and machine learning. **Plant Methods**, v. 18, n. 1, p. 30, 2022.
- 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.
- MAHLEIN, A.-K.; OERKE, E.-C.; STEINER, U.; DEHNE, H.-W. Recent advances in sensing plant diseases for precision crop protection. **European Journal of Plant Pathology**, v. 133, n. 1, p. 197–209, 2012.
- MOLINA, J. P.; PAUL, P. A.; AMORIM, L.; SILVA, L. DA; SIQUERI, F. V; BORGES, E. P.; CAMPOS, H. D.; VENANCIO, W. S.; MEYER, M. C.; MARTINS, M. C. Effect of target spot on soybean yield and factors affecting this relationship. **Plant Pathology**, v. 68, n. 1, p. 107–115, 2019.
- MOREIRA, M. A. Fundamentos do Sensoriamento Remoto e metodologias de aplicação. 3<sup>o</sup> Edição. **UFV**, 2005.
- NALEPA, J.; KAWULOK, M. Selecting training sets for support vector machines: a review. **Artificial Intelligence Review**, v. 52, n. 2, p. 857–900, 2019.
- NEGRISOLI, M. M.; NEGRISOLI, R.; SILVA, F. DA; LOPES, L. S.; SOUZA JÚNIOR, F. S. DE; VELINI, E. D.; CARBONARI, C. A.; RODRIGUES, S. A.; RAETANO, C. G. Soybean rust detection and disease severity classification by remote sensing. **Agronomy Journal**, v. 114, n. 6, p. 3246–3262, 1 nov. 2022.
- PERRY, E. M.; GOODWIN, I.; CORNWALL, D. Remote Sensing Using Canopy and Leaf Reflectance for Estimating Nitrogen Status in Red-blush Pears. **HortScience horts**, v. 53, n. 1, p. 78–83, 2018.
- QUINLAN, J. R. C4. 5: Programming for machine learning. **Morgan Kauffmann**, v. 38, n. 48, p. 49, 1993.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, n. 1974, p. 309, 1974.
- SANTANA, D. C.; TEIXEIRA FILHO, M. C. M.; SILVA, M. R. DA; CHAGAS, P. H. M. DAS; OLIVEIRA, J. L. G. DE; BAILO, F. H. R.; CAMPOS, C. N. S.; TEODORO, L. P. R.; SILVA JUNIOR, C. A. DA; TEODORO, P. E. Machine Learning in the Classification of Soybean Genotypes for Primary Macronutrients' Content Using UAV–Multispectral Sensor. **Remote Sensing**, v. 15, n. 5, p. 1457, 2023.
- SANTANA, D. C.; TEODORO, L. P. R.; BAILO, F. H. R.; SANTOS, R. G. DOS; CORADI, P. C.; BIDUSKI, B.; SILVA JUNIOR, C. A. DA; TEODORO, P. E.; SHIRATSUCHI, L. S.

Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. **Remote Sensing Applications: Society and Environment**, p. 100919, 2023.

SANTOS, H. G. DOS; JACOMINE, P. K. T.; ANJOS, L. H. C. DOS; OLIVEIRA, V. A. DE; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. DE; ARAUJO FILHO, J. C. DE; OLIVEIRA, J. B. DE; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos**. [s.l.] Brasília, DF: Embrapa, 2018., 2018.

SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the analysis of variance. **Biometrics**, p. 507–512, 1974.

SILVA BARROS, P. P. DA; ROSALEN, D. L.; IOST FILHO, F. H.; MARTINS, G. D.; LEO, N. DI. Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Rev. Bras. Cartogr**, v. 73, n. 2, 2021.

SILVA JUNIOR, C. A. DA; NANNI, M. R.; SHAKIR, M.; TEODORO, P. E.; OLIVEIRA-JÚNIOR, J. F. DE; CEZAR, E.; GOIS, G. DE; LIMA, M.; WOJCIECHOWSKI, J. C.; SHIRATSUCHI, L. S. Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics & Technology**, v. 89, p. 338–350, 2018.

SHAHI, T. B.; XU, C. Y.; NEUPANE, A.; GUO, W. Recent Advances in Crop Disease Detection Using UAV and Deep Learning Techniques. **Remote Sens**. v, 15, p. 1-29, 2023.

SNOUSY, M. B. AL; EL-DEEB, H. M.; BADRAN, K.; KHLIL, I. A. AL. Suite of decision tree-based classification algorithms on cancer gene expression data. **Egyptian Informatics Journal**, v. 12, n. 2, p. 73–82, 2011.

SOARES, R. M.; GODOY, C. V.; OLIVEIRA, M. C. N. DE. Escala diagramática para avaliação da severidade da mancha alvo da soja. **Tropical Plant Pathology**, v. 34, p. 333–338, 2009.

SEIXAS, S.; DINALI, C.; ALVADI, N. N.; BALBINOT, A.; FRANCISCO, J.; KRZYZANOWSKI, C.; VILLAS, R. M.; DE, B.; LEITE, C.; TÉCNICOS, E. Sistemas de Produção 17. Tecnologias de produção de soja. 2020.

ŠTEPANOVSKÝ, M.; IBROVÁ, A.; BUK, Z.; VELEMÍNSKÁ, J. Novel age estimation model based on development of permanent teeth compared with classical approach and other modern data mining methods. **Forensic Science International**, v. 279, p. 72–82, 2017.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791–797, 2015.

WEST, J. S.; BRAVO, C.; OBERTI, R.; MOSHOU, D.; RAMON, H.; MCCARTNEY, H. A. Detection of fungal diseases optically and pathogen inoculum by air sampling. **Precision crop protection-the challenge and use of heterogeneity**, p. 135–149, 2010.

ZAHIR, S. A. D. M.; OMAR, A. F.; JAMLOS, M. F.; AZMI, M. A. M.; MUNCAN, J. A review of visible and near-infrared (Vis-NIR) spectroscopy application in plant stress detection. **Sensors and Actuators A: Physical**, v. 338, p. 113468, 2022.