

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

VITÓRIA FÁTIMA BERNARDO

**RESPOSTA HIPERESPECTRAL DO ALGODOEIRO EM FUNÇÃO DA
SEVERIDADE DA MANCHA ALVO**

CHAPADÃO DO SUL – MS

2024

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

VITÓRIA FÁTIMA BERNARDO

**RESPOSTA HIPERESPECTRAL DO ALGODOEIRO EM FUNÇÃO DA
SEVERIDADE DA MANCHA ALVO**

Orientador: Prof. Dr. Gustavo de Faria Theodoro

Co-orientadora: Dra. Dthenifer Cordeiro Santana

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

2024



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



PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

CERTIFICADO DE APROVAÇÃO

DISCENTE: Vitória Fátima Bernardo

ORIENTADOR: Dr. Gustavo de Faria Theodoro

TÍTULO: Resposta hiperespectral do algodoeiro em função da severidade da mancha alvo.

AVALIADORES:

Prof. Dr. Gustavo de Faria Theodoro

Prof. Dra. Larissa Pereira Ribeiro Teodoro

Prof. Dra. Solange Maria Bonaldo

Chapadão do Sul, 12 de dezembro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Gustavo de Faria Theodoro, Professor do Magisterio Superior**, em 12/12/2024, às 15:16, 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 **SOLANGE MARIA BONALDO, Usuário Externo**, em 12/12/2024, às 15:33, 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 **Larissa Pereira Ribeiro, Professora do Magistério Superior**, em 13/12/2024, às 08:19, 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, informando o código verificador **5314711** e o código CRC **5D8BCD93**.

AGRADECIMENTOS

Agradeço primeiramente a Deus, que, com sua infinita bondade, me deu forças para realizar esse sonho e me mostrou que para conquistar meus objetivos preciso apenas de fé e determinação.

À minha mãe, Alessandra Manoela Bernardo, e ao meu “paidrasto”, Arnaldo Gomes da Silva, que sempre acreditaram em mim e não me deixaram desistir desse passo tão importante para minha vida e carreira profissional. Se cheguei aonde cheguei hoje é graças ao esforço dessas duas pessoas, que escolheram investir em mim e sonhar os mesmos sonhos que eu.

Ao meu melhor amigo Henrique Moura Barbosa, que, desde 2017, ainda no início da graduação, sempre se fez presente e que, sem sombra de dúvidas, é uma das pessoas que mais acreditou em mim nesse processo. Agradeço também às minhas companheiras diárias de trabalho Camila Crispim, Gabriela Diniz, Laurize Danielle, Kelly Silva e Raquel Dias que incentivaram esse sonho e me tiraram risadas até mesmo em dias de maior preocupação.

À Desafios agro, em especial ao pesquisador Alfredo Riciere Dias e à equipe de fitopatologia que atuaram na condução deste trabalho em campo.

Ao Prof. Dr. Gustavo de Faria Theodoro e à Dra. Dthenifer Cordeiro Santana pela orientação, ensinamentos e apoio durante todo esse período.

À Prof. Dra. Larissa Pereira Ribeiro Teodoro e Prof. Dra. Solange Maria Bonaldo por aceitarem fazer parte da banca e assim colaborarem com sua experiência e conhecimento.

À Universidade Federal de Mato Grosso do Sul, campus de Chapadão do Sul, e ao Programa de Pós-graduação em Agronomia que possibilitaram a concretização desse objetivo. E a todos aqueles que direta, ou indiretamente, fizeram parte dessa etapa em minha vida. A todos vocês o meu “Muito obrigada!”.

Epígrafe

“É necessário viver o processo, para poder alcançar o propósito.”

-Ana Paula Cordeiro.

RESUMO: Buscando impedir perdas produtivas ocasionadas por patógenos nas lavouras, técnicas de monitoramento por meio de imagens hiperespectrais têm se mostrado promissoras, visto sua capacidade de diagnosticar doenças de forma precisa e precoce. Nesse contexto, os objetivos desse trabalho foram: identificar diferenças na assinatura espectral de quatro níveis de severidade da mancha alvo no algodoeiro; identificar o algoritmo de aprendizagem de máquina (ML) mais preciso na classificação dos níveis; e determinar qual tamanho amostral (40, 60, 80 ou 100 folhas) garante melhor acurácia. O experimento foi conduzido na safra 2023/24, no município de Costa Rica/MS. Para obtenção dos níveis de severidade da mancha alvo (N1 – folhas sadias; N2 – folhas com 1 a 9% de severidade; N3 – folhas com 19 a 37%; N4 – severidade de 53% ou superior), foram instaladas parcelas experimentais ao campo, onde foram pulverizadas quatro diferentes combinações de fungicidas. No estádio F14, foram coletadas 100 amostras foliares em cada nível de severidade, a fim de realizar a leitura hiperespectral através do aparelho espectrorradiômetro FieldSpec. Esses dados obtidos foram submetidos à análise de ML, utilizando seis diferentes algoritmos. Ademais, os comprimentos de onda obtidos foram separados em 28 bandas e então submetidos à análise de componentes principais. Com isso, constatou-se que a curva espectral apresentou assinaturas distintas para os níveis de severidade da doença. Entre os modelos analisados, SVM demonstrou maior precisão na classificação, além disso, os tamanhos amostrais de 80 e 100 folhas demonstraram maior acurácia.

Palavras-chave: *Corynespora cassiicola*. *Gossypium hirsutum*. Sensoriamento remoto. Aprendizagem de máquina.

Hyperspectral response of cotton plants in relation to the severity of target spot.

ABSTRACT: To prevent yield losses caused by pathogens, monitoring techniques using hyperspectral images have shown promise, given their capacity to accurately and early diagnose diseases. In this context, the objectives of this study were: to identify differences in the spectral signature of different severities of target spot in cotton; to identify the most accurate machine learning algorithm (ML) for classifying levels; and to determine which sample size (40, 60, 80, or 100) ensured the best accuracy. The experiment was conducted during the 2023/24 agricultural year, in Costa Rica, MS. To obtain the severity levels of target spot (N1 – healthy leaves; N2 – leaves with 1 to 9% severity; N3 – leaves with 19 to 37%; N4 – severity of 53% or higher), experimental field plots were set up, where four different fungicide combinations were applied. At the F14 stage, 100 leaf samples were collected at each severity level in order to perform hyperspectral readings using the FieldSpec spectroradiometer. These data were subjected to ML analysis using six different algorithms. In addition, the wavelengths obtained were separated into 28 bands and then submitted to principal component analysis. It was found that the spectral curve exhibited distinct signatures for the disease severity levels. Among the models analyzed, SVM showed the highest accuracy in classification. Additionally, the sample sizes of 80 and 100 leaves showed greater accuracy.

Keywords: *Corynespora cassiicola*. *Gossypium hirsutum* Remote Sensing. Machine learning.

SUMÁRIO

INTRODUÇÃO	8
MATERIAL E MÉTODOS	10
RESULTADOS.....	14
DISCUSSÃO	19
CONCLUSÕES	23
REFERÊNCIAS.....	24
MATERIAL SUPLEMENTAR.....	28

INTRODUÇÃO

O algodoeiro (*Gossypium hirsutum* L) é uma planta de grande relevância socioeconômica, tendo em vista a sua fibra têxtil natural, que é a mais importante no mundo (SUASSUNA et al., 2021). Embora sua principal aplicabilidade seja na produção de fibras, o vegetal está presente na produção de farelo para alimentação animal (ARCANJO et al., 2024), e de óleo para alimentação humana (COELHO, 2019; SUASSUNA et al., 2021). Nesse cenário, o Brasil é o segundo maior exportador mundial da fibra e o terceiro maior produtor da commodity, estando atrás apenas da Índia e Estados Unidos. Além disso, o Centro-oeste se destaca no ranking brasileiro, sendo responsável por mais de 70% de toda a produção nacional (ABRAPA, 2024).

No entanto, acompanhado do aumento das áreas cultivadas e do sistema de produção intensivo, caracterizado pelas recorrentes sucessões soja/algodão, há também o aumento na probabilidade da ocorrência de doenças, tendo em vista a manutenção de inóculos constantemente no mesmo local, sujeitando as áreas cultivadas a impactos que refletirão diretamente nos fatores econômicos (CHITARRA, 2019). Dentre essas doenças é possível citar a mancha alvo, causada pelo agente etiológico *Corynespora cassiicola*, que pode infectar mais de 400 espécies de plantas, incluindo a soja, o feijão e a crotalária, espécies frequentemente inseridas no mesmo sistema de produção do algodão. Além disso, por seu caráter necrotrófico, pode sobreviver no campo por até dois anos, favorecendo sua permanência entre os diferentes cultivos (SOUZA e VIDAL, 2018).

Os sintomas visuais dessa doença no algodoeiro se caracterizam pelo surgimento de pequenas pontuações, de coloração vermelho-amarronzado, que evoluem para lesões circulares com um halo amarelado ao centro (Figura S1). Em condições de alta pressão da mancha alvo (*Corynespora cassiicola*) as plantas sofrem severa necrose, refletindo na senescência precoce das folhas, fator considerado potencial para a redução da produtividade, visto que leva à desfolha e, conseqüentemente, diminuição da área fotossintética da planta (GALBIERI et al., 2014).

Partindo do fato de que mais de 80% das áreas semeadas com algodoeiro no Brasil estão sob sistema de sucessão com a soja, é imprescindível que métodos de monitoramento e manejo sejam aplicados, a fim de desfavorecer o ciclo da doença e permitir o bom desenvolvimento de ambas as culturas. A ocorrência desse fungo na Índia foi responsável pela redução de 885 Kg ha⁻¹ na produtividade de algodão em caroço (ROSHAN BABA et al., 2022), enquanto no

Alabama, nos Estados Unidos, Bowen et al. (2018) constataram potencial de perda de 450 kg ha⁻¹, comprovando o impacto que *C. cassiicola* pode provocar nessa cultura.

Sendo assim, traz-se à tona o monitoramento a partir de imagens hiperespectrais, tecnologia que proporciona uma leitura das propriedades ópticas da superfície avaliada a partir de dados de reflectância coletados, normalmente, na faixa dos comprimentos de onda de 350 a 2500nm (FARBER et al., 2019).

Todo esse processo pode ser resumido e compreendido pela interação entre área foliar de plantas e luz natural, onde a imagem hiperespectral é utilizada no monitoramento da luz refletida e transmitida pela planta. Durante o processo de interação entre patógeno e hospedeiro, diferentes respostas fisiológicas e bioquímicas são ativadas e esse comportamento altera, consequentemente, as propriedades ópticas da planta, tornando possível a identificação e diferenciação das doenças (WAN et al., 2022).

Embora esse método expresse algumas desvantagens, como o elevado investimento financeiro, alta complexidade e demora na aquisição das informações, o vasto banco de dados gerado permite a identificação de um maior número de doenças que quando comparado a imagens Red, Green e Blue (RGB), além de superar técnicas multiespectrais por sua maior sensibilidade aos componentes analisados e por fornecer informações espectrais mais completas (FARBER et al., 2019; GOWEN et al., 2007).

Recentemente, Otone et al. (2024) observaram que, ao submeter folhas de soja, com três diferentes níveis de severidade de mancha alvo a análises de sensores hiperespectrais, foi possível obter assinaturas espectrais distintas, onde a maior reflectância visível ocorreu em folhas com o maior nível de severidade, enquanto a menor se deu em folhas saudáveis, certificando o potencial promissor do método.

Além disso, devido ao extenso banco de dados gerado por esse tipo de aparelho, métodos tradicionais de análise não conseguem atuar eficientemente. Assim a associação dessa prática ao uso de técnicas de aprendizado de máquinas tem colaborado com uma classificação de dados mais precisa, permitindo a identificação de diferentes doenças, como ferrugem asiática (*Phakopsora pachyrhizi*) na soja, vírus do enrolamento de folhas de videira (GLRaV-3), e podridão radicular (*Phymatotrichopsis omnivora*) no algodoeiro (YANG et al., 2014; GAO et al., 2020; e SANTANA et al., 2024).

Nessa perspectiva, os objetivos do trabalho foram: (I) identificar a diferença na assinatura espectral de quatro níveis de severidade de mancha alvo (*Corynespora cassiicola*) em algodoeiro; (II) identificar o algoritmo de aprendizagem de máquina mais preciso na

classificação dos níveis de severidade da doença e; (III) determinar um tamanho amostral de folhas que garanta melhor acurácia dos algoritmos.

MATERIAL E MÉTODOS

O experimento foi conduzido no município de Costa Rica – MS, mais precisamente na Fazenda Nova França, cujas coordenadas são S: 18° 13' 40,5" S e W: 53° 9' 46,4", altitude 860,0 m, durante a safra 2023/2024. 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 argilosa (Santos et al., 2018).

As condições climáticas de precipitação e temperatura média registradas durante o desenvolvimento do ensaio estão descritas na Figura 1. É possível observar a instabilidade do regime pluviométrico que, no decorrer do ciclo da cultura, exibiu picos de ocorrência, sendo um deles o possível facilitador da infecção inicial pela *Corynespora cassiicola* nas parcelas experimentais, no mês de março.




Figura 1. Condições pluviométricas e de temperatura média durante a condução do experimento (12/12/2023 – 09/07/2024). Fonte: INMET.

A semeadura do algodão ocorreu no dia 12 de dezembro de 2023, utilizando a cultivar IMA 2106GL, de ciclo médio, instalada em sistema de plantio direto sobre os restos culturais do nabo forrageiro. A densidade populacional foi de 10 plantas por metro, totalizando uma população inicial de 111.111,11 plantas por hectare. A emergência das plântulas ocorreu no dia 23 de dezembro de 2023. Durante o desenvolvimento do ensaio os tratamentos culturais e o manejo

fitossanitário foram realizados seguindo as recomendações para a cultura (DIAS e SANTOS, 2023), com exceção das aplicações de fungicidas (Tabela 1).

Para o delineamento experimental das análises de inteligência artificial por aprendizado de máquinas utilizou-se o esquema fatorial 6x4, sendo seis algoritmos de aprendizagem de máquinas e quatro tamanhos amostrais. Além disso, para a obtenção dos níveis de severidade da doença foram pulverizadas, de forma sequencial, quatro diferentes combinações de fungicidas, distribuídas em quatro parcelas experimentais cada (Tabela 1).

As parcelas em campo foram constituídas por quatro linhas, espaçadas em 0,9 m entre si, e com comprimento de 6,0 m, resultando em 21,6 m² de área total. A área útil utilizada para a coleta dos dados foi composta pelas duas linhas centrais de cada parcela, com 5,0 metros de comprimento, totalizando 9,0 m².

Tabela 1. Combinações de fungicidas e os momentos em que foram pulverizados na cultura do algodoeiro para obtenção de diferentes níveis de severidade da mancha alvo. Safra 2023/24. Costa Rica, MS.

Nível de severidade	Produtos aplicados	Concentração (g.i.a. kg ⁻¹ ou L ⁻¹)	Dose (g. i.a. ha ⁻¹)
N1	Piraclostrobina+Mefentrifluconazol+OV ¹	200+200	100+100
	>Piraclostrobina+Mefentrifluconazol+Clorotalonil+OV ²	>200+200+720	>100+100+1080
	>Fluxapiroxade+Protiocanazol+Mancozebe+OV ²	>200+280+750	>50+70+1125
	>Mefentrifluconazol+Piraclostrobina+Fluxapiroxade+Clorotalonil+OV ¹	>133,3+177,8+88,9+720	>80+106,7+53,3+1080
	>Fluxapiroxade+Protiocanazol+Mancozebe+OV ²	>200+280+750	>50+70+1125
	>Mefentrifluconazol+Piraclostrobina+Fluxapiroxade+Clorotalonil+OV ²	>133,3+177,8+88,9+720	>80+106,7+53,3+1080
	>Fenpropimorfe+Clorotalonil	>750+720	>375+1080
	>Fenpropimorfe+Clorotalonil	>750+720	>375+1080
N2	Azoxistrobina+Difenoconazol+OM ³	200+125	60+37,5
	>Fluxapiroxade+Protiocanazol+Mancozebe+OV ²	>200+280+750	>50+70+1125
	>Hidróxido de Fentina	>400	>200
	>Mefentrifluconazol+Piraclostrobina+Fluxapiroxade+Clorotalonil+OV ²	>133,3+177,8+88,9+720	>80+106,7+53,3+1080
	>Hidróxido de Fentina	>400	>200
	>Pidiflumetofen+Difenoconazol+Clorotalonil+OM ³	>75+125+720	>45+75+1080
	>Difenoconazol+Clorotalonil+OM ³	>250+720	>75+1080
	>Fenpropimorfe+Clorotalonil	>750+720	>225+1080
N3	Picoxistrobina+Ciproconazol	90+40	54+24
	>Picoxistrobina+Benzovindiflupyr+Mancozebe	>100+50+750	>60+30+1125
	>Hidróxido de Fentina	>400	>200
	>Picoxistrobina+Protiocanazol+Mancozebe	>100+116,7+750	>60+70+1125
	>Hidróxido de Fentina	>400	>200
	>Picoxistrobina+Protiocanazol+Mancozebe	>100+116,7+750	>60+70+1125
	>Difenoconazol+Clorotalonil+OM ³	>250+720	>75+1080
	>Difenoconazol+Clorotalonil+OM ³	>250+720	>75+1080
N4	Sem pulverizações	-	-

> Aplicação sequencial. Pulverizações realizadas em: 31DAE >38DAE >52DAE >63DAE >76DAE >87DAE >87DAE >100DAE >111DAE. DAE: Dias após a emergência. OV¹ Adicionado óleo vegetal a 500 mL p.c/ha. OV² Adicionado óleo vegetal a 250 mL p.c/ha. OM³ Adicionado óleo mineral a 250 mL p.c/ha.

Para a estimativa de severidade de mancha alvo (*C. cassiicola*) foi utilizado a escala diagramática proposta por Fantin et al. (2018) (Figura S2), determinando os quatro níveis da

doença da seguinte forma: nível 1, caracterizado por folhas saudáveis; nível 2, folhas com 1 a 9% de severidade; nível 3, folhas com 19 a 37%; e, por fim, o nível 4, com severidade foliar de 53% ou superior (Figura S3).

Posteriormente, foi realizada a coleta das folhas conforme a classificação de severidade da mancha alva, quando a cultura do algodoeiro se encontrava no estágio F14, correspondente à abertura da primeira flor no décimo quarto ramo frutífero. Foram coletadas 100 folhas para cada um dos quatro níveis de severidade. As amostras foram identificadas, armazenadas em caixa térmica, a fim de manter sua turgidez, e transportadas até o laboratório de espectroscopia da Universidade Federal de Mato Grosso do Sul, campus de Chapadão do Sul.

As folhas coletadas, no mesmo dia, foram submetidas à análise hiperspectral, por meio do espectrorradiômetro FieldSpec 4 HRes da Analytical Spectral Devices (Boulder, EUA) (Figura S4), aparelho que registra a reflectância de folhas na faixa de 350 a 2500 nm, 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. Além disso, a fim de auxiliar as leituras das folhas, foi utilizado um leitor opcional ASD Plant Probe, que impede que a leitura espectral seja afetada pela luminosidade do ambiente.

Após a obtenção dos dados espectrais, foram avaliados quatro diferentes tamanhos amostrais: 100 (N100), 80 (N80), 60 (N60) e 40 (N40) amostras foliares que foram submetidos a análise de aprendizagem de máquina utilizando os algoritmos: Redes Neurais Artificiais (RNA – do tipo Perceptron Multicamadas), modelo constituído por unidades de processamento conectadas entre si, baseadas no método de funcionamento do cérebro humano (LIAKOS et al., 2018); árvores de decisão REPTree (DT) e J48, algoritmos que organizam os dados em subconjuntos menores, gerando gráficos com arquitetura semelhante à de uma árvore (LIAKOS et al., 2018); random forest (RF), técnica que produz várias árvores de decisão, as quais sua média de probabilidades fornecerá o resultado final de classificação (BELGIU e DRĂGUȚ, 2016); máquina de vetor suporte (SVM), que classifica os dados a partir da construção de um hiperplano de separação linear (LIAKOS et al., 2018); e regressão logística (RL), utilizada como método tradicional de classificação. Todos os algoritmos foram selecionados segundo Santana et al. (2023), utilizando validação cruzada, com 10 folds e 10 repetições, e as configurações de parâmetros padrão do software Weka 3.8.5, com exceção das redes neurais que foram utilizados 10 neurônios na primeira e 10 neurônios na segunda camada, buscando aumentar a eficiência do processamento dos dados. Para essas análises foram utilizadas as informações referentes à faixa de 450 a 2500 nm, obtendo-se 1025 dados espectrais.

Foram utilizadas métricas de desempenho para determinar a eficácia dos modelos de aprendizado de máquinas, incluindo a porcentagem de classificação correta (CC), o F-score e

o coeficiente Kappa. Esses resultados foram submetidos à análise de variância, a fim de identificar a existência de diferenças significativas entre os modelos de aprendizado de máquinas e os tamanhos amostrais aplicados. O agrupamento das médias das métricas analisadas ocorreu por Scott-Knott, com nível de significância de 5%, utilizando o software Rbio (BHERING, 2017). Após isso foram formados boxplots através dos pacotes ggplot2 e ExpDes.pt do software R.

Além disso, os dados iniciais obtidos a partir da leitura espectral das folhas de algodão foram separados em 28 bandas espectrais, conforme Silva Júnior et al. (2018), em seguida submetidas à análise de estatística multivariada, utilizando o teste de componentes principais, com auxílio do software R versão 4.1.0, a fim de melhor caracterizar a diferenciação das assinaturas espectrais e sua relação com cada faixa do espectro (Tabela 2).

Tabela 2. Intervalos de comprimentos de onda (nm) utilizados para a definição de 28 bandas espectrais.

Banda	Faixa espectral (nm)
1	350–369
2	370
3	371–419
4	420
5	421–424
6	425
7	426–444
8	445–475
9	480
10	481–500
11	501–530
12	531–539
13	540
14	541–649
15	650
16	661–670
17	675
18	676–684
19	685–689
20	690–700
21	701–709

22	710
23	711–730
24	960
25	1100
26	1400
27	1930
28	2200

RESULTADOS

Os dados obtidos a partir da análise espectral das folhas de algodão mostraram variação na curva hiperespectral, em relação aos diferentes níveis de severidade da mancha alvo (Figura 2). Na região do visível, entre os comprimentos de onda de 400 e 700nm, houve maior reflectância em folhas do nível 4 (severidade de 53% ou mais), enquanto para os níveis 1 (folhas saudáveis), 2 (severidade de 1 a 9%) e 3 (severidade de 19 a 37%) observou-se comportamento muito semelhante, dificultando a distinção entre essas curvas nessa região do espectro.

Na região do infravermelho próximo (700 a 1300 nm), as folhas sadias (N1) exibiram reflectância superior às demais, diferente daquelas com maior severidade da doença (N4), que apresentaram assinatura espectral abaixo de todos os outros níveis, comportamento esse que se estendeu até a seção mediana do SWIR. Além disso, nessa faixa do espectro os quatro níveis de severidade de mancha alvo (*C. cassicola*) apontaram comportamento muito semelhante, principalmente entre os comprimentos de onda de 2000 e 2500 nm.




Figura 2. Curva espectral dos níveis de severidade de mancha alvo (*Corynespora cassiicola*) no algodão. Safra 2023/24. Costa Rica, MS.

Ao submeter as bandas espectrais, obtidas a partir da separação dos comprimentos de onda de todas as repetições dos quatro níveis de severidade, à análise de componentes principais (Figura 3), constatou-se alta relação das amostras de N4 com todas as 28 bandas avaliadas. Enquanto para folhas do N1, N2 e N3 houve maior relação com as bandas B1-B10 e B23-B28, comportamento esse que corrobora com a assinatura espectral da doença em todos os níveis de severidade.




Figura 3. Análise de componentes principais para as 28 bandas espectrais dentro dos quatro níveis de severidade da mancha alvo (*Corynespora cassiicola*) no algodão.

Diante das diferentes assinaturas espectrais geradas pelas diferentes porcentagens de severidade da mancha alvo (*Corynespora cassiicola*), realizou-se a submissão dos dados à análise de aprendizagem de máquinas, a fim de definir o melhor algoritmo para classificação dos níveis da doença. Sendo assim, foram selecionadas quatro configurações de entrada, correspondentes ao número de amostras foliares analisadas (100, 80, 60 e 40 folhas) e seis algoritmos de ML, analisados por três métricas de acurácia: classificação correta (CC), F-score e Kappa.

Para as métricas, classificação correta (CC) e Kappa, ao observar os algoritmos DT, SVM, RNA e RL constatou-se melhor desempenho quando utilizadas 100 e 80 amostras foliares. Por outro lado, para J48 e RF não houve diferença significativa entre o número de amostras fornecidas. Nessas mesmas métricas, identificou-se comportamento semelhante entre os tamanhos amostrais de 100 e 80 folhas, onde ambos apresentaram performance superior para SVM, seguido estatisticamente por RL, por conseguinte RNA e RF e, por fim DT e J48, sendo esses dois últimos análogos. Para 60 e 40 amostras obteve-se resposta similar aos dois citados anteriormente, tanto para SVM, quanto para RNA e RL. Todavia, ao utilizar 60 amostras foliares como entrada, observou-se o pior resultado em DT, enquanto para 40 amostras esse mesmo algoritmo se assemelhou ao J48, sendo ambos de menor acurácia, quando comparado aos demais.

Esses resultados destacam o papel promissor da SVM dentro da classificação de doenças por aprendizagem de máquinas, visto que sua porcentagem de acurácia foi superior aos demais algoritmos com qualquer tamanho amostral testado. Além disso, vale também dar ênfase ao comportamento com 80 amostras foliares, que se assemelhou estatisticamente àquele com 100 amostras, demonstrando ser possível obter informações acuradas com um menor número amostral.




Figure 4. Boxplot para a métrica de acurácia classificação correta (CC) dos algoritmos de aprendizagem de máquina com os diferentes tamanhos amostrais (N) utilizados na classificação da severidade de mancha alvo (*Corynespora cassiicola*) no algodão. Médias seguidas pelas mesmas letras maiúsculas para os diferentes tamanhos amostrais e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.




Figura 5. Boxplot para a métrica de acurácia coeficiente Kappa dos algoritmos de aprendizagem de máquina com os diferentes tamanhos amostrais (N) utilizados na classificação da severidade de mancha alvo (*Corynespora cassiicola*) no algodão. Médias seguidas pelas mesmas letras maiúsculas para os diferentes tamanhos amostrais e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

Ao verificar as análises utilizando a métrica de acurácia F-score, constatou-se que para SVM e DT não houve diferença significativa entre os quatro tamanhos amostrais testados. Para J48 apenas o uso de 80 amostras foliares distinguiu-se dos demais, sendo esse o de menor performance. Para RF 100 e 40 amostras se sobressaíram estatisticamente, enquanto para RNA utilizar 100, 80 ou 40 folhas demonstrou não haver diferença estatística.

Por fim, para RL o melhor resultado foi obtido quando utilizado 40 amostras foliares, diferindo estatisticamente dos demais. Quando realizada a comparação entre os algoritmos para cada um dos tamanhos amostrais utilizados constatou-se que 100, 80, 60 e 40 amostras foliares promoveram maior acurácia em RL e SVM.




Figura 06. Boxplot para a métrica de acurácia Fscore dos algoritmos de aprendizagem de máquina com os diferentes tamanhos amostrais (N) utilizados na classificação da severidade de mancha alvo no algodão. Médias seguidas pelas mesmas letras maiúsculas para os diferentes

tamanhos amostrais e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

Para essa última métrica foi possível observar a precisão dos dados mesmo ao utilizar o menor número de amostras do conjunto, visto que o uso de 40 folhas foi análogo, ou mesmo superior, ao uso de 100. Com isso sugere-se viabilidade na diminuição amostral, associada à maior praticidade e economia

DISCUSSÃO

Os resultados obtidos no presente estudo permitem afirmar que existe diferença entre a assinatura espectral de cada um dos quatro níveis de severidade da mancha alvo (*C. cassiicola*) no algodoeiro (Figura 2). Na região do visível (VIS), localizada entre os comprimentos de onda 400 e 700 nm, observou-se maior reflectância nas folhas do nível 4, ou seja, naquelas com maior severidade da doença. Nessa faixa do espectro existe alta relação com os pigmentos fotossintetizantes da planta, como clorofilas e carotenoides, que, em plantas saudáveis, estão constantemente atuando na absorção de luz (CHRISTENSON et al., 2014) e, por isso, essas resultam em reflectância inferior na curva espectral. Por outro lado, folhas com maior infecção pelo fungo têm a ação e a composição dos pigmentos comprometida, visto as alterações fisiológicas e bioquímicas ocorridas sobre o tecido da planta infectada, que podem alterar coloração, morfologia, estrutura, transpiração e, consequentemente, suas propriedades ópticas (MAHLEIN, 2016; WEST et al., 2010), resultando no aumento da reflectância espectral.

Essa mesma resposta também foi observada por Otonari et al. (2024), quando avaliaram três níveis de severidade de mancha alvo (*C. cassiicola*) na cultura da soja e concluíram que, na faixa do VIS, plantas submetidas à maior infecção da doença tendem a ter maior reflectância espectral, em relação às aquelas com severidade inferior ou mesmo saudáveis.

A proximidade entre a assinatura espectral das folhas saudáveis e dos dois primeiros níveis de severidade do patógeno nessa região do espectro, pode ser atribuída à característica dos sintomas visuais iniciais dessa doença em plantas de algodão, que manifesta lesões de coloração mais escuras, em tons de vermelho-amarronzado (GALBIERI et al., 2014) e que, por isso, promove menor reflectância quando comparado às lesões em estágio avançado, amareladas por conta da necrose dos tecidos e com alta concentração de pigmentos amarelos em sua

constituição, resultando em alta reflectância na porção verde do VIS (CHRISTENSON et al., 2014).

Na região do infravermelho próximo (NIR) o comportamento da curva é inverso ao discutido até o momento, nesse caso houve maior reflectância por parte de amostras do nível 1 (folhas saudas) e menor resposta espectral de folhas do nível 4 (severidade de 53% ou mais). Com o aumento brusco da reflectância entre os comprimentos de onda 750 e 951 nm é possível diferenciar nitidamente as folhas saudas daquelas com maior severidade da doença, corroborando com o observado por Calamita et al. (2021) que empregaram esta tecnologia para a diagnose precoce da podridão radicular da videira (*Armillaria mellea*).

Essa região do espectro está relacionada ao conteúdo estrutural interno das folhas, vibrações entre moléculas de CH, OH e NH, e aos espaços intercelulares (MOHD HILMI TAN et al., 2021). Sendo assim, a alteração na reflectância ocorre conforme há modificação nos constituintes celulares e na presença de ar nas paredes das células foliares (VESCOVO et al., 2012), processos que serão impactados pela presença do patógeno, que, durante a patogênese, interferirá na composição química dos tecidos e na estrutura foliar (MAHLEIN, 2016).

Vale ainda dizer que, ao observar todo o comprimento de onda fornecido (Figura 6), a região do NIR proporciona curvas espectrais com maior diferenciação entre os níveis de severidade da mancha alva (*C. cassicola*), fato esse que enfatiza o potencial dessa faixa espectral para a classificação de doenças de plantas. Respostas semelhantes também foram obtidas por outros autores, que afirmaram a maior importância da região do infravermelho próximo, quando comparado à região do visível, para a distinção entre plantas saudas e doentes (CALAMITA et al., 2021; ZHANG et al., 2005).

Essa maior relevância do infravermelho próximo destaca o uso dos sensores hiperespectrais na identificação e classificação de fitopatologias, visto que sensores multiespectrais, apesar de mais acessíveis economicamente, não fornecem informações referentes à essa faixa do espectro. Ademais, sua capacidade de obter respostas relacionadas às propriedades químicas da planta permite uma diagnose mais precisa e precoce, ainda que a doença não tenha manifestado sintomas visuais expressivos no tecido vegetal (GEWALI et al., 2018).

Na região do infravermelho de ondas curtas (SWIR), entre os comprimentos de onda 1300-2500nm, constatou-se alta proximidade entre as curvas dos diferentes níveis de severidade da mancha alva (*C. cassicola*), com menor reflectância de plantas do N4 na metade inicial dessa faixa e, na metade final, leve aumento na reflectância de plantas do N3.

O SWIR é caracterizado por possuir alta relação com a composição química e a presença de água nos tecidos vegetais (HOMOLOVÁ et al., 2013), e, comumente, em trabalhos realizados no setor de doenças de plantas, essa faixa do espectro tem retratado alta reflectância em condições de maior infecção por patógenos (SANTANA et al., 2024; OTONE et al., 2024; KNAUER et al., 2017).

No entanto, os resultados encontrados nesse estudo foram opostos, visto a baixa reflectância das amostras com severidade superior de *C. cassicola*, principalmente próximo aos comprimentos de onda de 1600 e 2200nm. Segundo Junges et al. (2020), essa região do espectro está associada à presença de compostos fenólicos, substâncias naturalmente abundantes na estrutura foliar do algodoeiro e que, sob infecção por patógenos, tem sua produção intensificada (EGBUTA et al., 2017).

Nesse caso, a maior reflectância das folhas do N3 pode estar associada ao aumento desses compostos, enquanto para as amostras de N4 a natureza necrotrófica do patógeno leva à morte rápida dos tecidos (GALBIERI et al., 2014), resultando no fim da produção dessas substâncias e, conseqüentemente, na diminuição da reflectância na curva espectral.

Sendo assim, a assinatura espectral que ocorreu na faixa do SWIR pode ser explicada por possíveis alterações na composição fisiológica e bioquímica das folhas, mas que, devido à variedade de bandas localizada nessa região do espectro e sua associação com aspectos tão variados da planta, como proteínas, amido e celulose (CURRAN, 1989), só poderia ser confirmada através de análises fisiológicas mais aprofundadas, como a de teores de metabólitos secundários, mais especificamente, de compostos fenólicos.

Em relação aos resultados obtidos na análise de componentes principais (Figura 3), evidenciou-se que a separação das faixas do espectro em diferentes bandas também colabora com a diferenciação dos níveis de severidade da doença e confirma a resposta espectral promovida por esses níveis. Esse fato pode ser exemplificado pela alta relação das bandas B11-B22 com amostras do N4, essas correspondem aos comprimentos de onda de 501 a 710 nm, faixa do espectro onde observou-se maior reflectância de folhas com maior severidade do patógeno.

Após a análise da assinatura espectral produzida pelos quatro níveis de severidade de mancha alvo (*C. cassicola*), as informações foram submetidas a modelos de aprendizagem de máquinas, para selecionar os algoritmos mais acurados para classificação da doença. Com isso, observou-se desempenho superior de SVM nas três métricas avaliadas, no entanto, em F-Score, esse algoritmo foi semelhante à RL.

A regressão logística é um método tradicional voltado para problemas de classificação (BISONG, 2019), mas que, apesar disso, tem sido comumente substituído por outros algoritmos de ML que oferecem a possibilidade de maior precisão nos resultados. Dentre esses está a máquina de vetor de suporte, algoritmo que também pode ser utilizado para fins de classificação de dados e que tem fornecido respostas satisfatórias para problemas envolvendo imagens hiperespectrais (BIGDELI et al., 2013).

Santana et al. (2024) constataram alta performance de SVM ao obter porcentagem de acurácia acima de 90,0% na classificação de níveis de severidade de ferrugem asiática (*Phakopsora pachyrhizi*) na cultura da soja. Ainda nessa mesma cultura, Otone et al. (2024) também validaram o bom desempenho desse algoritmo para a classificação de doenças, quando o comparou a outros cinco modelos de ML na distinção de três diferentes porcentagens de severidade de mancha alvo (*C. cassicola*). Todos esses resultados corroboram com o apresentado neste trabalho e ratificam o desempenho superior de SVM ao se tratar de informações hiperespectrais obtidas a partir de plantas contaminadas por patógenos.

A possibilidade de redução amostral foi observada nas três métricas de acurácia, onde, com base nos valores de CC e Kappa, o uso de 80 amostras foliares forneceu precisão tão boa quanto o uso de 100 amostras. Considerando os valores de F-score, utilizar como entrada 40 folhas de algodão colaborou com porcentagem de acurácia igual ou superior aos demais tamanhos amostrais.

Essa viabilidade na redução amostral, sem perda de precisão na classificação dos dados, propõe diferentes benefícios em todos os processos da análise, mas principalmente, economia de tempo e mão de obra (TEODORO et al., 2023), enquanto para o produtor permitirá a diagnose precoce e precisa da doença, ainda que o patógeno não tenha atingido grandes áreas da lavoura.

As informações discutidas no presente estudo permitem validar o potencial de sensores hiperespectrais na identificação e classificação de doenças em plantas, fornecendo uma visão mais tecnológica e avançada para as técnicas de monitoramento e diagnose. Segundo Liakos et al. (2016) a utilização das técnicas de aprendizado de máquinas associadas aos dados do sensor hiperespectral permitem que os sistemas de gerenciamento das fazendas obtenham informações mais completas, que colaborarão na tomada de decisão, refletindo diretamente nos resultados produtivos. Aliado a isso, a realização de pulverizações localizadas e mais precoces resultarão em controle rápido da doença e, conseqüentemente, redução no uso de fungicidas, fator que propõe benefícios financeiros e ambientais.

Em estudos futuros, seria interessante associar essa abordagem a análises fisiológicas, a fim de melhor compreender o comportamento óptico da mancha alvo (*C. cassiicola*) ao longo da curva espectral, especialmente na região do SWIR. Além disso, replicar o estudo em diferentes variedades de algodão e outras regiões poderá colaborar com uma classificação futura de dados mais precisa, eliminando problemas com variações genéticas relacionadas a cultivar ou ao patógeno.

CONCLUSÕES

Considerando os resultados obtidos neste trabalho, evidenciou-se que foi possível diferenciar os níveis de severidade da mancha alvo (*C. cassiicola*) através das diferenças na assinatura espectral fornecida, principalmente na região do NIR.

Ademais, constatou-se que o algoritmo SVM demonstrou boa performance para todas as métricas avaliadas e o uso de 80 e 100 amostras foliares demonstrou maior acurácia.

REFERÊNCIAS

- ABRAPA. Algodão no Brasil; Algodão no Mundo. Associação Brasileira dos Produtores de Algodão. Brasília, 2024. <<https://abrapa.com.br/dados/>>. Acesso em 21 de junho de 2024.
- ARCANJO, A. H. M.; ÍTAVO, L. C. V.; ÍTAVO, C. C. B. F.; DIAS, A. M.; DIFANTE, G. S.; LONGHINI, V. Z.; CUNHA, C. S.; GURGEL, A. L. C.; LIMA, E. A.; SANTANA, J. C. S.; SILVA, M. G. P. Nutrient intake, productive and metabolic parameters of Nellore bulls feed a forage free diet using cottonseed cake as a fiber source. **Tropical Animal Health and Production**. v. 56, n. 55, 2024.
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. **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.
- BIGDELI, B.; SAMADZADEGAN, F.; REINARTZ, P. A Multiple SVM System for Classification of Hyperspectral Remote Sensing Data. **Journal of the Indian Society of Remote Sensing**, v. 41, p. 763–776, 2013.
- BISONG, E. Logistic Regression. In: Building Machine Learning and Deep Learning Models on Google Cloud Platform. Apress, Berkeley, CA, 2019.
- BOWEN, K. L.; HAGAN, A. K.; PEGUES, M.; JONES, J.; MILLER, H. B. Epidemics and yield losses due *Corynespora cassiicola* on cotton. **Plant Disease**, v. 102, p. 2494-2499, 2018.
- CALAMITA, F.; IMRAN, H.A.; VESCOVO, L.; MEKHALFI, M.L.; La PORTA, N. Early Identification of Root Rot Disease by Using Hyperspectral Reflectance: The Case of Pathosystem Grapevine/Armillaria. **Remote Sens**. v. 13, n. 2436, 2021.
- CHITARRA, L. G.; TARDIN, F. D. Determinar os melhores fungicidas e/ou programas de fungicidas para o controle da mancha de ramulária (*Ramularia areola*) do algodoeiro no estado de Mato Grosso. IN: FARIAS NETO, A. L.; NASCIMENTO, A. F.; ROSSONI, A. L.; SOUZA MAGALHÃES, C. A. S.; ITUASSÚ, D. R.; HOOGERHEIDE, E. S. S.; IKEDA, F. S.; FERNANDES JUNIOR, F.; FARIA, G. R.; ISERNHAGEN, I.; VENDRUSCULO, L. G.; MORALES, M. M.; CARNEVALLI, R. A. Primeiras contribuições para o desenvolvimento de uma agropecuária sustentável (**Embrapa Agrossilvipastoril**). Brasília, 2019.
- 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, 2014.
- COELHO, J. D. Produção de Algodão. Caderno Setorial Etene. Banco do Nordeste. n. 99, 2019.
- CURRAN, P. J. Remote sensing of foliar chemistry, *Remote Sensing of Environment*, v. 30, n. 3, p. 271-278, 1989.
- DIAS, A. dos S.; SANTOS, C. C. O cultivo do algodão de ponta a ponta: manejo fitotécnico, nutricional e fisiológico. In: ANDRADE, J. K. B. Estudos em ciências florestais e agrárias. Campina Grande: Editora Licuri, p. 73-100, 2023.

- EGBUTA, M.A.; MCINTOSH, S.; ÁGUAS, D.L.E.; OLIVEIRA, T.; LIU, L. Biological Importance of Cotton By-Products Relative to Chemical Constituents of the Cotton Plant. **Molecules**, v. 22, n. 1, p. 93, 2017.
- FANTIN, L. H.; BRAGA, K.; CANTERI, M. G.; DIAS, A. R.; BORGES, E. P. Development and validation of diagrammatic scale to assess target spot severity in cotton. Australasian Plant Pathology Society Inc. 2018.
- 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.
- GALBIERI, R.; ARAÚJO, D. C. E. B.; KOBAYASTI, L.; GIROTTO, L.; MATOS, J. N.; MARANGONI, M. S.; ALMEIDA, W. P.; MEHTA, Y. R. Corynespora leaf blight of cotton in Brazil and its management. **American Journal of Plant Sciences**, v. 05, 2014.
- GAO, Z.; KHOT, L. R.; NAIDU, R. A.; ZHANG, Q. Early detection of grapevine leafroll disease in a red-berried wine grape cultivar using hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 179, n. 105807, p. 1-8, 2020.
- GEWALI, U. B.; MONTEIRO, S. T.; SABER, E. Machine Learning Based Hyperspectral Image Analysis: A Survey. **arXiv preprint arXiv:1802.08701**, v. 2, p. 1-46, 2018.
- GOWEN, A. A.; DONNELL, C. P.; CULLEN, P. J.; DOWNEY, G.; FRIAS, J. M. Hyperspectral imaging – an emerging process analytical tool for food quality and safety control. **Trends in Food Science & Technology**, v. 18, n. 12, p. 590-598, 2007.
- HOMOLOVÁ, L.; MALENOVSKÝ, Z.; CLEVERS, J. G. P. W.; GARCÍA-SANTOS, G.; SCHAEPMAN, M. E. Review of optical-based remote sensing for plant trait mapping. **Ecological Complexity**, v. 15, p. 1-16, 2013.
- 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. **Trop. planta pathol.** v. 45, p. 522–533, 2020.
- 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.47, p. 1-15, 2017.
- LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: A Review. **Sensors**, v. 18, n. 2674, p. 1-29, 2018.
- 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.
- MOHD HILMI TAN, M.I.S.; JAMLOS, M.F.; OMAR, A.F.; DZAHARUDIN, F.; CHALERMWISUTKUL, S.; AKKARAEKTHALIN, P. *Ganoderma boninense* Disease Detection by Near-Infrared Spectroscopy Classification: A Review. **Sensors (Basel)**, v. 21, n. 9, p. 3052, 2021.
- OTONE, J. D. de Q.; THEODORO, G. de F.; SANTANA, D. C.; TEODORO, L. P. R.; de OLIVEIRA, J. T.; de OLIVEIRA, I. C.; da SILVA JUNIOR, C. A.; TEODORO, P. E.; BAIO, F. H. R. Hyperspectral Response of the Soybean Crop as a Function of Target Spot

(*Corynespora cassiicola*) Using Machine Learning to Classify Severity Levels. **AgriEngineering**, v. 6, p. 330-343, 2024.

ROSHAN BABA, S.K.; BHATTIPROLU, S.L.; PRASANNA KUMARI, V.; CHIRANJEEVI, C.H. Estimation of yield losses in cotton due to major fungal foliar diseases. **The Journal of Research ANGRAU**, v. 50, n. 3, p. 17-27, 2022.

SANTANA, D. C.; OTONE, J. D. de Q.; BAIO, F. H. R.; PEREIRA RIBEIRO TEODORO, L.; ALVES, M. E. M.; SILVA JUNIOR, C. A. da; TEODORO, P. E. Machine learning in the classification of asian rust severity in soybean using hyperspectral sensor. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 313, n. 124113, 2024.

SANTANA, D. C.; TEODORO, L. P. R.; BAIO, 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.

SILVA JUNIOR, C. A. DA; NANNI, M. R.; SHAKIR, M.; TEODORO, P. E.; OLIVEIRAJÚNIOR, 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.

SOUZA, M. B.; VIDAL, R. L. Fungicidas protetores e sistêmicos no controle de *Corynespora cassiicola* em soja. **Revista de Agricultura Neotropical**, Cassilândia-MS, v. 5, n. 3, p. 65-69, 2018.

SUASSUNA, N. D.; MORELLO, C. L.; PERINA, F. J.; SILVA FILHO, J. L.; PEDROSA, M. B.; MAGALHÃES, F. O. C.; SOFIATTI, V.; LAMAS, F. M.; CHITARRA, L. G.; FARIAS, F. J. C.; RODRIGUES DO O, W. C. BRS 500 B2RF: transgenic cotton cultivar expressing Cry1Ac, Cry2Ab, and CP4-EPSPS with multiple disease resistance. **Crop Breeding and Applied Biotechnology**, v. 21, p. 1-5, 2021.

TEODORO, L. P. R.; ESTEVÃO, R.; SANTANA, D. C.; OLIVEIRA, I. C. de; OLIVEIRA, M. T. G.; OLIVEIRA, G. B. de.; ROJO BAIO, F. H.; da SILVA JUNIOR, C. A.; TEODORO, P. E. Eucalyptus Species Discrimination Using Hyperspectral Sensor Data and Machine Learning. **Florests**, v. 15, n. 39, p. 1-10, 2023.

VESCOVO, L.; WOHLFAHRT, G.; BALZAROLO, M.; PILLONI, S.; SOTTOCORNOLA, M.; RODEGHIERO, M.; GIANELLE, D. New Spectral Vegetation Indices Based on the Near-Infrared Shoulder Wavelengths for Remote Detection of Grassland Phytomass. **Int. J. Remote Sens.**, v.33, n.7, p.2178–2195, 2012.

WAN, L.; LI, H.; LI, C.; WANG, A.; YANG, Y.; WANG, P. Hyperspectral Sensing of Plant Diseases: Principle and Methods. **Agronomy**, v. 12, n. 1451, 2022.

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. In: OERKE, EC., GERHARDS, R., MENZ, G., SIKORA, R. Precision Crop Protection - the Challenge and Use of Heterogeneity. Springer, Dordrecht., p. 135–149, 2010.

YANG, C.; ODVODY, G. N.; FERNANDEZ, C. J.; LANDIVAR, J. A.; MINZENMAYER, R. R.; NICHOLS, R. L. Evaluating unsupervised and supervised image classification methods for mapping cotton root rot. **Precision Agriculture**, v. 16, p. 201-215, 2014.

ZHANG, M.; QIN, Z.; LIU, X. Remote Sensed Spectral Imagery to Detect Late Blight in Field Tomatoes. **Precis. Agric.**, v. 6, p. 489–508, 2005.

MATERIAL SUPLEMENTAR



Figura S1. Sintomas característicos de mancha alvo (*Corynespora cassiicola*) em folhas de algodão (*Gossypium hirsutum*).




Figura S2. Escala diagramática elaborada por Fantin et al., (2018), para avaliação da mancha alvo em folhas de algodoeiro.




Figura S3. Folhas saudáveis (A); com 1 a 9% de severidade de mancha alvo (B); com 19 a 37% de severidade (C); com severidade de 53% ou mais (D).



Figura S4. Espectrorradiômetro FieldSpec 4 HRes da Analytical Spectral Devices (Boulder, EUA) utilizado para as análises hiperespectrais.

COLEGIADO DE PÓS-GRADUAÇÃO EM AGRONOMIA

Rod MS 306, Km 105, Caixa Postal 112

Fone: (67)3562-6351

CEP 79560-000 - Chapadão do Sul - MS

Referência: Processo nº 23455.000687/2024-16

SEI nº 5314711