

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

VITOR DE SOUZA COSTA

**CLASSIFICAÇÃO DE NÍVEIS DE SEVERIDADE DA
MANCHA DE CERCOSPORA EM MILHO POR MEIO DE DADOS
HIPERESPECTRAIS E APRENDIZAGEM DE MAQUINA**

CHAPADÃO DO SUL – MS

2024

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

VITOR DE SOUZA COSTA

**CLASSIFICAÇÃO DE NÍVEIS DE SEVERIDADE DAMANCHA DE
CERCOSPORA EM MILHO POR MEIO DE DADOS
HIPERESPECTRAIS E APRENDIZAGEM DE MAQUINA**

Orientador: Prof. Dr. Gustavo de Faria Theodoro

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: Vitor de Souza Costa

ORIENTADOR: Dr. Gustavo de Faria Theodoro

TÍTULO: Classificação de níveis de severidade da mancha de Cercospora em milho por meio de dados hiperespectrais e aprendizagem de máquinas.

AVALIADORES:

Prof. Dr. Gustavo de Faria Theodoro

Prof. Dr. Paulo Eduardo Teodoro

Prof. Dra. Lilian Maria Arruda Bacchi

Chapadão do Sul, 13 de dezembro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Gustavo de Faria Theodoro, Professor do Magisterio Superior**, em 13/12/2024, às 09:17, 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 **Lilian Maria Arruda Bacchi, Usuário Externo**, em 13/12/2024, às 09:47, 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 **Paulo Eduardo Teodoro, Professor do Magisterio Superior**, em 13/12/2024, às 13:05, 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 **5314720** e o código CRC **313D69CE**.

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 23455.000694/2024-18

SEI nº 5314720

SUMÁRIO

1. Resumo.....	1
2. Palavras - Chave	1
3. Abstract	2
4. Keywords	2
5. Introdução.....	2
6. Material e Métodos.....	4
7. Discussão.....	8
8. Conclusão	9
9. Referências	10

RESUMO: A diagnose visual de doenças foliares pode ser limitada pela sua sintomatologia e a interação com outros fatores do meio, que dificultam a detecção de sua ocorrência precoce na lavoura. O objetivo deste trabalho foi identificar e classificar diferentes níveis de severidade da mancha de cercospora utilizando modelos de aprendizagem de máquina (AM) buscando o melhor algoritmo e inputs que garantam melhor desempenho. Foram avaliadas folhas saudias e três níveis de severidade da mancha de cercospora em folhas de milho, por meio de um sensor hiperespectral utilizando o espectrorradiômetro FieldSpec 4 Jr. Dos dados espectrais foram extraídas 28 bandas espectrais e foram calculado com os valores espectrais e índices de vegetação. Foram usados três inputs nos modelos de AM: espectro completo (WL), banda espectrais (SB) e índices de vegetação (IVs). Essas configurações foram utilizadas como input dos modelos de aprendizagem de máquina. Após a obtenção dos dados espectrais e a separação em bandas, os dados foram submetidos a análise de aprendizagem de máquina utilizando os algoritmos Redes Neurais Artificiais (ANN), árvore de decisão REPTree (DT) e J48, random forest (RF), máquina de vetor suporte (SVM) e utilizado como método tradicional de classificação regressão logística (RL). Ao comparar a eficácia dos três inputs entre os diferentes modelos, observou-se que para RNA e RF, as bandas espectrais foram o input mais eficaz. Já para os modelos DT, J48 e RL, os melhores resultados foram alcançados utilizando tanto o espectro completo quanto as bandas. No caso do SVM, o modelo mostrou-se mais eficiente ao utilizar WL como input. A aplicação de RL e SVM, dependendo dos recursos espectrais disponíveis, é uma abordagem precisa no monitoramento de cercosporiose em milho

PALAVRAS- CHAVE: *Cercospora zea-maydis*, inteligência artificial, sensoriamento remoto.

ABSTRACT: Visual diagnosis of leaf diseases can be limited by their etiology and interaction with other environmental factors, which make it difficult to detect their early occurrence in crops. The objective of this study was to identify and classify different levels of severity of cercospora leaf spot using machine learning models, searching for the best algorithm and inputs that guarantee better performance. Healthy leaves and three levels of severity of cercospora leaf spot on corn leaves were evaluated by means of a hyperspectral sensor using the FieldSpec 4 Jr spectroradiometer from Analytical Spectral Devices (Boulder, USA). From the spectral data, 28 spectral bands were extracted and calculated with spectral values and vegetation indices. These configurations were used as input for the machine learning models. After obtaining the spectral data and separating them into bands, the data were subjected to machine learning analysis using the algorithms Artificial Neural Networks (ANN), REPTree decision tree (DT) and J48, random forest (RF), support vector machine (SVM) and used as the traditional classification method logistic regression (RL). When comparing the effectiveness of the three inputs between the different models, it was observed that for ANN and RF, the spectral bands were the most effective input. For the DT, J48 and RL models, the best results were achieved with SB or WL. In the case of SVM, the model proved to be more efficient when using the full spectrum (WL). The application of RL and SVM, depending on the available spectral resources, is a practical and accurate approach in monitoring cercospora in corn.

KEYWORDS: *Cercospora zea-maydis*, artificial intelligence, remote sensing.

INTRODUÇÃO

Cercospora zea-maydis é um fungo destrutivo de grande impacto econômico que é agravado pelo clima tropical quente e alta umidade, e a quantificação dos danos causados por essa doença é essencial para a avaliação de danos a planta (Concepcion et al., 2021). Os primeiros relatos da ocorrência da doença no Brasil se deram no Sudoeste de Goiás, favorecida pelas condições climáticas e altitude da região (Pinto et al., 2004). A cercosporiose é causada por um fungo necrotrófico que tem como seu principal hospedeiro a cultura do milho, esse fungo pode sobreviver em restos de cultura e permanecer na área por anos, sua disseminação é favorecida pelo vento e respingos de chuva.

Devido ao seu impacto direto na redução de produtividade do milho os danos causados pela cercosporiose podem chegar em até 40 % na redução na produção grãos (Silva et al., 2021), pois diminui a área fotossintética por morte do tecido vegetal causado pelo ataque do fungo e conseqüentemente reduz taxa fotossintética. Algumas alternativas de controle são utilizadas para redução do dano na cultura, a escolha do material adequado para a região, a rotação de culturas na tentativa de quebrar o ciclo do patógeno e o manejo químico através de programas de fungicidas, que na atualidade é umas das estratégias de manejo mais utilizadas na cultura (Barros, 2020).

A utilização de informações hiperespectrais é uma ferramenta valiosa, pois pode fornecer informações abrangendo uma grande faixa do espectro. Esses dados podem contribuir para a identificação de faixas sensíveis que podem potencialmente fornecer informações sobre o estado morfofisiológico de plantas (Gao et al., 2020). Os dados de sensoriamento remoto também podem fornecer padrões de comportamentos espectrais específicos para estresses, incluindo aqueles provocados por doenças, e fornecer informações úteis para práticas específicas de manejo agrícola (Weiss et al., 2020). Dessa forma, a maioria dos estudos listados na literatura focaram na seleção de comprimentos de onda que caracterizassem estresses (Gao et al., 2020).

A utilização de sensores pode contribuir para a diagnose precoce de doenças e surtos de pragas, para que o manejo seja antecipado e não haja perdas significativas (Gonzalez-Dugo et al., 2015). Todavia, sensores hiperespectrais geram conjuntos de dados de alta dimensão e que precisam de computação e tempo adequados para processamento. Santana et al. (2024), utilizaram dados hiperespectrais para a classificação de severidade de ferrugem asiática da soja, afirmando que a detecção hiperespectral e o uso de algoritmos de ML é uma metodologia precisa na classificação de diferentes níveis de severidade sendo um forte aliado no monitoramento de doenças.

Diversos métodos têm sido propostos e utilizados para a classificação de espécies agrícolas em conjuntos de dados espectrais específicos por meio de avanços em técnicas de aprendizado de máquina envolvendo algoritmos de classificação avançados que aprimoram a acurácia dos modelos e recomendações para futuras pesquisas (Şimşek, 2024). Em muitos estudos, busca-se testar algoritmos capazes de superar os métodos de classificação tradicionais, como a Regressão Logística, conforme discutido por Santana et al. (2024). Entretanto, não existe nenhuma pesquisa usando sensores espectrais para detecção de cercosporiose em milho.

O objetivo do trabalho foi classificar níveis de severidade da mancha de cercospora em folhas de milho por meio de dados hiperespectrais e modelos de aprendizagem de máquina.

MATERIAL E MÉTODOS

O experimento foi conduzido no centro de Inovação Desafios Agro, fazenda Gávea (18° 45' 54.19" ; 52° 40' 56.83") situada no município de Chapadão do Sul-MS. O híbrido utilizado foi o Fórmula Vip 2 com semeadura realizada em 02/02/2024. com espaçamento entre linhas de 0,90 cm com cinco sementes por metro linear e se mantendo com estande final de cinco plantas por metro linear. A cultura anterior era soja. A adubação de base foi realizada com 200 Kg/ha do formulado 10-46-00. O manejo fitossanitário da área foi realizado de acordo com o padrão da fazenda.

A coleta das folhas de milho foi realizada a partir de um o monitoramento periódico da área até ser constatada a presença da doença e posteriormente acompanhando a evolução da doença até que fosse possível identificar os diferentes níveis de severidade nas folhas. Foram coletadas duas folhas por planta, sendo uma abaixo da espiga e outra acima, durante a coleta foi necessário tomar alguns cuidados para que as avaliações não fossem prejudicadas como, evitar excesso de orvalho nas folhas e armazenar e transportar as amostras foliares em caixa térmica até o laboratório, para que as mesmas não se desidratassem. Em cada nível foram coletadas 100 folhas para a leitura. Os níveis coletados foram N1 com severidade de 0,5 a 10%, N2 com severidade de 20 a 40%, N3 com severidade de 50 a 60% e folhas saudáveis.



Figure 1. Folhas representando os níveis de severidade de cercosporiose coletados.

Após a coleta das folhas foi realizada as análises hiperespectral utilizando o espectrorradiômetro FieldSpec 4 Jr da Analytical Spectral Devices (Boulder, EUA). O equipamento captura reflectância das folhas 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. No auxílio para as leituras das folhas, foi utilizado um leitor opcional ASD Plant Probe, proporcionando que a leitura espectral não seja afetada pela luminosidade do ambiente.

Foram extraídas as bandas espectrais, com o intuito de avaliar a melhor caracterização da doença em relação às características espectrais, buscando uma distinção na assinatura espectral para cada nível de severidade. A delimitação das bandas espectrais foi realizada de acordo com o Silva Junior et al. (2018), separando todo o espectro hiperespectral em 28 faixas denominadas bandas. Essa separação foi realizada a fim de diminuir a complexidade do posterior processamento dos dados, deixando apenas as faixas espectrais que possuem relação específica com características fisiológicas da planta. Além disso foram calculados com os valores espectrais índices de vegetação: EVI, EVI2, MVI, MCARI, NDRE, MSI e NDVI.

Após a obtenção dos dados espectrais e a separação em bandas, os dados foram submetidos a análise de aprendizagem de máquina utilizando os algoritmos Redes Neurais Artificiais (ANN), árvore de decisão REPTree (DT) e J48, random forest (RF), máquina de vetor suporte (SVM) e utilizado como método tradicional de classificação regressão logística (RL), todos os algoritmos foram selecionados segundo Santana et al., (2023), utilizando as configurações de parâmetros padrão do software Weka 3.8.5, com exceção das redes neurais em que foram utilizados 10 neurônios na primeira e 10 neurônios na segunda camada, buscando aumentar a eficiência do processamento dos dados.

Nos modelos foram utilizados três conjuntos distintos de inputs: o espectro completo (WL), as bandas espectrais (SB) e índices de vegetação (IVs). A avaliação do desempenho dos modelos foi conduzida por meio das métricas de classificações corretas (CC), F-score e do coeficiente Kappa.

RESULTADOS

Para cada nível de severidade da doença, foi construída uma curva espectral com o objetivo de distinguir os diferentes níveis de acordo com a intensidade dos sintomas (Figura 2). Na região do visível, observam-se variações significativas, especialmente nas faixas do verde e do vermelho. Nos níveis mais altos de severidade, a curva na região do vermelho apresentou um comportamento irregular, associado ao amarelecimento acentuado das folhas. No infravermelho próximo (NIR), os níveis de severidade mais baixos, N1 e N2, exibiram comportamentos espectrais semelhantes, enquanto N3 e as plantas saudáveis mostraram maior distinção. Os níveis de severidade mais intensos apresentaram menor fator de reflectância no NIR, indicando maior impacto da doença. Já na região do infravermelho de ondas curtas (SWIR), especialmente a partir de 1700 nm, a distinção entre os níveis de severidade se tornou ainda mais evidente, com os níveis mais altos apresentando maiores valores de reflectância, enquanto as plantas saudáveis mantiveram valores mais baixos, refletindo o estado saudável do tecido foliar.

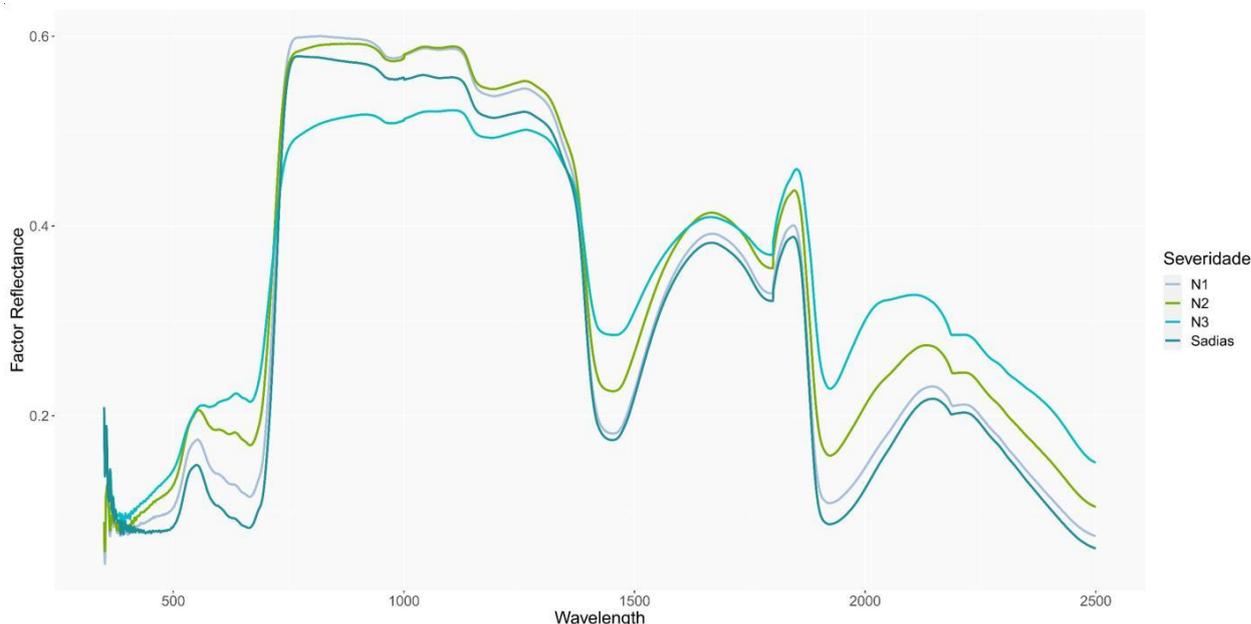


Figure 2. Curva espectral dos níveis de severidade de cercosporiose no milho para os níveis de severidade avaliados

Para classificar os níveis de severidade da cercosporiose em milho, foram avaliados três tipos de inputs, buscando métodos práticos e eficientes. Foram testados índices de vegetação (IVs), bandas espectrais (SB) e o espectro completo (WL) como

inputs (Figura 3). No caso dos IVs, tanto a RNA quanto a RL demonstraram boa performance em todas as métricas de acurácia utilizadas, evidenciando que os índices de vegetação podem ser eficazes em contextos de menor informação espectral. Para os inputs de SB, RL superou os demais modelos, apresentando uma performance superior ao identificar diferentes níveis de severidade. Quando toda a informação do espectro (WL) foi utilizada, o SVM e a RL obtiveram os melhores resultados, o que sugere que o espectro completo fornece informações adicionais para esses modelos.

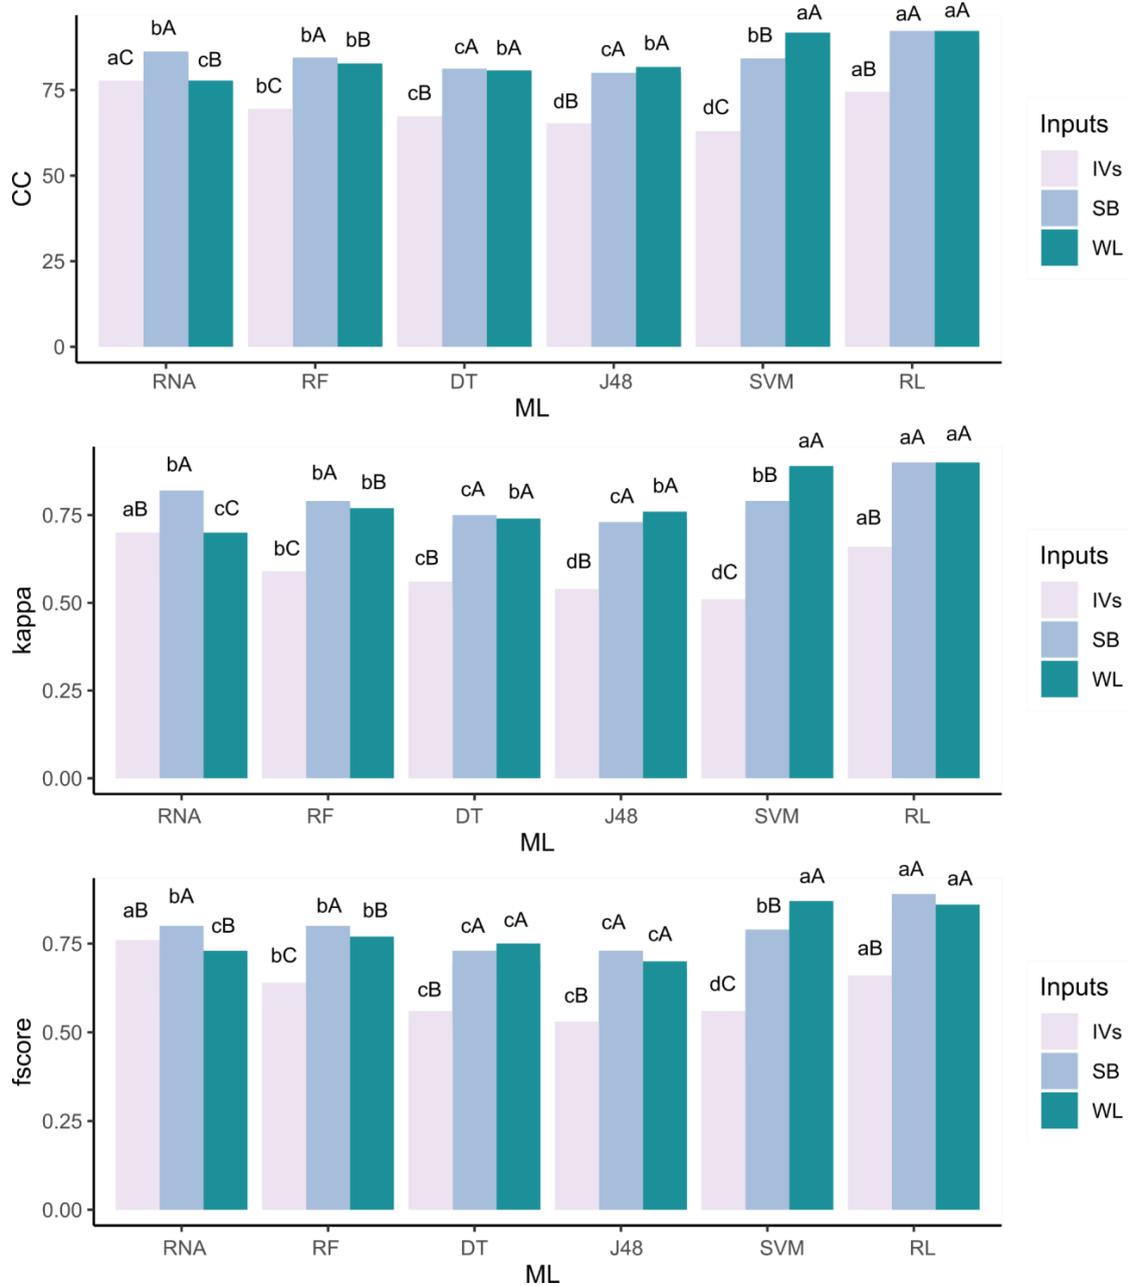


Figure 3. Agrupamento de médias para a métrica de acurácia classificação correta (CC), coeficiente kappa e Fscore dos algoritmos de aprendizagem de máquina com os diferentes inputs utilizados na classificação da severidade de ataque de cercospora no milho

Médias seguidas pelas mesmas letras maiúsculas para os diferentes inputs e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

Ao comparar a eficácia dos três inputs entre os diferentes modelos, observou-se que para RNA e RF, as bandas espectrais foram o input mais eficaz. Já para os modelos DT, J48 e RL, os melhores resultados foram alcançados com SB ou WL. No caso do SVM, o modelo mostrou-se mais eficiente ao utilizar o espectro completo (WL).

DISCUSSÃO

O estresse vegetal é influenciado por fatores abióticos e bióticos desfavoráveis, em que as plantas se comportam a esses estresses de forma complexa e que podem ser detectados por sensores. As alterações bioquímicas que ocorrem nos tecidos vegetais são essenciais para a detecção precoce de doenças vegetais usando sensores e a resposta espectral depende de múltiplas interações biofísicas e bioquímicas em que a faixa VIS (400–700 nm) é influenciada pelo conteúdo de pigmentos, a faixa NIR (700–1100 nm) é influenciada pela estrutura da folha, processos de espalhamento interno e pela absorção de luz pela água da folha e a WIR (1100–2500) é influenciada pela composição da água (Terentev et al., 2022).

A região do visível teve grande distinção entre os níveis de severidade. Zhao et al. (2017) comprovaram que a reflectância e as características de textura das folhas na faixa de 694 e 742 nm apresentam bom desempenho na distinção de amostras infestadas por pulgões de amostras saudáveis. Essa região também se destacou no comportamento espectral para cada nível de severidade de cercosporiose, região em que houve um comportamento muito distinto das folhas saudáveis. A faixa do visível, como mencionada é influenciada principalmente pelo conteúdo de pigmento da folha que é significativamente alterada pela incidência de doença. A resposta óptica ao estresse próximo a 700 nm, as mudanças correspondentes na refletância que ocorrem no espectro verde-amarelo, podem ser explicadas pela tendência geral do estresse de reduzir a concentração de clorofila nas folhas (Carter & Knapp, 2001).

Havendo a distinção de comportamento espectral os modelos de ML foram eficazes na distinção de cada nível de doença. Os resultados indicam que a Regressão Logística (RL) apresentou o melhor desempenho entre os modelos testados, alcançando boa acurácia de classificação em todos os tipos de input (IVs, SB e WL), destacando sua eficiência na classificação dos níveis de severidade da cercosporiose em milho. Santana et al. (2024) também observaram um desempenho superior da Regressão Logística na classificação de genótipos de soja em termos de caracteres industriais, quando comparada a outras técnicas padrão. RL oferece uma vantagem significativa em tarefas complexas, seja em doenças foliares ou em parâmetros industriais de culturas agrícolas, apresentando ampla aplicabilidade. RL se destaca como um método de classificação confiável e versátil, capaz de lidar com diferentes inputs espectrais para a distinção precisa de níveis de severidade de doenças. A utilização de dados hiperespectrais tem mostrado que, em algumas situações, modelos de machine learning e métodos tradicionais podem apresentar desempenhos de classificação equivalentes. Isso indica que, dependendo da riqueza e da qualidade dos dados espectrais, ambos os tipos de abordagem podem fornecer resultados comparáveis, embora os modelos de machine learning possam oferecer maior desempenho para dados complexos.

O SVM também demonstrou excelente desempenho, alcançando resultados comparáveis aos da RL ao utilizar o espectro completo (WL). RL e SVM também apresentaram superioridade na classificação de severidade de mancha alvo em soja utilizando dados hiperespectrais (de Queiroz Otone et al., 2024). Segundo Oliveira et al. (2024), o SVM mostrou-se superior a outros algoritmos na tarefa de predição de flavonoides em eucalipto, oferecendo uma abordagem mais simples e rápida para essa finalidade. Esses resultados destacam o SVM como uma ferramenta eficaz em aplicações onde a velocidade e a precisão são essenciais, consolidando-o como uma alternativa valiosa para análises espectrais em diferentes contextos agronômicos. Esse algoritmo também apresentou acurácia para classificar os níveis de severidade de ferrugem asiática usando todas as informações espectrais como entrada (Santana et al., 2024).

CONCLUSÃO

Os resultados sugerem que escolher o input ideal para classificação da severidade de mancha de cercospora em milho depende tanto do modelo de classificação quanto do tipo de informação espectral disponível, sendo necessário avaliar a disponibilidade da informação para escolher o melhor modelo. Dessa forma, a utilização de todo o espectro

associado aos modelos de aprendizagem de máquina RL e SVM é a abordagem mais precisa no monitoramento desta doença.

REFERENCIAS

- Barros, R (2020). Study on a foliar application of acibenzolar-s-methyl to induce resistance to asian rust in soybeans and gray leaf spot of maize. *Arquivos do Instituto Biológico*, v. 78, p. 519–528.
- Carter, G. A., & Knapp, A. K. (2001). Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *American Journal of Botany*, 88(4), 677–684.
- Concepcion, R., Dadios, E., Alejandrino, J., Mendigoria, C. H., Aquino, H., & Alajas, O. J. (2021). Diseased surface assessment of maize cercospora leaf spot using hybrid gaussian quantum-behaved particle swarm and recurrent neural network. *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 1–6.
- da Silva Junior, C. A., Nanni, M. R., Shakir, M., Teodoro, P. E., de Oliveira-Júnior, J. F., Cezar, E., de Gois, G., Lima, M., Wojciechowski, J. C., & Shiratsuchi, L. S. (2018). Soybean varieties discrimination using non-imaging hyperspectral sensor. *Infrared Physics & Technology*, 89, 338–350.
<https://doi.org/https://doi.org/10.1016/j.infrared.2018.01.027>
- de Oliveira, I. C., Santana, D. C., de Oliveira, J. L. G., Silva, E. V. M., da Silva Candido Seron, A. C., Blanco, M., Teodoro, L. P. R., da Silva Júnior, C. A., Baio, F. H. R., & Alves, C. Z. (2024). Flavonoids and their relationship with the physiological quality of seeds from different soybean genotypes. *Scientific Reports*, 14(1), 17008.
- de Oliveira, I. C., Santana, D. C., de Oliveira, J. L. G., Silva, E. V. M., da Silva Candido Seron, A. C., Blanco, M., Teodoro, L. P. R., da Silva Júnior, C. A., Baio, F. H. R., & Alves, C. Z. (2024b). Flavonoids and their relationship with the physiological quality of seeds from different soybean genotypes. *Scientific Reports*, 14(1), 17008.
- de Queiroz Otone, J. D., 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. (2024). Hyperspectral Response of the Soybean Crop as a Function of Target Spot (*Corynespora cassiicola*) Using Machine Learning to Classify Severity Levels. *AgriEngineering*, 6(1), 330–343.
- Gao, Z., Khot, L. R., Naidu, R. A., & Zhang, Q. (2020). Early detection of grapevine leafroll disease in a red-berried wine grape cultivar using hyperspectral imaging. *Computers and Electronics in Agriculture*, 179, 105807.
- Gonzalez-Dugo, V., Hernandez, P., Solis, I., & Zarco-Tejada, P. J. (2015). Using high-resolution hyperspectral and thermal airborne imagery to assess physiological condition in the context of wheat phenotyping. *Remote Sensing*, 7(10), 13586–13605.

- He, W., Zhu, Y., Leng, Y., Yang, L., Zhang, B., Yang, J., Zhang, X., Lan, H., Tang, H., & Chen, J. (2021). Transcriptomic analysis reveals candidate genes responding maize gray leaf spot caused by *Cercospora zeina*. *Plants*, *10*(11), 2257.
- Pinto, N. F. J. D. A., de angelis, B. R. U. N. O., & HABE, M. H. (2004). Avaliação da eficiência de fungicidas no controle da cercosporiose (*Cercospora zea-maydis*) na cultura do milho. *Revista Brasileira de Milho e Sorgo*, *3*(01).
- Santana, D. C., de Oliveira, I. C., de Oliveira, J. L. G., Baio, F. H. R., Teodoro, L. P. R., da Silva Junior, C. A., Seron, A. C. C., Ítavo, L. C. V., Coradi, P. C., & Teodoro, P. E. (2024). High-throughput phenotyping using VIS/NIR spectroscopy in the classification of soybean genotypes for grain yield and industrial traits. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, *310*, 123963.
- Santana, D. C., de Queiroz Otone, J. D., Baio, F. H. R., Teodoro, L. P. R., Alves, M. E. M., da Silva Junior, C. A., & Teodoro, P. E. (2024). Machine learning in the classification of asian rust severity in soybean using hyperspectral sensor. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, *313*, 124113.
- Santana, D. C., Teodoro, L. P. R., Baio, F. H. R., dos Santos, R. G., Coradi, P. C., Biduski, B., da Silva Junior, C. A., Teodoro, P. E., & Shiratsuchi, L. S. (2023). Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. *Remote Sensing Applications: Society and Environment*, 100919.
- Şimşek, F. F. (2024). Investigation of the Effect of Spectral Bands and Vegetation Index Selection on Agricultural Crop Type Classification (Especially for Double Crops).
- Silva, R. S., Campos, H. D., Ribeiro, L. M., Braz, G. B. P., Magalhães, W. B., & Bueno, J. N. (2021). Danos na cultura do milho em função da redução de área foliar por desfolha artificial e por doenças. *Summa Phytopathologica*, v. 46, p. 313–319.
- Terentev, A., Dolzhenko, V., Fedotov, A., & Eremenko, D. (2022). Current state of hyperspectral remote sensing for early plant disease detection: A review. *Sensors*, *22*(3), 757.
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, *236*, 111402.
- Zhao, Y., Yu, K., Feng, C., Cen, H., & He, Y. (2017). Early detection of aphid (*Myzus persicae*) infestation on Chinese cabbage by hyperspectral imaging and feature extraction. *Transactions of the ASABE*, *60*(4), 1045–1051.