UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

RESPOSTAS FISIOLÓGICAS E ESPECTRAIS DE PLANTAS DE MILHO INFESTADAS POR *Diatraea saccharalis* (FABRICIUS, 1794) (LEPIDOPTERA: CRAMBIDAE) E *Spodoptera frugiperda* (J. E. SMITH, 1797) (LEPIDOPTERA: NOCTUIDAE)

Marina Guimarães Brum de Castro

Engenheira Agrônoma

2023

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

RESPOSTAS FISIOLÓGICAS E ESPECTRAIS DE PLANTAS DE MILHO INFESTADAS POR *Diatraea saccharalis* (FABRICIUS, 1794) (LEPIDOPTERA: CRAMBIDAE) E *Spodoptera frugiperda* (J. E. SMITH, 1797) (LEPIDOPTERA: NOCTUIDAE)

Discente: Marina Guimarães Brum de Castro

Orientador: Prof. Dr. Odair Aparecido Fernandes

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para obtenção do título de Mestre em Agronomia (Entomologia Agrícola).

2023

C355r

Castro, Marina Guimarães Brum de

Respostas fisiológicas e espectrais de plantas de milho infestadas por Diatraea saccharalis (Fabricius, 1794) (Lepidoptera: Crambidae) e Spodoptera frugiperda (J. E. Smith, 1797) (Lepidoptera: Noctuidae) / Marina Guimarães Brum de Castro. -- Jaboticabal, 2023

41 p. : tabs., fotos

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Odair Aparecido Fernandes

1. Broca-da-cana-de-açúcar. 2. Lagarta-do-cartucho. 3. Estresse biótico. 4. Monitoramento. 5. Sensoriamento remoto. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

unesp

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: RESPOSTAS FISIOLÓGICAS E ESPECTRAIS DE PLANTAS DE MILHO INFESTADAS POR *Diatraea saccharalis* (FABRICIUS, 1794) (LEPIDOPTERA: CRAMBIDAE) E *Spodoptera frugiperda* (J. E. SMITH, 1797) (LEPIDOPTERA: NOCTUIDAE)

AUTORA: MARINA GUIMARÃES BRUM DE CASTRO
ORIENTADOR: ODAIR APARECIDO FERNANDES

Aprovada como parte das exigências para obtenção do Título de Mestra em Agronomia (Entomologia Agrícola), pela Comissão Examinadora:

Prof. Dr. ODAIR APARECIDO FERNANDES (Participaçao Virtual)
Departamento de Ciencias da Producao Agricola / FCAV UNESP Jaboticabal

Prof. Dr. ELISEU JOSÉ GUEDES PEREIRA (Participaçao Virtual)
Departamento de Entomologia / Universidade Federal de Viçosa - Viçosa/MG

gov.br
Documento assinado digitalmente
ELISEU JOSE GUEDES PEREIRA
Data: 11/07/2023 21:54:11-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. DAVID LUCIANO ROSALEN (Participaçao Virtual)
Departamento de Engenharia e Ciências Exatas (DECEx) / FCAV / UNESP - Jaboticabal

Jaboticabal, 10 de julho de 2023

DADOS CURRICULARES DA AUTORA

Marina Guimarães Brum de Castro nasceu em 08 de maio de 1996 na cidade de Juiz de Fora, Minas Gerais, Brasil. Obteve título de engenheira agrônoma pela Universidade Federal de Viçosa (UFV) em janeiro de 2020. Em 2017 e 2018 estagiou no Laboratório de Interação Inseto-Microrganismo sob orientação do Prof. Dr. Simon Luke Elliot. Inicialmente realizou atividades de apoio a pesquisa, como criação de insetos, preparo de dietas, montagem e avaliação de experimentos, e posteriormente trabalhou no projeto intitulado “Ecologia imune e trade-offs no besouro necrófago *Oxelytrum discicolle* (Coleoptera: Silphidae)” com Bolsa de Iniciação Científica FAPEMIG. Ingressou no Centro Acadêmico do curso no final de 2018 onde obteve maior experiência na área de gestão. No início de 2019 estagiou no Departamento de Botânica da Universidade Federal de Minas Gerais sob orientação do Prof. Dr. Joni Esrom Lima, realizando treinamento técnico-científico na área de biologia molecular de plantas. Também em 2019 trabalhou como gerente de qualidade no Núcleo de Estágios AGRO UFV, grupo ligado à coordenação do curso com intuito de aproximar empresas da Universidade. Em agosto de 2020 ingressou no mestrado do programa de Agronomia (Entomologia Agrícola) da UNESP/FCAV - Campus de Jaboticabal, com bolsa pela CAPES – Demanda Social, sob orientação do Prof. Dr. Odair Aparecido Fernandes.

“As coisas tangíveis
tornam-se insensíveis
à palma da mão

Mas as coisas findas
muito mais que lindas,
essas ficarão.”

Memória
Carlos Drummond de Andrade

Aos meus pais, Ubiratan e Mônica (in memoriam),
meus maiores exemplos de resiliência, dedicação e
amor incondicional.

DEDICO

AGRADECIMENTOS

Agradeço primeiramente a minha família. Ao meu pai Ubiratan, exemplo de profissional ético, dedicado e sonhador, que trabalha em busca do que se propõe sem hesitar. Aos meus irmãos João Pedro, Fabiana e Frederico, três pessoas que seguiram caminhos profissionais parecidos, mas que enfrentam jornadas muito distintas e que por isso se tornaram indivíduos únicos, que me inspiram e me dão orgulho. À Beth, amiga-irmã, pelo apoio e suporte através de seus conselhos nos momentos mais difíceis desse período.

Ao Prof. Dr. Odair Aparecido Fernandes, pela orientação, paciência e confiança em mim e no trabalho desenvolvido nesses anos de pós-graduação.

Aos docentes do Programa de Pós-graduação em Agronomia (Entomologia Agrícola) da Faculdade de Ciências Agrárias e Veterinárias - Unesp, e aos professores Dra. Fernanda Sayuri Yoshino Watanabe, Dr. Antonio Maria Garcia Tommaselli e Dr. Nilton Nobuhiro Imai da Faculdade de Ciências e Tecnologia – Unesp, por todo tempo e conhecimento gentilmente concedidos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Ao meu parceiro de projeto, João Rafael, pelo tempo e dedicação disponibilizado para acompanhamento desse trabalho, que sem sua ajuda não teria conseguido terminar.

Ao meu companheiro de vida e de trabalho, Luís Augusto, e aos meus colegas do Laboratório de Ecologia Aplicada, Gabriel, Sabrina, Thaynara, Vinícius, Gabriela, Yasmin, Beliza, Rafaela, Álvaro, André e João Marcelo, que auxiliaram nas análises e fizeram dessa jornada em meio a pandemia e mudanças de projeto menos estressantes.

Por fim agradeço a minha mãe, Mônica (in memoriam), que mesmo não mais presente, segue me guiando quando mais preciso.

SUMÁRIO

Página

RESUMO ii
ABSTRACT iii
LISTA DE FIGURAS iv
LISTA DE TABELAS vi
1. INTRODUÇÃO 1
2. REVISÃO DE LITERATURA 3
2.1. Importância e monitoramento de *Diatraea saccharalis* e *Spodoptera frugiperda* na cultura do milho 3
2.2. Sensoriamento remoto no controle de pragas 4
3. MATERIAL E MÉTODOS 8
3.1. Insetos 8
3.2. Plantas 8
3.3. Avaliação de injúria 9
3.4. Avaliação de resposta fisiológica 9
3.5. Avaliação hiperespectral e processamento de dados espectrais 10
3.6. Análise dos dados 14
4. RESULTADOS 17
4.1. Avaliação de resposta fisiológica 17
4.2. Avaliação hiperespectral 23
5. DISCUSSÃO 30
6. CONCLUSÕES 34
7. REFERÊNCIAS 35

RESPOSTAS FISIOLÓGICAS E ESPECTRAIS DE PLANTAS DE MILHO INFESTADAS POR *Diatraea saccharalis* (FABRICIUS, 1794) (LEPIDOPTERA: CRAMBIDAE) E *Spodoptera frugiperda* (J. E. SMITH, 1797) (LEPIDOPTERA: NOCTUIDAE)

RESUMO – O sensoriamento remoto vem se tornando uma alternativa relevante na otimização do monitoramento de pragas agrícolas. Contudo, antes de propor o uso de sensores como uma solução a detecção de ataque insetos, é essencial conhecer a resposta espectral de plantas sob diferentes tipos de estresses. Neste estudo foram determinados parâmetros de trocas gasosas e o comportamento espectral de plantas de milho em casa de vegetação infestadas por *Diatraea saccharalis* (Fabricius, 1794) (Lepidoptera: Crambidae) e *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: Noctuidae), a fim de investigar respostas fisiológicas e bandas espectrais sensíveis às diferentes injúrias causadas por estes insetos. Para isso, plantas de milho em estádio de desenvolvimento V5 foram aleatoriamente distribuídas em quatro tratamentos: plantas não infestadas, plantas infestadas por *D. saccharalis*, plantas infestadas por *S. frugiperda* e plantas infestadas por ambas as espécies. As medições da reflectância espectral foram realizadas por meio do sensor hiperespectral configurado para adquirir imagens em 50 bandas entre 500 e 900 nm. Ainda, a resposta fisiológica, dado por parâmetros de assimilação, concentração de CO_2 subestomatal, condutância estomática, déficit de vapor entre folha e ar e eficiência de uso da água fotossintética também foram obtidos utilizando sistema portátil de medição de fotossíntese. As leituras espectrais e fisiológicas foram realizadas em seis dias distintos durante o período de 14 dias de desenvolvimento larval. Ao final deste período, todas as plantas foram seccionadas para constatação de sucesso de infestação e somente as plantas infestadas foram consideradas nas análises. Modelos de classificação criados a partir dos espectros de reflectância médios permitiram a discriminação de plantas sadias e plantas com os estressores, sobretudo na região do visível (666,36 nm) para plantas com *S. frugiperda* e infravermelho próximo (866,05 nm) para plantas com *D. saccharalis*. Não houve diferença relevante nos parâmetros de troca gasosa entre plantas sadias e infestadas durante o período avaliado. Esses resultados indicam que o sensor imageador hiperespectral tem potencial para ser utilizado em atividades de monitoramento dessas pragas. Como não houve alterações significativas nos parâmetros de trocas gasosas, as mudanças espectrais provavelmente ocorreram por modificações estruturais internas das folhas ocasionadas pelas injúrias desses insetos.

Palavras-chave: broca-da-cana-de-açúcar, lagarta-do-cartucho, estresse biótico, manejo integrado de pragas, monitoramento, sensoriamento remoto

PHYSIOLOGICAL AND SPECTRAL RESPONSES OF MAIZE INFESTED BY *Diatraea saccharalis* (FABRICIUS, 1794) (LEPIDOPTERA: CRAMBIDAE) AND *Spodoptera frugiperda* (J. E. SMITH, 1797) (LEPIDOPTERA: NOCTUIDAE)

ABSTRACT – Remote sensing is becoming a relevant alternative in optimizing the monitoring of agricultural pests. However, before proposing the use of sensors as a solution for insect detection, it is essential to know the spectral response of plants under different types of stress. In this study, gas exchange parameters and the spectral behavior of maize plants in the greenhouse infested by *Diatraea saccharalis* (Fabricius, 1794) (Lepidoptera: Crambidae) and *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: Noctuidae) were determined in order to investigate physiological responses and spectral bands sensitive to the different injuries caused by these insects. For this, maize plants at V5 developmental stage were randomly assigned to four treatments: non-infested plants, plants infested by *D. saccharalis*, plants infested by *S. frugiperda* and plants infested by both species. Spectral reflectance measurements were performed using hyperspectral sensor configured to acquire images in 50 bands between 500 and 900 nm. The physiological response given by parameters of assimilation, substomatal CO_2 concentration, stomatal conductance, vapor deficit between leaf and air and photosynthetic water use efficiency were also obtained using a portable photosynthesis system. Spectral and physiological readings were performed on six different days during the 14-day period of larval development. At the end of this period, all plants were sectioned to verify successful infestation and only infested plants were considered in the analyses. Classification models created from the average reflectance spectra allowed the discrimination of healthy plants and plants with stressors, especially in the visible region (666.36 nm) for plants with *S. frugiperda* and near infrared (866.05 nm) for plants with *D. saccharalis*. There was no relevant difference in gas exchange parameters between healthy and infested plants during the evaluated period. These results indicate that the hyperspectral imaging sensor has the potential to be used in monitoring activities for these pests. As there were no significant changes in the gas exchange parameters, the spectral changes probably occurred due to internal structural changes in the leaves caused by the injuries of these insects.

Keywords: sugarcane borer, fall armyworm, biotic stress, integrated pest management, monitoring, remote sensing

LISTA DE FIGURAS

Figura 1. Detalhe da avaliação de resposta fisiológica por meio do sistema portátil de medição de fotossíntese (CIRAS-3®) acoplado à porção mediana da última folha totalmente expandida de planta de milho.....10

Figura 2. Detalhe do espectrorradiômetro (FieldSpec® Handheld) (**A**) e do sensor hiperespectral (Rikola®) (**B**) e sua disposição para tomada de imagens de plantas de milho (**C**).....12

Figura 3. Imagem tomada pelo sensor hiperespectral (Rikola®) mostrando a disposição dos alvos coloridos.....13

Figura 4. Análise de componentes principais (PCA) dos parâmetros fisiológicos de plantas de milho sadias e infestadas por *Diatraea saccharalis* e *Spodoptera frugiperda* em casa de vegetação obtidos antes da infestação (**A**) e após 14 dias da infestação (**B**).....18

Figura 5. Média (± EPM) dos valores referentes aos parâmetros fisiológicos ao longo dos 14 dias de avaliação. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).....20

Figura 6. Resposta fisiológica de milho infestado por *D. saccharalis* e *D. saccharalis* + *S. frugiperda* sob diferentes níveis de injúria, dado pelo volume de galeria (cm^3) consumida pela broca-do-colmo. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).....22

Figura 7. Resposta fisiológica de milho infestado por *S. frugiperda* e *D. saccharalis* + *S. frugiperda* sob diferentes níveis de injúria, dado pela nota de Davis final. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).....23

Figura 8. Comportamento espectral médio das plantas de milho sadias e infestadas nos seis dias de avaliação.....24

Figura 9. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas infestadas (DS+SF+DSSF) no 14º. DAI. Em (**A**) valores de ROC + AUC para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de ROC + AUC para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.....25

Figura 10. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas DS no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.....26

Figura 11. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas SF no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.....27

Figura 12. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas DSSF no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.....28

LISTA DE TABELAS

Tabela 1. Bandas espectrais configuradas para obtenção das imagens.....11

Tabela 2. Efeito dos tratamentos e data de avaliação sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Diatraea saccharalis*, *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.....19

Tabela 3. Médias (± EPM) dos valores de eficiência do uso da água (WUE) de plantas de milho infestadas por *Diatraea saccharalis*, *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* e as comparações entre esses tratamentos.....19

Tabela 4. Efeito dos tratamentos e volume da galeria sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Diatraea saccharalis* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.....21

Tabela 5. Efeito dos tratamentos e nota de injúria sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.....21

Tabela 6. Acurácia dos modelos de separação de plantas de controle de plantas infestadas no período de 14 dias após infestação (DAI).....29

1. INTRODUÇÃO

A implementação de tecnologias e serviços inovativos advindos da chamada “agricultura 4.0” permitem que produtores naveguem no atual momento de aumento exponencial de demanda por alimento, maior eficiência e menor impacto socioambiental na produção agrícola (Behmann et al., 2015; Silveira et al., 2021). Somado a um contexto de mudanças climáticas, faz-se cada vez mais necessário também a busca por tecnologias encarregadas de auxiliar no enfretamento das possíveis alterações bióticas e abióticas que se desencadearão (Calanca, 2017; Deutsch et al., 2018; Chaudhry e Sidhu, 2022). Nesse cenário, ferramentas como os sensores, que auxiliam na rápida obtenção de informações e acompanhamento espaço-temporal de grandes áreas, são cruciais para tomadas de decisões mais precisas e otimizadas (Moran et al., 1997; Seelan et al., 2003; Karthikeyan et al., 2020).

Técnicas de sensoriamento remoto já são amplamente utilizadas no monitoramento do uso da terra, previsão de safras e planejamento de aplicações de insumos (Sishodia et al., 2020; Weiss et al., 2020). Um segmento da aplicação de sensores que se iniciou na década de 80, mas que vem sendo mais explorado atualmente é a identificação de plantas sob algum tipo de estresse biótico (Riley, 1989; Prabhakar et al., 2012; Nansen e Elliott, 2016; Zhang et al., 2019). O uso de sensores na identificação de plantas atacadas por insetos-praga parte do princípio de que a herbivoria desencadeia modificações físicas, morfológicas e fisiológicas na planta, que podem ser capturadas pela alteração na reflectância da luz pela folha (Kumar et al., 2001). As mudanças espectrais são especialmente relacionadas às alterações no aparato fotossintético e seu desempenho (Behmann et al., 2015; Mahlein et al., 2018; Pinto et al., 2020). Diante disso, faz-se necessário primeiro conhecer qual o comportamento espectral de uma folha sadia, qual a alteração fisiológica desempenhada pelo estressor e, por fim, qual padrão de energia refletida após injúria, visto que plantas podem responder de formas diferentes de acordo com o estressor (Nansen e Elliott, 2016; Zhang et al., 2019).

A broca-do-colmo *Diatraea saccharalis* (Fabricius, 1794) (Lepidoptera: Crambidae), e a lagarta-do-cartucho *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: Noctuidae), são duas pragas do milho responsáveis por diferentes tipos

de injúria (Montezano et al., 2018; Francischini et al., 2019; Sun et al., 2021). *Diatraea saccharalis* tem comportamento broqueador, isto é, ao se alimentar do colmo forma galerias que facilitam a quebra e favorecerem a entrada de microrganismos patogênicos na planta (Cruz, 2007; Macedo et al., 2012; Valicente, 2015). Por outro lado, a lagarta-do-cartucho, *S. frugiperda*, é classificada como desfolhadora. Quando neonata, realiza raspagem das folhas e à medida que se desenvolve passa a causar desfolha, podendo consumir também a espiga (Valicente, 2015). Ainda, o estresse gerado pelas diferentes injúrias desses insetos pode resultar em alterações nas trocas gasosas das plantas, impactando o desenvolvimento e produtividade final destas (Welter, 1989; Peterson e Higley, 1993; Rossato et al., 2019; Anjorin et al., 2022).

O monitoramento da broca-do-colmo e da lagarta-do-cartucho normalmente é realizado ou pela amostragem de lagartas no talhão, o que requer mão de obra e tempo para cobrir grandes áreas, ou pela utilização de armadilhas do tipo delta com atrativo (alimentar ou sexual), que precisam de reposição frequente do produto e troca do piso colante no qual os insetos ficam aderidos (Cruz et al., 2010; Cruz et al., 2012). Com a demanda de soluções mais imediatas para auxiliar na tomada de decisões, o sensoriamento remoto apresenta-se como alternativa para o monitoramento dessas pragas a campo.

Para determinar a viabilidade de técnicas de sensoriamento remoto como ferramenta no monitoramento dessas pragas, neste trabalho foi investigada a resposta fisiológica e espectral do ataque isolado e conjunto de *D. saccharalis* e *S. frugiperda* em plantas de milho.

2. REVISÃO DE LITERATURA

2.1. Importância e monitoramento de *Diatraea saccharalis* e *Spodoptera frugiperda* na cultura do milho

A lagarta-do-cartucho *S. frugiperda* é uma mariposa nativa das Américas que hoje encontra-se dispersa globalmente (Goergen et al., 2016; Sun et al., 2021). Apesar de ter como principal hospedeiro o milho, ela é conhecida por ser altamente polífaga, já associada a 353 espécies de plantas, sendo a maioria da família Poaceae (Montezano et al., 2018). As condições climáticas favoráveis do Brasil, somados a abundância de possíveis hospedeiros, permitem que o inseto mantenha seu ciclo por todo ano, sendo essa uma das razões limitantes do seu controle (Cruz, 1995; Silva et al., 2017). O ciclo do inseto dura cerca de 30 dias em condições controladas, porém a fase crítica para a cultura ocorre no período larval, que dura entorno de 14 dias (Valicente, 2015). Devido à competição por recursos alimentares e hábito canibal após a eclosão das larvas, é comum que ocorra dispersão delas em plantas hospedeiras próximas (Chapman et al., 1999). Nos primeiros instares, a lagarta-do-cartucho se alimenta raspando a epiderme e o parênquima foliar e, quando mais desenvolvidas, passam a perfurar a folha ou a se alimentar da espiga (Valicente, 2015).

A broca-do-colmo *D. saccharalis* é também uma espécie polífaga presente em diferentes gramíneas, sendo mais conhecida pela sua associação com a cultura da cana-de-açúcar (Macedo et al., 2012). Semelhante ao que ocorre na cana, na cultura do milho a lagarta se alimenta raspando as folhas novas na região da bainha durante os primeiros instares e, após o terceiro instar, passa a se alimentar do interior do colmo (Cruz, 2007; Valicente, 2015). As galerias formadas dentro dos internódios enfraquecem a planta, podendo facilitar a quebra dessas antes do enchimento total da espiga, permitir a entrada de microrganismos patogênicos e diminuir o enchimento total de grãos (Cruz, 2007). As brocas permanecem dentro das galerias até a emergência do adulto, fator que dificulta seu controle (Cruz, 2007; Valicente, 2015).

Na ausência de métodos de controle, a lagarta-do-cartucho e a broca têm potencial de redução da produção final da cultura do milho acima de 20% (Valicente, 2015; Day et al., 2017). Em virtude desse número expressivo, o monitoramento constante dessas duas pragas é imprescindível para uma eficiente tomada de

decisão. Normalmente esta é baseada na amostragem de lagartas em pontos no talhão, ou pela utilização de armadilhas com uso de feromônios sexuais sintéticos ou fêmeas virgens presas no seu interior. Ambas as alternativas, apesar de efetivas, trazem desvantagens como maior mão de obra, disponibilidade de tempo para avaliar grandes áreas e reposição recorrente de feromônio e adesivo colante (Cruz et al., 2010; Cruz et al., 2012). Nos últimos anos algumas alternativas vêm surgindo, sendo uma delas o sensoriamento remoto e os respectivos sensores. Essas tecnologias emergentes capazes de identificarem variações na vegetação e no solo já são amplamente utilizados, embarcados principalmente em ARPs (Aeronaves Remotamente Pilotadas) e satélites, e auxiliam na otimização de produção agrícola, monitoramento de uso da terra, e na prestação de serviços ecossistêmicos (Lu et al., 2020; Weiss et al., 2020). Apesar desses avanços a detecção de plantas infestadas ainda é um desafio.

2.2. Sensoriamento remoto no controle de pragas

A American Society for Photogrammetry and Remote Sensing (2022) descreve o sensoriamento remoto como “técnicas usadas para obter e processar informação de algum objeto sem o contato físico direto com ele”. Através desses equipamentos se obtém a radiação eletromagnética refletida ou emitida por um objeto, e essa vai variar de acordo com propriedades do material, da atmosfera terrestre e da própria radiação envolvida (Kumar et al., 2001).

Os diferentes tipos de sensores são projetados para registrar vários comprimentos de onda ao longo do espectro eletromagnético (Eismann, 2012). As regiões mais utilizadas no sensoriamento remoto são a região do visível (400 a 700 nm), do infravermelho refletivo (700 a 3000 nm) e termal (3000 a 10000 nm) e, em menor proporção, a região de micro-ondas (10000 a 10^9 nm), de acordo com Eismann (2012) e Jensen (2014).

Com relação à fonte de energia utilizada, esses equipamentos são categorizados em ativos e passivos. Os sensores ativos são aqueles que produzem a radiação que irá interagir com os objetos (Zhu et al., 2018). São exemplos de sensores ativos o LiDAR (Light Detection and Ranging) e o RaDAR (Radio Detection and Ranging) (Eismann, 2012; Barros et al., 2021). Os sensores passivos, por sua vez,

dependem de uma fonte de radiação externa e trabalham então detectando a radiação solar refletida por objetos ou a emitida por eles (Novo, 2010; Jensen, 2014). Com os avanços da área, equipamentos vem integrando ambas as tecnologias, desta forma uma classificação alternativa para os sensores é em imageadores e não imageadores. O primeiro trata-se daqueles que captam uma imagem e que nela contém informações do objeto, seja ela a radiância ou emitância (Novo, 2010; Zhu et al., 2018). Já o segundo trata-se de um sensor que obtém apenas uma informação do que está dentro campo de visão da lente, um exemplo desses sensores são os espectrorradiômetros, que obtém gráficos ou perfis da reflectância do alvo avaliado (Novo, 2010).

A maioria dos sensores imageadores utilizados são ópticos, ou seja, trabalham nas regiões do visível e infravermelho refletivo, sobretudo o infravermelho próximo (700 a 1300 nm) e médio (1300 a 3000 nm) (Prabhakar et al., 2012; Zhang et al., 2019). Os equipamentos imageadores que trabalham nessas regiões são relativamente baratos em comparação aos outros tipos, como os termais e de fluorescência, e podem ser acoplados em diferentes tipos de plataforma (terrestre, aéreo ou orbital) (Zhang et al., 2019).

De acordo com a resolução espectral, os sensores que trabalham nessa faixa do visível ao infravermelho médio podem ser divididos em multiespectrais e hiperespectrais. Os multiespectrais são capazes de obter respostas espectrais em algumas bandas, que juntam informações de dezenas a centenas de nanômetros do espectro (Novo, 2010; Lu et al., 2020). Na agricultura são equipamentos que podem ser utilizados em avaliações de biomassa, produtividade e degradação do solo. Como esses sensores trabalham com a média de uma banda relativamente larga, informações cruciais podem ser perdidas e sinais iniciais de estresses podem ser camuflados (Lu et al., 2020). Já os sensores hiperespectrais permitem maior detalhamento, uma vez que respostas em centenas de bandas mais estreitas podem ser obtidas (Chabrillat et al., 2001; Jensen, 2014; Lu et al., 2020), que, consequentemente, são mais interessantes na obtenção de informações biofísicas e bioquímicas das plantas (Kumar et al., 2001; Sahoo et al., 2015).

A utilização de tecnologias de sensoriamento remoto na observação da vegetação se baseia no mesmo princípio que ocorre com qualquer objeto sobre a superfície terrestre: a radiação solar sofrerá reflexão, absorção e transmissão quando

atingir um alvo, como uma folha. De acordo com o comprimento de onda do espectro, ângulo de incidência, características físicas da superfície e conteúdo bioquímico dessa folha, ocorrerá variação no quanto e como esses processos acontecerão (Kumar et al., 2001).

Os insetos-praga causam nas vegetações uma série de injúrias, sendo as mais documentadas a desfolha, o broqueamento, o encarquilhamento, a clorose e a necrose, que podem resultar direta ou indiretamente na morte de plantas, sendo essa a razão de serem extensivamente estudados (Prabhakar et al., 2012). Esses danos geram também alteração da capacidade fotossintética foliar, destruição de pigmentos e alteração da quantidade de água intercelular. Esses estresses físicos e fisiológicos das plantas geralmente acarretam na alteração da reflectância da luz solar pela folha que, por sua vez, podem por vezes serem detectados por alterações na assinatura espectral da planta (Lillesand et al. 2004; Nabity et al., 2009; Zhang et al., 2019). É a partir desse pressuposto que tecnologias como os sensores tornaram-se possíveis saídas para um manejo integrado de pragas mais eficiente, identificando estresses causados pelos artrópodes antes mesmo de mudanças físicas na planta serem visíveis (Iost et al., 2020).

Nos últimos anos diferentes trabalhos com sensores multi e hiperespectrais foram realizados em condições de laboratório e campo para identificação de estresses bióticos e abióticos (Jorge et al., 2019; Nguyen e Nansen, 2020; Pinto et al., 2020; Barros et al., 2021; Iost et al., 2022; Williams et al. 2023). A utilização de sensores contudo ainda se mostra limitada por alguns fatores. A complexidade dos processamentos e análises após tomada de imagens, relacionada a calibração radiométrica, correção atmosférica e variação da angulação na coleta de dados, e cobertura de nuvens, somada a falta de softwares padrões entre equipamentos é um deles, visto que isso resulta em pouca acessibilidade à produtores (Moran et al., 1997; Seelan et al., 2003; Lu et al., 2020).

Outra limitação está relacionada ao fato de que, em condições de campo, dificilmente apenas um agente estressor estará atuando na planta em dado momento. Ademais, não são todas as pragas capazes de gerar uma resposta espectral identificável (Nansen e Elliot, 2016). Desta forma, ainda são necessárias muitas informações espectrais de diferentes plantas e estressores atuando individualmente e

em conjunto para a construção de uma base de dados que permita que o monitoramento utilizando o sensoriamento remoto seja praticável (Mulla, 2013).

3. MATERIAL E MÉTODOS

3.1. Insetos

Lagartas de terceiro ínstar de *D. saccharalis* foram fornecidas por biofábrica especializada, que mantém criação para fins de produção do parasitoide larval *Cotesia flavipes* (Cameron, 1891) (Hymenoptera: Braconidae). Neonatas de *S. frugiperda* foram obtidas da criação em larga escala do Laboratório de Ecologia Aplicada da Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista (UNESP), Jaboticabal, São Paulo, Brasil.

3.2. Plantas

Vasos plásticos de 21 litros foram preenchidos com substrato a base de solo, areia e esterco de gado bovino, na proporção de 3:1:1, respectivamente. Em seguida, sementes de milho do híbrido não transgênico Impacto® (Syngenta) foram semeadas. A adubação foi realizada no momento de plantio com 400 kg ha^{-1} do formulado NPK 8-28-16, e cobertura (no estádio fenológico V3) utilizando 300 kg ha^{-1} de ureia e 100 kg ha^{-1} de KCl. Os vasos foram acondicionados em casa de vegetação climatizada (27 ± 4ºC, UR 70 ±10% e luz natural) e estiveram sob regime hídrico controlado por irrigação automática durante todo o período, que ocorreu de novembro de 2021 à fevereiro de 2022.

O experimento foi conduzido em delineamento inteiramente casualizado (DIC), com quatro tratamentos: plantas de milho não infestadas (Controle), plantas de milho infestadas por *D. saccharalis* (DS), plantas de milho infestadas por *S. frugiperda* (SF) e plantas de milho infestadas por ambas as espécies (DSSF). Cada tratamento teve 10 repetições, sendo a unidade experimental constituída por um vaso com uma planta de milho.

A infestação artificial foi realizada em milho no estádio fenológico V5. As plantas dos tratamentos SF e DSSF receberam 20 neonatas de *S. frugiperda* no cartucho com auxílio de um pincel úmido. O broqueamento do colmo por *D. saccharalis* ocorre no terceiro ínstar das lagartas (Cruz et al., 2010), e, portanto, os tratamentos DS e DSSF receberam uma lagarta de *D. saccharalis* nesse estádio de desenvolvimento posicionada na axila da penúltima folha totalmente expandida. A confirmação da

infestação pela broca foi realizada pela observação da presença de orifício de entrada no colmo, que demorou um período médio de 30 minutos. Nos casos em que a infestação não foi concretizada, houve substituição por outra lagarta até a constatação de orifício de entrada.

3.3. Avaliação de injúria

Após 14 dias, as injúrias das plantas foram avaliadas de acordo com o inseto-praga. As plantas dos tratamentos com infestação de *D. saccharalis* tiveram o colmo partido longitudinalmente, para a medição do comprimento e diâmetro da seção consumida e assim o volume de galeria estimado. Quando a injúria e/ou o espécime não foram encontrados, a planta foi descartada das análises. Já os tratamentos com infestação de *S. frugiperda* foram avaliados visualmente quanto as lesões nas folhas, para atribuição de nota segundo a escala de Davis (1992). No tratamento com a infestação simultânea das pragas, ambas as avaliações foram realizadas.

3.4. Avaliação de resposta fisiológica

Os parâmetros de fotossíntese foram obtidos através do aparelho IRGA (Infrared Gas Analyser) CIRAS-3® (PP Systems, Amesbury, Estados Unidos da América), com fluxo de dióxido de carbono (CO_2) configurado para 410 µmol CO_2 mol^{-1} ar e fonte luminosa constante de 1800 µmol m^{-2} s^{-1}. A câmara de mensuração de área de 1,75 cm² foi acoplado na porção mediana da última folha expandida de cada planta (Figura 1) e os seguintes parâmetros foram mensurados: assimilação (A) (µmol CO_2 m^{-2} s^{-1}), transpiração (E) (mmol H_2O m^{-2} s^{-1}), concentração de CO_2 subestomatal (Ci) (µmol mol^{-1}), condutância estomática (gs) (mmol H_2O m^{-2} s^{-1}), déficit de vapor entre folha e ar (VPD) (kPa) e eficiência de uso da água (WUE) (mmol CO_2 mol^{-1} H_2O).

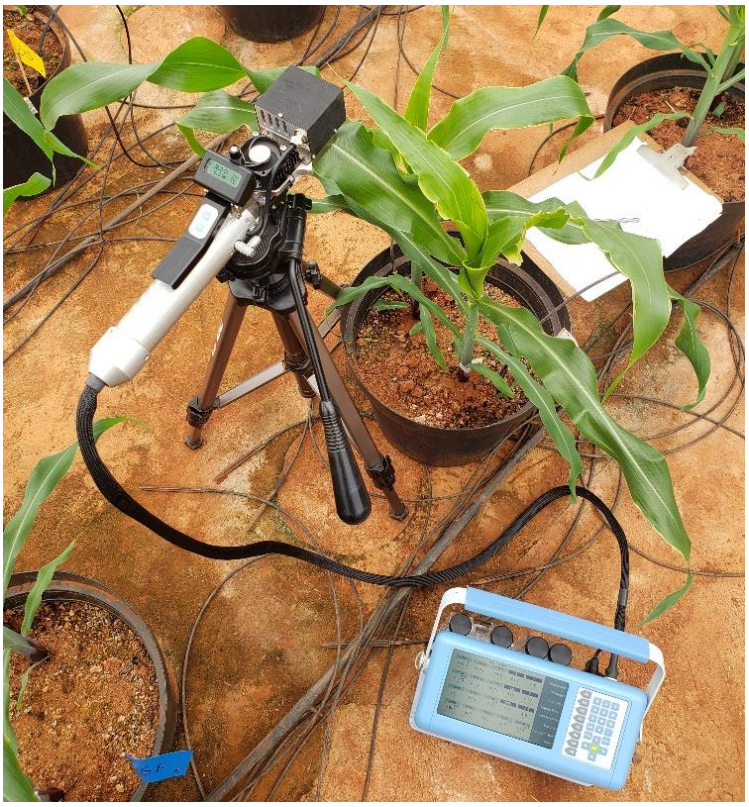

Figura 1. Detalhe da avaliação de resposta fisiológica por meio do sistema portátil de medição de fotossíntese (CIRAS-3®) acoplado à porção mediana da última folha totalmente expandida de planta de milho.

3.5. Avaliação hiperespectral e processamento de dados espectrais

Os instrumentos utilizados na avaliação hiperespectral das plantas foram o espectrorradiômetro portátil FieldSpec® Handheld (Analytical Spectral Devices, Boulder, Estados Unidos da América) (Figura 2 A), que obtém informações na faixa do espectro de 325 a 1075 nm com 1 nm de resolução espectral, e o sensor hiperespectral Rikola® DT-0014 (SINOP, Oulu, Finlândia) (Figura 2 B), com domínio espectral entre 500 e 900 nm. A Rikola® é uma câmera com princípio de funcionamento do Interferômetro de Fabry-Perot (FPI), isto é, ela possui duas placas espelhadas plano-paralelos que permitem a difração da luz incidente. O espaçamento entre as placas e a presença de dois sensores na câmera, sendo que um registra energia radiante de 500 a 636 nm enquanto o outro registra de 650 a 900 nm, permitem a obtenção de duas bandas espectrais simultaneamente (Saari et al., 2009; Miyoshi, 2016), e a alteração dos comprimentos de ondas é dado pela mudança da distância dessas placas (Miyoshi, 2016). Nesse estudo, o sensor Rikola® foi

configurado para obter 50 bandas (Tabela 1). Porém, no momento de processamento de dados, as bandas dos comprimentos de onda 634,06 nm, 646,32 nm e 650,37 nm foram excluídas por situarem no limite de transição entre os sensores 1 e 2 e consequentemente terem apresentado ruído.

Tabela 1. Bandas espectrais configuradas para obtenção das imagens.

Banda	λ (nm)	FWHM (nm)	Banda	λ (nm)	FWHM (nm)
1	506.41	12.89	26	706.22	12.34
2	514.41	14.24	27	714.36	12.42
3	522.19	14.87	28	722.32	12.3
4	530.13	14.59	29	730.32	12.19
5	538.33	12.24	30	738.05	12.06
6	546.23	12.19	31	746.28	12.15
7	554.41	11.89	32	754.08	11.84
8	562.22	12.18	33	762.01	12.15
9	570.09	12.31	34	770.43	12
10	578.41	11.1	35	778.23	11.98
11	586.28	13.45	36	786.13	14.9
12	594.07	13.59	37	794.26	15.22
13	601.77	13.23	38	802.28	13.68
14	610.05	15.18	39	810.46	14.21
15	618.47	16.31	40	818.06	14.44
16	626.48	15.43	41	826.18	14.51
17	634.06	18.85	42	834.39	16.73
18	646.32	14	43	842.32	16.75
19	650.37	14.7	44	849.81	17.49
20	658.28	13.47	45	857.75	18.15
21	666.36	15.61	46	866.05	19.05
22	674.24	15.88	47	874.34	17.03
23	681.92	15.8	48	882.4	16.94
24	690.24	15	49	890.07	17.26
25	698.05	12.3	50	898.24	20.17

λ: comprimento de onda central da banda; FWHM: *full width at half maximum* (largura a meia altura).

As imagens das plantas foram tomadas dentro da casa de vegetação com a Rikola® montada em barra fixada sobre dois tripés a uma distância de 3,5 m do chão (Figura 2 C). Antes da captação de cada imagem, o espectrorradiômetro foi utilizado na medição do fluxo radiante refletido de cinco placas: uma de resina que possui superfície ideal e difusora (placa Spectralon®) (*Lr*), e quatro placas de Etileno Acetato de Vinila (EVA), nas cores bege, cinza claro, cinza escuro e preto (*Lt*), que foram posicionados ao lado dos vasos (Figura 3). Esses dados de radiância obtidos em formato .asd foram convertidos em arquivo de texto pelo software ViewSpecPro (ASD, 2003).

Figura 2. Detalhe do espectrorradiômetro (FieldSpec® Handheld) (**A**) e do sensor hiperespectral (Rikola®) (**B**) e sua disposição para tomada de imagens de plantas de milho (**C**).

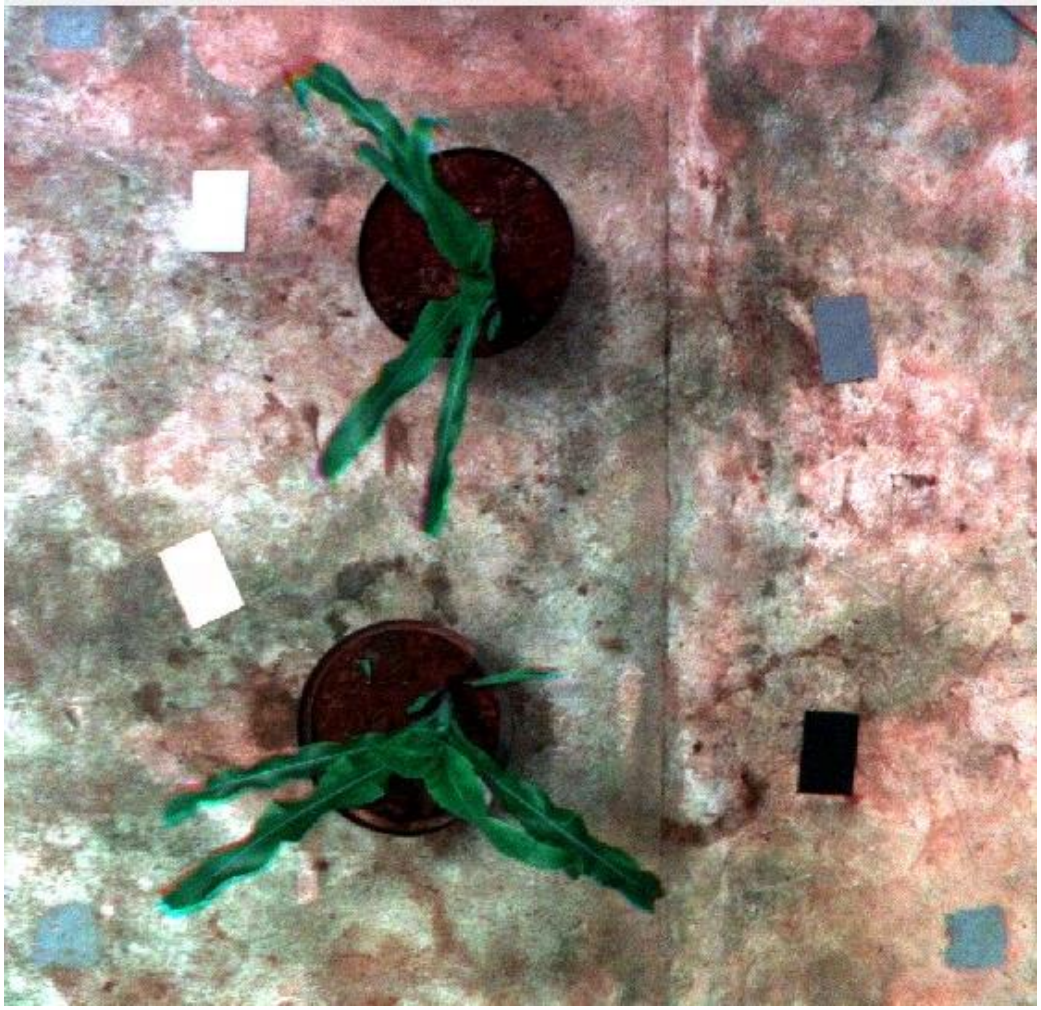

Figura 3. Imagem tomada pelo sensor hiperespectral (Rikola®) mostrando a disposição dos alvos coloridos.

Valores do espectro de reflectância (*ρt*) dos alvos coloridos foram então calculados segundo a Equação 1 (Jensen, 2014), em que *k* é um fator de calibração da placa Spectralon® dado pelo fabricante:

$$\rho t = k \frac{Lt}{Lr} \quad (1)$$

A partir desses dados de reflectância, fez-se a calibração radiométrica das imagens por linha empírica no software ENVI 5.1 (NV5 Geospatial, Broomfield, Estados Unidos da América). Neste método de calibração assume-se que há uma relação linear entre a radiância obtida em fóton.pixel^{-1}.s^{-1} com sensor imageador e o fator de reflectância obtido pelo espectrorradiômetro (Smith e Milton, 1999).

Com as imagens calibradas, 6 áreas de 5x5 pixels foram delimitadas do limbo foliar das plantas, tomando o cuidado de selecionar de múltiplas folhas e de locais onde a folha apresentava-se mais paralela à superfície do chão. A partir dessas áreas o espectro médio do vaso foi calculado no próprio software ENVI.

As avaliações hiperespectrais foram simultâneas às fisiológicas e ocorreram antes da infestação das plantas, 2 dias após a infestação (DAI) e em seguida de 3 em 3 dias até a finalização do experimento no 14º. DAI. Ambas as avaliações ocorreram no período da manhã (entre 9 e 12h).

3.6. Análise dos dados

Uma investigação preliminar dos parâmetros fisiológicos foi empregada utilizando análise de componentes principais (PCA) com todas as variáveis respostas (Ci, gs, E, VPD, A e WUE). O objetivo da PCA foi compreender a relação entre essas variáveis e verificar a possibilidade de distinção dos tratamentos ao final do experimento. Para cada PCA, foi utilizado os dois primeiros componentes para descrever a variância dos dados uma vez que estes componentes contém a maior parte da variância (>85%). Os PCA's e gráficos foram gerados pelos pacotes FactoMineR (versão 1.0.7) e factoextra (versão 1.0.7), respectivamente.

Em seguida, os dados fisiológicos do milho foram analisados utilizando modelos lineares mistos (MLM). Cada variável resposta foi modelada com a inclusão das variáveis preditoras tratamento (Controle, DS, SF, DSSF), data de avaliação e possíveis interações para entender o efeito das injúrias e estágios de desenvolvimento dos estressores sobre os parâmetros fisiológicos. Por se tratar de medidas repetidas no tempo considerando uma mesma unidade experimental (mesma planta), a identificação de cada vaso foi considerada como efeito aleatório. Gerados os modelos com o pacote "lme4" (versão 1.1-27.1), a seleção do melhor modelo se deu por meio do teste de razão de verossimilhança (LRT). Quando significativo, o teste Tukey ao nível de 5% foi adotado para comparação de médias dos tratamentos em cada data de avaliação.

Para avaliar os possíveis efeitos da dimensão das injúrias dos estressores comuns entre tratamentos sobre o conjunto de parâmetros fisiológicos foi conduzida uma Análise de Covariância Multivariada (MANCOVA) (Zablotski, 2019). Foram

consideradas a estimativa do volume das galerias provocadas por *D. saccharalis* nos tratamentos DS e DSSF e as notas visuais (Escala Davis) para a desfolha de *S. frugiperda* nos tratamentos SF e DSSF durante a avaliação destrutiva do último dia de avaliação como covariáveis. O conjunto de parâmetros fisiológicos adquiridos na última avaliação foram incluídos como variáveis resposta. Com o objetivo de entender possíveis relações entre as injúrias e os parâmetros fisiológicos, foram ajustadas regressões lineares para cada parâmetro. Quando não significativo, o modelo foi reajustado considerando somente a injúria. Todas as análises foram realizadas no software R (versão 4.2.0).

Os dados de fator de reflectância foram normalizados, pois apresentaram ruídos relacionados às condições ambientais dos dias de tomada de medida e do estádio vegetativo da planta. Para isso, utilizou-se a Equação 2 (Marston et al., 2022), em que $NR\lambda_{td}$ é a reflectância média normalizada do tratamento t (DS, SF ou DSSF) no comprimento de onda λ na data de avaliação d (0, 2, 5, 8, 11 ou 14 DAI); $R\lambda_{td}$ é a reflectância média no comprimento de onda λ do tratamento t na data de avaliação d; $R\lambda_c$ é a reflectância média no comprimento de onda λ do tratamento c (Controle) de todas as datas de avaliação; e $R\lambda_{cd}$ é a reflectância média no comprimento de onda λ do tratamento c (Controle) na data de avaliação d.

$$NR\lambda_{td} = \frac{R\lambda_{td} \times R\lambda_c}{R\lambda_{cd}} \quad (2)$$

Os dados de reflectância normalizados foram então analisados usando as bibliotecas Pandas (versão 1.3.5) e Numpy (versão 1.21.6). Para identificar o conjunto de bandas com maior capacidade preditiva, ou seja, que permita diferenciar plantas injuriadas (DS+SF+DSSF) das não-injuriadas após 14 dias de infestação, cada banda, de maneira individual, foi utilizada como preditora. O conjunto de dados foi inicialmente dividido em dados de treino e teste na proporção de 80 para 20. O algoritmo de *Random Forest* (número de árvores = 1000, tamanho máximo das árvores = 3) foi então utilizado para a classificação, e o desempenho dos modelos foi calculado usando os valores de ROC + AUC (área sob a curva da característica de operação do receptor). Essa medida traz em valores de 0 a 1 a capacidade do modelo

distinguir classes corretamente (Hanley e McNeil, 1982; Narkhede, 2018). As bandas com melhor desempenho, ou seja, ROC + AUC mais próximas a 1 foram escolhidas, e todas as combinações possíveis dessas bandas foram utilizadas como preditores. Por fim, o desempenho desses novos preditores foram avaliados usando também os valores de ROC + AUC.

Para os modelos criados para diferenciar as plantas do controle das plantas dos tratamentos (DS, SF e DSSF) no 14º. DAI, a metodologia para encontrar os preditores foi similar à anteriormente descrita. A diferença foi que para realizar o treinamento do modelo utilizou-se todos os dados, e, para avaliar o desempenho, foi utilizado o método leave-one-out. Esta abordagem foi necessária devido ao reduzido número de dados de cada tratamento (Hawkins et al., 2003). Identificada a melhor banda para diferenciar para cada um desses grupos das plantas do controle no 14º. DAI, testou-se a acurácia do modelo com essas bandas nos outros dias avaliação, para assim descobrir a partir de qual dia após início das injúrias a planta começa a apresentar alteração na reflectância espectral passível de ser identificada. As bibliotecas utilizadas para implementar os modelos de machine learning e para graficar os resultados foram o Scikit-Learn (versão 1.0.2) e Matplotlib (versão 3.2.2), respectivamente.

4. RESULTADOS

4.1. Avaliação de resposta fisiológica

A análise de componentes principais (PCA) permitiu explicar a maioria das variações nos dados de resposta fisiológica de plantas antes da infestação (90,2%) e ao final do experimento (89%) (Figura 4). As variáveis que mais contribuíram para explicar o modelo foram déficit de vapor entre folha e ar (VPD) e eficiência de uso da água (WUE). Na primeira avaliação VPD e transpiração (E) estavam negativamente relacionados a WUE. Essa relação se manteve entre E e WUE na última avaliação. No entanto, VPD passou a ter relação negativa com as variáveis correlacionadas condutância estomática (gs), assimilação (A) e concentração de CO_2 subestomatal (Ci). Além disso, observa-se na Figura 4 que a médias dos dados de cada tratamento estão muito próximas, com exceção de SF, no primeiro dia. Ao final do experimento há um afastamento dessas médias.

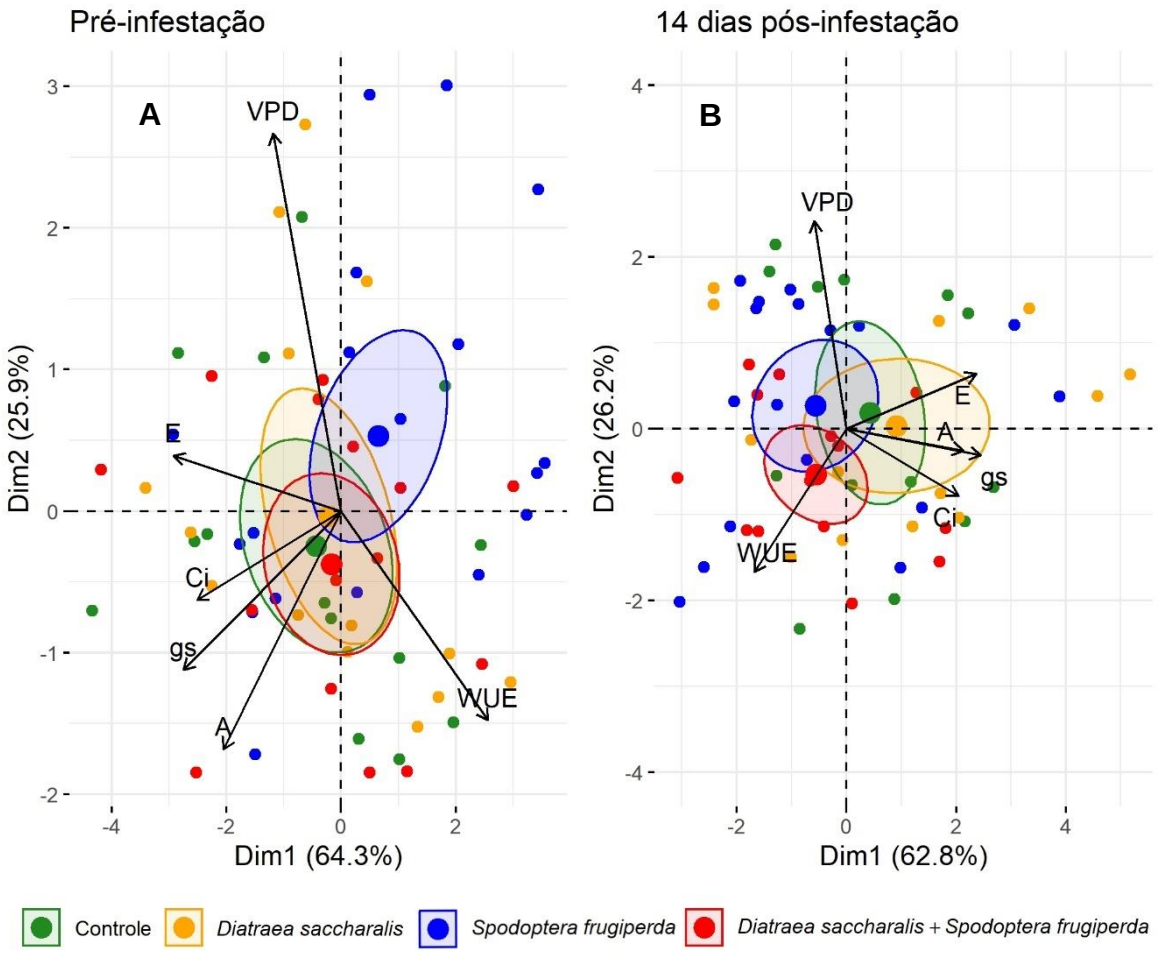

Figura 4. Análise de componentes principais (PCA) dos parâmetros fisiológicos de plantas de milho sadias e infestadas por *Diatraea saccharalis* e *Spodoptera frugiperda* em casa de vegetação obtidos antes da infestação (**A**) e após 14 dias da infestação (**B**).

Os resultados da análise de variância (ANOVA) apontam que entre os dias de avaliação há diferença significativa nos valores obtidos para todos os parâmetros (Figura 5) e, na análise dentro de cada data de avaliação, houve diferença entre tratamentos apenas para o parâmetro fisiológico WUE (Tabela 2). O teste de comparação múltipla, contudo, atesta que não há diferença significativa entre as médias dos tratamentos (Tabela 3). A análise MANCOVA (Tabelas 4 e 5) confirma o que foi obtido na ANOVA, indicando que tratamentos e a quantidade de injúria não teriam efeitos na troca gasosa.

Tabela 2. Efeito dos tratamentos e data de avaliação sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Diatraea saccharalis*, *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.

Fator de Variação	Assimilação (A)		Concentração CO_2 subestomatal (Ci)		Transpiração (E)		Condutância estomática (gs)		Déficit de pressão de vapor (VPD)		Eficiência do uso da água (WUE)	
	F	**P**	**F**	**P**	**F**	**P**	**F**	**P**	**F**	**P**	**F**	**P**
Tratamento	1,763	0,164	1,715	0,175	2,758	0,051	2,023	0,121	1,256	0,298	**2,767**	**0,0499**
Data	**4,067**	**0,001**	**6,398**	**<0,001**	**8,550**	**<0,001**	**3,829**	**0,002**	**70,854**	**<0,001**	**26,699**	**<0,001**

Os valores considerados significativos estão destacados em negrito.

Tabela 3. Médias (± EPM) dos valores de eficiência do uso da água (WUE) de plantas de milho infestadas por *Diatraea saccharalis*, *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* e as comparações entre esses tratamentos.

Tratamentos	**Eficiência do uso da água (WUE)** (mmol CO_2 mol^{-1} H_2O)
Controle	5,32±0,185
DS	5,23±0,186
SF	5,87±0,179
DSSF	5,30±0,164
Comparações	**P**
Controle – DS	0,988
Controle – SF	0,147
Controle – DSSF	0,999
DS – SF	0,073
DS – DSSF	0,994
DSSF – SF	0,093

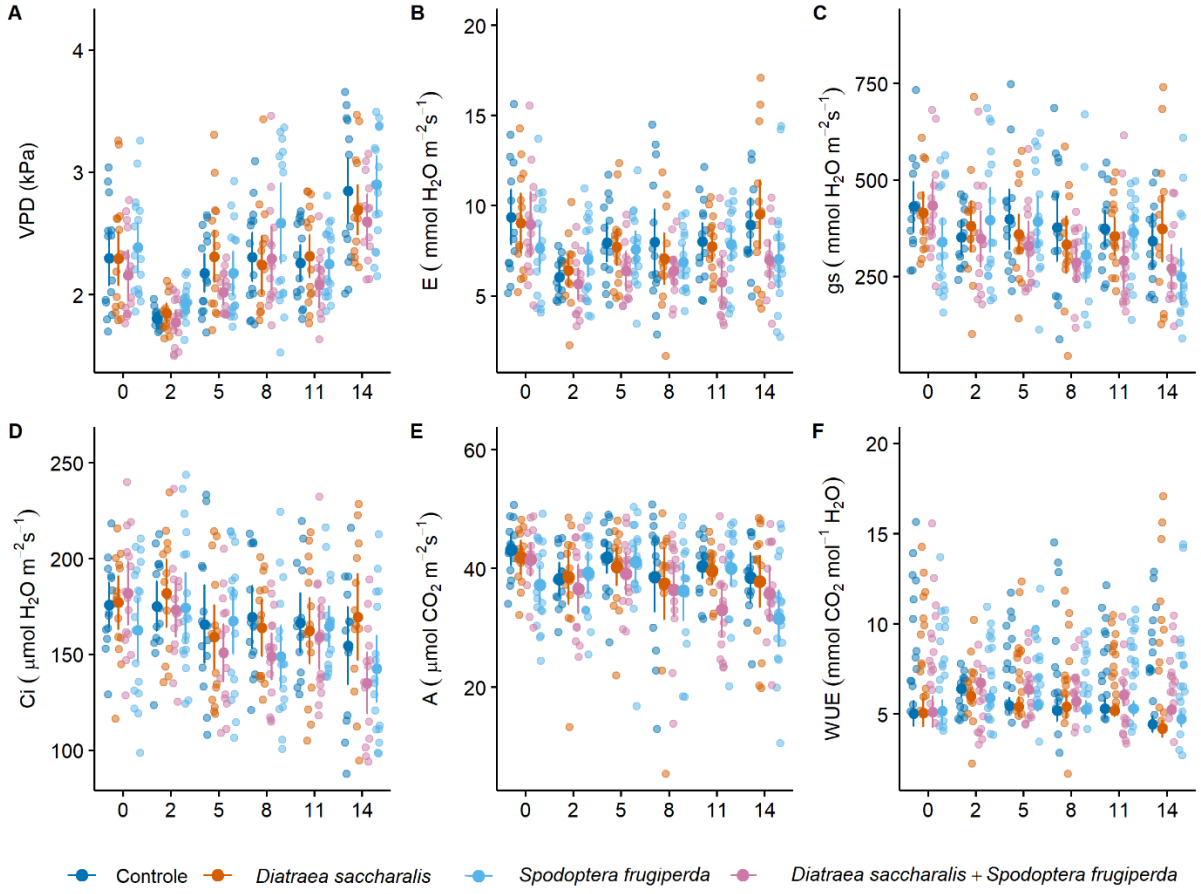

Figura 5. Média (± EPM) dos valores referentes aos parâmetros fisiológicos ao longo dos 14 dias de avaliação. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).

Tabela 4. Efeito dos tratamentos e volume da galeria sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Diatraea saccharalis* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.

Fator de Variação	F	GL	P
Tratamento	1,9	6	0,132
Volume da galeria	2,4	6	0,065

Tabela 5. Efeito dos tratamentos e nota de injúria (escala Davis) sobre as médias dos parâmetros fisiológicos de plantas de milho infestadas por *Spodoptera frugiperda* e *Diatraea saccharalis* + *Spodoptera frugiperda* em condições de casa de vegetação.

Fator de Variação	F	GL	P
Tratamento	2,5	6	0,052
Nota de injúria	1,6	12	0,122

Na análise de regressão linear de plantas infestadas com *D. saccharalis* (DS+DSSF) foi revelado que há uma relação positiva entre intensidade de injúria e o valor de WUE, enquanto que para E há uma relação negativa (Figura 6). Ademais, há uma tendência de que plantas injuriadas por broca apresentem menor gs e Ci quanto maior for a galeria formada. Para os tratamentos com infestação de *S. frugiperda* (SF+DSSF) a regressão linear apenas indicou que há uma tendência de que plantas mais desfolhadas apresentem menores valores de VPD, e maiores de Ci e gs (Figura 7).

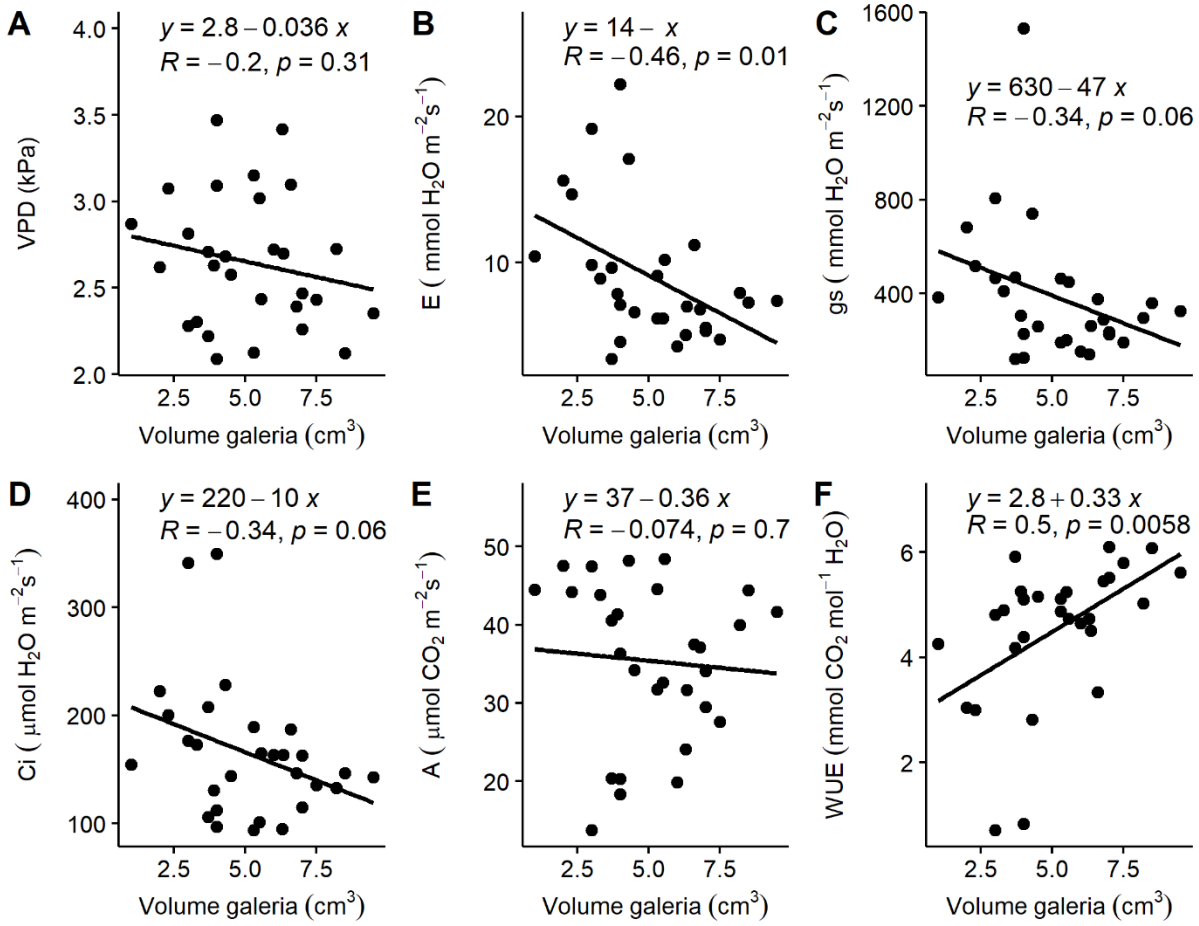

Figura 6. Resposta fisiológica de milho infestado por *D. saccharalis* e *D. saccharalis* + *S. frugiperda* sob diferentes níveis de injúria, dado pelo volume de galeria (cm³) consumida pela broca-do-colmo. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).

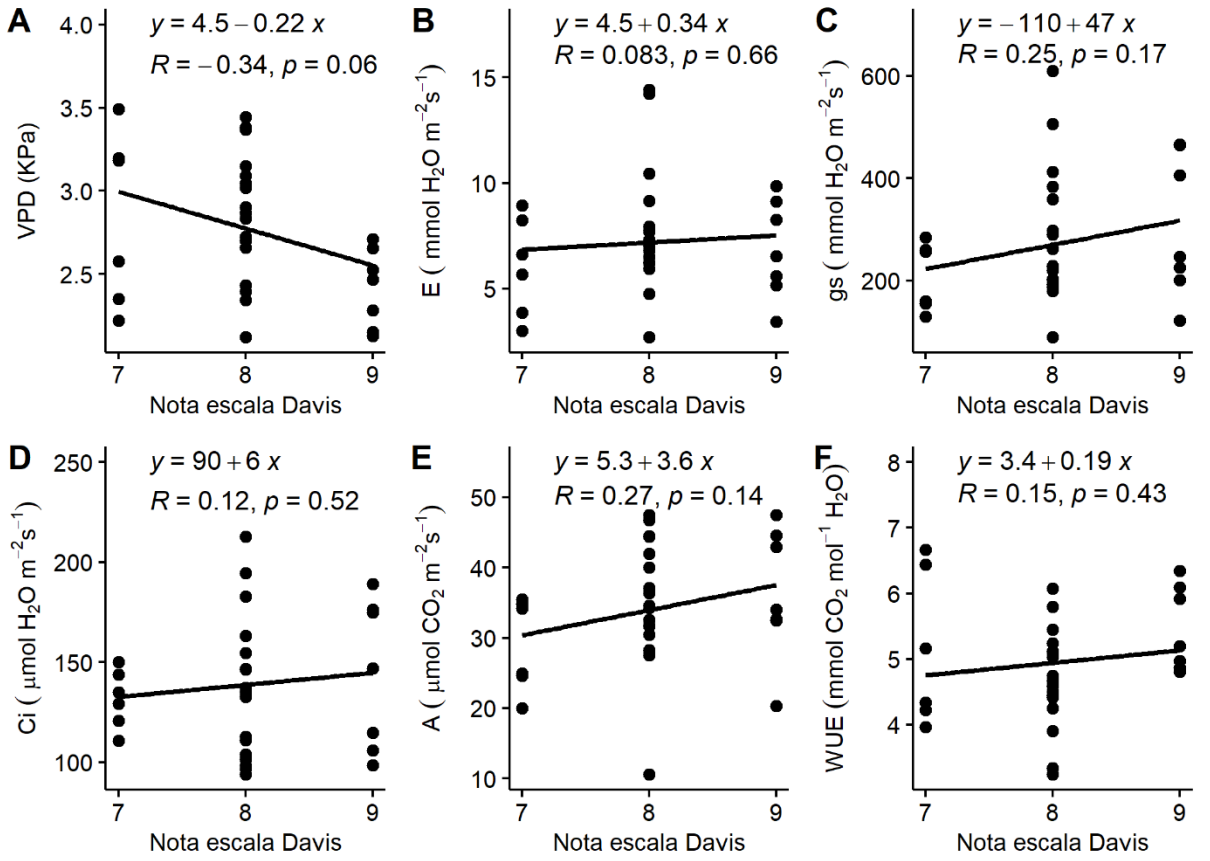

Figura 7. Resposta fisiológica de milho infestado por *S. frugiperda* e *D. saccharalis* + *S. frugiperda* sob diferentes níveis de injúria, dado pela nota de Davis final. **A -** Déficit de vapor entre folha e ar (VPD), **B** - Transpiração (E), **C -** Condutância estomática (gs), **D -** Concentração de CO_2 subestomatal (Ci), **E -** Assimilação (A) e **F -** Eficiência do uso da água (WUE).

4.2. Avaliação hiperespectral

As magnitudes do fator de reflectância espectral dos quatro tratamentos nas regiões do visível (500 nm a 690 nm) e *red-edge* (690 nm a 760 nm) variaram pouco entre as seis datas de avaliações e foram similares entre os tratamentos por todo período do trabalho (Figura 8). No entanto, alterações na reflectância da região espectral do infravermelho próximo (NIR) (760 nm a 900 nm) foram observadas durante os 14 dias de avaliação.

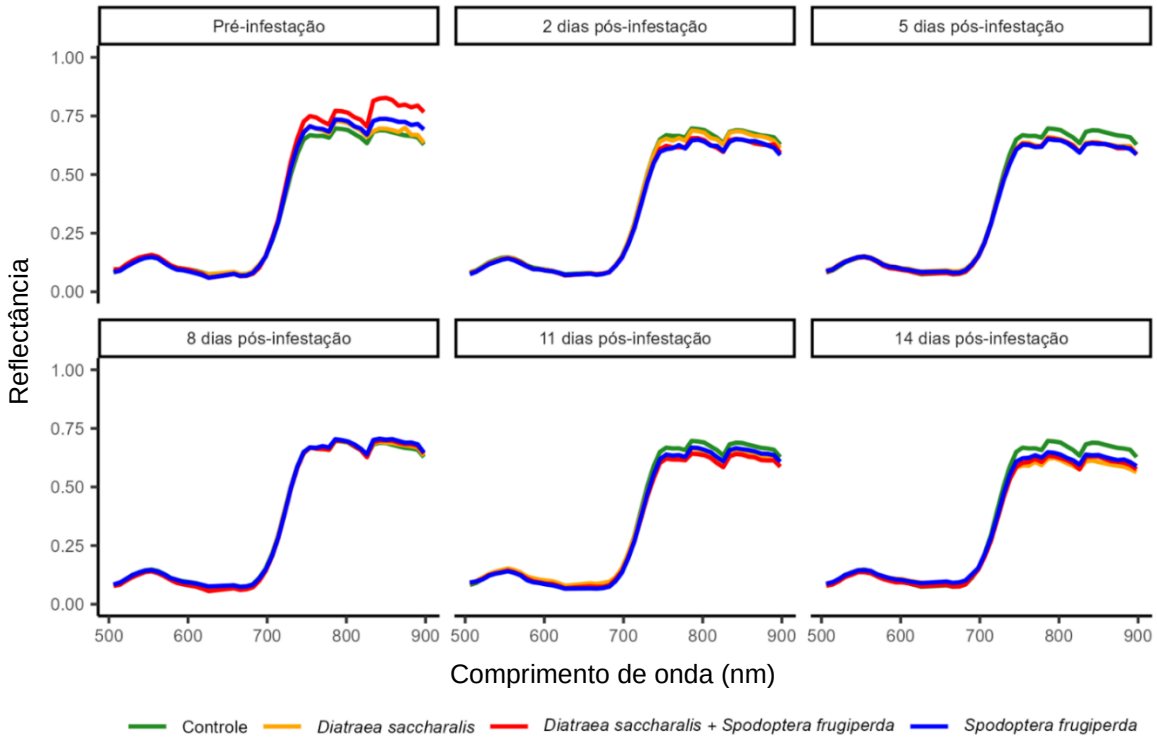

Figura 8. Comportamento espectral médio das plantas de milho sadias e infestadas nos seis dias de avaliação.

Semelhante ao que foi observado na primeira avaliação fisiológica, houve diferença entre tratamentos na porção NIR do espectro antes mesmo da infestação. Apesar disso, a partir do 2º. DAI a média da reflectância das plantas do controle se sobressai aos dos outros tratamentos, exceto no 8º. DAI. Os perfis espectrais dos tratamentos DS, SF e DSSF permanecem similares entre si do 5º. DAI até a conclusão das avaliações.

A melhor combinação de bandas para distinguir plantas sadias (controle) daquelas injuriadas (DS+SF+DSSF) no 14º. DAI foi a do grupo de comprimentos de onda da região do NIR: 762,01 nm, 810,46 nm, 857,75 nm e 866,05 nm (ROC + AUC = 98%) (Figura 9 A e B). O teste do modelo com essa combinação indicou 83% de acurácia. Já as melhores bandas para distinguir plantas de controle de plantas de DS (Figura 10 A e B), SF (Figura 11 A e B) e DSSF (12 A e B) foram diferentes para cada tratamento no 14º. DAI, sendo elas a banda do comprimento de onda 866,05 nm, 666,36 nm e 730,32 nm, respectivamente. A maior acurácia foi obtida no modelo de separação de controle e plantas infestadas somente por *D. saccharalis* (DS) (91,66%). Já as acurácias dos modelos de separação de plantas de controle de plantas

infestadas somente por *S. frugiperda* e plantas infestadas por ambas pragas (DSSF) foram 75% e 68%, respectivamente.

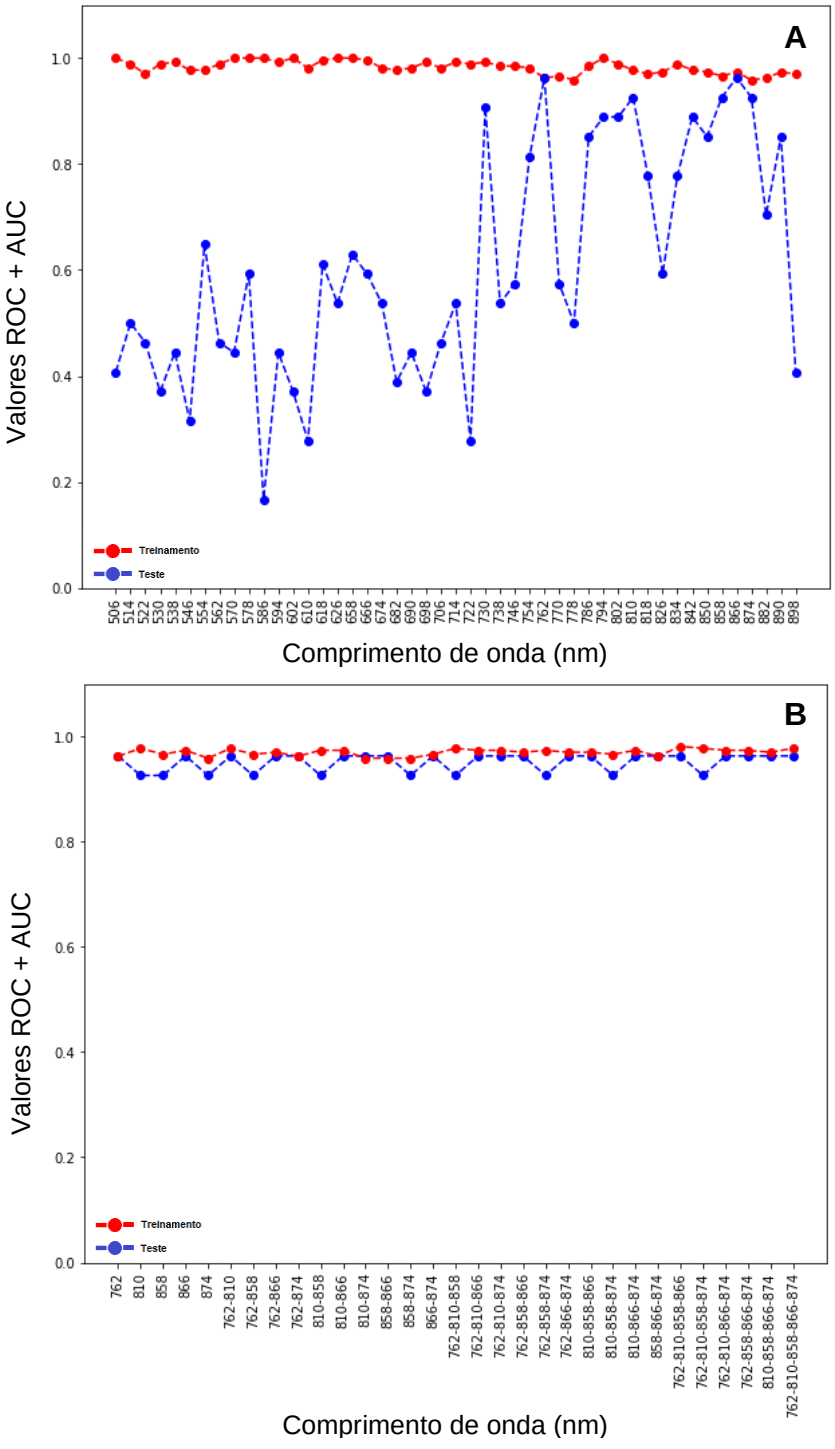

Figura 9. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas infestadas (DS+SF+DSSF) no 14º. DAI. Em (**A**) valores de ROC + AUC para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de ROC + AUC para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.

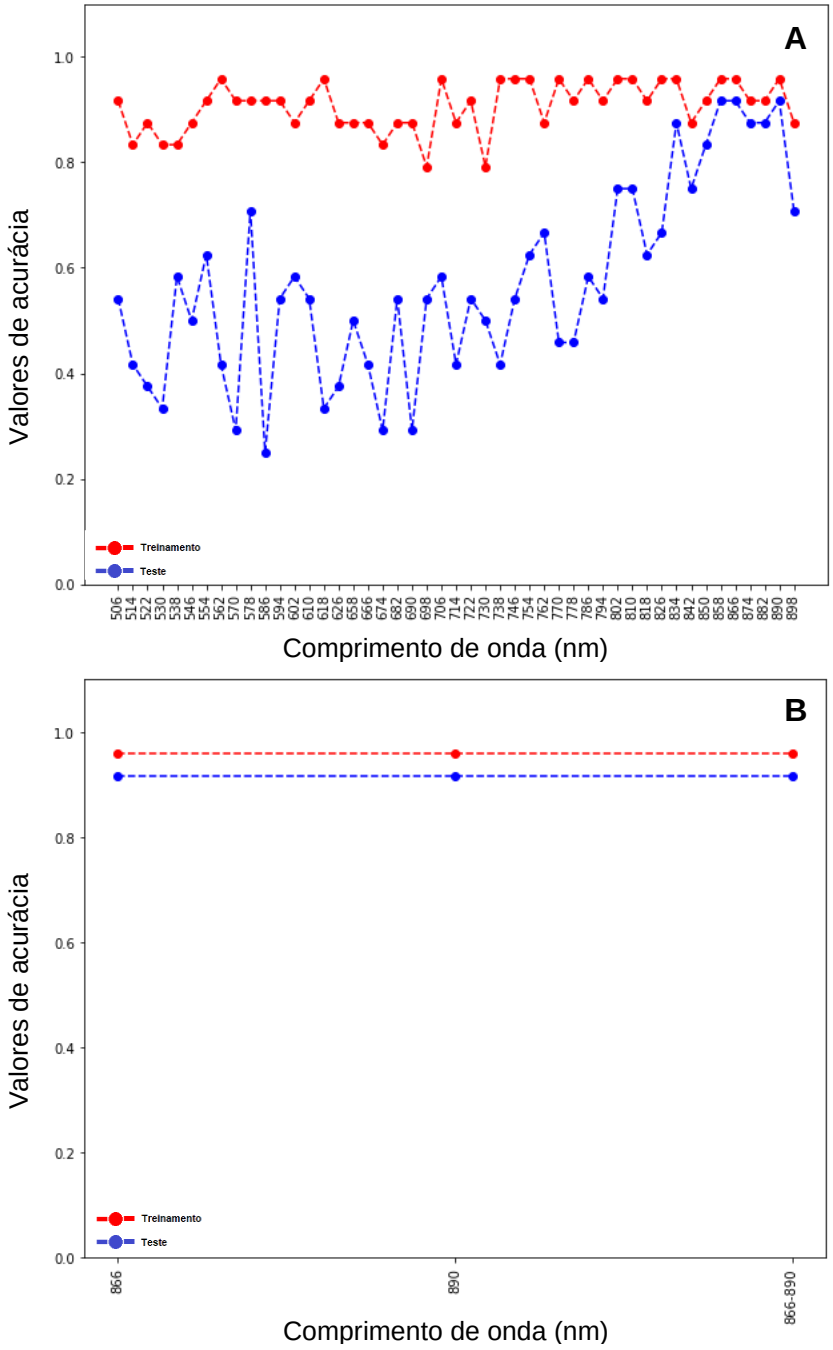

Figura 10. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas DS no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.

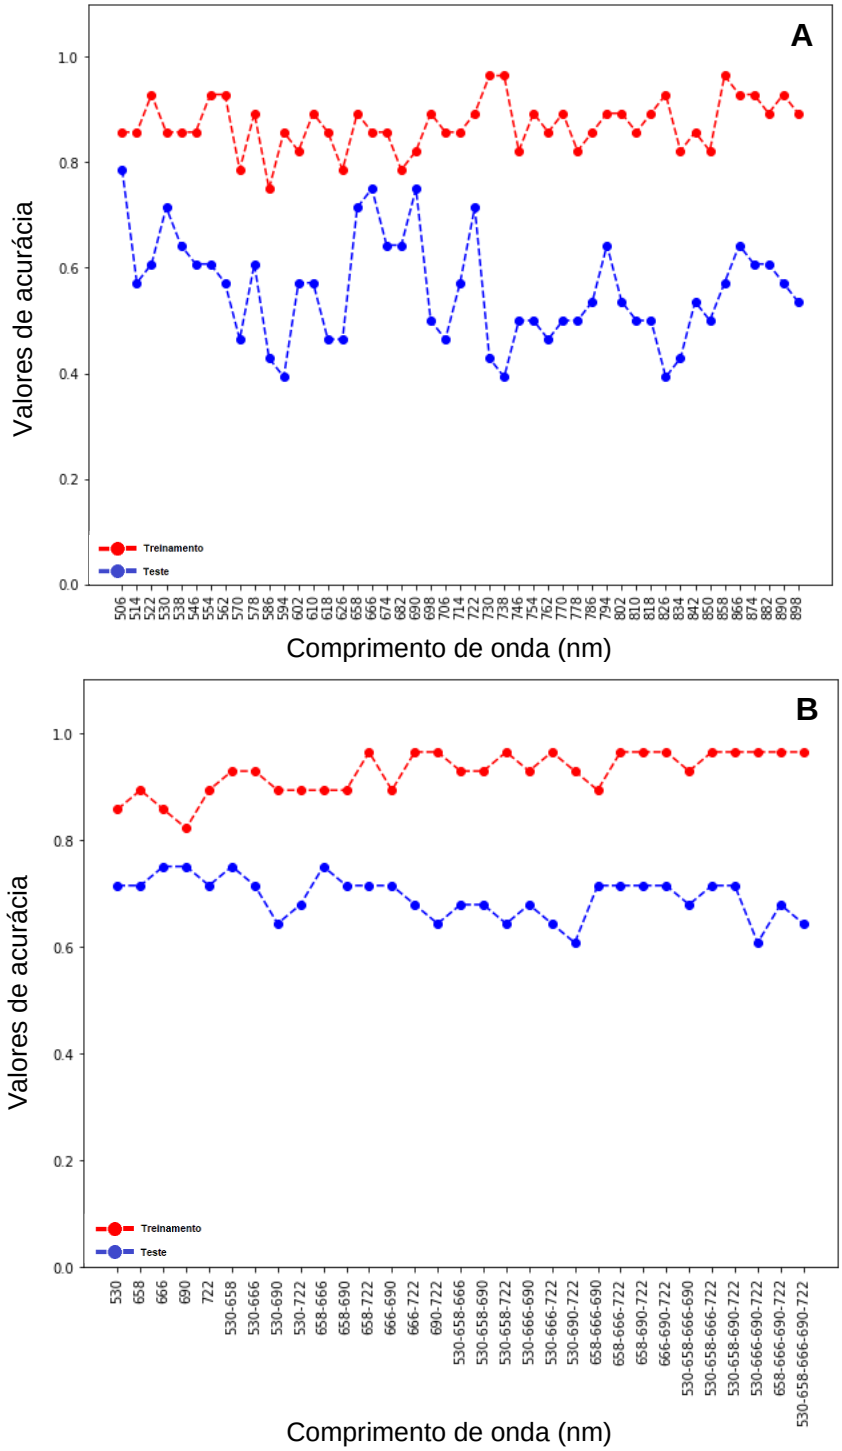

Figura 11. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas SF no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.

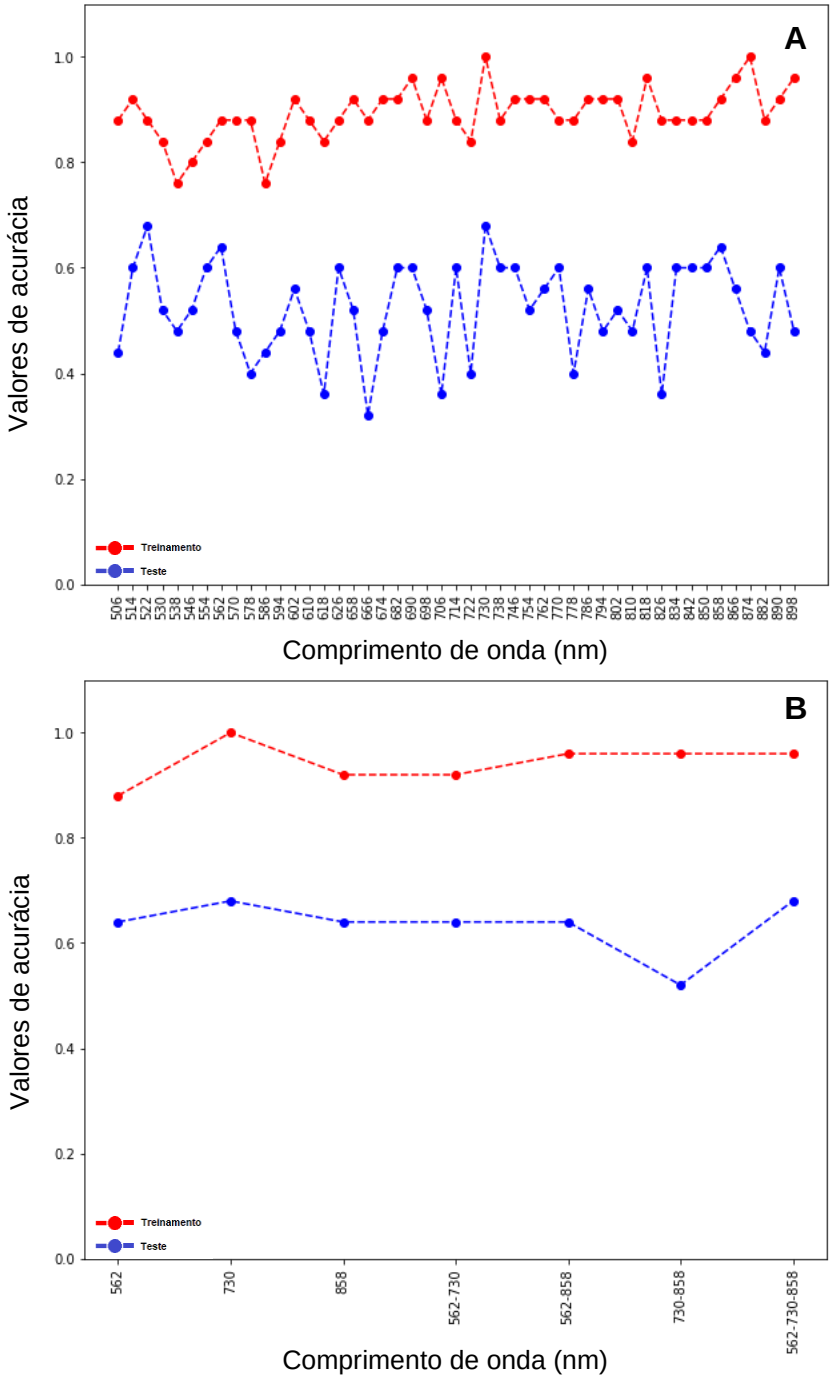

Figura 12. Modelo criado no *Random Forest* para diferenciar plantas sadias de plantas DSSF no 14º. DAI. Em (**A**) valores de acurácia para dados de treinamento e teste para todas as bandas do domínio espectral do sensor. Em (**B**) valores de acurácia para dados de treinamento e teste para as diferentes combinações das melhores banda para este modelo.

O desempenho desses modelos variou entre os dias de avaliação (Tabela 6). Enquanto que para DS a maior acurácia foi obtida no último dia de tomada de medidas (14 DAI), para os tratamentos SF e DSSF esses valores foram obtidos no 8º. (78,12%) e 11º. DAI (68,96%), respectivamente.

Tabela 6. Acurácia dos modelos de separação de plantas de controle de plantas infestadas no período de 14 dias após infestação (DAI).

	2 DAI	5 DAI	8 DAI	11 DAI	14 DAI
Controle x DS (866.05 nm)	67,85%	69,23%	25,00%	39,28%	91,66%
Controle x SF (666.36 nm)	59,37%	66,67%	78,12%	56,25%	75,00%
Controle x DSSF (730.32 nm)	51,72%	66,67%	41,38%	68,96%	68,00%

5. DISCUSSÃO

Os baixos valores de reflectância na região visível são característicos do comportamento espectral de vegetação, dado que nesta faixa ocorre alta absorção de luz por pigmentos, especialmente a clorofila, para sintetização de compostos orgânicos (Kumar et al., 2001; Prabhakar et al., 2012; Jensen, 2014). Contudo, quando a planta está sob estresse ou em fase de senescência, a diminuição da produção de clorofila faz com que outros pigmentos presentes no mesófilo foliar passem a ser mais atuantes e o perfil da planta varie nesta região, tendendo a aumentar a reflectância (Jensen, 2014). Essa mudança na faixa visível já foi relatada em trabalhos de herbivoria (Barros et al., 2021; Nansen et al., 2021; Iost et al., 2022), e era algo que se previa nos tratamentos com a broca-do-colmo, em virtude da injúria causada no interior da planta que dificulta a translocação de água e nutrientes para folhas gerando um estresse hídrico que pode alterar a quantidade de clorofila (Sepehri e Sanavy, 2003). Contudo, alterações significativas não foram detectadas nessa porção do espectro nesses tratamentos. O modelo classificatório de SF no 14º. DAI, no entanto, indicou a banda do vermelho (666,36 nm) como um bom separador entre plantas sadias e estressadas por *S. frugiperda*. Isso provavelmente ocorreu pelo recorte do limbo foliar, o que provocou diminuição da quantidade de clorofila atuante produzindo o efeito na assinatura espectral, com maior reflectância nessa região. Ainda assim, alterações significativas nas trocas gasosas desse tratamento não foram constatadas.

A região chamada de *red-edge* trata-se da transição da faixa de luz visível à faixa do NIR e é caracterizada pelo abrupto aumento do valor de reflectância (Horler et al., 1983; Jensen, 2014). A reflectância nessa região foi relativamente similar para todos os tratamentos, mas no último dia de avaliação a banda 730,32 nm pertencente ao *red-edge* foi capaz de separar plantas controle de plantas DSSF com certo grau de acurácia (68%).

A porção do espectro com maiores alterações foi a do NIR. Plantas geralmente têm um valor alto de reflectância e transmitância nessa porção, pois os níveis de energia nesses comprimentos de onda são insuficientes para realização de processos fotoquímicos pelos pigmentos, sendo assim pouco absorvido por estes (Prabhakar et al., 2012; Jensen, 2014). Os valores inferiores de reflectância para os tratamentos com os estressores podem ser explicados por alterações na estrutura celular das

folhas, possivelmente causados pela diminuição de espaços vazios, o que trouxe aumento da transmitância nessas plantas (Prabhakar et al., 2012; Jensen, 2014). A alteração estrutural, porém, precisa ser avaliada em estudos futuros para confirmação dessa hipótese.

Além de afetada pela estrutura celular das folhas, a reflectância do NIR é associada na literatura com o desempenho fotossintético das plantas (Smith e Milton, 1999; Kumar et al., 2001). Neste trabalho, porém, não foi verificada alteração significativa nos parâmetros fisiológicos nas plantas em resposta aos insetos, à semelhança de outros estudos (Peterson et al., 2004; Macedo et al., 2007; Pinto et al., 2020). Acredita-se que esse resultado indique que algum processo de compensação fisiológica esteja ocorrendo em folhas não afetadas pelos insetos (Trumble, 1993). Alguns trabalhos já mostraram que a desfolha pode levar a um possível mecanismo de tolerância da planta, através do aumento de variáveis fotossintéticas nas folhas restantes (Mitchell et al. 2016). Além disso, os efeitos na fotossíntese em plantas broqueadas podem estar mais relacionados com uma possível entrada de patógenos, como os fungos *Colletotrichum* spp. e *Fusarium* spp. do que propriamente com a injúria causada pelo inseto-praga (Rossato et al., 2011).

Alternativamente, esse resultado pode inferir que as densidades populacionais utilizadas e o tempo de atuação dos insetos tenham sido insuficientes para causar injúrias que alterem a fisiologia de plantas de milho de estádio fisiológico mais avançado (V5 à V8). Na regressão linear realizada para compreender a relação de intensidade de injúria com a média dos parâmetros de fotossíntese verificou-se relação negativa de volume de galeria com transpiração (E) e positiva com eficiência do uso da água (WUE). Como mostrado na PCA essas duas variáveis são relacionadas entre si. A transpiração é a perda de água da planta para atmosfera em forma de vapor através dos estômatos (Taiz et al., 2017). A obstrução causada por *D. saccharalis* pode ter afetado a absorção de água, fazendo com que a planta passasse a moderar a quantidade de água perdida, ou seja aumentasse WUE, diminuindo a perda de água (E) de forma a não afetar a entrada de CO_2 na planta. Assim, para entender se intensidades de injúrias maiores causarão efeito mais expressivo sobre a fisiologia de plantas de milho sugere-se que o estudo deva ser aprofundado utilizando

plantas mais novas e acompanhamento dos tratamentos até o momento de produção da espiga.

Os resultados da avaliação espectral indicam que apesar das duas pragas ocasionarem tipos de injúria diferentes, as alterações provocadas pelos seus danos levam a mudanças no perfil espectral da folha parecidas entre si, com a diminuição da reflectância da luz na porção do infravermelho próximo. Ademais, o tratamento com infestação simultânea das duas pragas não ocasionou uma alteração aditiva no comportamento espectral das plantas desse tratamento como inicialmente pensado. Possivelmente as respostas dos danos de uma delas está mascarando a da outra, o que dificultou na criação de um modelo classificatório com uma banda nessa porção.

O valor de ROC + AUC obtido no modelo de classificação de plantas injuriadas vs não injuriadas no 14º. DAI (83%) e o valor de acurácia no modelo de classificação de controle vs DS (91,66%) e SF (78,12%) indicam que esses são bons modelos discriminativos e com isso há a possibilidade da utilização do sensoriamento remoto no monitoramento dessas pragas na cultura do milho (Delalieux et al., 2007). Porém é importante destacar que houve variação do desempenho dos modelos entre os dias de avaliação. Do ponto de vista prático essa variação de desempenho das bandas escolhidas não é interessante pois restringe a utilização do sensor a alguns períodos após a infestação, sendo então necessário investigação de outras bandas que sejam responsivas nas avaliações com menor desempenho para construção de uma metodologia mais robusta para o monitoramento.

O alto desempenho do modelo de classificação de plantas controle vs SF (78,12%) aos 8 DAI é interessante visto que a identificação precoce da presença de insetos é essencial para um controle mais eficiente. Contudo, estudos com diferentes níveis populacionais das pragas devem ser realizados a campo antes de propor o uso de sensores. Esses estudos fora de ambientes controlados são essenciais uma vez que a campo outros desafios como a angulação do equipamento e da iluminação, densidade da vegetação, sensitividade do sensor e interferências da atmosfera deverão ser avaliados e superados (Jensen, 2014).

Por fim, sugere-se a avaliação da longevidade da alteração das respostas espectrais após saída do inseto da planta por empupação ou emergência do adulto. Isto decorre, pois além de permitir distinguir plantas sadias de injuriadas, as respostas

espectrais precisam permitir a distinção entre plantas injuriadas contendo o inseto daquelas com injúria já sem a presença inseto/sem o inseto se alimentando, para que assim a tomada de decisão de controle seja correta. Em tratando-se de um inseto broqueador como *D. saccharalis* indica-se que o acompanhamento do estádio de desenvolvimento dele na planta seja realizado através de plantas sentinelas, plantas essas semeadas e infestadas da mesma forma que a do experimento, contudo com propósito de serem abertas e averiguadas quanto ao desenvolvimento do inseto.

Diante disso, os resultados apresentados são encorajadores, pois já indicam que é possível determinar a injúria em momento em que o inseto está presente. Isto será fundamental para futura utilização destas ferramentas na tomada de decisão de controle dessas pragas.

6. CONCLUSÕES

- Há diferença na resposta espectral de plantas sadias e plantas infestadas com *D. saccharalis* e *S. frugiperda.*
- As bandas espectrais com maior capacidade de predição de infestação de *D. saccharalis* e *S. frugiperda* são distintas, sendo 866,05 e 666,36 nm, respectivamente. No caso da infestação das duas pragas simultaneamente, a banda é 730,32 nm.
- As injúrias causadas por *D. saccharalis* e *S. frugiperda* não provocam alterações significativas nos parâmetros fotossintéticos em plantas de milho no estádio V5 a V8.

7. REFERÊNCIAS

American Society for Photogrammetry and Remote Sensing (ASPRS). What is ASPRS? Disponível em: <https://www.asprs.org/organization/what-is-asprs.html>. Acesso em: 02 set. 2022.

Analytical Spectral Devices (2003) **FieldSpec®UV/VNIR: HandHeld Spectroradiometer - User's Guide**. Boulder, Estados Unidos da América.

Anjorin FB, Odeyemi OO, Akinbode OA, Kareem KT (2022) Fall armyworm (*Spodoptera frugiperda*) (JE Smith) (Lepidoptera: Noctuidae) infestation: Maize yield depression and physiological basis of tolerance. **Journal of Plant Protection Research** 62:12-21.

Barros PPS, Rosalen DL, Iost Filho FH, Martins GD, Di Leo N (2021) Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Revista Brasileira de Cartografia** 73:489-515.

Barros PPS, Schutze IX, Iost Filho FH, Yamamoto PT, Fiorio PR, Demattê JAM (2021) Monitoring *Bemisia tabaci* (Gennadius) (Hemiptera: Aleyrodidae) infestation in soybean by proximal sensing. **Insects** 12:47-59.

Behmann J, Mahlein AK, Rumpf T, Römer C, Plümer L (2015) silv. **Precision Agriculture** 16:239-260.

Calanca PP (2017) Effects of abiotic stress in crop production. In.: Ahmed M, Stockle C (Eds.) **Quantification of climate variability, adaptation and mitigation for agricultural sustainability**. Springer, p. 165-180.

Chabrillat S, Goetz AF, Olsen HW, Krosley L (2001) Field and imaging spectrometry for identiication and mapping of expansive soils. In.: van der Meer FD, Jong SM (Eds.) **Imaging Spectrometry: Basic Principles and Prospective Applications**. Springer, p. 87-109.

Chapman JW, Williams T, Escribano A, Caballero P, Cave RD, Goulson D (1999) Fitness consequences of cannibalism in the fall armyworm, *Spodoptera frugiperda*. **Behavioral Ecology** 10:298-303.

Chaudhry S, Sidhu GPS (2022) Climate change regulated abiotic stress mechanisms in plants: A comprehensive review. **Plant Cell Reports** 41:1-31.

Chávez-Arias CC, Ligarreto-Moreno GA, Ramírez-Godoy A, Restrepo-Díaz H (2021) Maize responses challenged by drought, elevated daytime temperature and arthropod herbivory stresses: A physiological, biochemical and molecular view. **Frontiers in Plant Science** p.1512.

Cruz I (1995) **A lagarta-do-cartucho na cultura do milho.** Sete Lagoas: Embrapa Milho e Sorgo, p. 45 (Embrapa Milho e Sorgo. Circular técnica, 21).

Cruz I (2007) **A Broca da Cana-de-Açúcar, *Diatraea saccharalis*, em milho no Brasil.** Sete Lagoas: Embrapa Milho e Sorgo, 12 p. (Embrapa-CNPMS. Circular Técnica, 90).

Cruz I, Figueiredo M, Silva RB (2010) **Monitoramento de adultos de *Spodoptera frugiperda* (JE Smith) (Lepidoptera: Noctuidae) e *Diatraea saccharalis* (Fabricius) (Lepidoptera: Pyralidae) em algumas regiões produtoras de milho no Brasil.** Embrapa Milho e Sorgo, p. 8-16 (Embrapa-CNPMS. Documentos, 93).

Cruz I, Figueiredo MLC, Silva RB, Silva IF, Paula CS (2012) Using sex pheromone traps in the decision-making process for pesticide application against fall armyworm (*Spodoptera frugiperda* [Smith] [Lepidoptera: Noctuidae]) larvae in maize. **International Journal of Pest Management** 58:83-90.

Davis FM, Ng SS, Williams WP (1992) **Visual rating scales for screening whorl stage corn for resistance to fall armyworm**. Mississipi State University, 9p. (Boletim Técnico, 186).

Day R, Abrahams P et al. (2017) Fall armyworm: Impacts and implications for Africa. **Outlooks on Pest Management** 28:196-201.

Delalieux S, van Aardt J, Keulemans W, Schrevens,E, Coppin P (2007) Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. **European Journal of Agronomy**, 27:130-143.

Deutsch CA, Tewksbury JJ, Tigchelaar M, Battisti DS, Merrill SC, Huey RB, Naylor RL (2018) Increase in crop losses to insect pests in a warming climate. **Science** 361:916-919.

Eismann MT (2012) **Hyperspectral remote sensing**. Bellingham: SPIE Press, 725p.

Francischini FJB, Cordeiro EMG et al. (2019) *Diatraea saccharalis* history of colonization in the Americas: The case for human-mediated dispersal. **Plos One** 14:e0220031.

Goergen G, Kumar PL, Sankung SB, Togola A, Tamò M (2016) First report of outbreaks of the fall armyworm *Spodoptera frugiperda* (JE Smith) (Lepidoptera: Noctuidae), a new alien invasive pest in West and Central Africa. **PloS one** 11:165-632.

Hanley JA, McNeil BJ (1982) The meaning and use of the area under a receiver operating characteristic (ROC) curve. **Radiology** 1:29-36.

Harris CR, Millman KJ et al. (2020) Array programming with NumPy. **Nature** 585:357-362.

Hawkins DM, Basak SC, Mills D (2003) Assessing Model Fit by Cross-Validation. **Journal of Chemical Information and Computer Sciences** 43:579-586.

Horler DNH, Dockray M, Barber J (1983) The red edge of plant leaf reflectance. **International Journal of Remote Sensing** 4:273-288.

Hunter JD (2007) Matplotlib: A 2D graphics environment. **Computing in Science & Engineering** 9:90-95.

Iost Filho FH, Heldens WB, Kong Z, de Lange ES (2020) Drones: Innovative technology for use in precision pest management. **Journal of Economic Entomology** 113:1-25.

Iost Filho FH, de Bastos Pazini J, de Medeiros AD, Rosalen DL, Yamamoto PT (2022) Assessment of injury by four major pests in soybean plants using hyperspectral proximal imaging. **Agronomy** 12:1516-1536.

Jorge J, Vallbé M, Soler JA (2019) Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. **European Journal of Remote Sensing** 52:169-177.

Jensen JR (2014) **Remote Sensing of the Environment: An Earth Resource Perspective**. Harlow: Pearson, 613p.

Karthikeyan L, Chawla I, Mishra AK (2020) A review of remote sensing applications in agriculture for food security: Crop growth and yield, irrigation, and crop losses. **Journal of Hydrology** 586:124905.

Kassambara A, Mundt F. Factoextra: Extract and Visualize the Results of Multivariate Data Analyses. R Package Version 1.0.7. Disponível em: <https://CRAN.R-project.org/package=factoextra>. Acesso em: 12 set. 2022.

Kumar L, Schmidt K, Dury S, Skidmore A (2001) Imaging spectrometry and vegetation science. In.: van der Meer FD, Jong SM (Eds.) **Imaging Spectrometry: Basic Principles and Prospective Applications**. Springer, p. 111-154.

Lenth R, Buerkner P, Giné-Vázquez I, Herve M, Jung M, Love J, Miguez F, Riebl H and Singmann H. Package 'emmeans': Estimated Marginal Means, aka Least-Squares Means. Disponível em: <https://CRAN.R-project.org/package=emmeans>. Acesso em: 12 set. 2022.

Lê S, Josse J, Husson F (2008) FactoMineR: A package for multivariate analysis. **Journal of Statistical Software** 25:1-18.

Lillesand TM, Kiefer RW, Chipman JW (Eds.) (2004) **Remote Sensing and Image Interpretation**. New York: John Wiley, 763p.

Lu B, Dao PD, Liu J, He Y, Shang J (2020) Recent advances of hyperspectral imaging technology and applications in agriculture. **Remote Sensing** 12:1-44.

Macedo TB, Peterson RKD, Dausz CL, Weaver DK (2007) Photosynthetic responses of wheat, *Triticum aestivum* L., to defoliation patterns on individual leaves. **Environmental Entomology** 36:602-608.

Macedo N, Macedo D, Campos MBS, Novaretti WRT, Ferraz LCCB (2012) Manejo de pragas e nematoides. In.: Santos F, Borém A, Caldas C (Eds.) **Cana-de-açúcar: bioenergia, açúcar e etanol - Tecnologias e perspectivas**. Viçosa: UFV, p. 119-159.

Mahlein AK, Kuska MT, Behmann J, Polder G, Walter A (2018) Hyperspectral sensors and imaging technologies in phytopathology: State of the art. **Annual Review of Phytopathology** 56:535-558.

Maleki F, Muthukrishnan N, Ovens K, Reinhold C, Forghani (2020) R machine learning algorithm validation: from essentials to advanced applications and implications for regulatory certification and deployment. **Neuroimaging Clinics** 30:433-445.

Marston ZPD, Cira TM et al. (2022) Linear support vector machine classification of plant stress from soybean aphid (Hemiptera: Aphididae) using hyperspectral reflectance. **Journal of Economic Entomology** 115:1557-1563.

McKinney W et al. (2010) Data structures for statistical computing in python. **Proceedings of the 9th Python in Science Conference** 445:51-56.

Montezano DG, Specht A, Sosa-Gómez DR, Roque-Specht VF, Sousa-Silva JC, Paula-Moraes SV, Peterson JA, Hunt TE (2018) Host plants of *Spodoptera frugiperda* (Lepidoptera: Noctuidae) in the Americas. **African entomology** 26:286-300.

Moran MS, Inoue Y, Barnes EM (1997) Opportunities and limitations for image-based remote sensing in precision crop management. **Remote Sensing of Environment** 6:319-346.

Mitchell C, Brennan RM, Graham J, Karley AJ (2016) Plant defense against herbivorous pests: Exploiting resistance and tolerance traits for sustainable crop protection. **Frontiers in Plant Science** 7:1132.

Miyoshi GT (2016) **Caracterização espectral de espécies de Mata Atlântica de interior em nível foliar e de copa**. Dissertação (Mestrado em Ciências Cartográficas) – Unesp, Jaboticabal.

Mulla DJ (2013) Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering** 114:358-371.

Nabity PD, Zavala JA, EH (2009) Indirect suppression of photosynthesis on individual leaves by arthropod herbivory. **Annals of Botany** 103:655-663.

Nansen C, Elliott N (2016) Remote sensing and reflectance profiling in entomology. **Annual Review of Entomology** 61:139-158.

Nansen C, Murdock M, Purington R, Marshall S (2021) Early infestations by arthropod pests induce unique changes in plant compositional traits and leaf reflectance. **Pest Management Science** 77:5158-5169.

Narkhede S (2018) **Understanding AUC - ROC Curve**. Disponível em: <https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5>. Acesso em: 22 out 2022.

Nguyen HD, Nansen C (2020). Hyperspectral remote sensing to detect leafminer-induced stress in bok choy and spinach according to fertilizer regime and timing. **Pest Management Science** 76:2208-2216.

Novo EMLM (Ed.) (2010) **Sensoriamento remoto: Princípios e aplicações**. São Paulo: Blucher, 388p.

Pedregosa F et al. (2011) Scikit-learn: Machine Learning in Python. **Journal of Machine Learning** 12:2825-2830.

Peterson RK, Higley LG (1993) Arthropod injury and plant gas exchange: current understandings and approaches for synthesis. **Trends In Agriculture Sciences** 1:93-100.

Peterson RKD, Shannon CL, Lenssen AW (2004) Photosynthetic responses of legume species to leaf-mass consumption injury. **Environmental Entomology** 33:450-456.

Pinheiro J, Bates D. R Core Team, nlme: Linear and Nonlinear Mixed Effects Models. R package version 3.1-160. Disponível em: <https://CRAN.R-project.org/package=nlme>. Acesso em: 12 set. 2022.

Pinto J, Powell S, Peterson R, Rosalen D, Fernandes O (2020) Detection of defoliation injury in peanut with hyperspectral proximal remote sensing. **Remote Sensing** 12:3828.

Prabhakar M, Prasad YG, Rao MN (2012) Remote sensing of biotic stress in crop plants and its applications for pest management. In.: Venkateswarlu B, Shanker AK, Shanker C, Maheswari M (Eds.) **Crop stress and its management: Perspectives and strategies**. Springer, p. 517-545.

R Devolpment Core Team, R: a language and environment for statistical computing. v. 4.2.0.

Rossato JAS, Fernandes OA, Mutton MJR, Higley LG, Madaleno LL (2011) Sugarcane response to two biotic stressors: *Diatraea saccharalis* and *Mahanarva fimbriolata*. **International Sugar Journal** 113:453-455.

Rossato JAS, Madaleno LL, Mutton MJR, Higley LG, Fernandes OA (2019) Photosynthesis, yield and raw material quality of sugarcane injured by multiple pests. **PeerJ** 7:e6166.

Riley JR (1989) Remote sensing in entomology. **Annual Review of Entomology** 34:247-271.

Saari H, Aallos VV, Akujärvi A, Antila T, Holmlund C, Kantojärvi U, Mäkynen J, Ollila J (2009) Novel miniaturized hyperspectral sensor for UAV and space applications. **SPIE** 7474:74741M-1.

Sahoo RN, Ray SS, RMK (2015) Hyperspectral remote sensing of agriculture. **Current Science** 108:848-859.

Seelan SK, Laguette S, Casady GM, Seielstad GA (2003) Remote sensing applications for precision agriculture: A learning community approach. **Remote Sensing of Environment** 88:157-169.

Sepehri A, Sanavy SAMM (2003) Water and Nitrogen Stress on Maize Photosynthesis. **Journal of Biological Sciences** 3: 578-584.

Silveira F, Lermen FH, Amaral FG (2021) An overview of agriculture 4.0 development: Systematic review of descriptions, technologies, barriers, advantages, and disadvantages. **Computers and Electronics in Agriculture** 189:106405.

Sishodia RP, Ray RL, Singh SK (2020) Applications of remote sensing in precision agriculture: A review. **Remote Sensing** 12:3136.

Smith GM, Milton EJ (1999) The use of the empirical line method to calibrate remotely sensed data to reflectance. **International Journal of Remote Sensing** 20:2653-2662.

Sun X, Hu C, Jia H, Wu Q, Shen X, Zhao S, Jiang Y, Wu K (2021) Case study on the first immigration of fall armyworm, *Spodoptera frugiperda* invading into China. **Journal of Integrative Agriculture** 20:664-672.

Taiz L, Zeiger E, Møller IM, Murphy A (Eds) (2017) **Fisiologia e Desenvolvimento Vegetal**. Artmed Editora, 888p.

Trumble JT, Kolodny-Hirsch DM, Ting IP (1993) Plant compensation for arthropod herbivory**. Annual Review of Entomology** 38:93-119.

Valicente FH (2015) **Manejo integrado de pragas na cultura do milho.** Sete Lagoas: Embrapa Milho e Sorgo, 12 p. (Embrapa-CNPMS. Circular Técnica, 208).

Weiss M, Jacob F, Duveiller G (2020) Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment** 236:111402.

Welter SC (2019) Arthropod impact on plant gas exchange. In.: Bernays EA (Ed) **Insect-plant interactions.** CRC Press, p. 135-164.

Williams D, Karley A, Britten A, McCallum S, Graham J (2023) Raspberry plant stress detection using hyperspectral imaging. **Plant Direct** 7:e490.

Zablotski Y (2019) MANCOVA: analyse multiple responses. Disponível em: <https://yury-zablotski.netlify.app/post/mancova/>. Acesso em: 22 jan 2023.

Zhang J, Huang Y, Pu R, Gonzalez-Moreno P, Yuan L, Wu K, Huang W (2019) Monitoring plant diseases and pests through remote sensing technology: A review. **Computers and Electronics in Agriculture** 165:104943.

Zhu L, Suomalainen J, Liu J, Hyyppä J, Kaartinen H, Haggren H (2018) A review: Remote sensing sensors. In.: Rustamov RB, Hasanova S, Zeynalova MH (Eds) **Multi-purposeful application of geospatial data**. IntechOpen, p. 19-42.