



UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA AGRÍCOLA

**ISABELA ORDINE PIRES DA SILVA SIMÕES**

**FENOTIPAGEM DE ALTO RENDIMENTO BASEADA EM  
CAMPO PARA RESISTÊNCIA DA CANA-DE-AÇÚCAR ÀS  
FERRUGENS ALARANJADA E MARROM**

CAMPINAS

2022

**ISABELA ORDINE PIRES DA SILVA SIMÕES**

**FENOTIPAGEM DE ALTO RENDIMENTO BASEADA EM  
CAMPO PARA RESISTÊNCIA DA CANA-DE-AÇÚCAR ÀS  
FERRUGENS ALARANJADA E MARROM**

Tese apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Doutora em Engenharia Agrícola, na Área de Máquinas agrícolas.

Orientador: Prof. Dr. Lucas Rios do Amaral

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA TESE DEFENDIDA PELA ALUNA ISABELA ORDINE PIRES DA SILVA SIMÕES E ORIENTADA PELO PROF. DR. LUCAS RIOS DO AMARAL.

CAMPINAS

2022

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Área de Engenharia e Arquitetura  
Elizangela Aparecida dos Santos Souza - CRB 8/8098

Si51f Simões, Isabela Ordine Pires da Silva, 1983-  
Simões, Isabela Ordine Pires da Silva, 1983- Fenotipagem de alto rendimento baseada em campo para resistência da cana-de-açúcar às ferrugens alaranjada e marrom / Isabela Ordine Pires da Silva Simões. – Campinas, SP : [s.n.], 2022.

Orientador: Lucas Rios do Amaral.  
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Sensoriamento remoto. 2. Plantas - Doenças - Pragas. 3. Processamento de imagens. 4. Cana-de-açúcar. I. Amaral, Lucas Rios do, 1985-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Field-based high-throughput phenotyping for resistance of sugarcane orange and brown rust

**Palavras-chave em inglês:**

Remote sensing

Plant - Diseases - Pests

Image processing

Sugarcane

**Área de concentração:** Máquinas Agrícolas

**Titulação:** Doutora em Engenharia Agrícola

**Banca examinadora:**

Lucas Rios do Amaral [Orientador]

Antonio Maria Garcia Tommaselli

Gleyce Kelly Dantas Araujo Figueiredo

Roberto Fritsche-Neto

Rodrigo Gazaffi

**Data de defesa:** 02-05-2022

**Programa de Pós-Graduação:** Engenharia Agrícola

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0002-8350-824>

- Currículo Lattes do autor: <http://lattes.cnpq.br/8234951490113910>

Este exemplar corresponde à redação final da **Tese de Doutorado** defendida por **Isabela Ordine Pires da Silva Simões**, aprovada pela Comissão Julgadora em 02 de Maio de 2022, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

**FEAGRI**

---

**Prof. Dr. Antonio Maria Garcia Tommaselli – Membro Titular**  
Unesp/Presidente Prudente

---

**Prof. Dra. Gleyce Kelly Dantas Araujo Figueiredo – Membro Titular**  
UNICAMP/Campinas

---

**Prof. Dr. Lucas Rios do Amaral – Presidente e  
Orientador**

---

**Prof. Dr. Roberto Fritsche-Neto – Membro Titular**  
Esalq/USP-Piracicaba

**Faculdade de  
Engenharia Agrícola  
Unicamp**

**A Ata da defesa com as respectivas assinaturas dos membros encontra-se no processo de  
vida acadêmica da discente.**

## **AGRADECIMENTOS**

Gostaria de agradecer às seguintes pessoas e organizações por sua assistência durante esses quatro anos dedicados ao desenvolvimento desta tese.

Agradeço aos meus pais Maria de Fátima e Reynaldo Pires pelo apoio e por investirem em mim. Ao Daniel Simões, meu querido esposo, pelo apoio e amizade durante a realização deste projeto. Agradeço também a sua família, especialmente Nelson Oliveira e Mônica Niemayer pela amizade.

Gostaria de agradecer ao meu orientador, Professor Lucas Rios do Amaral, por proporcionar a oportunidade única e apoio, também por confiar a mim decisões importantes em relação ao projeto.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro - Código de Financiamento 001. Agradeço também ao pessoal da Ridesa, Danilo Cursi e Roberto Giacomini, além de outros pesquisadores que fizeram parte do projeto pela troca de conhecimentos e apoio.

Gostaria de agradecer aos meus colegas Rodrigo Greggio, Joaquim Pedro de Lima, Agda Loureiro, Maiara Push e Thiago Luiz Bracco pela assistência no levantamento de campo, troca de conhecimento e pesquisa em grupo.

“Toda a nossa ciência, comparada com a  
realidade, é primitiva e infantil - e, no  
entanto, é a coisa mais preciosa que  
temos.”

~ Albert Einstein

## RESUMO

O principal gargalo para acelerar a obtenção de novas variedades de cana-de-açúcar com características desejáveis para atender as demandas do setor sucroenergético e adaptação às mudanças climáticas é a ausência de métodos de fenotipagem de plantas de alto rendimento para avaliação das variedades em campo. Métodos tradicionais de fenotipagem de campo dependem de especialistas treinados, são lentos, trabalhosos e subjetivos, além de apresentarem riscos para os avaliadores que muitas vezes tem de fazer a avaliação caminhando por dosséis completamente formados. Atualmente, os Veículos Aéreos Não Tripulados (VANT) são considerados por alguns autores a melhor plataforma para a aquisição de imagens no sensoriamento remoto de campos de melhoramento genético vegetal, tornando-se ferramenta crítica na fenotipagem baseada em campo (FBC). O objetivo deste trabalho foi desenvolver uma metodologia para determinação do nível de severidade das ferrugens alaranjada e marrom da cana-de-açúcar por meio de processamento de imagens de alta resolução espacial com sensores acoplados em VANT. Mais especificamente, o capítulo três, referente ao primeiro artigo, trata da exploração de dados multiespectrais de sensor embarcado em VANT para fenotipagem de campo de variedades de cana-de-açúcar em relação a resistência à infecção pelas ferrugens alaranjada e marrom. Os resultados mostraram que apesar dos dados de refletância serem sensíveis aos sintomas das duas doenças, não permitiram a determinação da severidade das mesmas como substituição direta das notas de infecção atribuídas visualmente ou por meio de processamento de imagens das folhas. Porém, é possível classificar as variedades em relação a resistência geral à infecção pelos dois tipos de ferrugens simultaneamente, com alta acurácia, em três classes: resistentes, moderadamente resistentes e susceptíveis. Portanto, as imagens aéreas multiespectrais não permitiram a distinção entre os dois tipos de ferrugens. Já o capítulo quatro, referente ao segundo artigo, trata do processamento de imagens RGB de folhas infectadas para identificação dos sintomas foliares dentre os dois tipos de ferrugens, com alta acurácia mostrada nos resultados. Esse diagnóstico não é uma tarefa simples na rotina de fenotipagem e se mostrou como alternativa uma vez que não foi possível a distinção dentre as duas doenças em imagens aéreas. Os resultados mostram que os dados fenotípicos obtidos a partir de imagens aéreas podem melhorar a eficiência e a qualidade na coleta de dados a nível de campo em relação a infecção pelas ferrugens, com potencial de ser escalável para dezenas de milhares de parcelas dentro de um programa moderno de melhoramento de plantas, porém, a distinção de infecção pelas duas doenças necessita de observação próxima das folhas.

**Palavras-chave:** Sensoriamento remoto; Doenças de plantas; Resistência a doenças; análise de imagens orientada à objetos (OBIA); processamento de imagens.

## ABSTRACT

The main bottleneck for obtaining new sugarcane varieties with desirable characteristics to meet the demands of the sugarcane industry and adaptation to climate change is the absence of high-throughput phenotyping methods for plant varieties evaluation in the field. Traditional field phenotyping methods rely on trained specialists, and are slow, laborious and subjective; in addition, it presents risks for evaluators who often have to carry out the evaluation by walking through fully formed canopies. Currently, Unmanned Aerial Vehicles (UAV) are considered by some authors to be the best platform for image acquisition in remote sensing of plant breeding fields, becoming a critical tool in field-based phenotyping (FBC). The objective of this work was to develop a methodology to determine the severity level of orange and brown sugarcane rust by processing high spatial resolution images with sensors coupled to UAV. More specifically, chapter three, referring to the first article, deals with the exploitation of multispectral data from an UAV embedded sensor for field phenotyping of sugarcane varieties in relation to resistance to infection by orange and brown rust. The results showed that despite the reflectance data being sensitive to the symptoms of the two diseases, they did not allow the determination of their severity as a direct replacement of the infection scores attributed visually or through image processing of the leaves. However, it is possible to classify the varieties in relation to general resistance to infection by both types of rust simultaneously, with high accuracy, in three classes: resistant, moderately resistant and susceptible. Therefore, the multispectral aerial images did not allow the distinction between the two types of rust. Chapter four, referring to the second article, deals with the processing of RGB images of infected leaves to identify leaf symptoms between the two types of rust, with high accuracy shown in the results. This diagnosis is not a simple task in the phenotyping routine and proved to be an alternative since it was not possible to distinguish between the two diseases in aerial images. The results show that phenotypic data obtained from aerial images can improve efficiency and quality in collecting data at the field level regarding rust infection, with the potential to be scalable to tens of thousands of plots within a modern plant-breeding program. However, the distinction between infections by the two diseases requires close observation of the leaves.

**Keywords:** Remote sensing; plant diseases; Disease resistance; Object-oriented image analysis (OBIA); image processing.

## LISTA DE FIGURAS

<b>Figura 1.</b> Escala de diagnóstico de folhas infectadas por ferrugens (AMORIM et al., 1987).....	28
<b>Figura 2.</b> Localização da área de estudo. ....	30
<b>Figura 3.</b> Layout do campo experimental com 24 variedades (V1-24) × 3 blocos (R1-3) em cores diferentes (a); área experimental em imagem aérea com parcelas experimentais (linhas brancas) e variedades susceptíveis doadoras de esporos (linhas azuis) adquirida usando o veículo aéreo não tripulado (VANT) e câmera multiespectral (b); e dimensões individuais das parcelas, com destaque para as duas linhas de cana que compreendem uma parcela (c). .....	31
<b>Figura 4.</b> Exemplos de máscaras para separação solo/vegetação das linhas de plantio feita por meio da definição do limiar de 30% de refletância no Índice de Folha Verde (GLI).....	33
<b>Figura 5.</b> Média de notas de infecção pelas ferrugens alaranjada e marrom das três parcelas experimentais de cana-de-açúcar das 24 variedades avaliadas. As notas de infecção foram atribuídas com pontuação variando entre 1 e 9. V1 à V24 = variedades de 1 a 24. A barra de erro nos gráficos indica a amplitude de variação das notas entre as três parcelas experimentais de cada variedade....	37
<b>Figura 6.</b> Correlação entre a média das maiores notas de infecção dentre os dois tipos de ferrugens das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.....	38
<b>Figura 7.</b> Correlação entre a média das notas de infecção para a ferrugem alaranjada das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.....	38
<b>Figura 8.</b> Correlação entre a média das notas de infecção para a ferrugem marrom das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.....	39
<b>Figura 9.</b> Importância das variáveis para classificação varietal selecionadas com o uso do algoritmo Recursive Feature Elimination (RFE) dentre as diferentes bandas espectrais e índices de vegetação testados para cada avaliação e AUDPCs - refletância. GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; CIrededge = Índice de clorofila – Rededge, CIGreen = Índice de clorofila – Green.....	40

<b>Figura 10.</b> Amostras rotuladas com a classe final de resistência geral às ferrugens alaranjada e marrom em imagem com composição das bandas do vermelho, NIR e Rededge aos 195 DAP.....	44
<b>Figura 11.</b> (a) Pústula de ferrugem alaranjada em alta resolução; (b) Pústula de ferrugem marrom em alta resolução; (c) Pústulas de ferrugem alaranjada e (d) Pústulas de ferrugem marrom com uma resolução menor (FERRARI et al., 2013).....	55
<b>Figura 12.</b> Diagrama de fluxo de trabalho das principais etapas para o processamento e análise de imagens das folhas.....	57
<b>Figura 13.</b> Esquema de preparação das imagens para coleta de dados para treinamento e teste dos modelos de classificação: (a) imagem inteira de 30 cm de folha de cana-de-açúcar infectada com ferrugem alaranjada; (b) exemplos de sub-imagens com lesões; (c) mosaico de sub-imagens de lesões e folha saudável com diversas tonalidades; (d) exemplo de área do mosaico segmentada com posterior coleta de amostras de segmentos de lesões e folha saudável.....	58
<b>Figura 14.</b> Importância das principais características selecionadas pelos modelos de aprendizagem de máquina dentre as 25 características selecionadas após a segmentação e rotulação das amostras utilizadas para a geração dos modelos.....	64
<b>Figura 15.</b> Esquema de numeração de folhas pelo sistema de Kuijper. Fonte: DILLEWIJN, 1952, adaptado pela autora. ....	80
<b>Figura 16.</b> Escala de diagnóstico de folhas infectadas por ferrugens estabelecida pela Copersucar. ....	81
<b>Figura 17.</b> À esquerda, lesões (pústulas) de ferrugem marrom e, à direita, de ferrugem alaranjada. ....	81
<b>Figura 18.</b> Sensor multiespectral Micasense Rededge.....	82
<b>Figura 19.</b> Bandas disponíveis no sensor Micasense Rededge e assinatura espectral típica da vegetação saudável e estressada.....	82
<b>Figura 20.</b> Veículo aéreo não tripulado escolhido para este estudo.....	83
<b>Figura 21.</b> Exemplo de ponto de controle utilizado no campo experimental. ....	83
<b>Figura 22.</b> Parâmetros para o cálculo da altura de voo para aquisição das imagens com câmera digital RGB. ....	84
<b>Figura 23.</b> Interface da calculadora de voo da fabricante Micasense (MicaSense, Inc., Seattle, WA, EUA). ....	85
<b>Figura 24.</b> Polígono de plano de voo, com sobreposições lateral e longitudinal e com área maior do que a área de interesse (MicaSense, Inc., Seattle, WA, EUA – adaptada pela autora).....	85
<b>Figura 25.</b> Sobreposições longitudinal e lateral das imagens (MicaSense, Inc., Seattle, WA, EUA – adaptada pela autora). ....	86

<b>Figura 26.</b> Plano de voo realizado no software livre Mission Planner. ....	86
<b>Figura 27.</b> Foto de trabalho em campo. ....	87
<b>Figura 28.</b> Mosaicos das avaliações a) 1, b) 2, c) 3 e d) 4. ....	88
<b>Figura 29.</b> Shapefile para análise de imagem das parcelas experimentais. ....	89
<b>Figura 30.</b> Assinatura espectral típica da vegetação (Filho et al., 2008). ....	89
<b>Figura 31.</b> Padrão de refletância médio de três repetições de parcelas de variedades de cana-de-açúcar na banda do vermelho aos 150, 165, 180 e 195 DAP bem como o valor da AUDPC – refletância para a banda do vermelho de acordo com a classe final de resistência às ferrugens alaranjada e marrom atribuída pelo programa de melhoramento genético. Os gráfico evidenciam o aumento da refletância na banda do vermelho de acordo com a susceptibilidade das variedades a partir dos 165 DAP. ....	90
<b>Figura 32.</b> Suporte para câmera utilizado para aquisição de imagens de folhas de cana-de-açúcar infectadas. ....	91
<b>Figura 33.</b> Imagens de folhas de cana-de-açúcar infectadas a) com ferrugem alaranjada e b) com ferrugem marrom. ....	92

## LISTA DE TABELAS

<b>Tabela 1.</b> Índices de vegetação testados no estudo.....	34
<b>Tabela 2.</b> Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência às ferrugens alaranjada e marrom em conjunto, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.....	41
<b>Tabela 3.</b> Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência à ferrugem alaranjada, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.....	42
<b>Tabela 4.</b> Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência à ferrugem marrom, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.....	43
<b>Tabela 5.</b> Características extraídas dos segmentos e classificação de importância.....	59
<b>Tabela 6.</b> Características extraídas dos segmentos e definições (DEFINIENS, 2012).....	60
<b>Tabela 7.</b> Resultados da classificação dos modelos para ferrugem alaranjada e marrom da cana-de-açúcar com base em 25 características de segmentos de imagens de folhas para os conjuntos de dados de teste e validação.....	63

## SUMÁRIO

<b>1. INTRODUÇÃO GERAL.....</b>	14
<b>2. REVISÃO BIBLIOGRÁFICA .....</b>	16
<b>3. DADOS MULTISPECTRAIS BASEADOS EM VANT PARA FENOTIPAGEM DE RESISTÊNCIA DA CANA-DE-AÇÚCAR ÀS FERRUGENS ALARANJADA E MARROM .....</b>	26
<b>3.1. INTRODUÇÃO.....</b>	26
<b>3.2. MATERIAL E MÉTODOS .....</b>	29
<b>3.2.1. Aquisição e processamento das imagens.....</b>	31
<b>3.2.2. Extração de dados de refletância.....</b>	32
<b>3.2.3. Índices de Vegetação.....</b>	33
<b>3.2.4. Predição da classe varietal de resistência às doenças .....</b>	34
<b>3.2.5. Avaliação da acurácia.....</b>	36
<b>3.3. RESULTADOS .....</b>	36
<b>3.3.1. Dados de resistência das variedades aos dois tipos de ferrugem .....</b>	36
<b>3.3.2. Correlação dos índices e bandas espectrais com as notas de infecção.....</b>	37
<b>3.3.3. Predição das classes de resistência às doenças .....</b>	39
<b>3.4. DISCUSSÃO.....</b>	44
<b>3.5. CONCLUSÕES.....</b>	46
<b>4. RECONHECIMENTO DAS FERRUGENS ALARANJADA E MARROM DA CANA-DE-AÇÚCAR POR MEIO DO PROCESSAMENTO DE IMAGENS DAS FOLHAS .....</b>	53
<b>4.1. INTRODUÇÃO.....</b>	53
<b>4.2. MATERIAL E MÉTODOS .....</b>	55
<b>4.2.1. Aquisição e processamento das imagens.....</b>	55
<b>4.2.2. Organização e pré-processamento das imagens para coleta de dados de treinamento e teste dos modelos de classificação .....</b>	57
<b>4.2.3. Validação do método de identificação das doenças.....</b>	58
<b>4.2.4. Segmentação .....</b>	58
<b>4.2.5. Seleção de características dos segmentos .....</b>	59
<b>4.2.6. Avaliação de acurácia .....</b>	62
<b>4.3. RESULTADOS .....</b>	63
<b>4.4. DISCUSSÃO.....</b>	64
<b>4.5. CONCLUSÃO .....</b>	66
<b>5. DISCUSSÃO GERAL E CONCLUSÃO .....</b>	72
<b>REFERÊNCIAS GERAIS .....</b>	74
<b>APÊNDICE A – ESTUDOS PRELIMINARES E DETALHAMENTO EXPERIMENTAL CAPÍTULO 3</b>	80
<b>APÊNDICE B – DETALHAMENTO EXPERIMENTAL CAPÍTULO 4.....</b>	91

## 1. INTRODUÇÃO GERAL

Uma das principais doenças que afetam a cana-de-açúcar (*Saccharum officinarum L.*) é a ferrugem, principalmente as causadas pelos fungos *Puccinia kuehnii* (ferrugem alaranjada) e *Puccinia melanocephala* (ferrugem marrom), sendo que sua principal medida de controle é o uso de variedades resistentes (CURSI et al., 2022). Assim, as referidas ferrugens têm grande foco na etapa de avaliação de resistência à determinadas doenças nos programas de melhoramento genético vegetal da cana-de-açúcar.

Nas duas últimas décadas o estudo genético das culturas progrediu em um ritmo acelerado, mas a tradução desses dados para a identificação de características desejáveis é limitada pela falta de conhecimento dos fenótipos associados a elas (FURBANK; TESTER, 2011; ZAMAN-ALLAH et al., 2015). Desse modo, a fenotipagem de alto rendimento é altamente demandada.

Atualmente os pesquisadores avaliam a severidade das ferrugens alaranjada e marrom da cana-de-açúcar exclusivamente por estimativa visual no campo. Este método de avaliação é demorado e trabalhoso se muitas variedades estão sendo avaliadas, além de ser bastante subjetivo. Portanto, métodos alternativos que forneçam uma avaliação mais rápida, precisa e acurada da infecção e severidade por essas doenças são desejados. Diversos autores concordam que uma alternativa mais precisa e acurada para a análise de sintomas foliares é por meio da análise digital de imagens, sejam essas do dossel ou das folhas individualmente (MUTKA; BART, 2015). Os VANTS são uma importante ferramenta, flexível e acessível para a fenotipagem em campo (BERNI et al., 2009; LIEBISCH et al., 2015), sendo uma alternativa de baixo custo para atender os requisitos críticos de resoluções espaciais, espectrais e temporais em monitoramentos agrícolas.

De acordo com Mahlein (2016), os dados coletados para a fenotipagem em campo devem possibilitar: (i) a detecção de doenças nos primeiros estágios, (ii) a diferenciação entre as doenças, (iii) a separação de estresses causados por doenças e por fatores abióticos e (iv) a quantificação ou determinação dos níveis de severidade e, por consequência, de suscetibilidade do genótipo analisado.

Assim, este trabalho teve como objetivo geral desenvolver uma metodologia para fenotipagem da cana-de-açúcar em relação a resistência às ferrugens alaranjada e marrom por meio de processamento de imagens de alta resolução espacial com sensores acoplados em VANT. Também teve como objetivo fornecer bases para o desenvolvimento de uma solução para a identificação rápida e acurada dos dois tipos de ferrugens da cana-de-açúcar por meio de imagens RGB das folhas, uma vez que não foi possível a distinção dos sintomas dentre as duas doenças em imagens aéreas.

Os capítulos 3 e 4 contém os artigos que serão submetidos e apresentam os trabalhos desenvolvidos como objetivos específicos respectivos:

**1 - Avaliar a sensibilidade de dados de sensores embarcados em VANT para determinação do nível de severidade das ferrugens alaranjada e marrom da cana-de-açúcar por meio de processamento de imagens.**

**2 – Desenvolver uma metodologia para identificação dos sintomas dos dois tipos de ferrugens da cana-de-açúcar por meio do processamento de imagens RGB das folhas.**

## 2. REVISÃO BIBLIOGRÁFICA

Os programas de melhoramento genético da cana-de-açúcar têm concentrado esforços para o desenvolvimento e lançamento de novas variedades adaptadas às mudanças climáticas e de alto rendimento, que sejam resistentes e tolerantes a estresses abióticos e bióticos encontrados nos ambientes de produção para atender às demandas do setor sucroenergético (DAL-BIANCO et al., 2012). O processo de melhoramento genético da cana-de-açúcar é longo e extremamente trabalhoso, envolvendo a obtenção de milhares de indivíduos de progênies ao ano, seguida por 12 a 15 anos de seleção e experimentação em campo (CURSI et al., 2022). O processo é ainda mais trabalhoso devido à complexidade genética da cultura, com elevado número de cromossomos (100 a 130), ao tamanho do genoma, com aproximadamente 10 Gb (D'HONT, 2005) e a ocorrência de aneuploidia, com um número variável de cromossomos em cada grupo de homeologia (GRIVET; ARRUDA, 2002), fazendo com que a obtenção de variedades com alta performance agrícola se torne um grande desafio (BALSALOBRE et al., 2016).

A infecção pelas ferrugens causadas pelos fungos *Puccinia kuehnii* (ferrugem alaranjada) e *Puccinia melanocephala* (ferrugem marrom) é favorecida por condições climáticas quentes e úmidas. Têm como principal sintoma o aparecimento de pústulas no limbo foliar inferior, que ocasionam morte do tecido vegetal e redução da área fotossintética e, por consequência, redução na produção de colmos. A ferrugem alaranjada apresenta pústulas que incidem mais na base das folhas, porém podem ocorrer distribuídas por toda a superfície; já as pústulas de ferrugem marrom ocorrem em maior número do centro para as pontas das folhas.

A ferrugem está entre as doenças que causam perdas relevantes em lavouras de cana-de-açúcar e está presente em quase todas as áreas de cultivo (GIRARD, 2004), sendo a principal medida de controle à esses patógenos o uso de variedades resistentes (DAL-BIANCO et al., 2012). Assim, uma das etapas com grande foco no processo de fenotipagem dos programas de melhoramento genético da cana-de-açúcar é a avaliação de resistência à essas doenças.

A Fenotipagem Baseada em Campo (FBC) é um componente crítico no processo de melhoramento genético das culturas, pois possibilita a expressão máxima de características genéticas, como potencial produtivo e tolerância a estresses bióticos e abióticos em condições adversas, tanto ambientais quanto de produção (ARAUS; CAIRNS, 2014; NEILSON et al., 2015). O método mais comum para a detecção e diagnóstico de doenças em plantas nos processos de fenotipagem em campo é a estimativa visual feita por observadores humanos (BOCK et al., 2010; FORREST et al., 1991). As estimativas visuais identificam as doenças baseando-se em sintomas característicos (lesões, ferrugem, galhas, tumores, cancros, murcha, podridão) ou outros sinais visíveis do patógeno (hifas de oídio e conídios ou uredósporos da ferrugem) e são realizadas por especialistas treinados, sendo a confiabilidade e precisão imprescindíveis para o desempenho das avaliações, sendo, por isso, objeto de intensa pesquisa e investigação (MAHLEIN, 2016).

A estimativa visual tornou-se mais precisa e confiável devido à disponibilidade de diretrizes detalhadas e padrões usados para o treinamento de avaliadores (BOCK et al., 2010). No entanto, está sempre sujeita à experiência de um indivíduo e pode ser afetada com o tempo, causando significativa variabilidade entre os avaliadores e prejudicando a repetibilidade das observações (BOCK et al., 2008; FORREST et al., 1991; NEWTON; HACKETT, 1994; STEDDOM et al., 2005). Além disso, esse método é demorado e apresenta limitações quanto ao tamanho das áreas experimentais e do desenvolvimento da cultura. A coleta de dados em campo requer repetidas medições, com alto risco de danificar as plantas e lesionar a pessoa envolvida com a coleta dos dados, à medida que caminha por dosséis totalmente desenvolvidos (YANG et al., 2020b).

O alto rendimento na FBC refere-se ao esforço associado à realização das medições. As ferramentas de fenotipagem baseadas em imagens são capazes de gerar imagens de milhares de plantas ou parcelas em poucas horas, e fazê-lo com um alto nível de precisão (FAHLGREN; GEHAN; BAXTER, 2015). A eficiência na seleção de novas variedades depende da fenotipagem acurada com base em dados coletados em campo, relativos ao potencial genético influenciado pelo ambiente de produção alvo, expresso em termos de produtividade da cultura, produção de biomassa e resistência a estresses abióticos e bióticos (REYNOLDS et al., 2020). As tecnologias empregadas na fenotipagem aumentam o rendimento na triagem das plantas e podem ser usadas para gerar conjuntos completos de dados, acelerando e melhorando o processo de melhoramento genético (MAHLEIN, 2016; ROITSCH et al., 2019a).

Uma fenotipagem de campo rápida e consistente, que apresente um bom desempenho na aquisição de dados com acurácia baseada em correlações com níveis definidos de significância estatística entre os dados de sensores e fenótipos, é a solução para o gargalo do avanço no melhoramento genético de plantas, fornecendo subsídios para o sucesso da seleção de novas variedades em campo. Os novos métodos de fenotipagem rápida e aprimorada devem equilibrar velocidade, custo e acurácia (ROITSCH et al., 2019b).

Recentemente, avanços foram feitos na fenotipagem de alto rendimento para acelerar a seleção de variedades em campo usando sistemas de sensoriamento remoto (FAHLGREN; GEHAN; BAXTER, 2015; HASSAN et al., 2019; LIEBISCH et al., 2015; REYNOLDS et al., 2020; YANG et al., 2020a, 2020b; ZHOU et al., 2020). A tecnologia de sensoriamento remoto por satélite oferece medições precisas, oportunas e econômicas em grande escala para a cana-de-açúcar (APAN et al., 2004; CANATA et al., 2016; DUVEILLER; LÓPEZ-LOZANO; BARUTH, 2013; PICOLI et al., 2015; VERMA et al., 2019). No entanto, ela não corresponderá à resolução espacial (submétrica) e temporal (diária / semanal) que pode ser alcançada com a fenotipagem baseada em dados de sensor acoplado em VANT. Essa maior resolução espacial é necessária para distinguir pequenas alterações espectrais nos dados de imagens das plantas, como, por exemplo, devido a infecção por doença, estresse por seca ou deficiências minerais. A resolução espacial das imagens de sensores baseados em VANT para fenotipagem é em nível de parcela experimental e fornece a possibilidade de registros

das parcelas individualmente ou múltiplas e é, portanto, aplicável ao melhoramento genético de plantas (YANG et al., 2020b). As opções de sensoriamento remoto de alta resolução espacial de plataformas aéreas tripuladas são caras e limitadas pela complexidade operacional para aplicação em pequenos lotes de reprodução (YANG et al., 2017). Os VANTs são relativamente pequenos e baratos para operar para a comunidade de sensoriamento remoto de plantações experimentais (YUE et al., 2018).

O maior desafio na detecção de doenças em plantas por sensoriamento remoto para a FBC é a quantificação dos sintomas em diversos níveis de severidade, principalmente nos primeiros estágios de infecção e de maneira automática (MUTKA; BART, 2015; ZHANG et al., 2018). Essa quantificação deve ter igual ou maiores precisão e acurácia que a feita por avaliação visual humana. Apesar dos sintomas possuírem diferentes assinaturas espectrais, o principal desafio é identificar pequenas lesões das doenças e diferenciá-las de outros tipos de lesões foliares em variados níveis de infestação, sendo necessários métodos mais complexos de processamento e análise das imagens.

As técnicas de imagem multi e hiperespectral dividem cada pixel de uma imagem em bandas de comprimento de onda que capturam a radiação eletromagnética refletida da vegetação na região do visível (400–700 nm), infravermelho próximo (700–1300 nm) e infravermelho de ondas curtas (1400–3000 nm) do espectro eletromagnético, que podem conter informações sobre o estado fisiológico das folhas, conteúdo de água, pigmentos e componentes estruturais da biomassa (YENDREK et al., 2017). Por exemplo, plantas verdes saudáveis refletem mais luz NIR de 700 a 1500 nm, enquanto plantas sob estresse têm uma absorção de vermelho reduzida na banda ativa da clorofila e refletem mais luz de comprimento de onda vermelha em comparação com plantas saudáveis (KARLOVSKA et al., 2016). Portanto, a aplicação potencial de sensores hiperespectrais e multiespectrais baseados em VANTs precisa ser investigada para a classificação varietal na resistência à doenças para melhorar a eficiência e acurácia da seleção de novas variedades no melhoramento genético.

Apesar do progresso feito até agora nos sistemas de detecção e monitoramento de doenças com sensores multi e hiperespectrais embarcados em VANT (ABDULRIDHA et al., 2020; ABDULRIDHA; BATUMAN; AMPATZIDIS, 2019; CHIVASA; MUTANGA; BIRADAR, 2020; HUANG et al., 2019; SHAKOOR; LEE; MOCKLER, 2017; YE et al., 2020), existem poucos estudos sobre o monitoramento de doenças em variedades de cana-de-açúcar (MORIYA et al., 2017; SOCA-MUÑOZ et al., 2020). A ferrugem alaranjada produz lesões laranjas (pústulas) que tendem a se agrupar próximas ao ponto de inserção da folha ao colmo, sendo que em condições de alta severidade da doença é comum a coalescência das mesmas e necrose das folhas, que geralmente ocorre a partir das bordas. Esse agrupamento e necrose pode causar o rompimento das folhas e consequente perda de água pela planta, levando a um estresse hídrico (ESALQ, 2011). Em condições de campo, a ferrugem alaranjada pode ser confundida com a ferrugem marrom, porém esta, em geral, apresenta pústulas de maior tamanho e mais alongadas, ocorrendo em maior número do centro para a ponta das

folhas, com coloração mais escura e raramente promovendo necrose nas folhas (CDA, 2010), prejudica a taxa fotossintética, ocasionando reduções na altura, diâmetro dos colmos e quantidade de perfilhos (HOY; HOLLIER, 2009). Apan et al. (2004) examinaram a potencialidade de imagens hiperespectrais para detecção de ferrugem alaranjada em lavouras de cana-de-açúcar, e verificaram que nas regiões infectadas com ferrugem alaranjada foram encontrados valores de refletância mais elevados na região espectral do vermelho e algumas regiões do infravermelho de ondas curtas (sigla em inglês SWIR - Short Wave Infrared) do que nas áreas sadias, sendo que as regiões do SWIR são altamente relacionadas com o conteúdo de água nas plantas, sendo que quanto maior a reflexão nestas regiões menor o conteúdo de água. Isto indica que as regiões contaminadas pela ferrugem alaranjada apresentaram maior estresse hídrico. Já em Saito et al. (2012), não foram encontradas áreas de diferenciação entre áreas saudáveis e infectadas com ferrugem marrom na região do SWIR (SAITO; IMAI; TOMMASELLI, 2012). Soca-Muñoz et al. (2020) analisaram valores médios e desvio padrão da assinatura espectral de refletância de cinco níveis de infecção pelas ferrugens alaranjada e marrom em folhas de cana-de-açúcar e observaram maiores diferenças entre folhas saudáveis e doentes nas bandas do vermelho (Red) e infravermelho próximo (NIR), demonstrando a possibilidade de não se utilizar a banda do infravermelho de ondas curtas (SWIR) para verificar níveis de severidade de infecção pelas doenças. Isso é interessante uma vez que os sensores que possuem filtro na região SWIR são mais caros ou são comercializados como sensor único.

A identificação visual de cada tipo de ferrugem não é uma tarefa simples, demandando pessoal técnico especializado para realizar as observações a olho nu, ou por meio de observações microscópicas de características morfológicas de agentes causais ou ainda a detecção com uso de técnicas de biologia molecular. Então, obter essa distinção também por meio de análise de imagens, daria mais confiança para os cientistas no armazenamento dos dados das avaliações e facilitaria as análises nos campos experimentais e lavouras. O processamento de imagem de folhas tem sido aplicado no reconhecimento de muitas doenças em plantas (MANAVALAN, 2021; QIN et al., 2016; SRIVASTAVA et al., 2020). Alguns estudos se dedicaram ao reconhecimento da ferrugem em imagens RGB de folhas de cana-de-açúcar, dentre outras doenças (MANAVALAN, 2021), porém até onde sabemos não foram encontrados estudos que se dedicaram a distinguir os sintomas dentre os dois tipos de ferrugens.

A acurácia do reconhecimento baseado em imagens para doenças de plantas depende muito da segmentação das lesões nas imagens (BARBEDO, 2016). Métodos de segmentação de imagens baseados em limiares têm sido amplamente usados na segmentação de imagens de lesões de plantas doentes (QIN et al., 2016). No entanto, geralmente há uma grande variação na cor tanto entre lesões de doenças diferentes quanto entre lesões de uma doença em estágios diferentes. Portanto, é muito difícil determinar o limite apropriado quando métodos de segmentação de imagem baseados em limite são usados para resolver problemas de segmentação para imagens de doenças em plantas com cores complexas. Métodos de segmentação de imagens baseados em um algoritmo de agrupamento difuso

C-means (THAILAMBAL; YOGESHWARI, 2020) ou algoritmo de agrupamento K-means (SHI; WANG; ZHANG, 2016) têm sido usados para realizar a segmentação de lesões em imagens de doenças de plantas. Esses métodos de segmentação exigem que seja definido o número de agrupamentos adequado, e a escolha errada desse número pode levar à super ou subsegmentação das imagens das lesões, exigindo também um grande custo computacional para determinação do número apropriado de agrupamentos, especialmente para operações de segmentação em imagens de alta resolução. Sendo assim, uma interessante alternativa é a análise de imagens orientada a objeto (OBIA), que foi desenvolvida especificamente para o trabalho com imagens de alta resolução, quando a análise das características espectrais dos pixels não é suficiente, ou é pouco eficaz diante da quantidade de informações que podem ser obtidas de objetos de interesse, quando se analisam também características de formato e de textura (WONG T. et al., 2003). A análise OBIA é largamente utilizada no processamento de imagens em sensoriamento remoto convencional (imagens aéreas e de satélite), mas até onde sabemos, ainda não havia sido testado para análise de imagens de doenças em folhas.

## REFERÊNCIAS

- ABDULRIDHA, J. et al. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. **Precision Agriculture**, v. 21, n. 5, p. 955–978, 2020.
- ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. **Remote Sensing**, v. 11, n. 11, 2019.
- AGISOFT METASHAPE. MicaSense RedEdge MX processing workflow ( including Reflectance Calibration ) in Agisoft Metashape Professional. 2021.
- AHMED, A. A.; REDDY, G. H. A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning. **AgriEngineering**, v. 3, n. 3, p. 478–493, 2021.
- APAN, A. et al. Detecting sugarcane “orange rust” disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v. 25, n. 2, p. 489–498, 2004.
- ARAUS, J. L.; CAIRNS, J. E. Field high-throughput phenotyping: The new crop breeding frontier. **Trends in Plant Science**, v. 19, n. 1, p. 52–61, 2014.
- BALSALOBRE, T. W. A. et al. Mixed modeling of yield components and brown rust resistance in sugarcane families. **Agronomy Journal**, v. 108, n. 5, p. 1824–1837, 2016.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52–60, 2016.
- BARRETO, F. Z. et al. Validation of molecular markers associated with brown rust resistance in sugarcane. **Summa Phytopathologica**, v. 43, n. 1, p. 36–40, 2017.
- BELGIU, M.; DRĀGU, L. Random forest in remote sensing: A review of applications and future

- directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BERNI, J. A. J. et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BOCK, C. H. et al. Visual Rating and the Use of Image Analysis for Assessing Different Symptoms of Citrus Canker on Grapefruit Leaves. **Plant Disease**, v. 92, n. 4, p. 530–541, 2008.
- BOCK, C. H. et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59–107, 2010.
- CAMARGO, A.; SMITH, J. S. Image pattern classification for the identification of disease causing agents in plants. v. 66, p. 121–125, 2009.
- CANATA, T. . et al. Measuring height of sugarcane plants through LiDAR technology. p. 1–13, 2016.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859–881, 2017.
- CHIVASA, W.; MUTANGA, O.; BIRADAR, C. UAV-based multispectral phenotyping for disease resistance to accelerate crop improvement under changing climate conditions. **Remote Sensing**, v. 12, n. 15, 2020.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- CURSI, D. E. et al. History and Current Status of Sugarcane Breeding, Germplasm Development and Molecular Genetics in Brazil. **Sugar Tech**, v. 24, n. 1, p. 112–133, 2022.
- D'HONT, A. Unraveling the genome structure of polyploids using FISH and GISH; examples of sugarcane and banana. **Cytogenetic and Genome Research**, v. 109, n. 1–3, p. 27–33, 2005.
- DAL-BIANCO, M. et al. Sugarcane improvement: How far can we go? **Current Opinion in Biotechnology**, v. 23, n. 2, p. 265–270, 2012.
- DEFINIENS. Definiens Developer XD 2.0.4 Reference Book. p. 106, 2012.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, n. 3, p. 1091–1116, 2013.
- FAHLGREN, N.; GEHAN, M. A.; BAXTER, I. Lights, camera, action: High-throughput plant phenotyping is ready for a close-up. **Current Opinion in Plant Biology**, v. 24, p. 93–99, 2015.
- FERRARI, J. T. et al. Ferrugem alaranjada da cana-de-açúcar no Brasil. **Biológico**, v. 75, p. 71–74, 2013.
- FORREST, W. et al. **Disease assessment terms and concepts**. *Plant Disease*, 1991. Disponível em: <<http://agris.fao.org/agris/>>

- search/search/display.do?f=2012/OV/OV201208481008481.xml;US19930116789>
- FURBANK, R. T.; TESTER, M. Phenomics - technologies to relieve the phenotyping bottleneck. **Trends in Plant Science**, v. 16, n. 12, p. 635–644, 2011.
- GIRARD, J. H. H. T. J. C. Targeted mapping of a sugarcane rust resistance gene ( Bru1 ) using bulked segregant analysis and AFLP markers. v. 570, p. 759–764, 2004.
- GRANDINI, M.; BAGLI, E.; VISANI, G. Metrics for Multi-Class Classification: an Overview. p. 1–17, 2020.
- GRIVET, L.; ARRUDA, P. Sugarcane genomics: Depicting the complex genome of an important tropical crop. **Current Opinion in Plant Biology**, v. 5, n. 2, p. 122–127, 2002.
- HASSAN, M. A. et al. Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. **Plant Methods**, v. 15, n. 1, p. 1–12, 2019.
- HAYNES, K.; WEINGARTNER, D. P. The Use of Area Under the Disease Progress Curve to Assess Resistance to Late Blight in Potato Germplasm. **American Journal Of Potato Research**, n. December 2003, p. 137–141, 2004.
- HOY, J. W.; HOLLIER, C. A. Effect of Brown Rust on Yield of Sugarcane in Louisiana. **Plant Disease**, v. 93, n. 11, p. 1171–1174, 2009.
- HUANG, H. et al. Detection of helminthosporium leaf blotch disease based on UAV imagery. **Applied Sciences (Switzerland)**, v. 9, n. 3, p. 1–14, 2019.
- KARLOVSKA, A. et al. PLANT REFLECTED SPECTRA DEPENDING ON BIOLOGICAL CHARACTERISTICS AND GROWTH CONDITIONS. **International Scientific Conference Rural Development 2017**, 2016.
- KHAN, A.; YADAV, M. S. Image Processing Based Disease Detection for Sugarcane Leaves. **International Journal Of Advance Research, Ideas And Inovations In Technology**, v. 3, n. 4, p. 497–502, 2017.
- LEIVA-VALENZUELA, G. A.; AGUILERA, J. M. Automatic detection of orientation and diseases in blueberries using image analysis to improve their postharvest storage quality. **Food Control**, v. 33, n. 1, p. 166–173, 2013.
- LIEBISCH, F. et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. **Plant Methods**, v. 11, n. 1, 2015.
- LU, J.; TAN, L.; JIANG, H. Review on convolutional neural network (CNN) applied to plant leaf disease classification. **Agriculture (Switzerland)**, v. 11, n. 8, p. 1–18, 2021.
- MAHLEIN, A.-K. Present and Future Trends in Plant Disease Detection. **Plant Disease**, v. 100, n. 2, p. 1–11, 2016.
- MAIA JÚNIOR, S. DE O. et al. Caracterização Morfológica E Produtiva E Suas Correlações Em Cultivares De Cana-De-Açúcar. **Revista Ciência Agrícola**, v. 16, n. 1, p. 31–42, 2018.
- MANAVALAN, R. Efficient Detection of Sugarcane Diseases through Intelligent Approaches : A Review. **Asian Journal of Research and Review in Agriculture**, v. 3, n. 4, p. 27–37, 2021.

- MORIYA, E. A. S. et al. Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 2, p. 740–748, 2017.
- MUTKA, A. M.; BART, R. S. Image-based phenotyping of plant disease symptoms. **Frontiers in Plant Science**, v. 5, n. 1, p. 1–8, 2015.
- NEILSON, E. H. et al. Utilization of a high-throughput shoot imaging system to examine the dynamic phenotypic responses of a cereal crop plant to nitrogen and water deficiency over time. **Journal of Experimental Botany**, v. 66, n. 7, p. 1817–1832, 2015.
- NEWTON, A. C.; HACKETT, C. A. Subjective components of mildew assessment on spring barley. **European Journal of Plant Pathology**, v. 100, n. 6, p. 395–412, 1994.
- NIEMEYER, J.; ROTTENSTEINER, F.; SOERGEL, U. Contextual classification of lidar data and building object detection in urban areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 152–165, 2014.
- PATIL, S. B.; BODHE, S. K. Leaf Disease Severity Measurement Using Image Processing. **International Journal of Engineering and Technology**, v. 3, n. 5, p. 297–301, 2011.
- PICOLI, M. C. A. et al. The use of ALOS/PALSAR data for estimating sugarcane productivity. **Engenharia Agrícola**, v. 34, n. 6, p. 1245–1255, 2015.
- QIN, F. et al. Identification of alfalfa leaf diseases using image recognition technology. **PLoS ONE**, v. 11, n. 12, p. 1–26, 2016.
- RACZKO, E.; ZAGAJEWSKI, B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. **European Journal of Remote Sensing**, v. 50, n. 1, p. 144–154, 2017.
- RAUT, S.; INGOLE, K. Review On Leaf Disease Detection Using Image Processing Techniques. **International Research Journal of Engineering and Technology (IRJET)**, v. 4, n. 4, p. 22–24, 2017.
- REYNOLDS, M. et al. Breeder friendly phenotyping. **Plant Science**, v. 295, n. December 2019, p. 110396, 2020.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. December 2018, p. 2–10, 2019a.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. January, p. 2–10, 2019b.
- SAITO, É. A.; IMAI, N. N.; TOMMASELLI, A. M. G. Análise Espectral De Amostras De Cana-De-Açúcar. **Anais do III Simpósio Brasileiro de Geomática**, n. 1, p. 169–174, 2012.
- SANJEL, S. et al. Comparison of progress of brown rust and orange rust and conditions conducive for severe epidemic development during the sugarcane crop season in Florida. **Plant Disease**, v. 103, n. 5, p. 825–831, 2019.
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers**

- and Electronics in Agriculture, v. 72, n. 1, p. 1–13, 2010.
- SANTOS, F.; BORÉM, A. Cana-de-açúcar: do Plantio à Colheita. n. June, p. 89–115, 2013.
- SCHAAD, N. W.; FREDERICK, R. D. Real-time PCR and its application for rapid plant disease diagnostics. **Canadian Journal of Plant Pathology**, v. 24, n. 3, p. 250–258, 2002.
- SHAKOOR, N.; LEE, S.; MOCKLER, T. C. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field. **Current Opinion in Plant Biology**, v. 38, p. 184–192, 2017.
- SHI, Y.; WANG, X.; ZHANG, S. Plant disease leaf image segmentation using K-Means clustering based on internet of things. **International Journal of Research in Agricultural Sciences**, v. 3, n. 2, p. 2348–3997, 2016.
- SIMKO, I.; PIEPHO, H. P. The area under the disease progress stairs: Calculation, advantage, and application. **Phytopathology**, v. 102, n. 4, p. 381–389, 2012.
- SOCA-MUÑOZ, J. L. et al. Spectral signature of brown rust and orange rust in sugarcane. **Revista Facultad de Ingeniería**, n. 96, p. 9–20, 2020.
- SONG, Y. et al. **IKNN: Informative K-nearest neighbor pattern classification**. [s.l: s.n.]. v. 4702 LNAI
- SRIVASTAVA, S. et al. A Novel Deep Learning Framework Approach for Sugarcane Disease Detection. **SN Computer Science**, v. 1, n. 2, p. 1–7, 2020.
- STEDDOM, K. et al. Comparison of Visual and Multispectral Radiometric Disease Evaluations of Cercospora Leaf Spot of Sugar Beet. **Plant Disease**, v. 89, n. 2, p. 153–158, 2005.
- THAILAMBAL, G.; YOGESHWARI, M. Automatic segmentation of plant leaf disease using improved fast Fuzzy C-Means clustering and adaptive Otsu thresholding. **European Journal of Molecular and Clinical Medicine**, v. 7, n. 3, p. 5447–5462, 2020.
- THANH NOI, P.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, 2017.
- THOMPSON, L. J.; PUNTEL, L. A. Transforming unmanned aerial vehicle (UAV) and multispectral sensor into a practical decision support system for precision nitrogen management in corn. **Remote Sensing**, v. 12, n. 10, 2020.
- TRIMBLE INC. eCognition Developer 9.1. n. March, 2017.
- TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.
- VERMA, A. K. et al. Modelling of sugarcane yield using LISS-IV data based on ground LAI and yield observations. **Geocarto International**, v. 0, n. 0, p. 1–18, 2019.
- WONG T., H. et al. Feature extraction based on object oriented analysis. **Proceedings of ATC**, p. 1–10, 2003.

- YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, 2017.
- YANG, M. et al. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, n. June, p. 1–16, 2020a.
- YANG, W. et al. Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives. **Molecular Plant**, v. 13, n. 2, p. 187–214, 2020b.
- YANG, X. Parameterizing Support Vector Machines for Land Cover Classification. **Photogrammetric Engineering & Remote Sensing**, v. 77, n. 1, p. 27–37, 2011.
- YE, H. et al. Identification of banana fusarium wilt using supervised classification algorithms with UAV-based multi-spectral imagery. **International Journal of Agricultural and Biological Engineering**, v. 13, n. 3, p. 136–142, 2020.
- YENDREK, C. R. et al. High-throughput phenotyping of maize leaf physiological and biochemical traits using hyperspectral reflectance. **Plant Physiology**, v. 173, n. 1, p. 614–626, 2017.
- YUE, J. et al. A comparison of crop parameters estimation using images from UAV-mounted snapshot hyperspectral sensor and high-definition digital camera. **Remote Sensing**, v. 10, n. 7, 2018.
- ZAMAN-ALLAH, M. et al. Unmanned aerial platform-based multi-spectral imaging for field phenotyping of maize. **Plant Methods**, v. 11, n. 1, p. 1–10, 2015.
- ZHANG, D. et al. Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. **PLoS ONE**, v. 13, n. 5, p. 1–14, 2018.
- ZHENG, Q. et al. New spectral index for detecting wheat yellow rust using sentinel-2 multispectral imagery. **Sensors (Switzerland)**, v. 18, n. 3, p. 1–19, 2018.
- ZHOU, J. et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. **Computers and Electronics in Agriculture**, v. 175, n. March, p. 105576, 2020.

### **3. DADOS MULTISPECTRAIS BASEADOS EM VANT PARA FENOTIPAGEM DE RESISTÊNCIA DA CANA-DE-AÇÚCAR ÀS FERRUGENS ALARANJADA E MARROM**

**Resumo:** O principal gargalo para acelerar a obtenção de novas variedades de cana-de-açúcar com características desejáveis para atender as demandas do setor sucroenergético e adaptação às mudanças climáticas é a ausência de métodos de fenotipagem de plantas de alto rendimento para avaliação das variedades em campo. Neste estudo exploramos dados multiespectrais com sensor embarcado em VANT para melhorar a eficiência na avaliação da fenotipagem de campo de variedades de cana-de-açúcar em relação a resistência à infecção pelas ferrugens alaranjada e marrom. Dados espectrais de cinco bandas (Azul, Verde, Vermelho, Borda do Vermelho e Infravermelho próximo) e quatorze índices de vegetação foram testados em correlações diretas com notas de infecção coletadas em campo para os dois tipos de ferrugem. Além disso, três modelos de aprendizagem de máquina (Random Forest, SVM e KNN) foram utilizados para classificação das variedades em classes de resistência atribuídas pelo programa de melhoramento genético. As correlações entre os dados da banda do Vermelho e as notas de infecção devido aos dois tipos de ferrugem em conjunto foram significativas ( $R = 0,67$ ) para avaliações feitas a partir dos 165 dias após o plantio (DAP), sendo os dados mais sensíveis à infecção pelas doenças. Já para a classificação varietal em três classes de resistência, alta acurácia geral (88,1%) e balanceada (Resistente = 90,3, Moderadamente resistente = 88,6 e Susceptível = 82,1) foram alcançadas aos 195 DAP, com modelo SVM radial. Desse modo, concluímos que dados multiespectrais baseados em VANT são uma ferramenta promissora para a fenotipagem de novas variedades de cana-de-açúcar em relação a resistência a essas doenças.

**Palavras-chave:** Sensoriamento remoto; fenotipagem de alto rendimento; Doenças de plantas; VANT; agricultura digital

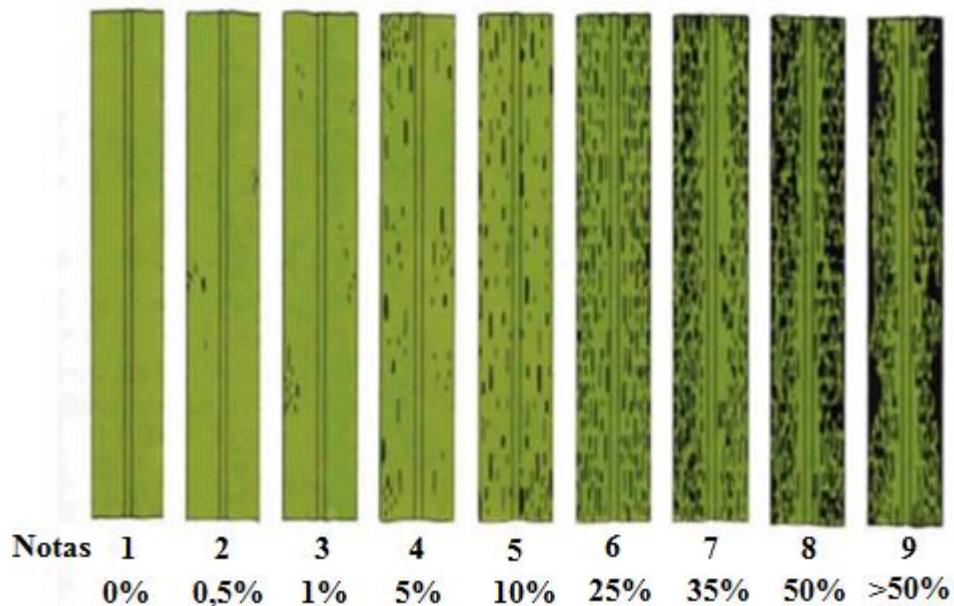
#### **3.1. INTRODUÇÃO**

Uma das principais doenças que afetam a cana-de-açúcar (*Saccharum officinarum L.*) é a ferrugem, principalmente as causadas pelos fungos *Puccinia kuehnii* (ferrugem alaranjada) e *Puccinia melanocephala* (ferrugem marrom). A ferrugem alaranjada produz lesões laranjas (pústulas) nas folhas que tendem a ser agrupadas em manchas. As folhas rompidas permitem que a água escape da planta, levando também ao estresse hídrico (APAN et al., 2004). Já a ferrugem marrom prejudica a taxa fotossintética ocasionando reduções na altura, diâmetro dos colmos e quantidade de perfilhos (HOY; HOLLIER, 2009). Como a principal medida de controle à esses patógenos é o uso de variedades resistentes (DAL-BIANCO et al., 2012), uma das etapas dos programas de melhoramento genético vegetal da cana-de-açúcar é a avaliação de resistência às referidas doenças. A ferrugem marrom está entre as doenças que causam perdas relevantes em lavouras de cana-de-açúcar e está

presente em quase todas as áreas de cultivo do mundo (GIRARD, 2004). O processo de melhoramento genético da cana-de-açúcar é longo e extremamente trabalhoso, envolvendo a obtenção de milhares de indivíduos progêneres ao ano, seguida por 12 a 15 anos de seleção e experimentação em campo (CURSI et al., 2022). Nas duas últimas décadas o conhecimento genético das culturas progrediu em um ritmo acelerado, mas a tradução desses dados para a identificação de características desejáveis é limitada pela falta de conhecimento dos fenótipos associados a elas (FURBANK; TESTER, 2011; ZAMAN-ALLAH et al., 2015). Desse modo, a fenotipagem de alto rendimento é altamente demandada para o avanço no melhoramento genético de plantas e sucesso na seleção de novas variedades em campo.

O método mais comum para a detecção e diagnóstico de doenças em plantas nos processos de fenotipagem em campo é a estimativa visual feita por observadores humanos (BOCK et al., 2010; FORREST et al., 1991), que identificam as doenças baseando-se em sintomas característicos (lesões, ferrugem, galhas, tumores, cancros, murcha, podridão) ou outros sinais visíveis do patógeno (hifas de oídio e conídios ou uredósporos da ferrugem) e são realizadas por especialistas treinados, sendo a confiabilidade e precisão imprescindíveis para o desempenho das avaliações, sendo, por isso, objeto de intensa pesquisa e investigação (MAHLEIN, 2016).

A estimativa visual tornou-se mais precisa e confiável devido à disponibilidade de diretrizes detalhadas e padrões usados para o treinamento de avaliadores (BOCK et al., 2010). No entanto, está sempre sujeita à experiência de um indivíduo e pode ser afetada com o tempo, causando significativa variabilidade entre os avaliadores e prejudicando a repetibilidade das observações (BOCK et al., 2008; FORREST et al., 1991; NEWTON; HACKETT, 1994; STEDDOM et al., 2005). Além disso, esse método é demorado e apresenta limitações quanto ao tamanho das áreas experimentais e do desenvolvimento da cultura. A coleta de dados em campo requer repetidas medições, com alto risco de danificar as plantas e lesionar a pessoa envolvida com a coleta dos dados, à medida que caminha por dosséis totalmente desenvolvidos (YANG et al., 2020b). Atualmente os pesquisadores avaliam a severidade das ferrugens alaranjada e marrom da cana-de-açúcar exclusivamente por estimativa visual no campo. Nessa avaliação atribui-se notas de 1 (0% de área foliar com sintomas) a 9 (mais de 50% de área foliar com sintomas) para a identificação do nível de severidade da doença. De acordo com a escala de diagnóstico estabelecida pela Coordenadoria de Fitopatologia do Centro de Tecnologia Copersucar (AMORIM et al., 1987; CDA, 2010) (Figura 1). Portanto, um método alternativo que forneça uma avaliação mais rápida e precisa da severidade dessas doenças é desejado.



**Figura 1.** Escala de diagnóstico de folhas infectadas por ferrugens (AMORIM et al., 1987).

As ferramentas de fenotipagem baseadas em imagens são capazes de gerar imagens de milhares de plantas ou parcelas em poucas horas, e fazê-lo com um alto nível de precisão (FAHLGREN; GEHAN; BAXTER, 2015). A eficiência na seleção de novas variedades depende da fenotipagem acurada com base em dados coletados em campo, relativos ao potencial genético influenciado pelo ambiente de produção alvo, expresso em termos de produtividade da cultura, produção de biomassa e resistência a estresses abióticos e bióticos (REYNOLDS et al., 2020).

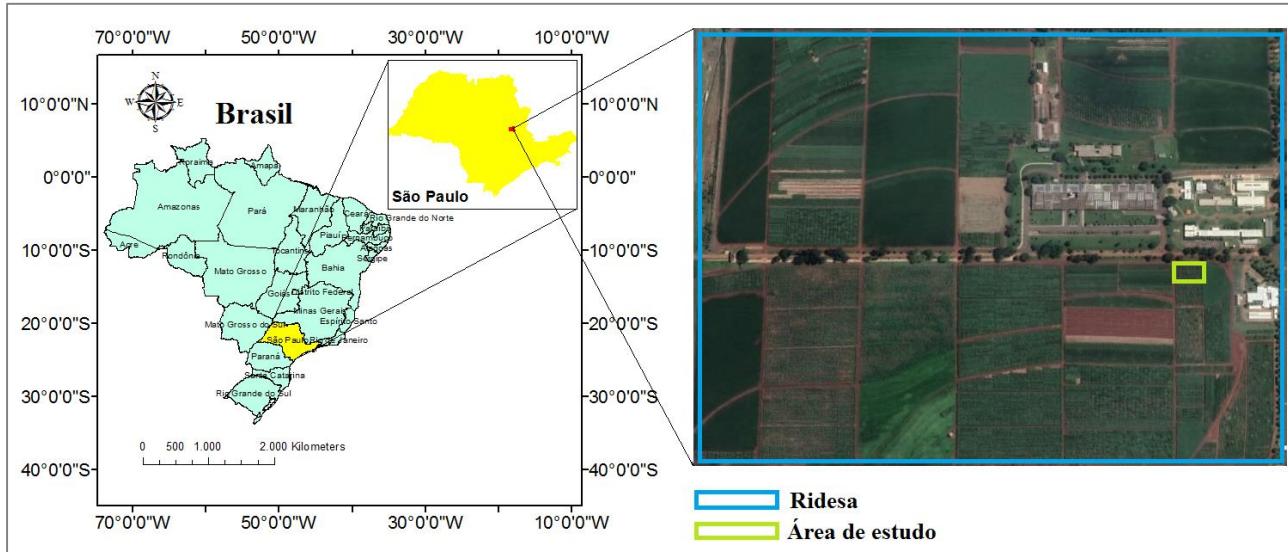
Recentemente, avanços foram feitos na fenotipagem de alto rendimento para acelerar a seleção de variedades em campo usando sistemas de sensoriamento remoto (FAHLGREN; GEHAN; BAXTER, 2015; HASSAN et al., 2019; LIEBISCH et al., 2015; REYNOLDS et al., 2020; YANG et al., 2020a, 2020b; ZHOU et al., 2020). A tecnologia de sensoriamento remoto por satélite oferece medições precisas, oportunas e econômicas em grande escala para a cana-de-açúcar (APAN et al., 2004; CANATA et al., 2016; DUVEILLER; LÓPEZ-LOZANO; BARUTH, 2013; PICOLI et al., 2015; VERMA et al., 2019). No entanto, ela não corresponderá à resolução espacial (submétrica) e temporal (diária / semanal) que pode ser alcançada com a fenotipagem baseada em dados de sensor acoplado em Vôrtice Aéreo Não Tripulado (VANT). Essa maior resolução espacial é necessária para distinguir pequenas alterações espectrais nos dados de imagens das plantas, como, por exemplo, devido a infecção por doença, estresse por seca ou deficiências minerais. A resolução espacial das imagens de sensores baseados em VANT para fenotipagem é em nível de parcela experimental e fornece a possibilidade de registros das parcelas individualmente ou múltiplas e é, portanto, aplicável ao melhoramento genético de plantas (YANG et al., 2020b). Além disso, os VANTS são relativamente pequenos e baratos para operar no sensoriamento remoto de plantações experimentais (YUE et al., 2018).

Apesar do progresso feito até agora nos sistemas de detecção e monitoramento de doenças com sensores multi e hiperespectrais embarcados em VANT (ABDULRIDHA et al., 2020; ABDULRIDHA; BATUMAN; AMPATZIDIS, 2019; CHIVASA; MUTANGA; BIRADAR, 2020;

HUANG et al., 2019; SHAKOOR; LEE; MOCKLER, 2017; YE et al., 2020), existem poucos estudos sobre o monitoramento e fenotipagem de resistência à doenças em variedades de cana-de-açúcar (MORIYA et al., 2017; SOCA-MUÑOZ et al., 2020). Mais especificamente ao monitoramento de ferrugens, Soca-Muñoz et al. (2020) tomaram imagens multiespectrais com sensor embarcado em UAV a 80 m de altura para análise de parcelas experimentais de cana-de-açúcar e observaram diferenças nos valores de refletância no NDVI que possibilitaram diferenciar plantas saudáveis de plantas infectadas, mas não conseguiram diferenciar a infecção por cada tipo de ferrugem. Neste mesmo estudo eles sugerem adquirir imagens com uma resolução espacial sub-centimétrica para possibilitar a observação direta das lesões. Então seria interessante o teste com imagens de resolução mais alta ou menor Ground Sample Distance (GSD), trabalhando também com as bandas multiespectrais separadamente e também com outros índices de vegetação. Além disso, Soca-Muñoz et al. (2020) analisaram valores médios e desvio padrão da assinatura espectral de refletância de cinco níveis de infecção pelas ferrugens alaranjada e marrom em folhas de cana-de-açúcar e observaram maiores diferenças entre folhas saudáveis e doentes nas bandas do vermelho (Red) e infravermelho próximo (NIR), demonstrando a possibilidade de não se utilizar a banda do infravermelho de ondas curtas (SWIR) para verificar níveis de severidade de infecção pelas doenças. Os sensores SWIR tem maior custo e normalmente são comercializados separadamente, portanto seria interessante trabalhar com sensores mais acessíveis ou que abrangem mais bandas espetrais. Assim, este trabalho teve como objetivo avaliar a utilidade de dados multiespectrais derivados de sensor embarcado em VANT para a fenotipagem da cana-de-açúcar em relação a resistência à infecção pelas ferrugens alaranjada e marrom. Nossa hipótese é de que os dados de imagem multiespectral derivados de sensor embarcado em VANT, tanto a refletância registrada isoladamente em cada uma das bandas, quanto diversos índices de vegetação testados, são sensíveis aos sintomas das doenças e são capazes de discriminar as variedades em relação a resistência à infecção pelos dois tipos de ferrugem.

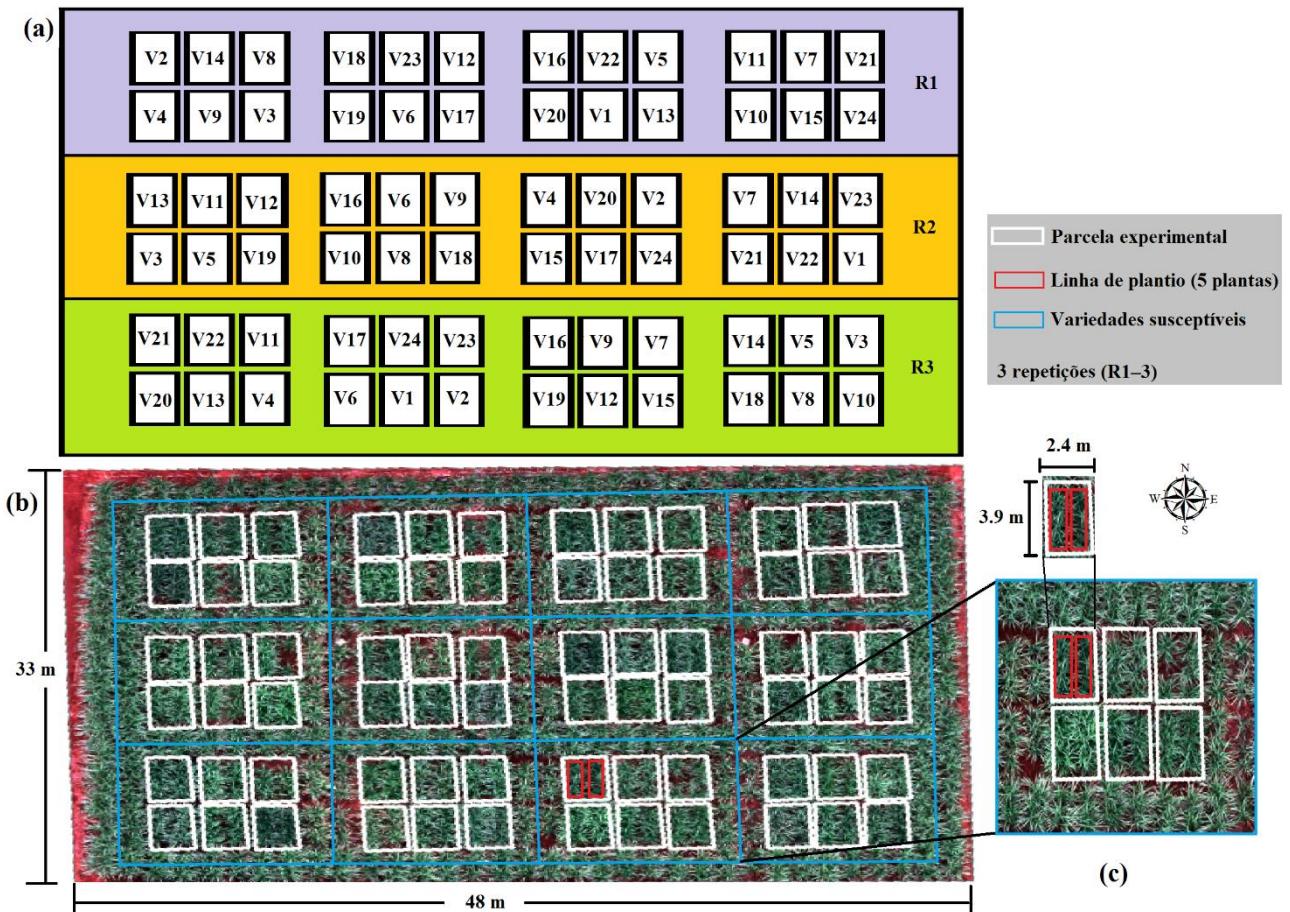
### **3.2. MATERIAL E MÉTODOS**

O estudo foi realizado em campo experimental para desenvolvimento de variedades de cana na cidade de Araras, SP, Brazil (Longitude 47°22'50.02"W, Latitude 22°18'58.33"S), com altitude de 706 m acima do nível do mar (Figura 2). O clima é subtropical com uma faixa de temperatura média de 29 a 34°C entre outubro e abril, e precipitação média anual de 1575 mm com acumulação média de 226 mm entre dezembro e janeiro.



**Figura 2.** Localização da área de estudo.

O experimento foi plantado em agosto de 2019. A época de avaliação das plantas se iniciou quando as mesmas estavam com cinco meses de idade e mais susceptíveis à infecção pelas ferrugens devido às condições climáticas (alta umidade e temperatura do mês de janeiro). A infecção pelas ferrugens alaranjada e marrom se deu de forma natural por meio da doação de esporos de variedades suscetíveis plantadas em torno das variedades avaliadas. Vinte e quatro variedades de cana-de-açúcar foram cultivadas em parcelas ao acaso, com três repetições, totalizando 72 parcelas experimentais. Cada parcela foi composta por duas linhas de cana (linhas vermelhas na Figura 3c) e área de 9,36 m<sup>2</sup> (3,9 x 2,4 m). A área experimental total possui 1584 m<sup>2</sup> (33 x 48 m) (Figura 3). O manejo da cultura foi feito segundo rotina de condução dos campos de melhoramento.



**Figura 3.** Layout do campo experimental com 24 variedades (V1-24) × 3 blocos (R1–3) em cores diferentes (a); área experimental em imagem aérea com parcelas experimentais (linhas brancas) e variedades susceptíveis doadoras de esporos (linhas azuis) adquirida usando o veículo aéreo não tripulado (VANT) e câmera multiespectral (b); e dimensões individuais das parcelas, com destaque para as duas linhas de cana que compreendem uma parcela (c).

As notas de infecção pelas ferrugens marrom e alaranjada foram atribuídas por especialistas de campo a cada duas semanas, a partir do 150 DAP. As notas foram atribuídas de acordo com a escala de diagnóstico estabelecida pela Coordenadoria de Fitopatologia do Centro de Tecnologia Copersucar (AMORIM et al., 1987; CDA, 2010), onde 1 se refere a ausência de sintomas ou sintomas muito leves e 9 à sintomas muito graves (APÊNDICE A). É atribuída uma nota para a folha +3 de cada uma das cinco plantas de cada linha de plantio, sendo que após a atribuição das notas é calculada a nota média de severidade da doença para cada parcela. Ao fim do período de avaliações, oito avaliações no total, entre 21/01/2020 à 28/04/2020, uma classe de resistência final foi atribuída às variedades de acordo com a área abaixo da curva de infecção (AUDPC – notas de infecção) obtida ao longo do período de avaliações para ambas as ferrugens, sendo as classes: resistente, moderadamente resistente e suscetível (SANJEL et al., 2019). Essas classes de resistência são o alvo de interesse do programa de melhoramento genético e serão as classes a serem preditas pelos modelos de aprendizagem de máquina testados neste estudo.

### 3.2.1. Aquisição e processamento das imagens

As imagens foram adquiridas usando uma câmera multiespectral de alta resolução, Micasense

Rededge, com 16 megapixels, que trabalha com as bandas Azul (465-485nm), Verde (550-570nm), Vermelho (663-673nm), Red Edge (712-722nm), Infravermelho Próximo (820-860nm), em cinco canais distintos, com 12 bits de resolução radiométrica (MicaSense, Inc., Seattle, WA, EUA) montada no VANT quadrirotor modelo Q-45 da montadora brasileira G-drones. A câmera possui um sensor de luz solar com GNSS e unidade de medição inercial (IMU).

As imagens foram capturadas usando um padrão de mapeamento em grade única, com plano de voo projetado para mapear uma área que exceda a área de interesse em 20% para minimizar os efeitos da distorção radial ao redor da periferia da área de interesse. O plano de voo teve os seguintes parâmetros: 26 m de altitude, com GSD de 1,77 cm e 80% de sobreposição frontal e lateral (APÊNDICE A). As coletas das imagens foram feitas em quatro datas a partir do quinto mês, ou aos 150 dias após o plantio (DAP) das variedades, sendo as coletas aos 150, 165, 180 e 195 DAP. As imagens foram processadas usando o software Metashape (Agisoft LLC, Russia) com o algoritmo Structure from Motion (SfM). O SfM encontra pontos correspondentes entre as imagens, características e coordenadas, rastreando de uma imagem para a próxima usando a transformação de recurso invariável de escala (SIFT). Mosaicos de alta resolução espacial (1,77 cm × 1,77 cm) foram produzidos com as cinco bandas multiespectrais. Os valores de refletância espectral foram extraídos e os valores dos índices de vegetação (IV) foram calculados para cada linha de plantio.

### **3.2.2. Extração de dados de refletância**

As imagens capturadas na área de estudo foram mosaicas no software Metashape, que gera dois tipos de ortomosaicos multiespectrais: o *No Alpha* e os mosaicos transparentes. Eles foram gerados para cada banda da imagem (Azul, Verde, Vermelho, Rededge e NIR). As imagens *No Alpha* foram usadas como entrada no QGIS para criação de arquivos shapefile que foram desenhados individualmente para cada linha de plantio de cada um dos blocos experimentais para análise precisa dos dados espectrais das folhas de cada linha de plantio. No software R o arquivo shapefile foi então usado para recortar as imagens do mosaico na extensão da área de cada linha de plantio dos blocos experimentais.

Uma vez que os compartimentos do shapefile foram extraídos para cada parcela, a área de solo foi subtraída por meio de máscara feita com a determinação de limiares de refletância em diversos índices de vegetação testados. A máscara para remoção de solo permite uma análise mais precisa dos dados espectrais da vegetação (THOMPSON; PUNTEL, 2020). O índice de vegetação escolhido para geração das máscaras de separação solo/vegetação com valores limiares de refletância foi o Índice de Folha Verde (GLI), com limiar de separação solo/vegetação de 30% de refletância (Figura 4). A mediana de refletância da vegetação para cada linha de plantio foi então extraída para os índices de vegetação estudados e para cada banda espectral disponível no sensor.



**Figura 4.** Exemplos de máscaras para separação solo/vegetação das linhas de plantio feita por meio da definição do limiar de 30% de refletância no Índice de Folha Verde (GLI).

Neste estudo também foram calculadas as áreas abaixo da curva (AUDPCs) ou integrais definidas dos valores de refletância ao longo das avaliações, que chamaremos de AUDPCs - refletância. As AUDPCs são utilizadas na matemática para solução de problemas de acumulação (ou variação líquida) nos quais temos a taxa de variação de uma grandeza e temos que calcular o valor da grandeza acumulada ao longo do tempo (HAYNES; WEINGARTNER, 2004; SIMKO; PIEPHO, 2012). Neste caso, determinamos a variação da refletância nos índices de vegetação e bandas multiespectrais ao longo do tempo das avaliações, onde o eixo y se refere ao valor de refletância e o eixo x ao tempo (t) das avaliações, neste caso, 45 dias ( $t = 195 - 150 = 45$  dias). Esse valor de refletância acumulado será utilizado como variável preditora para a classificação das variedades pelos modelos de aprendizagem de máquina em relação as classes de resistência final atribuídas às variedades. Para qualquer grandeza cuja taxa é dada pela função  $r$ , a integral definida  $\int_a^b r(t)dt$  descreve o quanto a grandeza mudou entre  $t = a$  e  $t = b$ . Então, assim como temos a variação da temperatura de um líquido devido ao aquecimento, temos a variação de refletância da vegetação devido a diminuição do seu vigor e lesões causadas pelas doenças. Até onde sabemos, essa variável preditora não foi utilizada em nenhum outro estudo para esse objetivo.

### 3.2.3. Índices de Vegetação

O diagnóstico dos sintomas das ferrugens alaranjada e marrom pode resultar em mudanças nos pigmentos e estrutura interna das folhas e ao teor de umidade. Assim, índices de vegetação (IVs) focados em um ou mais desses atributos foram selecionados da literatura (Tabela 1) para serem utilizados em conjunto com as bandas isoladamente na determinação da suscetibilidade das variedades ao ataque do patógeno.

**Tabela 1.** Índices de vegetação testados no estudo.

IV	Nome	Equação	Relacionado	Referência
NDVI	Normalized Difference Vegetation Index	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Clorofila, LAI, biomassa, produtividade	Rouse et al. (1974)
GNDVI	Green Normalized Difference Vegetation Index	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Clorofila, LAI, nitrogênio, proteína, água	Gitelson et al. (1996)
NDRE	Normalized Difference Rededge Index	$(\text{NIR} - \text{Rededge}) / (\text{NIR} + \text{Rededge})$	Clorofila	Gitelson and Merzlyak (1994)
RVI	Ratio Vegetation Index	NIR/Red	Biomassa, água, nitrogênio	Pearson and Miller (1972)
CIgreen	Chlorophyll index - Green	$(\text{NIR}/\text{G}) - 1$	Clorofila	Gitelson et al. (2003)
CIrededge	Chlorophyll index - Rededge	$(\text{NIR}/\text{Rededge}) - 1$	Clorofila	Gitelson et al. (2003)
DVI	Difference Vegetation Index	NIR - Rededge	Nitrogênio, clorofila	Jordan (1969)
EVI	Enhanced Vegetation Index	$2.5 * (\text{NIR} - \text{Red}) / (\text{NIR} + 6 * \text{Red} - 7.5 * \text{Blue} + 1)$	Clorofila, biomassa, nitrogênio	Huete et al. (2002)
CVI	Chlorophyll Vegetation Index	$(\text{NIR} * \text{Red}) / (\text{Green}^2)$	Clorofila	Vincini et al. (2008)
TVI	Triangular Vegetation Index	$0.5 * (120 * (\text{NIR} - \text{Green}) - 200 * (\text{Red} - \text{Green}))$	LAI verde, clorofila, dossel	Broge and Leblanc (2000)
PSRI	Plant Senescence Reflectance Index	$(\text{Red} - \text{Green}) / (\text{Rededge})$	Clorofila, nitrogênio, maturidade	Merzlyak et al. (1999)
BGI	Blue Green Pigment Index	Blue / Green	Clorofila, LAI	Zarco-Tejada et al. (2005)
VARI	Visible Atmospherically Resistant Index	$(\text{Green} - \text{Red}) / (\text{Green} + \text{Red} - \text{Blue})$	Dossel, biomassa, clorofila	Gitelson et al. (2002)
GLI	Green Leaf Index	$(2 * \text{Green} - \text{Red} - \text{Blue}) / (2 * \text{Green} + \text{Red} + \text{Blue})$	Clorofila	Louhaichi et al. (2001)

### 3.2.4. Predição da classe varietal de resistência às doenças

Primeiramente executamos análises descritivas e de correlação entre a verdade de campo (notas de infecção de cada parcela experimental, 1 a 9) e os dados espectrais para verificar a influência da infecção por cada uma das ferrugens (alaranjada e marrom) sobre os dados espectrais. Para determinação da sensibilidade dos dados espectrais à infecção pelas doenças individualmente e infecção geral devido a ambas, calculou-se os coeficientes de correlação de Pearson entre as notas atribuídas a cada linha de plantio (2 por parcela) e a mediana de refletância da vegetação nas bandas individuais e índices de vegetação testados, considerando nível de significância  $< 0.05$ . Obtivemos a correlação entre a média das maiores notas de infecção dentre as duas ferrugens das quatro avaliações e os dados multiespectrais das quatro avaliações, incluindo o valor da área abaixo da curva de refletância das mesmas (AUDPC - refletância) para as bandas e IVs testados; entre a média das notas

de ferrugem alaranjada e os dados espectrais das quatro avaliações mais o AUDPC – refletância; e entre a média de notas para ferrugem marrom e os dados das quatro avaliações mais o AUDPC - refletância.

Além dessa análise, a classe de resistência final atribuída pelo programa de melhoramento foi usada como alvo das previsões pelos modelos de aprendizagem de máquina (ML), tanto para cada tipo de ferrugem individualmente, quanto a classe correspondente a doença para qual a variedade é mais suscetível. Neste caso, classificando a variedade quanto ao nível de infecção geral causados por ambas as doenças.

Os modelos de ML escolhidos para teste de classificação da resistência das variedades de cana-de-açúcar à infecção pelas ferrugens alaranjada e marrom foram Random Forest, KNN e SVM (radial). Algoritmos supervisionados são amplamente usados porque são mais robustos do que abordagens baseadas em modelos não supervisionados (NIEMEYER; ROTTENSTEINER; SOERGEL, 2014). Esses classificadores aprendem as características das classes alvo a partir de amostras de treinamento e aplicam posteriormente o conhecimento na classificação de amostras de conjunto de teste para validação (BELGIU; DRĂGU, 2016). A literatura mostra que algoritmos de classificação supervisionada, como árvores de decisão (DT), método de k-vizinhos mais próximos (kNN), redes neurais artificiais (ANN), máquinas de vetores de suporte (SVM) e floresta aleatória (RF) foram desenvolvidos e testados para monitoramento de safra e classificação de cobertura da terra usando dados de sensoriamento remoto (THANH NOI; KAPPAS, 2017; ZHENG et al., 2018). Entre esses métodos, os algoritmos SVM, RF e KNN são algoritmos de classificação muito populares no sensoriamento remoto da vegetação (RACZKO; ZAGAJEWSKI, 2017) e neste estudo, serão testados para construir os modelos de classificação com base em conjunto de dados multiespectrais para variáveis preditoras. Testamos então a possibilidade de prever a classe de resistência às ferrugens alaranjada e marrom (atribuída ao final de oito avaliações visuais em campo) por meio de dados multiespectrais coletados em quatro avaliações: 150, 165, 180 e 195 DAP das variedades avaliadas. Os modelos de classificação foram desenvolvidos usando o pacote “caret” dentro do software R versão 3.5.3.

As variáveis mais importantes para a classificação varietal foram determinadas e então utilizadas para o desenvolvimento dos modelos de classificação. A seleção das bandas e IVs a serem usados na classificação varietal pelos modelos de ML foi realizada por meio da medida de importância das variáveis com o algoritmo Recursive Feature Elimination (RFE) do pacote “Caret” para o software R. Esta função implementa a seleção retroativa das variáveis com base na classificação de importância das mesmas. As variáveis são classificadas e as menos importantes são eliminadas sequencialmente antes da modelagem. O objetivo é determinar um subconjunto de variáveis que podem ser usadas para o desenvolvimento de um modelo acurado de classificação.

### 3.2.5. Avaliação da acurácia

Neste estudo, a acurácia foi a estatística (Eq. 1) usada para avaliar os modelos de classificação.

$$\text{Acurácia} = \frac{\text{Número de previsões corretas}}{\text{Número total de previsões}} \quad (1)$$

Para obter o máximo possível de informações dos dados limitados, a validação cruzada k-fold foi usada para ajuste dos parâmetros na etapa de treinamento dos modelos. Neste estudo, a validação cruzada com quatro folds com duas repetições foi utilizada. O conjunto de dados foi dividido aleatoriamente em 70% para o conjunto de treinamento e 30% para o conjunto de teste.

Após o treinamento, as amostras de teste foram usadas para avaliação da acurácia. Matrizes de confusão balanceadas para problemas com três classes foram usadas para avaliar a acurácia das classificações. A acurácia geral denota a probabilidade de que uma amostra selecionada aleatoriamente seja classificada corretamente de acordo com sua classe rótulo. As classes finais de resistência às ferrugens atribuídas pelos cientistas às variedades de cana-de-açúcar avaliadas foram usadas como rótulo das amostras para avaliar a acurácia da classificação.

O coeficiente Kappa ( $K_c$ ), que também é uma medida de acurácia da classificação, foi medida complementar adotada (Eq. 2) (CONGALTON, 1991):

$$K_c = N \sum_{n=1}^r \frac{n_{irow} n_{icol}}{N^2} - \sum_{i=1}^r n_{irow} n_{icol} \quad (2)$$

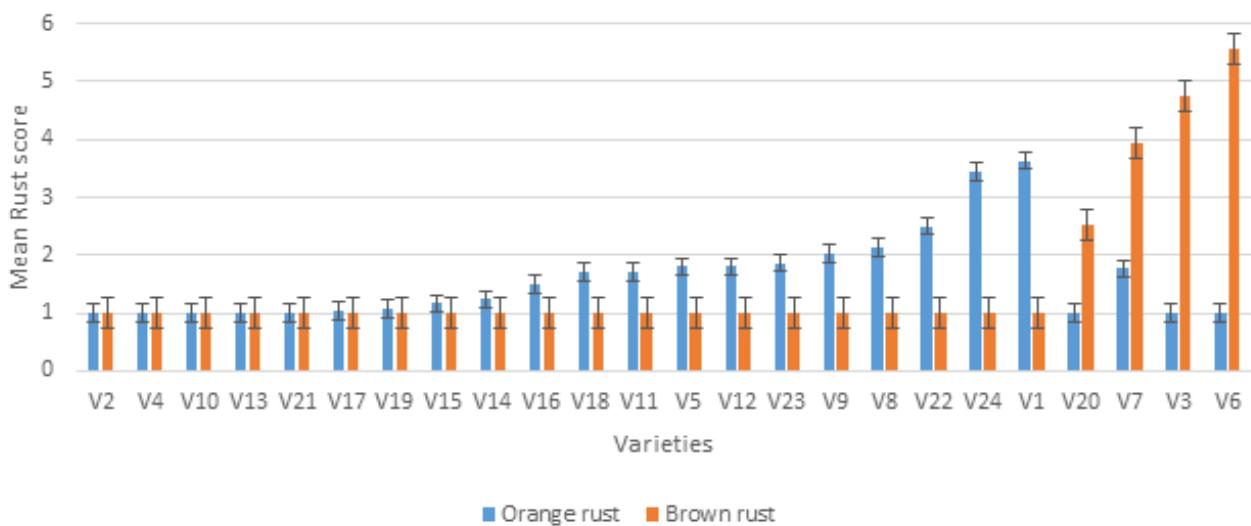
, onde  $n_{ii}$  é o elemento de posição i-ésima linha e i-ésima coluna,  $n_{icol}$  são as somas das colunas e  $n_{irow}$  são as somas das linhas. Um valor Kappa de 1 representa uma concordância perfeita, enquanto um valor de 0 representa nenhuma concordância.

## 3.3. RESULTADOS

### 3.3.1. Dados de resistência das variedades aos dois tipos de ferrugem

Níveis significativos de infecção pelas duas ferrugens se desenvolveram nas variedades mais susceptíveis durante o período das avaliações. As notas de infecção obtidas visualmente nas quatro avaliações acompanhadas (150, 165, 180 e 195 DAP) foram altamente correlacionadas ( $R = 0,87 - 0,98$ ) para as duas ferrugens. O nível de infecção entre as variedades diferiu significativamente de acordo com coeficiente de correlação de pearson, com  $p < 0,001$  para nível de significância  $< 0,05$ , com maior nota média de infecção de 5,6 para a variedade mais suscetível à ferrugem marrom e 3,6 para a mais suscetível à alaranjada na escala de 1-9 (Figura 5). As variedades mais resistentes tiveram nota média de 1,0. De acordo com a curva de infecção obtida ao longo das avaliações, dentre as 24 variedades de cana-de-açúcar avaliadas, uma variedade foi classificada como suscetível à ferrugem alaranjada (V24) e uma à ferrugem marrom (V6), cinco variedades moderadamente

resistentes à ferrugem laranja (V1, V22) e à ferrugem marrom (V20, V3 e V7) e o restante das variedades resistente às duas ferrugens, com média de notas ao longo das avaliações variando entre 1,0 (primeira avaliação) e 2,1 (última avaliação).

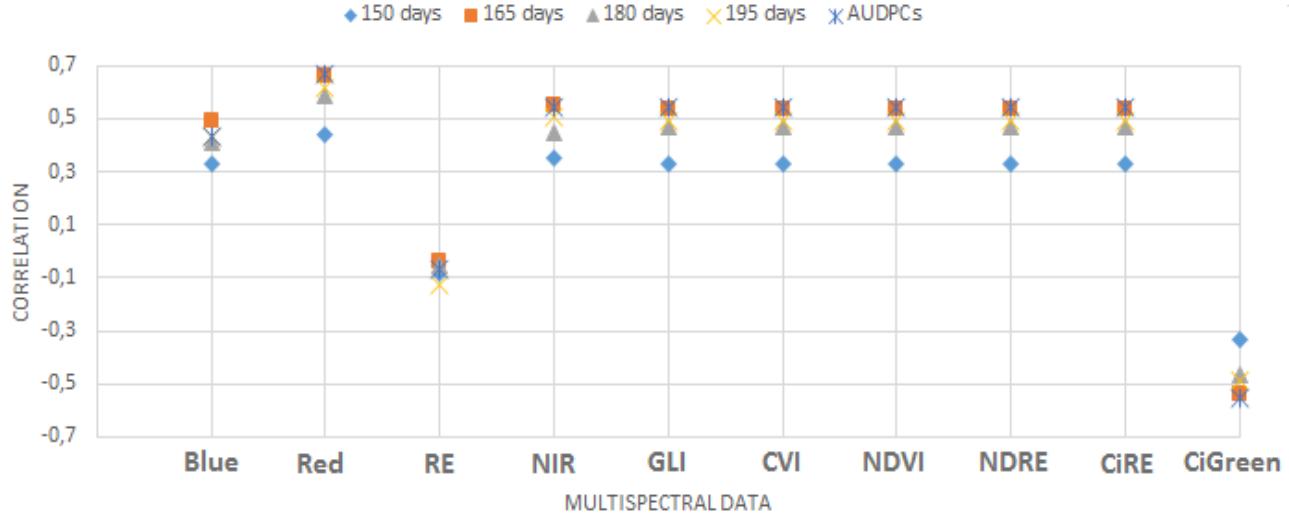


**Figura 5.** Média de notas de infecção pelas ferrugens alaranjada e marrom das três parcelas experimentais de cana-de-açúcar das 24 variedades avaliadas. As notas de infecção foram atribuídas com pontuação variando entre 1 e 9. V1 à V24 = variedades de 1 a 24. A barra de erro nos gráficos indica a amplitude de variação das notas entre as três parcelas experimentais de cada variedade.

### 3.3.2. Correlação dos índices e bandas espectrais com as notas de infecção

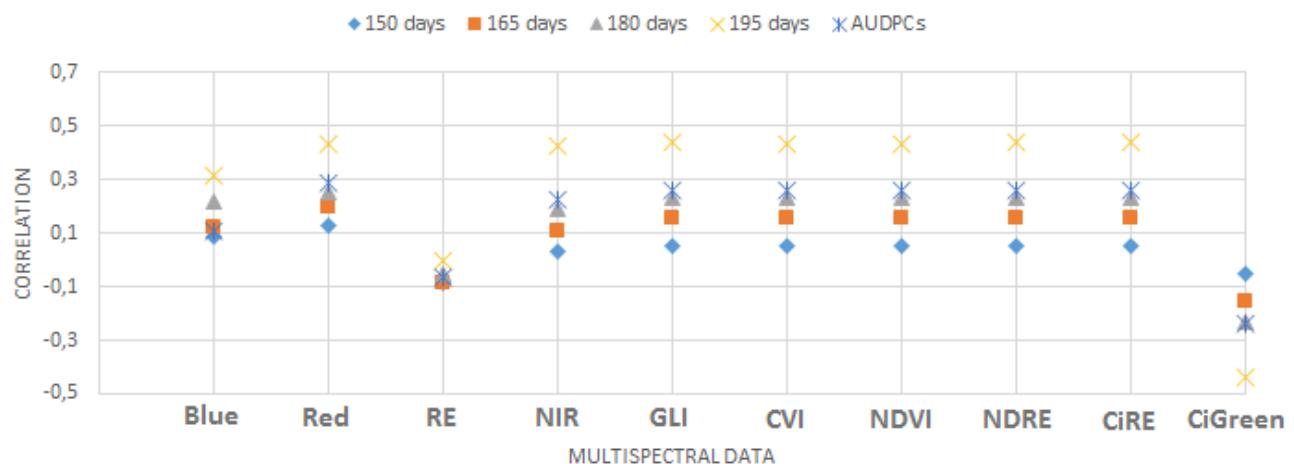
Para a análise de correlação entre as avaliações visuais de campo (notas de infecção de cada parcela experimental, 1 a 9) e os dados espectrais, utilizamos a média das notas ao longo das avaliações, uma vez que as avaliações ao longo do ciclo da cultura tiveram alta correlação entre si ( $R = 0.87 - 0.98$ ). As correlações apresentadas nos gráficos das figuras 6, 7 e 8 são referentes às bandas e índices de vegetação que apresentaram os maiores valores de correlação com as notas de infecção ou que apresentaram grande importância como variáveis preditivas para os modelos de ML discutida a diante.

No gráfico da figura 6 observa-se que as correlações encontradas entre a média das maiores notas de infecção dentre os dois tipos de ferrugem das quatro avaliações e os dados de RE não foram significativas ( $p > 0,05$ ), além disso, em relação aos dados multiespectrais da avaliação aos 150 dias, somente as correlações de Vermelho e NIR foram significativas.



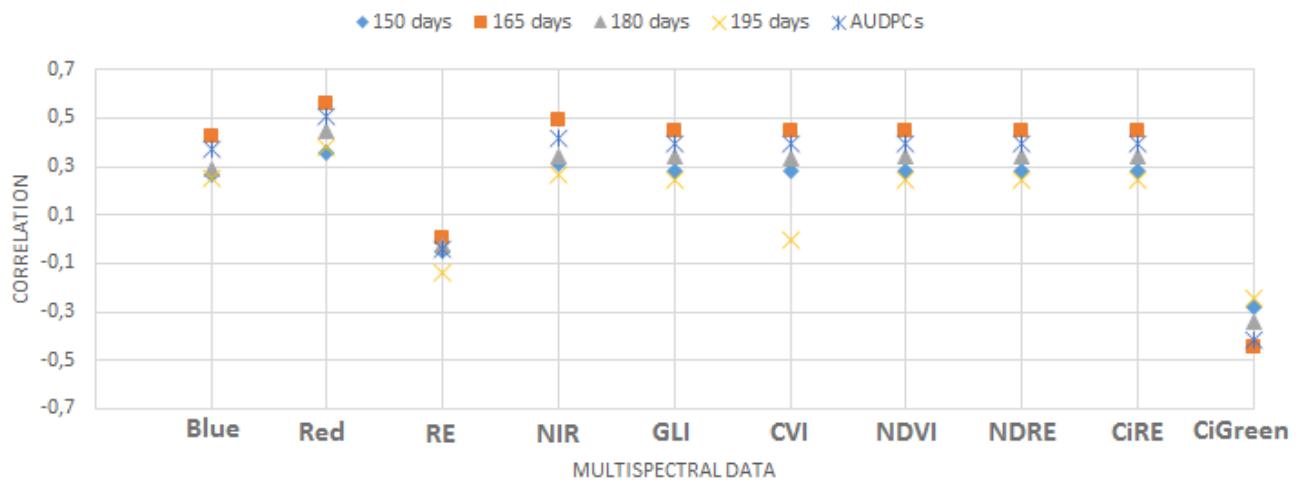
**Figura 6.** Correlação entre a média das maiores notas de infecção dentre os dois tipos de ferrugens das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.

As correlações entre a média das notas de infecção para a ferrugem alaranjada (Figura 7) das quatro avaliações e os dados multiespectrais da avaliação aos 150 dias não foram significativos ( $p > 0,05$ ) para nenhuma banda ou índice de vegetação; já para os dados da avaliação aos 165 dias, somente a correlação com os dados de Red foram significativas. Além disso as correlações com os dados de RE não foram significativas para nenhuma das avaliações.



**Figura 7.** Correlação entre a média das notas de infecção para a ferrugem alaranjada das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.

As correlações entre a média das notas de infecção para a ferrugem marrom (Figura 8) das quatro avaliações e os dados multiespectrais das quatro avaliações foram significativas exceto para os dados de RE, que não apresentaram correlação significativa para nenhuma das avaliações.

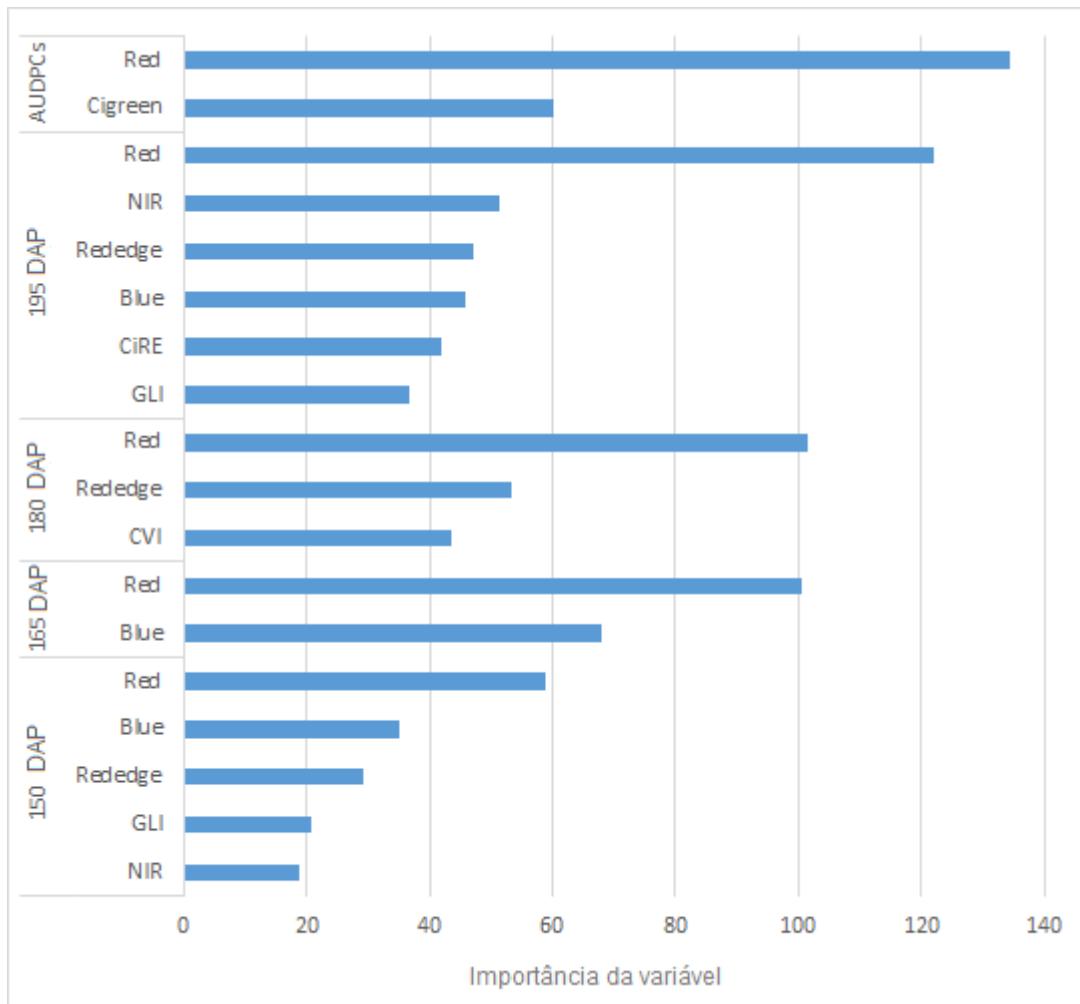


**Figura 8.** Correlação entre a média das notas de infecção para a ferrugem marrom das quatro avaliações e os dados multiespectrais derivados de sensor embarcado em VANT. RE = Rededge; GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; NDVI = Índice de Vegetação por Diferença Normalizada; NDRE = Índice de Rededge de Diferença Normalizada; CiRE = Índice de clorofila - Rededge; CiGreen = Índice de clorofila – Green.

Em termos absolutos, as maiores correlações significativas entre os dados obtidos por sensor embarcado em VANT e dados de verdade de campo, se deram entre os dados da banda vermelha aos 165 ( $R = 0,66$ ) e 195 ( $R = 0,62$ ) DAP e dados de AUDPC – refletância da banda vermelha ( $R = 0,67$ ) e a média das maiores notas dentre os dois tipos de ferrugens para as quatro avaliações.

### 3.3.3. Predição das classes de resistência às doenças

Inicialmente os modelos de ML foram desenvolvidos com todas as variáveis testadas (5 bandas multiespectrais e 14 índices de vegetação) para cada data de avaliação e AUDPCs – refletância das bandas e índices. No entanto, para melhorar a classificação, a otimização de variáveis foi implementada. Durante a otimização, o algoritmo Recursive Feature Elimination (RFE) descartou as variáveis menos importantes. Outros estudos confirmam que o descarte de variáveis menos importantes melhora os resultados de classificação de modelos de aprendizagem como os testados neste estudo (CHEMURA; MUTANGA; DUBE, 2017). Quando a importância da variável é muito baixa, isso significa que esta não é importante para as previsões ou que é altamente colinear com uma ou mais variáveis. As bandas e índices de maior importância foram então selecionadas como variáveis preditoras para o desenvolvimento e teste dos modelos de classificação (Figura 9).



**Figura 9.** Importância das variáveis para classificação varietal selecionadas com o uso do algoritmo Recursive Feature Elimination (RFE) dentre as diferentes bandas espectrais e índices de vegetação testados para cada avaliação e AUDPCs - refletância. GLI = Índice de Folha Verde; CVI = Índice de Clorofila Vegetação; CIrededge = Índice de clorofila – Rededge, CIGreen = Índice de clorofila – Green.

Os resultados de classificação para predição de resistência às ferrugens alaranjada e marrom separadamente e simultaneamente pelos modelos mostram que estes são capazes de classificar com alta acurácia a resistência aos dois tipos de ferrugem simultaneamente (infecção e sintomas devido às duas doenças), mas não classificar a resistência específica à cada uma delas (tabelas 2, 3 e 4). Valores altos de acurácia geral não devem ser considerados quando os de acurácia balanceada são nulos (NA), pois isso significa que o modelo, por exemplo, classificou todas as amostras como uma das classes e portanto não conseguiu diferenciar-as. De acordo com os valores de acurácia balanceada, os resultados mostram que, com os modelos SVM radial foi possível realizar a fenotipagem de variedades de cana-de-açúcar em relação a resistência geral às ferrugens alaranjada e marrom. Com grande capacidade de distinção entre as classes moderadamente resistentes e susceptíveis. Isso é importante pois, o número de amostras de variedades suscetíveis era reduzido em comparação com as demais classes. E essa é a principal classe considerada para o futuro da nova variedade nos programas de melhoramento.

**Tabela 2.** Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência às ferrugens alaranjada e marrom em conjunto, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.

			150 DAP	165 DAP	180 DAP	195 DAP	AUDPCs refletância	
		Acurácia geral (%)	69,1	83,3	64,3	81,0	83,3	
RF		R	58,6	91,7	70,5	82,1	92,2	
		M	65,8	92,3	60,4	75,8	75,4	
		S	64,1	82,1	72,5	72,5	64,1	
		Kappa	0,18	0,55	0,33	0,59	0,61	
		Acurácia geral (%)	73,8	71,4	71,4	78,6	78,6	
KNN		R	86,6	64,1	74,2	79,4	83,8	
		M	90,2	59,9	57,6	75,3	68,8	
		S	46,3	98,8	72,5	64,1	58,8	
		Kappa	0,12	0,31	0,27	0,52	0,47	
		Acurácia geral (%)	73,9	83,3	76,2	88,1	78,5	
SVM radial		R	70,5	90,5	78,7	90,3	77,2	
		M	74,4	93,4	71,4	88,6	71,7	
		S	59,9	97,6	46,3	82,1	97,6	
		Kappa	0,19	0,52	0,38	0,71	0,47	

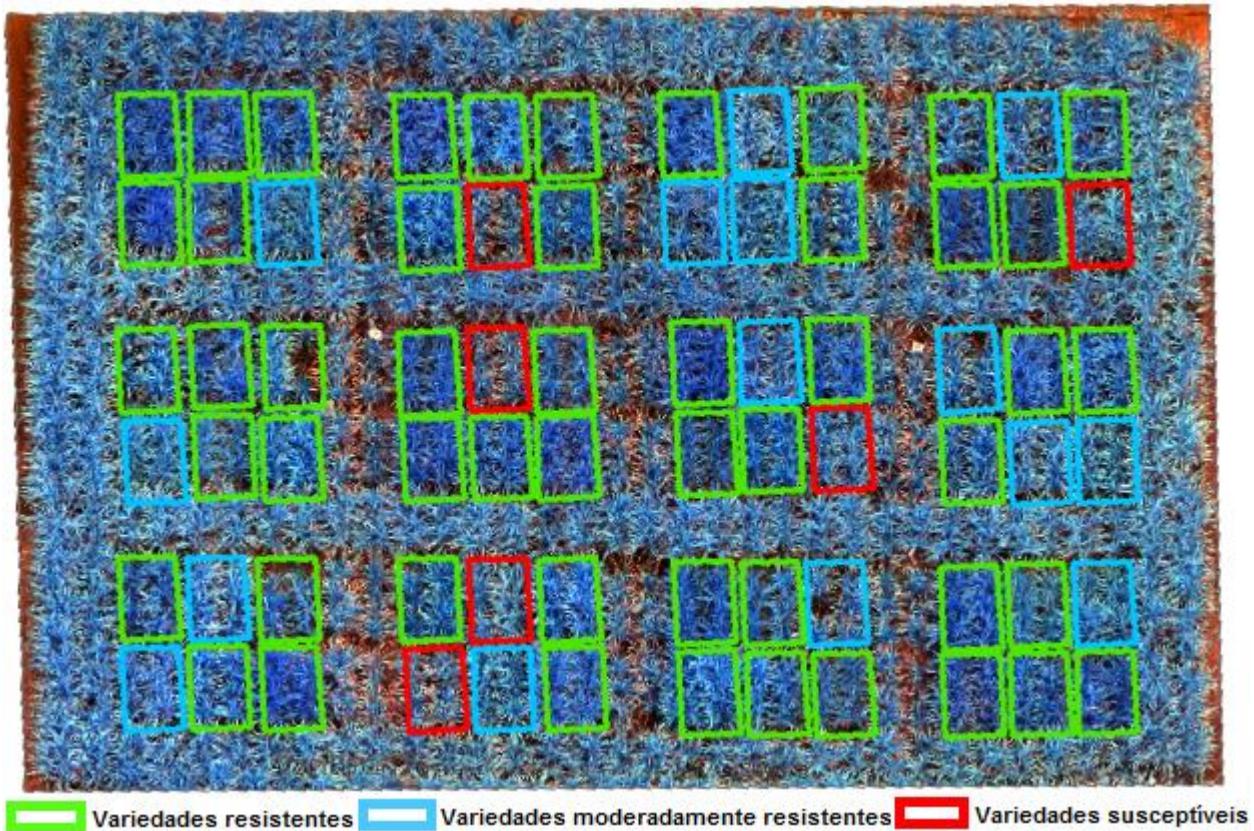
**Tabela 3.** Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência à ferrugem alaranjada, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.

		150 DAP	165 DAP	180 DAP	195 DAP	AUDPCs refletância
Acurácia geral (%)		93,0	88,0	90,0	93,0	90,0
RF	R	96,0	45,0	NA	97,0	71,0
	Acurácia balanceada (%)	M	98,0	46,0	NA	NA
	S	NA	NA	NA	0,75	NA
	Kappa	0,38	-0,04	0	0,48	0,29
Acurácia geral (%)		90,0	90,0	90,0	90,0	90,0
KNN	R	NA	NA	NA	96,0	NA
	Acurácia balanceada (%)	M	NA	NA	NA	46,0
	S	NA	NA	NA	NA	NA
	Kappa	0	0	0	0,17	0
Acurácia geral (%)		88,0	90,0	90,0	90,0	90,0
SVM radial	R	45,0	NA	NA	44,0	NA
	Acurácia balanceada (%)	M	46,0	NA	NA	NA
	S	NA	NA	NA	49,0	NA
	Kappa	-0,03	0	0	-0,04	0

**Tabela 4.** Resultados das classificações feitas com os modelos de máquina de vetores de suporte (SVM), vizinho mais próximo K (KNN) e floresta aleatória (RF) com o conjunto de dados multiespectrais, para discriminação das variedades entre as classes finais de resistência à ferrugem marrom, sendo resistentes (R), moderadamente resistentes (M) e susceptíveis (S) para as quatro datas de avaliação e AUDPCs - refletância, com validação cruzada 4-fold com 2 repetições.

		150 DAP	165 DAP	180 DAP	195 DAP	AUDPCs refletância
RF	Acurácia geral (%)	76,0	86,0	88,0	86,0	86,0
	R	42,0	87,0	94,0	71,0	69,0
	Acurácia balanceada (%)	M	43,0	61,0	NA	72,0
		S	49,0	49,0	1	NA
	Kappa		-0,1	0,39	0,27	0,42
	Acurácia geral (%)	85,0	83,0	83,0	83,0	83,0
KNN	R	NA	67,0	60,0	67,0	43,0
	Acurácia balanceada (%)	M	NA	62,0	61,0	69,0
		S	NA	1	NA	NA
	Kappa		0	0,38	0,15	0,37
	Acurácia geral (%)	83,0	90,0	86,0	81,0	88,0
	Acurácia geral (%)	R	60,0	83,0	NA	61,0
SVM radial	M	NA	80,0	NA	66,0	NA
	Acurácia balanceada (%)	S	67,0	100,0	NA	49,0
		Kappa	0,17	0,56	0	0,24
	Acurácia geral (%)					0,27

Apresentamos uma imagem com composição das bandas do vermelho, NIR e Rededge dos dados coletados durante a avaliação aos 195 DAP (figura 10), com as classes de resistência final atribuída pelo programa de melhoramento relativas ao tipo de ferrugem ao qual as variedades se mostraram mais suscetíveis. Essas classes foram adotadas como rótulos das amostras para aprendizagem dos modelos de ML para predizer a classe de infecção geral causada por ambas as doenças simultaneamente.



**Figura 10.** Amostras rotuladas com a classe final de resistência geral às ferrugens alaranjada e marrom em imagem com composição das bandas do vermelho, NIR e Rededge aos 195 DAP.

### 3.4. DISCUSSÃO

Para as mesmas bandas espectrais e índices de vegetação, as correlações com as notas de infecção devidas a cada tipo de ferrugens individualmente foram mais fracas do que as correlações com as maiores notas de infecção dentre as duas doenças. Este resultado indica que os dados espectrais são sensíveis a infecção causada pelas duas doenças simultaneamente e não a uma delas especificamente, talvez devido a queda de vigor geral e maior área foliar infectada quando ambas são consideradas. Essa conclusão pode ser confirmada por meio dos resultados de classificação dos modelos de ML testados. Esse resultado corrobora com (SOCA-MUÑOZ et al., 2020) que ao tomar imagens multiespectrais com sensor embarcado em VANT a 80 m de altura para análise de parcelas experimentais de cana-de-açúcar observou diferença de refletância no NDVI que possibilitou diferenciar plantas saudáveis de plantas infectadas, mas não conseguiu diferenciar a infecção por cada tipo de ferrugem com o IV testado.

A banda Vermelha foi classificada como a mais importante para o processo de classificação pelos modelos de ML testados. Isso é explicado pela alta correlação dos dados da mesma com as notas de infecção atribuídas em campo exposta nos gráficos das figuras 5, 6 e 7. Esse resultado corrobora com os resultados alcançados em APAN et al. (2004) que verificou que plantas de cana-de-açúcar infectadas por ferrugem alaranjada apresentaram uma maior refletância nas bandas do vermelho e infravermelho de ondas curtas do que plantas saudáveis ao analisar dados do sensor hiperespectral do satélite EO-1 Hyperion (APAN et al., 2004). KARLOVSKA et al. (2016) também verificaram que as plantas infectadas tanto pela ferrugem alaranjada quanto pela marrom tiveram a

absorção da luz vermelha reduzida e, portanto, maior reflecção, sendo que a luz vermelha é mais absorvida por plantas saudáveis, uma vez que é utilizada pela clorofila para a atividade fotossintética (KARLOVSKA et al., 2016). Como visto, a ferrugem marrom prejudica a taxa fotossintética das plantas, levando a uma maior reflexão na banda vermelha devido a infecção, já a ferrugem alaranjada leva a um maior estresse hídrico e perda geral de vigor, o que pode ser melhor refletido em bandas e índices mais relacionados ao conteúdo de água das plantas. Podemos perceber isso nos resultados obtidos, uma vez que os dados de refletância da banda vermelha se relacionam mais com as notas de infecção da ferrugem marrom do que com as notas de ferrugem alaranjada. A perda de umidade devido as lesões ou folhas rompidas desempenha um fator importante na detecção de doenças (CROFT et al. 2000). Os resultados apresentados em Apan et al. (2004) mostram que a discriminação entre plantas saudáveis, moderadamente e altamente infectadas pela ferrugem alaranjada pode ser significativamente aumentada pela incorporação das bandas sensíveis à umidade na região do infravermelho de ondas curtas (SWIR), portanto seria interessante que estudos futuros testassem essa região do espectro para fenotipagem de resistência as ferrugens.

Dos IVs testados, apenas o GLI = Índice de Folha Verde, o CVI = Índice de Clorofila Vegetação, CIGreen = Índice de clorofila – Green e o CIrededge = Índice de clorofila - Rededge foram selecionados como variáveis importantes para classificação das variedades pelos modelos. Também é observada uma maior correlação entre os IVs testados e a infecção pela ferrugem marrom. Esse resultado corrobora com outros encontrados na literatura uma vez que esses índices são altamente relacionados à clorofila e portanto à atividade fotossintética das plantas. Além disso, são calculados com valores das bandas azul, verde, vermelho, NIR e Rededge. Bandas que, com exceção da verde, também foram selecionadas individualmente pelos modelos como mais importantes. Em análise de imagens multiespectrais de folhas de cana-de-açúcar infectadas tanto com ferrugem alaranjada quanto com ferrugem marrom, Soca-Muñoz et al. (2020) também verificaram que para regiões saudáveis das folhas observou-se uma baixa refletância na banda vermelha, com alta refletância nas bandas RE e NIR; já para as regiões infectadas com os dois tipos de ferrugem houve uma diminuição da refletância espectral nas bandas verde, RE e NIR, com aumento da refletância na banda vermelha para as folhas contaminadas com ferrugem marrom.

Os resultamos mostraram que os valores de refletância adquiridos na quarta avaliação (195 DAP) foram mais eficientes para a predição das classes, alcançando maior acurácia geral ( $> 88.1\%$ ). Provavelmente isso se deu uma vez que as plantas infectadas apresentavam, nesta data, além das pústulas de ferrugens, sintomas de infecção registráveis pelos dados espectrais como déficit hídrico devido a infecção e perda geral de vigor. Isso indica a possibilidade de se realizar a fenotipagem em relação à resistência as doenças realizando-se apenas uma avaliação com coleta de dados de refletância. Apesar disso, neste estudo, também testamos a possibilidade de predizer a classe de resistência às ferrugens por meio da AUDPC dos valores de refletância para cada banda e índice de vegetação testados. E com esses dados, foi possível predizer quais variedades eram susceptíveis a

pelo menos uma das doenças com 97,6% de acurácia balanceada para essa classe de resistência, resultado melhor que o alcançado com os valores de refletância coletados aos 195 DAP (82.1% - acurácia balanceada). Portanto, mais estudos são necessários para avaliar a utilização de AUDPCs de valores de refletância na predição de classes de resistência a doenças em avaliações de fenotipagem, buscando compreender como a curva é afetada ao longo do ciclo da cultura e quais as melhores épocas para comporem essa curva.

Os resultados mostram que com o emprego de dados multiespectrais derivados de sensor embarcado em VANT e os modelos de aprendizado de máquina testados, especialmente o SVM radial, pelos valores de acurácia alcançados, é possível realizar a fenotipagem de variedades de cana-de-açúcar em relação a resistência geral às ferrugens alaranjada e marrom. Os resultados de acurácia balanceada também mostram que o modelo tem grande capacidade de distinção entre as classes de susceptibilidade, distinguindo com alta acurácia as classes moderadamente resistentes e susceptíveis. Isso é importante pois, o número de amostras de variedades susceptíveis era reduzido em comparação com as demais classes. E as variedades que são assim classificadas são retiradas do processo de melhoramento genético.

### **3.5. CONCLUSÕES**

Dentre as bandas Azul, Verde, Vermelho, Rededge, NIR e 14 índices de vegetação testados, a banda do Vermelho é a mais sensível à infecção causada pelas ferrugens alaranjada e marrom no sensoriamento remoto de variedades de cana-de-açúcar.

O modelo de classificação SVM radial com os dados de refletância das bandas Vermelha, Azul, Rededge, NIR e os IVs Cirededge e GLI coletados aos 195 DAP como variáveis preditoras foi capaz de prever a classe de resistência geral aos dois tipos de ferrugem com acurácia superior a 88%. Assim, este modelo apresenta alta capacidade preditiva para a fenotipagem de novas variedades de cana-de-açúcar em relação a classes de resistência “resistente”, “moderadamente resistente” e “susceptível” às ferrugens.

Os dados multiespectrais de refletância coletados com sensor embarcado em VANT são sensíveis à infecção causada pelas duas ferrugens (alaranjada e marrom) simultaneamente, mas não especificamente à uma delas, se mostrando uma ferramenta promissora para a fenotipagem de novas variedades em relação a resistência às doenças.

## **REFERÊNCIAS**

- ABDULRIDHA, J. et al. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. **Precision Agriculture**, v. 21, n. 5, p. 955–978, 2020.

- ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. **Remote Sensing**, v. 11, n. 11, 2019.
- AGISOFT METASHAPE. MicaSense RedEdge MX processing workflow ( including Reflectance Calibration ) in Agisoft Metashape Professional. 2021.
- AHMED, A. A.; REDDY, G. H. A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning. **AgriEngineering**, v. 3, n. 3, p. 478–493, 2021.
- APAN, A. et al. Detecting sugarcane “orange rust” disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v. 25, n. 2, p. 489–498, 2004.
- ARAUS, J. L.; CAIRNS, J. E. Field high-throughput phenotyping: The new crop breeding frontier. **Trends in Plant Science**, v. 19, n. 1, p. 52–61, 2014.
- BALSALOBRE, T. W. A. et al. Mixed modeling of yield components and brown rust resistance in sugarcane families. **Agronomy Journal**, v. 108, n. 5, p. 1824–1837, 2016.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52–60, 2016.
- BARRETO, F. Z. et al. Validation of molecular markers associated with brown rust resistance in sugarcane. **Summa Phytopathologica**, v. 43, n. 1, p. 36–40, 2017.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BERNI, J. A. J. et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BOCK, C. H. et al. Visual Rating and the Use of Image Analysis for Assessing Different Symptoms of Citrus Canker on Grapefruit Leaves. **Plant Disease**, v. 92, n. 4, p. 530–541, 2008.
- BOCK, C. H. et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59–107, 2010.
- CAMARGO, A.; SMITH, J. S. Image pattern classification for the identification of disease causing agents in plants. v. 66, p. 121–125, 2009.
- CANATA, T. . et al. Measuring height of sugarcane plants through LiDAR technology. p. 1–13, 2016.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859–881, 2017.
- CHIVASA, W.; MUTANGA, O.; BIRADAR, C. UAV-based multispectral phenotyping for disease resistance to accelerate crop improvement under changing climate conditions. **Remote Sensing**, v. 12, n. 15, 2020.

- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- CURSI, D. E. et al. History and Current Status of Sugarcane Breeding, Germplasm Development and Molecular Genetics in Brazil. **Sugar Tech**, v. 24, n. 1, p. 112–133, 2022.
- D'HONT, A. Unraveling the genome structure of polyploids using FISH and GISH; examples of sugarcane and banana. **Cytogenetic and Genome Research**, v. 109, n. 1–3, p. 27–33, 2005.
- DAL-BIANCO, M. et al. Sugarcane improvement: How far can we go? **Current Opinion in Biotechnology**, v. 23, n. 2, p. 265–270, 2012.
- DEFINIENS. Definiens Developer XD 2.0.4 Reference Book. p. 106, 2012.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, n. 3, p. 1091–1116, 2013.
- FAHLGREN, N.; GEHAN, M. A.; BAXTER, I. Lights, camera, action: High-throughput plant phenotyping is ready for a close-up. **Current Opinion in Plant Biology**, v. 24, p. 93–99, 2015.
- FERRARI, J. T. et al. Ferrugem alaranjada da cana-de-açúcar no Brasil. **Biológico**, v. 75, p. 71–74, 2013.
- FORREST, W. et al. **Disease assessment terms and concepts**. *Plant Disease*, 1991. Disponível em: <<http://agris.fao.org/agris-search/search/display.do?f=2012/OV/OV201208481008481.xml;US19930116789>>
- FURBANK, R. T.; TESTER, M. Phenomics - technologies to relieve the phenotyping bottleneck. **Trends in Plant Science**, v. 16, n. 12, p. 635–644, 2011.
- GIRARD, J. H. H. T. J. C. Targeted mapping of a sugarcane rust resistance gene ( Bru1 ) using bulked segregant analysis and AFLP markers. v. 570, p. 759–764, 2004.
- GRANDINI, M.; BAGLI, E.; VISANI, G. Metrics for Multi-Class Classification: an Overview. p. 1–17, 2020.
- GRIVET, L.; ARRUDA, P. Sugarcane genomics: Depicting the complex genome of an important tropical crop. **Current Opinion in Plant Biology**, v. 5, n. 2, p. 122–127, 2002.
- HASSAN, M. A. et al. Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. **Plant Methods**, v. 15, n. 1, p. 1–12, 2019.
- HAYNES, K.; WEINGARTNER, D. P. The Use of Area Under the Disease Progress Curve to Assess Resistance to Late Blight in Potato Germplasm. **American Journal Of Potato Research**, n. December 2003, p. 137–141, 2004.
- HOY, J. W.; HOLLIER, C. A. Effect of Brown Rust on Yield of Sugarcane in Louisiana. **Plant Disease**, v. 93, n. 11, p. 1171–1174, 2009.
- HUANG, H. et al. Detection of helminthosporium leaf blotch disease based on UAV imagery. **Applied Sciences (Switzerland)**, v. 9, n. 3, p. 1–14, 2019.
- KARLOVSKA, A. et al. PLANT REFLECTED SPECTRA DEPENDING ON BIOLOGICAL

- CHARACTERISTICS AND GROWTH CONDITIONS. **International Scientific Conference Rural Development 2017**, 2016.
- KHAN, A.; YADAV, M. S. Image Processing Based Disease Detection for Sugarcane Leaves. **International Journal Of Advance Research, Ideas And Innovations In Technology**, v. 3, n. 4, p. 497–502, 2017.
- LEIVA-VALENZUELA, G. A.; AGUILERA, J. M. Automatic detection of orientation and diseases in blueberries using image analysis to improve their postharvest storage quality. **Food Control**, v. 33, n. 1, p. 166–173, 2013.
- LIEBISCH, F. et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. **Plant Methods**, v. 11, n. 1, 2015.
- LU, J.; TAN, L.; JIANG, H. Review on convolutional neural network (CNN) applied to plant leaf disease classification. **Agriculture (Switzerland)**, v. 11, n. 8, p. 1–18, 2021.
- MAHLEIN, A.-K. Present and Future Trends in Plant Disease Detection. **Plant Disease**, v. 100, n. 2, p. 1–11, 2016.
- MAIA JÚNIOR, S. DE O. et al. Caracterização Morfológica E Produtiva E Suas Correlações Em Cultivares De Cana-De-Açúcar. **Revista Ciência Agrícola**, v. 16, n. 1, p. 31–42, 2018.
- MANAVALAN, R. Efficient Detection of Sugarcane Diseases through Intelligent Approaches : A Review. **Asian Journal of Research and Review in Agriculture**, v. 3, n. 4, p. 27–37, 2021.
- MORIYA, E. A. S. et al. Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 2, p. 740–748, 2017.
- MUTKA, A. M.; BART, R. S. Image-based phenotyping of plant disease symptoms. **Frontiers in Plant Science**, v. 5, n. 1, p. 1–8, 2015.
- NEILSON, E. H. et al. Utilization of a high-throughput shoot imaging system to examine the dynamic phenotypic responses of a cereal crop plant to nitrogen and water deficiency over time. **Journal of Experimental Botany**, v. 66, n. 7, p. 1817–1832, 2015.
- NEWTON, A. C.; HACKETT, C. A. Subjective components of mildew assessment on spring barley. **European Journal of Plant Pathology**, v. 100, n. 6, p. 395–412, 1994.
- NIEMEYER, J.; ROTTENSTEINER, F.; SOERGEL, U. Contextual classification of lidar data and building object detection in urban areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 152–165, 2014.
- PATIL, S. B.; BODHE, S. K. Leaf Disease Severity Measurement Using Image Processing. **International Journal of Engineering and Technology**, v. 3, n. 5, p. 297–301, 2011.
- PICOLI, M. C. A. et al. The use of ALOS/PALSAR data for estimating sugarcane productivity. **Engenharia Agrícola**, v. 34, n. 6, p. 1245–1255, 2015.
- QIN, F. et al. Identification of alfalfa leaf diseases using image recognition technology. **PLoS ONE**, v. 11, n. 12, p. 1–26, 2016.

- RACZKO, E.; ZAGAJEWSKI, B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. **European Journal of Remote Sensing**, v. 50, n. 1, p. 144–154, 2017.
- RAUT, S.; INGOLE, K. Review On Leaf Disease Detection Using Image Processing Techniques. **International Research Journal of Engineering and Technology (IRJET)**, v. 4, n. 4, p. 22–24, 2017.
- REYNOLDS, M. et al. Breeder friendly phenotyping. **Plant Science**, v. 295, n. December 2019, p. 110396, 2020.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. December 2018, p. 2–10, 2019a.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. January, p. 2–10, 2019b.
- SAITO, É. A.; IMAI, N. N.; TOMMASELLI, A. M. G. Análise Espectral De Amostras De Cana-De-Açúcar. **Anais do III Simpósio Brasileiro de Geomática**, n. 1, p. 169–174, 2012.
- SANJEL, S. et al. Comparison of progress of brown rust and orange rust and conditions conducive for severe epidemic development during the sugarcane crop season in Florida. **Plant Disease**, v. 103, n. 5, p. 825–831, 2019.
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1–13, 2010.
- SANTOS, F.; BORÉM, A. Cana-de-açúcar: do Plantio à Colheita. n. June, p. 89–115, 2013.
- SCHAAD, N. W.; FREDERICK, R. D. Real-time PCR and its application for rapid plant disease diagnostics. **Canadian Journal of Plant Pathology**, v. 24, n. 3, p. 250–258, 2002.
- SHAKOOR, N.; LEE, S.; MOCKLER, T. C. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field. **Current Opinion in Plant Biology**, v. 38, p. 184–192, 2017.
- SHI, Y.; WANG, X.; ZHANG, S. Plant disease leaf image segmentation using K-Means clustering based on internet of things. **International Journal of Research in Agricultural Sciences**, v. 3, n. 2, p. 2348–3997, 2016.
- SIMKO, I.; PIEPHO, H. P. The area under the disease progress stairs: Calculation, advantage, and application. **Phytopathology**, v. 102, n. 4, p. 381–389, 2012.
- SOCA-MUÑOZ, J. L. et al. Spectral signature of brown rust and orange rust in sugarcane. **Revista Facultad de Ingeniería**, n. 96, p. 9–20, 2020.
- SONG, Y. et al. **IKNN: Informative K-nearest neighbor pattern classification**. [s.l.: s.n.]. v. 4702 LNAI
- SRIVASTAVA, S. et al. A Novel Deep Learning Framework Approach for Sugarcane Disease Detection. **SN Computer Science**, v. 1, n. 2, p. 1–7, 2020.
- STEDDOM, K. et al. Comparison of Visual and Multispectral Radiometric Disease Evaluations of

- Cercospora Leaf Spot of Sugar Beet. **Plant Disease**, v. 89, n. 2, p. 153–158, 2005.
- THAILAMBAL, G.; YOGESHWARI, M. Automatic segmentation of plant leaf disease using improved fast Fuzzy C-Means clustering and adaptive Otsu thresholding. **European Journal of Molecular and Clinical Medicine**, v. 7, n. 3, p. 5447–5462, 2020.
- THANH NOI, P.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, 2017.
- THOMPSON, L. J.; PUNTEL, L. A. Transforming unmanned aerial vehicle (UAV) and multispectral sensor into a practical decision support system for precision nitrogen management in corn. **Remote Sensing**, v. 12, n. 10, 2020.
- TRIMBLE INC. eCognition Developer 9.1. n. March, 2017.
- TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.
- VERMA, A. K. et al. Modelling of sugarcane yield using LISS-IV data based on ground LAI and yield observations. **Geocarto International**, v. 0, n. 0, p. 1–18, 2019.
- WONG T., H. et al. Feature extraction based on object oriented analysis. **Proceedings of ATC**, p. 1–10, 2003.
- YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, 2017.
- YANG, M. et al. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, n. June, p. 1–16, 2020a.
- YANG, W. et al. Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives. **Molecular Plant**, v. 13, n. 2, p. 187–214, 2020b.
- YANG, X. Parameterizing Support Vector Machines for Land Cover Classification. **Photogrammetric Engineering & Remote Sensing**, v. 77, n. 1, p. 27–37, 2011.
- YE, H. et al. Identification of banana fusarium wilt using supervised classification algorithms with UAV-based multi-spectral imagery. **International Journal of Agricultural and Biological Engineering**, v. 13, n. 3, p. 136–142, 2020.
- YENDREK, C. R. et al. High-throughput phenotyping of maize leaf physiological and biochemical traits using hyperspectral reflectance. **Plant Physiology**, v. 173, n. 1, p. 614–626, 2017.
- YUE, J. et al. A comparison of crop parameters estimation using images from UAV-mounted snapshot hyperspectral sensor and high-definition digital camera. **Remote Sensing**, v. 10, n. 7, 2018.
- ZAMAN-ALLAH, M. et al. Unmanned aerial platform-based multi-spectral imaging for field phenotyping of maize. **Plant Methods**, v. 11, n. 1, p. 1–10, 2015.

- ZHANG, D. et al. Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. **PLoS ONE**, v. 13, n. 5, p. 1–14, 2018.
- ZHENG, Q. et al. New spectral index for detecting wheat yellow rust using sentinel-2 multispectral imagery. **Sensors (Switzerland)**, v. 18, n. 3, p. 1–19, 2018.
- ZHOU, J. et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. **Computers and Electronics in Agriculture**, v. 175, n. March, p. 105576, 2020.

## 4. RECONHECIMENTO DAS FERRUGENS ALARANJADA E MARROM DA CANA-DE-AÇÚCAR POR MEIO DO PROCESSAMENTO DE IMAGENS DAS FOLHAS

**Resumo:** Em campos experimentais, cientistas avaliam a resistência às ferrugens alaranjada e marrom da cana-de-açúcar exclusivamente por identificação e graduação de infecção por estimativa visual nas folhas. A identificação entre os dois tipos de ferrugens é uma tarefa desafiadora, demandando técnicos especializados para realizar as observações a olho nu, por meio de observações microscópicas de características morfológicas dos agentes causais ou, ainda, a detecção com uso de técnicas de biologia molecular, o que se mostra geralmente demorado e possivelmente subjetivo, podendo ser substituído por análise de imagens das folhas, o que facilitaria o processo de identificação. Modelos Support Vector Machine radial (SVM) apresentaram alta acurácia ( $>0.88$ ) na identificação dos dois tipos de ferrugens, classificando segmentos de imagens RGB de folhas infectadas gerados com segmentação orientada a objetos (OBIA). Isso fornece bases para o desenvolvimento de aplicativos que identifiquem os dois tipos de ferrugens automaticamente por meio de imagens RGB das folhas de cana-de-açúcar.

**Palavras-chave:** Fenotipagem, Resistência a doenças, Análise de imagens orientada a objetos, PDI, sensoriamento remoto.

### 4.1. INTRODUÇÃO

Uma das principais doenças que afetam a cana-de-açúcar é a ferrugem, principalmente as causadas pelos fungos *Puccinia kuehnii* (ferrugem alaranjada) e *Puccinia melanocephala* (ferrugem marrom). A infestação por ferrugens é favorecida por condições climáticas quentes e úmidas (FERRARI et al., 2013). Têm como principal sintoma o aparecimento de pústulas no limbo foliar inferior, que ocasionam morte do tecido vegetal e redução da área fotossintética e, por consequência, redução na produção de colmos. A ferrugem alaranjada apresenta pústulas que incidem mais na base das folhas, porém podem ocorrer distribuídas por toda a superfície; já as pústulas de ferrugem marrom ocorrem em maior número do centro para as pontas das folhas.

A principal medida de controle à esses patógenos é o uso de variedades resistentes (DAL-BIANCO et al., 2012). Assim, uma das etapas com grande foco no processo de fenotipagem dos programas de melhoramento genético da cana-de-açúcar é a avaliação de resistência à essas doenças. A estimativa do grau de infecção das folhas e a identificação do tipo de ferrugem são feitas por especialistas de forma visual, o que está sempre sujeito à experiência do avaliador e pode ser afetada com o tempo, prejudicando a repetibilidade das observações (BOCK et al., 2008).

Uma alternativa mais precisa e acurada para a análise dos sintomas foliares é por meio da análise digital de imagens, sejam essas do dossel ou das folhas individualmente (MUTKA; BART, 2015). A identificação de cada tipo de ferrugem não é uma tarefa simples, demandando pessoal técnico especializado para realizar as observações a olho nu, por meio de observações microscópicas de características morfológicas de agentes causais ou, ainda, a detecção com uso de técnicas de biologia molecular. Assim, a distinção desses sintomas por meio de análise de imagens daria mais

confiança para os cientistas no armazenamento dos dados das avaliações e facilitaria as análises nos campos experimentais e lavouras. Alguns estudos se dedicaram ao reconhecimento da ferrugem em imagens RGB de folhas de cana-de-açúcar, dentre outras doenças (MANAVALAN, 2021), porém nenhum estudo visou distinguir os sintomas dentre os dois tipos de ferrugens.

O processamento de imagem tem sido aplicado no reconhecimento de muitas doenças em plantas (MANAVALAN, 2021; QIN et al., 2016; SRIVASTAVA et al., 2020). A acurácia do reconhecimento baseado em imagens para doenças de plantas depende muito da segmentação das lesões nas imagens (BARBEDO, 2016). Métodos de segmentação de imagens baseados em limiares têm sido amplamente usados na segmentação de imagens de lesões de plantas doentes (QIN et al., 2016). No entanto, geralmente há uma grande variação na cor, tanto entre lesões de doenças diferentes quanto entre lesões de uma doença em estágios diferentes. Portanto, é muito difícil determinar o limite apropriado quando métodos de segmentação de imagem baseados em limite são usados para resolver problemas de segmentação para imagens de doenças em plantas com cores complexas. Métodos de segmentação de imagens baseados em algoritmo de agrupamento difuso de C-means (THAILAMBAL; YOGESHWARI, 2020) ou agrupamento K-means (SHI; WANG; ZHANG, 2016) têm sido usados para realizar a segmentação de lesões em imagens de doenças de plantas. Esses métodos de segmentação devem especificar o número de agrupamentos. O número de agrupamento inadequado pode levar à super ou subsegmentação das imagens das lesões. No entanto, um grande esforço computacional é necessário para determinar o número apropriado de agrupamentos, especialmente para operações de segmentação em imagens de alta resolução. A análise de imagens orientada a objeto (OBIA) foi desenvolvida especificamente para o trabalho com imagens de alta resolução, quando a análise das características espectrais dos pixels não é suficiente, ou é pouco eficaz diante da quantidade de informações que podem ser obtidas de objetos de interesse, quando se analisam também características de formato e de textura (WONG T. et al., 2003). A análise OBIA é largamente utilizada no processamento de imagens em sensoriamento remoto convencional (imagens aéreas e de satélite), mas até onde sabemos, ainda não foi testado para análise de imagens de doenças em folhas.

Neste estudo, testamos a segmentação orientada a objeto automática, que elimina a necessidade de estabelecimento de limiares espectrais para segmentação e, portanto, elimina o viés humano do processamento. Ainda, procedeu-se com a extração e seleção de características preditivas das classes dos segmentos coletados e classificação destas por modelos de aprendizado de máquina. Com base nas características preditivas selecionadas, os modelos de reconhecimento das doenças foram construídos usando três métodos de aprendizagem supervisionada, incluindo floresta aleatória (RF), máquina de vetores de suporte (SVM) e K-vizinho mais próximo (KNN). Por tanto, o objetivo deste estudo foi desenvolver uma metodologia para identificação dos sintomas dos dois tipos de ferrugens da cana-de-açúcar por meio do processamento de imagens RGB das folhas. Com isso, esperamos fornecer bases para o desenvolvimento de um sistema de diagnóstico automático dessas doenças em

imagens RGB das folhas.

#### 4.2. MATERIAL E MÉTODOS

A identificação do tipo de ferrugem é uma tarefa complexa quando feita por especialistas, a olho nu, mas quando observada com lupa ou imagem de altíssima resolução as diferenças de coloração e formato das primeiras pústulas são mais facilmente observáveis (Figura 11). A ferrugem alaranjada apresenta pústulas menores, surgindo com cor laranja ou castanho alaranjada, que não se tornam escuras com o passar do tempo. Já a ferrugem marrom apresenta pústulas de maior tamanho e mais alongadas, surgem com coloração laranja e castanho-avermelhado tornando-se marrom-escuro quando maduras (FERRARI et al., 2013). Então uma hipótese deste trabalho é de que a diferenciação entre os sintomas dos dois tipos de ferrugens nas imagens das folhas se dá, principalmente, pelas características de cor, formato e textura das imagens das pústulas.

Assim, 90 folhas de cana-de-açúcar, compreendendo 24 variedades em desenvolvimento, foram coletadas aos 195 dias após o plantio, em um campo experimental de fenotipagem com foco na avaliação de resistência às ferrugens alaranjada e marrom. As plantas foram infectadas naturalmente por meio da doação de esporos de variedades suscetíveis às doenças plantadas ao redor das variedades avaliadas e foram encontradas folhas infectadas em diversos estágios das doenças e folhas de diferentes idades e, portanto, com diferentes tonalidades.

Para analisar a concordância entre o reconhecimento realizado por meio de análise de imagens e por meio de avaliações visuais, o tipo de ferrugem foi identificado pelos especialistas. A estimativa foi feita observando-se diretamente as folhas a olho nu no dia da coleta.



**Figura 11.** (a) Pústula de ferrugem alaranjada em alta resolução; (b) Pústula de ferrugem marrom em alta resolução; (c) Pústulas de ferrugem alaranjada e (d) Pústulas de ferrugem marrom com uma resolução menor (FERRARI et al., 2013)

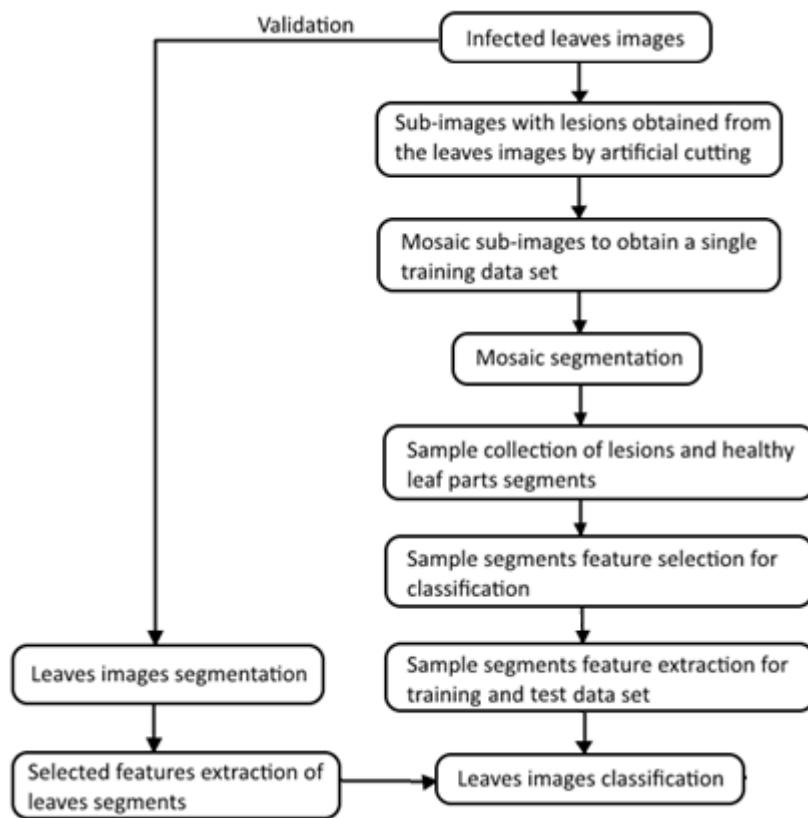
##### 4.2.1. Aquisição e processamento das imagens

As imagens das folhas infectadas foram obtidas com tamanho de 3872x2592 pixels (formatos Raw + Jpeg) com câmera digital RGB com resolução de 10.2 megapixels, em ambiente parcialmente coberto com iluminação natural difusa, totalizando 90 imagens. Uma prancha com 0,30 m de

comprimento de fundo branco foi feita para obtenção de imagens de mesmo tamanho, abrangendo o terço médio das folhas e prensagem das mesmas para que ficassem mais expandidas possível. O posicionamento da lente da câmera foi paralelo ao plano das folhas (nadir) e a 0,35 m de distância das mesmas (APÊNDICE B).

A estratégia metodológica para o processamento das imagens das folhas proposta neste trabalho é a de segmentação orientada a objeto, seguida de extração de características dos segmentos e classificação destas por modelo de aprendizado de máquina, de maneira automática, sem a necessidade de estabelecimento de limiares espectrais para segmentação e, portanto, eliminando o viés humano do processamento. A proposta é que o método possibilite a identificação de cada tipo de ferrugem. Em estudo anterior, os classificadores SVM (RACZKO; ZAGAJEWSKI, 2017), K-nearest neighbor (KNN) (QIN et al., 2016; SONG et al., 2007) e Random Forest (RACZKO; ZAGAJEWSKI, 2017) foram testados e os melhores resultados de reconhecimento de doenças em folhas de Alfafa foram obtidos com modelos SVM (QIN et al., 2016). O SVM tem sido amplamente utilizado no reconhecimento de imagens de doenças de plantas (CAMARGO; SMITH, 2009; LEIVA-VALENZUELA; AGUILERA, 2013; QIN et al., 2016) e tem como objetivo tentar encontrar o hiperplano ótimo no espaço de classificação n-dimensional com a maior diferença entre as classes. Os núcleos da função de base polinomial e radial (RBF) são as funções mais comumente usadas para classificação por SVM (YE et al., 2020). Vários estudos descobriram que o RBF é superior ao kernel polinomial para a classificação de dados de sensoriamento remoto (YANG, 2011). Portanto neste estudo, os modelos SVM para reconhecimento de imagem de doença foram construídos com uma função de base radial. Portanto esses modelos também serão testados nesse estudo. Os modelos de classificação gerados foram desenvolvidos usando o pacote “caret” dentro do software R versão 3.5.3.

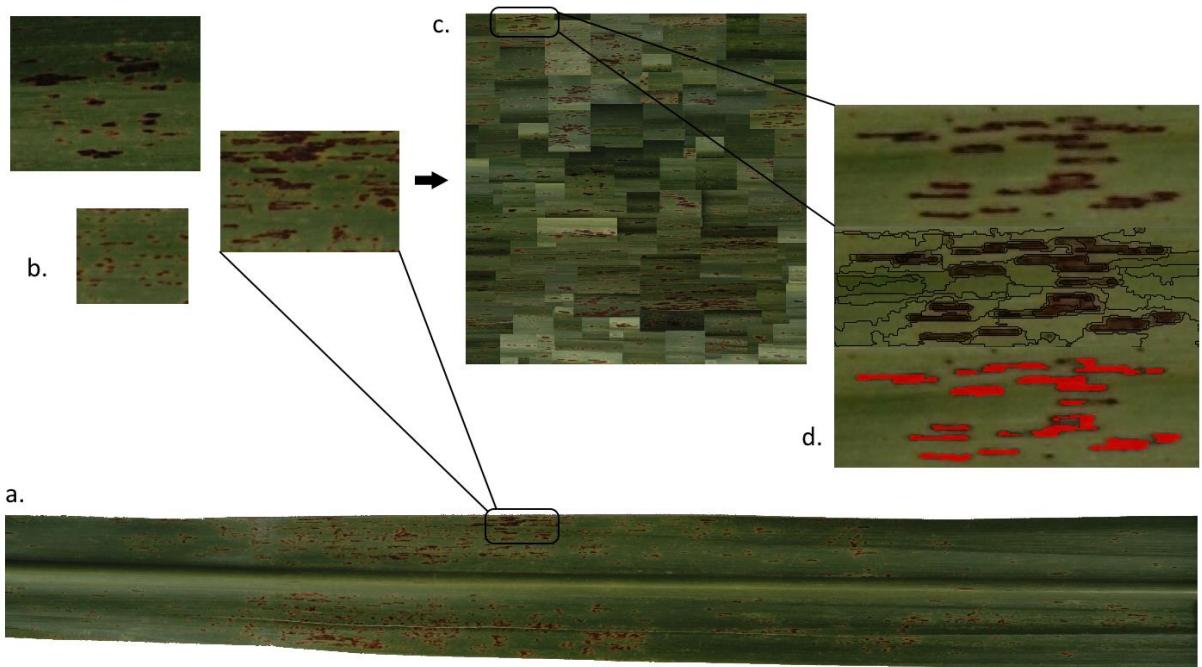
O fluxo de trabalho de processamento e análise das imagens é apresentado na Figura 12 e as etapas descritas nos itens que seguem.



**Figura 12.** Diagrama de fluxo de trabalho das principais etapas para o processamento e análise de imagens das folhas.

#### 4.2.2. Organização e pré-processamento das imagens para coleta de dados de treinamento e teste dos modelos de classificação

A tonalidade das folhas varia bastante com o estágio de desenvolvimento, senescência e variedade da cultura. Por essa razão as técnicas de filtragem de imagens são insuficientes para minimizar o efeito dessa variação quando o objetivo é utilizar método automático de processamento, e não análises individuais para cada imagem das folhas. Considerando essa variação, para que os modelos de classificação fossem treinados, sub-imagens com partes de folhas saudáveis com diversas tonalidades e lesões em todos os estágios de desenvolvimento, de ambas as ferrugens, foram extraídas por corte artificial das imagens inteiras das folhas (Figura 13). No total obtivemos 216 sub-imagens com uma ou múltiplas lesões típicas de ferrugem alaranjada e 217 sub-imagens com lesões de ferrugem marrom. As sub-imagens foram então mosaicadas em formato Jpeg. Após a segmentação dos mosaicos, que será detalhada na próxima seção, foi feita a coleta simultânea de amostras de segmentos de lesões e folha saudável para geração de arquivos de dados a serem utilizados no treinamento e teste dos modelos de classificação. Ao todo foram amostrados 1039 segmentos de lesões de ferrugem alaranjada, 497 de ferrugem marrom e 1972 de folha saudável no mosaico de imagens.



**Figura 13.** Esquema de preparação das imagens para coleta de dados para treinamento e teste dos modelos de classificação: (a) imagem inteira de 30 cm de folha de cana-de-açúcar infectada com ferrugem alaranjada; (b) exemplos de sub-imagens com lesões; (c) mosaico de sub-imagens de lesões e folha saudável com diversas tonalidades; (d) exemplo de área do mosaico segmentada com posterior coleta de amostras de segmentos de lesões e folha saudável.

#### 4.2.3. Validação do método de identificação das doenças

Para validação dos modelos de aprendizagem de máquina ou método de identificação das doenças, imagens de outras dez folhas foram segmentadas e amostras de segmentos de lesões e folha saudável foram coletadas. Para este conjunto de dados de validação foram obtidos 762 segmentos de lesão de ferrugem alaranjada, 443 de ferrugem marrom e 1886 de folha saudável. Os dados das características selecionadas dos segmentos foram então extraídos para que pudessem ser classificados pelos modelos.

#### 4.2.4. Segmentação

Apesar da análise de imagens de folhas se encontrar dentro da grande área do sensoriamento remoto (BOCK et al., 2010), a maior parte das ferramentas disponíveis para o processamento de imagens de grandes áreas não são exploradas para essa aplicação. A análise de imagens orientada a objeto (OBIA) foi desenvolvida especificamente para o trabalho com imagens de alta resolução, quando a análise das características espectrais dos pixels não é suficiente, ou é pouco eficaz diante da quantidade de informações que podem ser obtidas de objetos de interesse, quando se analisam também características de formato e de textura (WONG T. et al., 2003).

Como descrito anteriormente, as pústulas das ferrugens, que são os primeiros sintomas foliares observados, podem apresentar coloração e formato diferentes entre os dois tipos de ferrugens (alaranjada e marrom). Apesar do número de lesões não ser contabilizado nas avaliações visuais, importando somente a área de cobertura dos sintomas, para diferenciar as duas doenças, a segmentação das imagens deveria permitir tanto a distinção entre áreas lesionadas e sadias (para

obter-se a área de infecção), quanto a segmentação de pústulas e áreas de coalescência das mesmas, ou seja, individualizar as lesões em segmentos, para que os mesmos pudessem ser diferenciados tanto por padrões de coloração quanto por padrões de formato e textura.

Para tanto, o software comercial eCognition Developer 8 (Trimble GeoSpatial, Munique, Alemanha), largamente utilizado no processamento de imagens em sensoriamento remoto, foi utilizado para segmentação orientada a objeto das imagens com o algoritmo multiresolution de segmentação (DEFINIENS, 2012). A escala de segmentação adequada foi definida em 10, de modo a gerar os segmentos que melhor delimitavam as áreas das lesões. Os valores dos demais parâmetros envolvidos na segmentação foram 1 para o peso de todas as bandas, 0,1 para formato e 0,5 para compacidade. Antes da segmentação também geramos a conversão do espaço de cores RGB para HSI (Hue, Saturation, Intensity) para minimização dos efeitos de variação de iluminação e obtenção de características de cor (Hue) dos elementos da imagem, importantes para a segmentação de imagens RGB e consequentemente para separação das classes de interesse dos segmentos (RAUT; INGOLE, 2017).

#### **4.2.5. Seleção de características dos segmentos**

Após a segmentação e coleta de amostras de lesões das duas ferrugens e folha saudável aplicou-se a função de Otimização do espaço de características, que oferece um método para calcular, matematicamente, a melhor combinação de características para diferenciação ou maior distância mínima média entre as amostras das classes de interesse (TRIMBLE INC., 2017). Inicialmente selecionou-se as características dentre um conjunto de 202 características de cor, formato e textura disponíveis no software, e destas, 114 foram selecionadas e então foram realizados treinamento e teste dos modelos de classificação. Em uma tentativa de simplificação dos modelos, as características de textura foram retiradas e um conjunto de 52 características espectrais e de formato disponíveis no software foi otimizado resultando em 25 características principais para diferenciação das amostras coletadas nas imagens, resultando em melhores classificações, portanto foram adotadas no restante do estudo. As características e a posição no ranking de importância para diferenciação das classes de interesse, ferrugem alaranjada, ferrugem marrom e folha saudável, se encontram na tabela 5. A descrição dessas mesmas características se encontra na tabela 6.

**Tabela 5.** Características extraídas dos segmentos e classificação de importância.

<b>Classificação das características</b>	<b>Características</b>	<b>Classificação das características</b>	<b>Características</b>
1	Number of edges (polygon)	14	Degree of skeleton branching
2	Mean Layer 1*	15	Rectangular Fit
3	Max. diff.	16	Brightness
4	Standard deviation Layer 1*	17	Standard deviation of area represented by segments

5	Average area represented by segments	18	Mean Layer 2
6	Radius of largest enclosed ellipse	19	Standard deviation of length of edges (polygon)
7	Compactness (polygon)	20	Roundness
8	Standard deviation Layer 3*	21	Radius of smallest enclosing ellipse
9	Elliptic Fit	22	Mean Layer 3*
10	Standard deviation Layer 2*	23	Compactness
11	HIS Transformation Hue	24	Length
12	Density	25	Shape index
13	Average length of edges (polygon)	-	-

Note:

\* Layer 1 = Vermelho, Layer 2 = Verde, Layer 3 = Azul

**Tabela 6.** Características extraídas dos segmentos e definições (DEFINIENS, 2012).

Características	Definição
Number of edges (polygon)	The number of edges of a polygon.
HIS Transformation Hue	Hue (color)
Average area represented by segments	The average area of all triangles created by a Delaunay triangulation.
Elliptic Fit	Describes how well an image object fits into an ellipse of similar size and proportions.
Density	Describes the distribution in space of the pixels of an image object.
Average length of edges (polygon)	The average length of all edges in a polygon.
Radius of smallest enclosing ellipse	Describes how much the shape of an image object is similar to an ellipse.
Max. diff.	<ul style="list-style-type: none"> <li>• i; j are image layers</li> <li>• <math>\overline{c(v)}</math> is the brightness of image object <math>v</math></li> <li>• <math>\bar{c}_{i(v)}</math> is the mean intensity of image layer i of image object <math>v</math></li> <li>• <math>\bar{c}_{j(v)}</math> is the mean intensity of image layer j of image object <math>v</math></li> <li>• <math>c_k^{max}</math> is the brightest possible intensity value of image layer k</li> <li>• <math>K_B</math> are image layers of positive brightness weight with <math>K_B = fk</math> 2    K: wk = 1g;    where wk is the image layer weight.</li> </ul>

	$\frac{1}{K_B} c_k^{max} = \frac{\max_{i,j \in K_B}  \bar{c}_{i(v)} - \bar{c}_{j(v)} }{\bar{c}(v)}$
Rectangular Fit	Describes the difference between a master rectangle and the considered object using the same measure of area, width and length for the master rectangle.
Length	The length of a 2D image object is calculated using the length-to-width ratio.
Compactness (polygon)	The ratio of the area of a polygon to the area of a circle with the same perimeter.
Standard deviation of length of edges (polygon)	Measures how the lengths of edges deviate from their mean value.
Radius of largest enclosed ellipse	Describes how similar an image object is to an ellipse.
Standard deviation of area represented by segments	The standard deviation of all triangles created by the Delaunay triangulation.
Standard deviation Layer 1/2/3*	For each image layer, a separate standard deviation feature.
Mean Layer 1/2/3*	The mean intensity of all pixel/voxels forming an image object.
Shape index	Describes the smoothness of the image object borders.
Degree of skeleton branching	The internal structure of the polygons can be derived using skeletons. A very high degree of skeleton branching is an indication of a complex and non-smooth polygon shape.
Compactness	Can be defined by the product of the width and the length over pixels numbers.
Brightness	Best image layers providing the spectral information are used for calculation. It is the mean intensity of the image layer of the image object.
Roundness	Describes how similar an image object is to an ellipse. It is calculated by the difference of the enclosing ellipse and the enclosed ellipse.

Note:

\* Layer 1 = Red, Layer 2 = Green, Layer 3 = Blue

#### 4.2.6. Avaliação de acurácia

Neste estudo, a acurácia foi a estatística usada para avaliar os modelos de classificação (Eq. 1).

$$\text{Acurácia} = \frac{\text{Número de previsões corretas}}{\text{Número total de previsões}} \quad (1)$$

Matrizes de confusão balanceadas para problemas com três classes foram usadas para avaliar a acurácia das classificações (GRANDINI; BAGLI; VISANI, 2020). A acurácia geral denota a probabilidade de que uma amostra selecionada aleatoriamente seja classificada corretamente de acordo com sua classe rótulo.

O conjunto de dados foi dividido aleatoriamente em 70% para o conjunto de treinamento e 30% para o conjunto de teste. A validação cruzada k-fold foi usada para ajuste dos parâmetros na etapa de treinamento dos modelos. Neste estudo, a validação cruzada com quatro folds com duas repetições foi utilizada. Após o treinamento, as amostras de teste foram usadas para avaliação da acurácia.

O coeficiente Kappa ( $K_c$ ), que também é uma medida de acurácia da classificação, foi calculado da seguinte forma (Eq. 2) (CONGALTON, 1991):

$$K_c = N \sum_{n=1}^r \frac{n_{irow} n_{icol}}{N^2} - \sum_{i=1}^r n_{irow} n_{icol} \quad (2)$$

, onde  $n_{ii}$  é o elemento de posição i-ésima linha e i-ésima coluna,  $n_{icol}$  são as somas das colunas e  $n_{irow}$  são as somas das linhas. Um valor Kappa de 1 representa uma concordância perfeita, enquanto um valor de 0 representa nenhuma concordância.

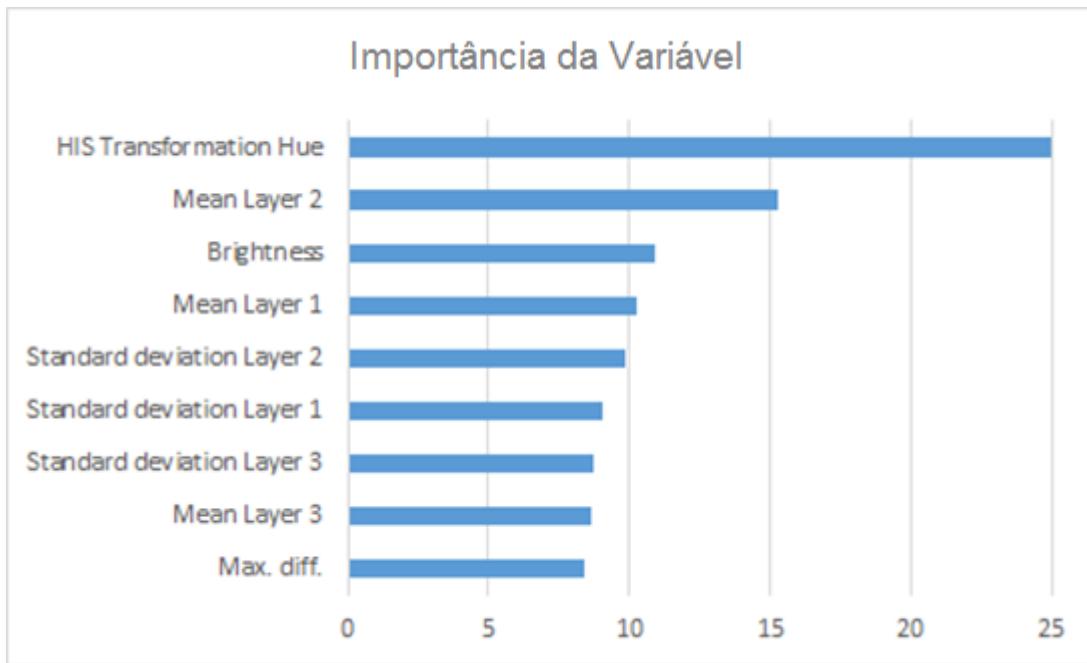
#### 4.3. RESULTADOS

Os modelos foram capazes de diferenciar os dois tipos de ferrugem com alta acurácia (tabela 7 – acurácia > 0,8), tanto para o conjunto de dados de teste quanto para o de validação.

**Tabela 7.** Resultados da classificação dos modelos para ferrugem alaranjada e marrom da cana-de-açúcar com base em 25 características de segmentos de imagens de folhas para os conjuntos de dados de teste e validação.

Conjunto de teste		RF	KNN	SVM radial
Acurácia geral (%)		90,0	89,0	89,0
	Alaranjada	83,0	83,0	84,0
Acurácia balanceada (%)	Marrom	85,0	82,0	81,0
	Folha saudável	99,0	99,0	99,0
Kappa		80,0	79,0	80,0
Conjunto de validação		RF	KNN	SVM radial
Acurácia geral (%)		90,0	89,0	90,0
	Alaranjada	87,0	86,0	88,0
Acurácia balanceada (%)	Marrom	80,0	76,0	80,0
	Folha saudável	98,0	98,0	99,0
Kappa		81,0	79,0	82,0

Considerando a acurácia de reconhecimento das doenças com o conjunto de dados de validação, o melhor modelo construído foi com SVM radial com base nas 9 principais características preditivas selecionadas. A importância das principais características dos segmentos para a diferenciação das doenças pelos modelos é apresentada na figura 14. A remoção do restante de características do conjunto de dados de entrada para treinamento dos modelos não alterou os resultados de acurácia das classificações dos conjuntos de dados de teste e validação. Portanto podemos destacar que baseados nessas 9 características, modelos de aprendizagem de máquina como os testados neste estudo são capazes de reconhecer as lesões dos dois tipos de ferrugem em imagens RGB de folhas infectadas por meio da segmentação orientada a objetos. Sendo os valores de cor (Hue), obtidos com a transformação do espaço de cores HIS a característica preditiva mais importante para a classificação.



**Figura 14.** Importância das principais características selecionadas pelos modelos de aprendizagem de máquina dentre as 25 características selecionadas após a segmentação e rotulação das amostras utilizadas para a geração dos modelos.

#### 4.4. DISCUSSÃO

O histórico complexo de análise de imagens de doenças em plantas apresenta grandes desafios para a segmentação e a classificação (BARBEDO, 2016). O processamento de imagens tem sido largamente utilizado na análise de doenças foliares, sendo a segmentação das áreas lesionadas uma de suas fases mais importantes. Métodos de segmentação de imagens baseados em limiares espectrais são amplamente utilizados na segmentação de imagens de lesões foliares (PATIL; BODHE, 2011). No entanto, há grande variação de cor, tanto entre as lesões de diferentes doenças quanto entre lesões em diferentes estágios de infecção, além de uma grande variação entre tons de verde das áreas foliares saudáveis, o que normalmente exige que se faça a limiarização individual para cada folha analisada (BARBEDO, 2016). Desse modo, é difícil determinar os limiares apropriados para uma segmentação satisfatória quando há uma variação complexa de cores. Além disso, filtros podem ser aplicados de acordo com a qualidade da imagem de cada folha. Logo, o método proposto neste trabalho com a segmentação orientada a objeto (OBIA) pode ser mais explorado, visando simplificar o reconhecimento de diversas doenças, inserindo mais esse tema na grande área do sensoriamento remoto. A diferenciação entre as lesões e áreas de folha sadias se dá mais facilmente com base em características de cor, embora para várias doenças de diversas culturas, os sintomas muitas vezes não possuem bordas bem definidas (BARBEDO, 2016). O método de segmentação (OBIA), utilizado neste estudo, permite padronização na delimitação das áreas de infecção, diminuindo o erro na classificação.

Neste estudo, 202 características de cor, formato e textura foram extraídas e testadas, destas, 114 foram inicialmente selecionadas de acordo com sua importância para separação das classes de

interesse dos objetos segmentados. As características de textura foram retiradas do conjunto de variáveis preditivas, uma vez que se mostraram redundantes para reconhecimento das classes (ferrugem alaranjada, ferrugem marrom e folha saudável), sobrando assim 52 características de cor e formato. Destas, 25 características principais foram selecionadas por meio da função de otimização. Essas 25 características selecionadas serviram então de variáveis preditivas para treinamento, teste e validação dos modelos de aprendizagem de máquina. Resultados satisfatórios de classificação também foram obtidos com os modelos de reconhecimento das doenças construídos com base em apenas 9 características selecionadas como mais importantes pelos modelos, indicando que essas poderiam ser usadas efetivamente para a identificação das duas doenças, bem como a distinção entre partes doentes e sadias das folhas de cana-de-açúcar. Com a transformação no espaço de cores para HSI, foi possível diferenciar satisfatoriamente os sintomas com as características de cor (Hue), bem como a máxima diferença (Max. Diff.), que é função do brilho e média de intensidade das camadas e bandas selecionadas, o desvio padrão de intensidade de reflexão ou radiometria dos segmentos nas três bandas (RGB), a média de intensidade de reflexão dos segmentos também nas 3 bandas e o valor de brilho dos segmentos (I em HSI). Ou seja, a distinção entre os sintomas das duas doenças e entre essas e segmentos de folha saudável se deu por características de cor e intensidade, e não por características de formato ou textura.

A tentativa de reconhecer as doenças por meio de processamento de imagens RGB das folhas geraram resultados satisfatórios, não havendo grande confusão na distinção entre os dois tipos de ferrugens ou entre esses e áreas de folha saudável. Os resultados demonstraram que o reconhecimento foi melhor com o modelo gerado com SVM radial. A acurácia de classificação das doenças do conjunto de validação foi muito próxima da do conjunto de teste, o que indicou que este modelo não só poderia ser usado para obter resultados de reconhecimento satisfatórios, mas também tem forte habilidade de generalização, fornecendo bases para construção de um sistema de diagnóstico automático das doenças em imagens RGB de folhas de cana-de-açúcar. O fundo complexo de imagens adquiridas em campo apresenta grandes desafios para a segmentação e reconhecimento dos alvos nas imagens (BARBEDO, 2016). As imagens das folhas de cana-de-açúcar usadas neste estudo foram tiradas em um fundo branco. Portanto mais estudos são necessários para determinar se os métodos usados neste estudo são adequados para a identificação automática e diagnóstico de doenças das folhas ainda na natureza.

Neste estudo, foi investigado o reconhecimento de duas das principais doenças avaliadas na fenotipagem de novas variedades de cana-de-açúcar para o processo de melhoramento genético. Seria interessante construir um banco de dados de padrões abrangente de imagens de lesões para estabelecer bases sólidas para a aplicação da tecnologia de reconhecimento automático de outras doenças da cultura em imagens das folhas. Atualmente, o uso de smartphones para tirar fotos e processar dados tornou-se uma importante ferramenta (AHMED; REDDY, 2021). Um aplicativo móvel poderia ser desenvolvido usando o modelo de reconhecimento de imagens ideal de doenças

em folhas de cana-de-açúcar construídos neste estudo para realizar o diagnóstico e compartilhamento de informações (LU; TAN; JIANG, 2021). Uma vez implementando, este processo não requereria pessoal especializado ou quaisquer reagentes químicos. No entanto, as técnicas tradicionais podem desempenhar um papel importante na detecção de doenças nos estágios iniciais ou especialmente na detecção de folhas infectadas de forma latente ainda sem o aparecimento de sintomas (SCHAAD; FREDERICK, 2002).

#### **4.5. CONCLUSÃO**

Com a segmentação orientada a objeto de imagens RGB de folhas de cana-de-açúcar infectadas pelas ferrugens alaranjada e marrom e transformação no espaço de cores para HSI, foi possível diferenciar satisfatoriamente os sintomas dos dois tipos de ferrugem, alaranjada e marrom com as características de cor (Hue) dos segmentos obtidas com a transformação HSI, bem como a máxima diferença (Max. Diff.), que é função do brilho e média de intensidade das camadas e bandas selecionadas, o desvio padrão de intensidade de reflexão ou radiometria dos segmentos nas três bandas (RGB), a média de intensidade de reflexão dos segmentos também nas 3 bandas e o valor de brilho dos segmentos (I em HSI).

Os modelos de reconhecimento de doenças foram construídos usando três métodos de aprendizagem supervisionada, incluindo RF, SVM radial e KNN. Os resultados demonstraram que o reconhecimento foi melhor com o modelo gerado SVM radial com base nas 9 principais características preditivas selecionadas.

O reconhecimento de doenças em plantas requer pessoal técnico especializado e experiente para realizar as observações a olho nu, ou por meio de observações microscópicas de características morfológicas de agentes causais ou ainda a detecção com uso de técnicas de biologia molecular (SANKARAN et al., 2010). Assim, geralmente é necessária uma grande quantidade de recursos humanos e materiais. Portanto, uma solução viável foi fornecida para o diagnóstico e identificação dos dois tipos de ferrugem da cana-de-açúcar por meio de imagens RGB das folhas infectadas.

#### **REFERÊNCIAS**

- ABDULRIDHA, J. et al. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. **Precision Agriculture**, v. 21, n. 5, p. 955–978, 2020.
- ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. **Remote Sensing**, v. 11, n. 11, 2019.
- AGISOFT METASHAPE. MicaSense RedEdge MX processing workflow ( including Reflectance Calibration ) in Agisoft Metashape Professional. 2021.
- AHMED, A. A.; REDDY, G. H. A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning. **AgriEngineering**, v. 3, n. 3, p. 478–493, 2021.

- APAN, A. et al. Detecting sugarcane “orange rust” disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v. 25, n. 2, p. 489–498, 2004.
- ARAUS, J. L.; CAIRNS, J. E. Field high-throughput phenotyping: The new crop breeding frontier. **Trends in Plant Science**, v. 19, n. 1, p. 52–61, 2014.
- BALSALOBRE, T. W. A. et al. Mixed modeling of yield components and brown rust resistance in sugarcane families. **Agronomy Journal**, v. 108, n. 5, p. 1824–1837, 2016.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52–60, 2016.
- BARRETO, F. Z. et al. Validation of molecular markers associated with brown rust resistance in sugarcane. **Summa Phytopathologica**, v. 43, n. 1, p. 36–40, 2017.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BERNI, J. A. J. et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BOCK, C. H. et al. Visual Rating and the Use of Image Analysis for Assessing Different Symptoms of Citrus Canker on Grapefruit Leaves. **Plant Disease**, v. 92, n. 4, p. 530–541, 2008.
- BOCK, C. H. et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59–107, 2010.
- CAMARGO, A.; SMITH, J. S. Image pattern classification for the identification of disease causing agents in plants. v. 66, p. 121–125, 2009.
- CANATA, T. . et al. Measuring height of sugarcane plants through LiDAR technology. p. 1–13, 2016.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859–881, 2017.
- CHIVASA, W.; MUTANGA, O.; BIRADAR, C. UAV-based multispectral phenotyping for disease resistance to accelerate crop improvement under changing climate conditions. **Remote Sensing**, v. 12, n. 15, 2020.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- CURSI, D. E. et al. History and Current Status of Sugarcane Breeding, Germplasm Development and Molecular Genetics in Brazil. **Sugar Tech**, v. 24, n. 1, p. 112–133, 2022.
- D’HONT, A. Unraveling the genome structure of polyploids using FISH and GISH; examples of sugarcane and banana. **Cytogenetic and Genome Research**, v. 109, n. 1–3, p. 27–33, 2005.
- DAL-BIANCO, M. et al. Sugarcane improvement: How far can we go? **Current Opinion in**

- Biotechnology**, v. 23, n. 2, p. 265–270, 2012.
- DEFINIENS. Definiens Developer XD 2.0.4 Reference Book. p. 106, 2012.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, n. 3, p. 1091–1116, 2013.
- FAHLGREN, N.; GEHAN, M. A.; BAXTER, I. Lights, camera, action: High-throughput plant phenotyping is ready for a close-up. **Current Opinion in Plant Biology**, v. 24, p. 93–99, 2015.
- FERRARI, J. T. et al. Ferrugem alaranjada da cana-de-açúcar no Brasil. **Biológico**, v. 75, p. 71–74, 2013.
- FORREST, W. et al. **Disease assessment terms and concepts**. *Plant Disease*, 1991. Disponível em: <<http://agris.fao.org/agris-search/search/display.do?f=2012/OV/OV201208481008481.xml;US19930116789>>
- FURBANK, R. T.; TESTER, M. Phenomics - technologies to relieve the phenotyping bottleneck. **Trends in Plant Science**, v. 16, n. 12, p. 635–644, 2011.
- GIRARD, J. H. H. T. J. C. Targeted mapping of a sugarcane rust resistance gene (Bru1) using bulked segregant analysis and AFLP markers. v. 570, p. 759–764, 2004.
- GRANDINI, M.; BAGLI, E.; VISANI, G. Metrics for Multi-Class Classification: an Overview. p. 1–17, 2020.
- GRIVET, L.; ARRUDA, P. Sugarcane genomics: Depicting the complex genome of an important tropical crop. **Current Opinion in Plant Biology**, v. 5, n. 2, p. 122–127, 2002.
- HASSAN, M. A. et al. Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. **Plant Methods**, v. 15, n. 1, p. 1–12, 2019.
- HAYNES, K.; WEINGARTNER, D. P. The Use of Area Under the Disease Progress Curve to Assess Resistance to Late Blight in Potato Germplasm. **American Journal Of Potato Research**, n. December 2003, p. 137–141, 2004.
- HOY, J. W.; HOLLIER, C. A. Effect of Brown Rust on Yield of Sugarcane in Louisiana. **Plant Disease**, v. 93, n. 11, p. 1171–1174, 2009.
- HUANG, H. et al. Detection of helminthosporium leaf blotch disease based on UAV imagery. **Applied Sciences (Switzerland)**, v. 9, n. 3, p. 1–14, 2019.
- KARLOVSKA, A. et al. PLANT REFLECTED SPECTRA DEPENDING ON BIOLOGICAL CHARACTERISTICS AND GROWTH CONDITIONS. **International Scientific Conference Rural Development 2017**, 2016.
- KHAN, A.; YADAV, M. S. Image Processing Based Disease Detection for Sugarcane Leaves. **International Journal Of Advance Research, Ideas And Innovations In Technology**, v. 3, n. 4, p. 497–502, 2017.
- LEIVA-VALENZUELA, G. A.; AGUILERA, J. M. Automatic detection of orientation and diseases in blueberries using image analysis to improve their postharvest storage quality. **Food**

**Control**, v. 33, n. 1, p. 166–173, 2013.

LIEBISCH, F. et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. **Plant Methods**, v. 11, n. 1, 2015.

LU, J.; TAN, L.; JIANG, H. Review on convolutional neural network (CNN) applied to plant leaf disease classification. **Agriculture (Switzerland)**, v. 11, n. 8, p. 1–18, 2021.

MAHLEIN, A.-K. Present and Future Trends in Plant Disease Detection. **Plant Disease**, v. 100, n. 2, p. 1–11, 2016.

MAIA JÚNIOR, S. DE O. et al. Caracterização Morfológica E Produtiva E Suas Correlações Em Cultivares De Cana-De-Açúcar. **Revista Ciência Agrícola**, v. 16, n. 1, p. 31–42, 2018.

MANAVALAN, R. Efficient Detection of Sugarcane Diseases through Intelligent Approaches : A Review. **Asian Journal of Research and Review in Agriculture**, v. 3, n. 4, p. 27–37, 2021.

MORIYA, E. A. S. et al. Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images.

**IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 2, p. 740–748, 2017.

MUTKA, A. M.; BART, R. S. Image-based phenotyping of plant disease symptoms. **Frontiers in Plant Science**, v. 5, n. 1, p. 1–8, 2015.

NEILSON, E. H. et al. Utilization of a high-throughput shoot imaging system to examine the dynamic phenotypic responses of a cereal crop plant to nitrogen and water deficiency over time. **Journal of Experimental Botany**, v. 66, n. 7, p. 1817–1832, 2015.

NEWTON, A. C.; HACKETT, C. A. Subjective components of mildew assessment on spring barley. **European Journal of Plant Pathology**, v. 100, n. 6, p. 395–412, 1994.

NIEMEYER, J.; ROTTENSTEINER, F.; SOERGEL, U. Contextual classification of lidar data and building object detection in urban areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 152–165, 2014.

PATIL, S. B.; BODHE, S. K. Leaf Disease Severity Measurement Using Image Processing. **International Journal of Engineering and Technology**, v. 3, n. 5, p. 297–301, 2011.

PICOLI, M. C. A. et al. The use of ALOS/PALSAR data for estimating sugarcane productivity. **Engenharia Agrícola**, v. 34, n. 6, p. 1245–1255, 2015.

QIN, F. et al. Identification of alfalfa leaf diseases using image recognition technology. **PLoS ONE**, v. 11, n. 12, p. 1–26, 2016.

RACZKO, E.; ZAGAJEWSKI, B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. **European Journal of Remote Sensing**, v. 50, n. 1, p. 144–154, 2017.

RAUT, S.; INGOLE, K. Review On Leaf Disease Detection Using Image Processing Techniques. **International Research Journal of Engineering and Technology (IRJET)**, v. 4, n. 4, p. 22–24, 2017.

REYNOLDS, M. et al. Breeder friendly phenotyping. **Plant Science**, v. 295, n. December 2019, p.

110396, 2020.

- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. December 2018, p. 2–10, 2019a.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. January, p. 2–10, 2019b.
- SAITO, É. A.; IMAI, N. N.; TOMMASELLI, A. M. G. Análise Espectral De Amostras De Cana-De-Açúcar. **Anais do III Simpósio Brasileiro de Geomática**, n. 1, p. 169–174, 2012.
- SANJEL, S. et al. Comparison of progress of brown rust and orange rust and conditions conducive for severe epidemic development during the sugarcane crop season in Florida. **Plant Disease**, v. 103, n. 5, p. 825–831, 2019.
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1–13, 2010.
- SANTOS, F.; BORÉM, A. Cana-de-açúcar: do Plantio à Colheita. n. June, p. 89–115, 2013.
- SCHAAD, N. W.; FREDERICK, R. D. Real-time PCR and its application for rapid plant disease diagnostics. **Canadian Journal of Plant Pathology**, v. 24, n. 3, p. 250–258, 2002.
- SHAKOOR, N.; LEE, S.; MOCKLER, T. C. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field. **Current Opinion in Plant Biology**, v. 38, p. 184–192, 2017.
- SHI, Y.; WANG, X.; ZHANG, S. Plant disease leaf image segmentation using K-Means clustering based on internet of things. **International Journal of Research in Agricultural Sciences**, v. 3, n. 2, p. 2348–3997, 2016.
- SIMKO, I.; PIEPHO, H. P. The area under the disease progress stairs: Calculation, advantage, and application. **Phytopathology**, v. 102, n. 4, p. 381–389, 2012.
- SOCA-MUÑOZ, J. L. et al. Spectral signature of brown rust and orange rust in sugarcane. **Revista Facultad de Ingeniería**, n. 96, p. 9–20, 2020.
- SONG, Y. et al. **IKNN: Informative K-nearest neighbor pattern classification**. [s.l.: s.n.]. v. 4702 LNAI
- SRIVASTAVA, S. et al. A Novel Deep Learning Framework Approach for Sugarcane Disease Detection. **SN Computer Science**, v. 1, n. 2, p. 1–7, 2020.
- STEDDOM, K. et al. Comparison of Visual and Multispectral Radiometric Disease Evaluations of Cercospora Leaf Spot of Sugar Beet. **Plant Disease**, v. 89, n. 2, p. 153–158, 2005.
- THAILAMBAL, G.; YOGESHWARI, M. Automatic segmentation of plant leaf disease using improved fast Fuzzy C-Means clustering and adaptive Otsu thresholding. **European Journal of Molecular and Clinical Medicine**, v. 7, n. 3, p. 5447–5462, 2020.
- THANH NOI, P.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, 2017.

- THOMPSON, L. J.; PUNTEL, L. A. Transforming unmanned aerial vehicle (UAV) and multispectral sensor into a practical decision support system for precision nitrogen management in corn. **Remote Sensing**, v. 12, n. 10, 2020.
- TRIMBLE INC. eCognition Developer 9.1. n. March, 2017.
- TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.
- VERMA, A. K. et al. Modelling of sugarcane yield using LISS-IV data based on ground LAI and yield observations. **Geocarto International**, v. 0, n. 0, p. 1–18, 2019.
- WONG T., H. et al. Feature extraction based on object oriented analysis. **Proceedings of ATC**, p. 1–10, 2003.
- YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, 2017.
- YANG, M. et al. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, n. June, p. 1–16, 2020a.
- YANG, W. et al. Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives. **Molecular Plant**, v. 13, n. 2, p. 187–214, 2020b.
- YANG, X. Parameterizing Support Vector Machines for Land Cover Classification. **Photogrammetric Engineering & Remote Sensing**, v. 77, n. 1, p. 27–37, 2011.
- YE, H. et al. Identification of banana fusarium wilt using supervised classification algorithms with UAV-based multi-spectral imagery. **International Journal of Agricultural and Biological Engineering**, v. 13, n. 3, p. 136–142, 2020.
- YENDREK, C. R. et al. High-throughput phenotyping of maize leaf physiological and biochemical traits using hyperspectral reflectance. **Plant Physiology**, v. 173, n. 1, p. 614–626, 2017.
- YUE, J. et al. A comparison of crop parameters estimation using images from UAV-mounted snapshot hyperspectral sensor and high-definition digital camera. **Remote Sensing**, v. 10, n. 7, 2018.
- ZAMAN-ALLAH, M. et al. Unmanned aerial platform-based multi-spectral imaging for field phenotyping of maize. **Plant Methods**, v. 11, n. 1, p. 1–10, 2015.
- ZHANG, D. et al. Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. **PLoS ONE**, v. 13, n. 5, p. 1–14, 2018.
- ZHENG, Q. et al. New spectral index for detecting wheat yellow rust using sentinel-2 multispectral imagery. **Sensors (Switzerland)**, v. 18, n. 3, p. 1–19, 2018.
- ZHOU, J. et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. **Computers and Electronics in Agriculture**, v. 175, n. March, p. 105576, 2020.

## 5. DISCUSSÃO GERAL E CONCLUSÃO

As avaliações de resistência a doenças da cana-de-açúcar ainda são feitas por avaliação visual nos campos de fenotipagem nos programas de melhoramento genético da cana-de-açúcar. A adoção de técnicas de sensoriamento remoto e análise de imagens para fenotipagem ainda é incipiente até os dias de hoje. No entanto há uma demanda crescente para a implantação de novas tecnologias de fenotipagem de alto rendimento para que novas variedades resistentes e tolerantes a estresses bióticos e abióticos possam ser liberadas mais rapidamente atendendo assim as demandas no setor sucro-energético diante das mudanças climáticas.

A possibilidade de substituição das avaliações visuais em campo por técnicas de sensoriamento remoto com VANT reduziria o tempo das avaliações e possibilitaria a avaliação de muitas outras novas variedades no mesmo experimento. Isso reduziria também a demanda de especialistas em campo, liberando-os para atividades como análise de imagens e pesquisa correlacional com dos dados de fenotipagem com dados genéticos. As técnicas de fenotipagem por sensoriamento remoto com sensores embarcados em VANT juntamente com aprendizagem de máquina no processamento e análise de imagens estão se consolidando e provavelmente se tornarão ferramentas imprescindíveis em campos de produção.

Portanto, esta tese apresentou uma abordagem para realização da avaliação de resistência às ferrugens alaranjada e marrom da cana-de-açúcar por meio de sensoriamento remoto com sensor multiespectral embarcado em VANT. Também apresentou uma metodologia para reconhecimento de cada tipo de ferrugem por meio do processamento de imagens RGB de folhas infectadas, o que dá bases para um diagnóstico mais preciso e sem viés humano das doenças. A viabilidade dos métodos apresentados foi avaliada por meio da sensibilidade dos dados de refletância e radiométricos aos sintomas de infecção manifestados pelas plantas.

No capítulo 3, referente ao primeiro artigo, abordamos como os dados de refletância das parcelas experimentais se relacionam com o nível de infecção das mesmas pelas ferrugens. Encontramos correlações significativas entre as notas de infecção e os dados de refletância, mas estas não foram suficientes para substituição direta de notas de infecção atribuídas visualmente ou por meio de processamento de imagens das folhas. Com as bandas e IVs testados neste estudo, não foi possível a distinção de infecção por cada tipo de ferrugem por meio de imagens aéreas, porém, foi possível predizer com alta acurácia as três classes de resistência (resistentes, moderadamente resistentes e susceptíveis) por meio de modelos de aprendizagem de máquina. Consideramos importante o fato dos modelos conseguirem distinguir com precisão as variedades consideradas susceptíveis, pois em um protocolo de fenotipagem, poderiam ser analisadas de maneira proximal apenas essas variedades, afim de se determinar a qual tipo de ferrugem são suscetíveis. A análise empírica dos dados mostrou que a relação da refletância das parcelas experimentais e o nível de infecção é estabelecida principalmente pela variação da atividade

fotossintética das folhas, expressa principalmente nos dados de refletância da banda vermelha do sensor.

No capítulo 4, referente ao segundo artigo, mostramos como foi possível a distinção dos sintomas das duas doenças, com alta acurácia, por meio de processamento e classificação de imagens RGB de folhas infectadas. A partir de segmentação orientada a objeto, criamos segmentos de imagens abordando os sintomas (pústulas e áreas de coalescência) dos dois tipos de ferrugens e as características de cor, forma e texturas foram extraídas e analisadas para determinação das mais importantes para distinção das classes de segmentos ferrugem alaranjada, ferrugem marrom e folha saudável. Com as características selecionadas, fornecemos as bases para criação de algoritmo de segmentação e classificação automáticas de imagens de folhas para diagnóstico dos dois tipos de ferrugens. Isso daria mais confiança aos pesquisadores diminuindo a dependência de análise visual especializada e possibilitaria o armazenamento dos dados, que poderiam ser revisados e utilizados para modelagens futuras a qualquer momento.

A infecção pela ferrugem alaranjada rompe as folhas das plantas causando maior estresse hídrico. A correlação da infecção pela ferrugem alaranjada com os dados espectrais foi menor do que a correlação dos mesmos com a ferrugem marrom. O estresse hídrico pode ser melhor detectado por meio de dados de refletância das bandas do infravermelho de ondas curtas. Portanto estudos futuros deveriam avaliar a sensibilidade de dados espectrais do infravermelho de ondas curtas, juntamente com as bandas testadas neste estudo, para verificar a possibilidade de diferenciação das duas doenças em imagens aéreas com os dados dessas bandas como variáveis preditoras. Isso também poderia aumentar a acurácia do método proposto neste trabalho. Em estudos futuros também seria interessante que a avaliação visual das folhas das plantas fosse substituída por análise de imagens RGB das folhas, para que os modelos fossem treinados com valores verdadeiros de infecção.

## REFERÊNCIAS GERAIS

- ABDULRIDHA, J. et al. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. **Precision Agriculture**, v. 21, n. 5, p. 955–978, 2020.
- ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. **Remote Sensing**, v. 11, n. 11, 2019.
- AGISOFT METASHAPE. MicaSense RedEdge MX processing workflow ( including Reflectance Calibration ) in Agisoft Metashape Professional. 2021.
- AHMED, A. A.; REDDY, G. H. A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning. **AgriEngineering**, v. 3, n. 3, p. 478–493, 2021.
- APAN, A. et al. Detecting sugarcane “orange rust” disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v. 25, n. 2, p. 489–498, 2004.
- ARAUS, J. L.; CAIRNS, J. E. Field high-throughput phenotyping: The new crop breeding frontier. **Trends in Plant Science**, v. 19, n. 1, p. 52–61, 2014.
- BALSALOBRE, T. W. A. et al. Mixed modeling of yield components and brown rust resistance in sugarcane families. **Agronomy Journal**, v. 108, n. 5, p. 1824–1837, 2016.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52–60, 2016.
- BARRETO, F. Z. et al. Validation of molecular markers associated with brown rust resistance in sugarcane. **Summa Phytopathologica**, v. 43, n. 1, p. 36–40, 2017.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BERNI, J. A. J. et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, 2009.
- BOCK, C. H. et al. Visual Rating and the Use of Image Analysis for Assessing Different Symptoms of Citrus Canker on Grapefruit Leaves. **Plant Disease**, v. 92, n. 4, p. 530–541, 2008.
- BOCK, C. H. et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59–107, 2010.
- CAMARGO, A.; SMITH, J. S. Image pattern classification for the identification of disease causing agents in plants. v. 66, p. 121–125, 2009.
- CANATA, T. . et al. Measuring height of sugarcane plants through LiDAR technology. p. 1–13, 2016.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with

- machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859–881, 2017.
- CHIVASA, W.; MUTANGA, O.; BIRADAR, C. UAV-based multispectral phenotyping for disease resistance to accelerate crop improvement under changing climate conditions. **Remote Sensing**, v. 12, n. 15, 2020.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- CURSI, D. E. et al. History and Current Status of Sugarcane Breeding, Germplasm Development and Molecular Genetics in Brazil. **Sugar Tech**, v. 24, n. 1, p. 112–133, 2022.
- D'HONT, A. Unraveling the genome structure of polyploids using FISH and GISH; examples of sugarcane and banana. **Cytogenetic and Genome Research**, v. 109, n. 1–3, p. 27–33, 2005.
- DAL-BIANCO, M. et al. Sugarcane improvement: How far can we go? **Current Opinion in Biotechnology**, v. 23, n. 2, p. 265–270, 2012.
- DEFINIENS. Definiens Developer XD 2.0.4 Reference Book. p. 106, 2012.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, n. 3, p. 1091–1116, 2013.
- FAHLGREN, N.; GEHAN, M. A.; BAXTER, I. Lights, camera, action: High-throughput plant phenotyping is ready for a close-up. **Current Opinion in Plant Biology**, v. 24, p. 93–99, 2015.
- FERRARI, J. T. et al. Ferrugem alaranjada da cana-de-açúcar no Brasil. **Biológico**, v. 75, p. 71–74, 2013.
- FORREST, W. et al. **Disease assessment terms and concepts**. *Plant Disease*, 1991. Disponível em: <<http://agris.fao.org/agris-search/search/display.do?f=2012/OV/OV201208481008481.xml;US19930116789>>
- FURBANK, R. T.; TESTER, M. Phenomics - technologies to relieve the phenotyping bottleneck. **Trends in Plant Science**, v. 16, n. 12, p. 635–644, 2011.
- GIRARD, J. H. H. T. J. C. Targeted mapping of a sugarcane rust resistance gene (Bru1) using bulked segregant analysis and AFLP markers. v. 570, p. 759–764, 2004.
- GRANDINI, M.; BAGLI, E.; VISANI, G. Metrics for Multi-Class Classification: an Overview. p. 1–17, 2020.
- GRIVET, L.; ARRUDA, P. Sugarcane genomics: Depicting the complex genome of an important tropical crop. **Current Opinion in Plant Biology**, v. 5, n. 2, p. 122–127, 2002.
- HASSAN, M. A. et al. Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. **Plant Methods**, v. 15, n. 1, p. 1–12, 2019.
- HAYNES, K.; WEINGARTNER, D. P. The Use of Area Under the Disease Progress Curve to Assess Resistance to Late Blight in Potato Germplasm. **American Journal Of Potato Research**, n. December 2003, p. 137–141, 2004.

- HOY, J. W.; HOLLIER, C. A. Effect of Brown Rust on Yield of Sugarcane in Louisiana. **Plant Disease**, v. 93, n. 11, p. 1171–1174, 2009.
- HUANG, H. et al. Detection of helminthosporium leaf blotch disease based on UAV imagery. **Applied Sciences (Switzerland)**, v. 9, n. 3, p. 1–14, 2019.
- KARLOVSKA, A. et al. PLANT REFLECTED SPECTRA DEPENDING ON BIOLOGICAL CHARACTERISTICS AND GROWTH CONDITIONS. **International Scientific Conference Rural Development 2017**, 2016.
- KHAN, A.; YADAV, M. S. Image Processing Based Disease Detection for Sugarcane Leaves. **International Journal Of Advance Research, Ideas And Innovations In Technology**, v. 3, n. 4, p. 497–502, 2017.
- LEIVA-VALENZUELA, G. A.; AGUILERA, J. M. Automatic detection of orientation and diseases in blueberries using image analysis to improve their postharvest storage quality. **Food Control**, v. 33, n. 1, p. 166–173, 2013.
- LIEBISCH, F. et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. **Plant Methods**, v. 11, n. 1, 2015.
- LU, J.; TAN, L.; JIANG, H. Review on convolutional neural network (CNN) applied to plant leaf disease classification. **Agriculture (Switzerland)**, v. 11, n. 8, p. 1–18, 2021.
- MAHLEIN, A.-K. Present and Future Trends in Plant Disease Detection. **Plant Disease**, v. 100, n. 2, p. 1–11, 2016.
- MAIA JÚNIOR, S. DE O. et al. Caracterização Morfológica E Produtiva E Suas Correlações Em Cultivares De Cana-De-Açúcar. **Revista Ciência Agrícola**, v. 16, n. 1, p. 31–42, 2018.
- MANAVALAN, R. Efficient Detection of Sugarcane Diseases through Intelligent Approaches : A Review. **Asian Journal of Research and Review in Agriculture**, v. 3, n. 4, p. 27–37, 2021.
- MORIYA, E. A. S. et al. Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 2, p. 740–748, 2017.
- MUTKA, A. M.; BART, R. S. Image-based phenotyping of plant disease symptoms. **Frontiers in Plant Science**, v. 5, n. 1, p. 1–8, 2015.
- NEILSON, E. H. et al. Utilization of a high-throughput shoot imaging system to examine the dynamic phenotypic responses of a cereal crop plant to nitrogen and water deficiency over time. **Journal of Experimental Botany**, v. 66, n. 7, p. 1817–1832, 2015.
- NEWTON, A. C.; HACKETT, C. A. Subjective components of mildew assessment on spring barley. **European Journal of Plant Pathology**, v. 100, n. 6, p. 395–412, 1994.
- NIEMEYER, J.; ROTTENSTEINER, F.; SOERGEL, U. Contextual classification of lidar data and building object detection in urban areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 152–165, 2014.
- PATIL, S. B.; BODHE, S. K. Leaf Disease Severity Measurement Using Image Processing.

- International Journal of Engineering and Technology**, v. 3, n. 5, p. 297–301, 2011.
- PICOLI, M. C. A. et al. The use of ALOS/PALSAR data for estimating sugarcane productivity. **Engenharia Agrícola**, v. 34, n. 6, p. 1245–1255, 2015.
- QIN, F. et al. Identification of alfalfa leaf diseases using image recognition technology. **PLoS ONE**, v. 11, n. 12, p. 1–26, 2016.
- RACZKO, E.; ZAGAJEWSKI, B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. **European Journal of Remote Sensing**, v. 50, n. 1, p. 144–154, 2017.
- RAUT, S.; INGOLE, K. Review On Leaf Disease Detection Using Image Processing Techniques. **International Research Journal of Engineering and Technology (IRJET)**, v. 4, n. 4, p. 22–24, 2017.
- REYNOLDS, M. et al. Breeder friendly phenotyping. **Plant Science**, v. 295, n. December 2019, p. 110396, 2020.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. December 2018, p. 2–10, 2019a.
- ROITSCH, T. et al. Review: New sensors and data-driven approaches—A path to next generation phenomics. **Plant Science**, v. 282, n. January, p. 2–10, 2019b.
- SAITO, É. A.; IMAI, N. N.; TOMMASELLI, A. M. G. Análise Espectral De Amostras De Cana-De-Açúcar. **Anais do III Simpósio Brasileiro de Geomática**, n. 1, p. 169–174, 2012.
- SANJEL, S. et al. Comparison of progress of brown rust and orange rust and conditions conducive for severe epidemic development during the sugarcane crop season in Florida. **Plant Disease**, v. 103, n. 5, p. 825–831, 2019.
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1–13, 2010.
- SANTOS, F.; BORÉM, A. Cana-de-açúcar: do Plantio à Colheita. n. June, p. 89–115, 2013.
- SCHAAD, N. W.; FREDERICK, R. D. Real-time PCR and its application for rapid plant disease diagnostics. **Canadian Journal of Plant Pathology**, v. 24, n. 3, p. 250–258, 2002.
- SHAKOOR, N.; LEE, S.; MOCKLER, T. C. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field. **Current Opinion in Plant Biology**, v. 38, p. 184–192, 2017.
- SHI, Y.; WANG, X.; ZHANG, S. Plant disease leaf image segmentation using K-Means clustering based on internet of things. **International Journal of Research in Agricultural Sciences**, v. 3, n. 2, p. 2348–3997, 2016.
- SIMKO, I.; PIEPHO, H. P. The area under the disease progress stairs: Calculation, advantage, and application. **Phytopathology**, v. 102, n. 4, p. 381–389, 2012.
- SOCA-MUÑOZ, J. L. et al. Spectral signature of brown rust and orange rust in sugarcane. **Revista Facultad de Ingeniería**, n. 96, p. 9–20, 2020.

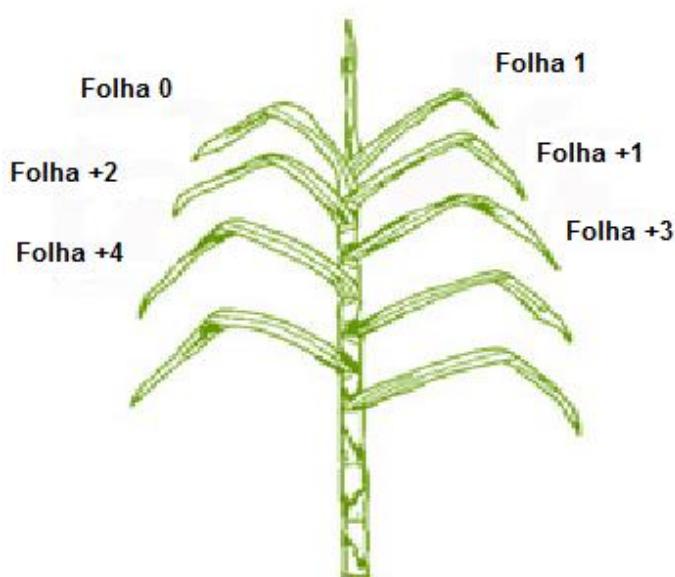
- SONG, Y. et al. **IKNN: Informative K-nearest neighbor pattern classification.** [s.l.: s.n.]. v. 4702 LNAI
- SRIVASTAVA, S. et al. A Novel Deep Learning Framework Approach for Sugarcane Disease Detection. **SN Computer Science**, v. 1, n. 2, p. 1–7, 2020.
- STEDDOM, K. et al. Comparison of Visual and Multispectral Radiometric Disease Evaluations of Cercospora Leaf Spot of Sugar Beet. **Plant Disease**, v. 89, n. 2, p. 153–158, 2005.
- THAILAMBAL, G.; YOGESHWARI, M. Automatic segmentation of plant leaf disease using improved fast Fuzzy C-Means clustering and adaptive Otsu thresholding. **European Journal of Molecular and Clinical Medicine**, v. 7, n. 3, p. 5447–5462, 2020.
- THANH NOI, P.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, 2017.
- THOMPSON, L. J.; PUNTEL, L. A. Transforming unmanned aerial vehicle (UAV) and multispectral sensor into a practical decision support system for precision nitrogen management in corn. **Remote Sensing**, v. 12, n. 10, 2020.
- TRIMBLE INC. eCognition Developer 9.1. n. March, 2017.
- TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.
- VERMA, A. K. et al. Modelling of sugarcane yield using LISS-IV data based on ground LAI and yield observations. **Geocarto International**, v. 0, n. 0, p. 1–18, 2019.
- WONG T., H. et al. Feature extraction based on object oriented analysis. **Proceedings of ATC**, p. 1–10, 2003.
- YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, 2017.
- YANG, M. et al. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, n. June, p. 1–16, 2020a.
- YANG, W. et al. Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives. **Molecular Plant**, v. 13, n. 2, p. 187–214, 2020b.
- YANG, X. Parameterizing Support Vector Machines for Land Cover Classification. **Photogrammetric Engineering & Remote Sensing**, v. 77, n. 1, p. 27–37, 2011.
- YE, H. et al. Identification of banana fusarium wilt using supervised classification algorithms with UAV-based multi-spectral imagery. **International Journal of Agricultural and Biological Engineering**, v. 13, n. 3, p. 136–142, 2020.
- YENDREK, C. R. et al. High-throughput phenotyping of maize leaf physiological and biochemical traits using hyperspectral reflectance. **Plant Physiology**, v. 173, n. 1, p. 614–626, 2017.

- YUE, J. et al. A comparison of crop parameters estimation using images from UAV-mounted snapshot hyperspectral sensor and high-definition digital camera. **Remote Sensing**, v. 10, n. 7, 2018.
- ZAMAN-ALLAH, M. et al. Unmanned aerial platform-based multi-spectral imaging for field phenotyping of maize. **Plant Methods**, v. 11, n. 1, p. 1–10, 2015.
- ZHANG, D. et al. Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. **PLoS ONE**, v. 13, n. 5, p. 1–14, 2018.
- ZHENG, Q. et al. New spectral index for detecting wheat yellow rust using sentinel-2 multispectral imagery. **Sensors (Switzerland)**, v. 18, n. 3, p. 1–19, 2018.
- ZHOU, J. et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. **Computers and Electronics in Agriculture**, v. 175, n. March, p. 105576, 2020.

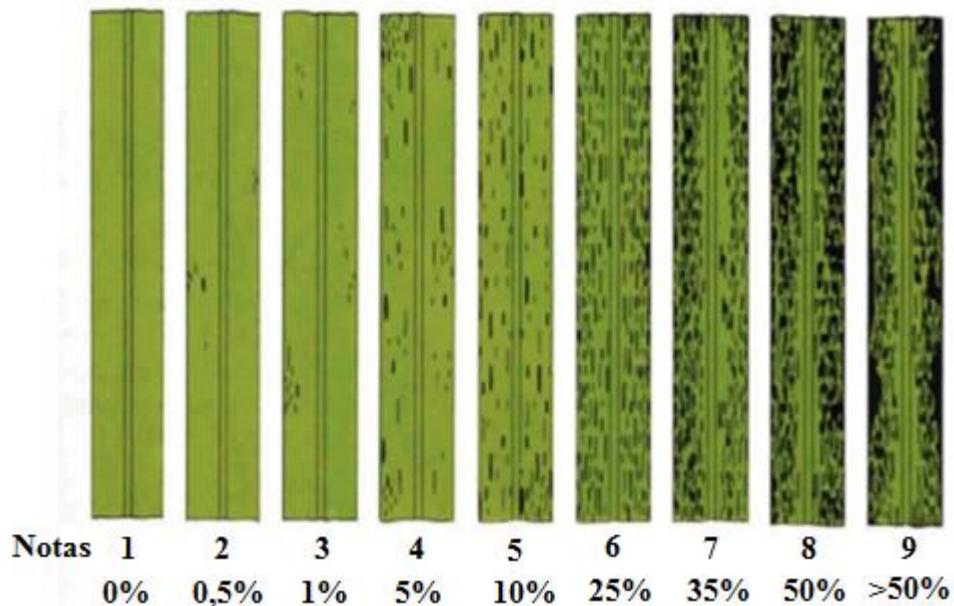
## APÊNDICE A – ESTUDOS PRELIMINARES E DETALHAMENTO EXPERIMENTAL

### CAPÍTULO 3

As avaliações de resistência às ferrugens alaranjada e marrom feitas em campos experimentais de melhoramento da cana-de-açúcar são feitas a cada 15 dias, iniciando-se quando as plantas atingem idade de aproximadamente 5 meses, que é quando elas se mostram mais suscetíveis à ferrugem (BARRETO et al., 2017). Para tal, são realizadas verificações visuais nas folhas +3 (Figura 15) de 10 plantas em cada parcela experimental (BARRETO et al., 2017), cada uma cultivada com uma variedade a ser avaliada. Nessa avaliação atribui-se notas de 1 (0% de área foliar com sintomas) a 9 (mais de 50% de área foliar com sintomas) para a identificação do nível de severidade da doença. De acordo com a escala de diagnóstico estabelecida pela Coordenadoria de Fitopatologia do Centro de Tecnologia Copersucar (AMORIM et al., 1987; CDA, 2010) (Figura 16). Após a atribuição das notas a cada planta das parcelas experimentais é calculada a nota média de severidade da doença para cada parcela. As classes de resistência à ferrugem são: variedades resistentes, moderadamente suscetíveis e suscetíveis. Essas classes são atribuídas as variedades após a finalização das avaliações de acordo com a área abaixo da curva de infecção (AUDPC) gerada com a atribuição das notas para cada parcela ao longo das avaliações. Variedades classificadas como susceptíveis são excluídas do programa de melhoramento. Neste trabalho, o nível de severidade obtido pela avaliação visual foi considerado como referência para avaliar os métodos de processamento das imagens.



**Figura 15.** Esquema de numeração de folhas pelo sistema de Kuijper. Fonte: DILLEWIJN, 1952, adaptado pela autora.



**Figura 16.** Escala de diagnóstico de folhas infectadas por ferrugens estabelecida pela Copersucar.



**Figura 17.** À esquerda, lesões (pústulas) de ferrugem marrom e, à direita, de ferrugem alaranjada.

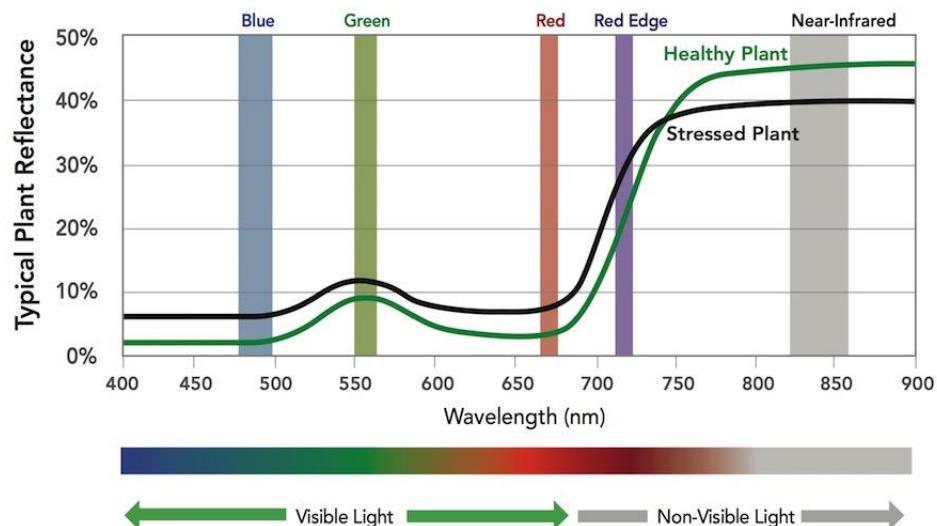
Quando do início das avaliações no campo experimental, a largura das folhas está entre 4 a 5 cm (MAIA JÚNIOR et al., 2018). Os sintomas da ferrugem marrom aparecem como pontuações cloróticas, mais visíveis na contraluz e lesões alongadas de margem irregular, geralmente com 0,2 a 1,0 cm de comprimento e 0,1 cm de largura, de coloração marrom a marrom escura, visíveis de ambos os lados da folha. O mesmo ocorre com os sintomas da ferrugem alaranjada, porém com coloração mais alaranjada (SANTOS; BORÉM, 2013). Desse modo, o menor objeto a ser evidenciado no mapeamento são lesões com 0,2 a 0,5 cm de comprimento e 0,1 cm de largura, exigindo uma resolução espacial das imagens de 0,5 cm ou menos (ZHANG et al., 2018).

Para tanto, avaliamos a utilidade dos dados de duas câmeras acopladas ao VANT para realizar a fenotipagem em relação a infecção pelas ferrugens. A primeira foi uma câmera **digital RGB** (G9x, Canon, Ohta-ku, Tokyo, Japan), com dimensão de imagem de 20,2 megapixels e 14 bits de resolução radiométrica. A tentativa de se trabalhar com câmera RGB se justificou pelo seu menor custo e facilidade de processamento. A camera RGB também permite uma maior resolução espacial em comparação com a câmera multiespectral e portanto, teria maior possibilidade de gerar imagens com GSD de 0,5 cm ou menos. A outra câmera avaliada foi uma **multiespectral de alta resolução**, **Micasense Rededge** (RedEdgeTM, MicaSense, Seattle, Washington, USA), com 16 megapixels, que trabalha com as bandas Azul (465-485nm), Verde (550-570nm), Vermelho (663-673nm), Red Edge

(712-722nm) e Infravermelho Próximo (820-860nm), apresentando 12 bits de resolução radiométrica (Figura 18). Esse sensor tem menor possibilidade de gerar imagens resolução espacial suficiente para individualizar pequenas lesões menores de 0,5 cm, uma vez que essa também é a medida espacial física entre seus filtros, porém, juntamente com o sensor solar, regista dados de refletância em todas as bandas disponíveis (Figura 19), possibilitando uma análise de vigor da vegetação mais detalhada.



**Figura 18.** Sensor multiespectral Micasense Rededge.



**Figura 19.** Bandas disponíveis no sensor Micasense Rededge e assinatura espectral típica da vegetação saudável e estressada.

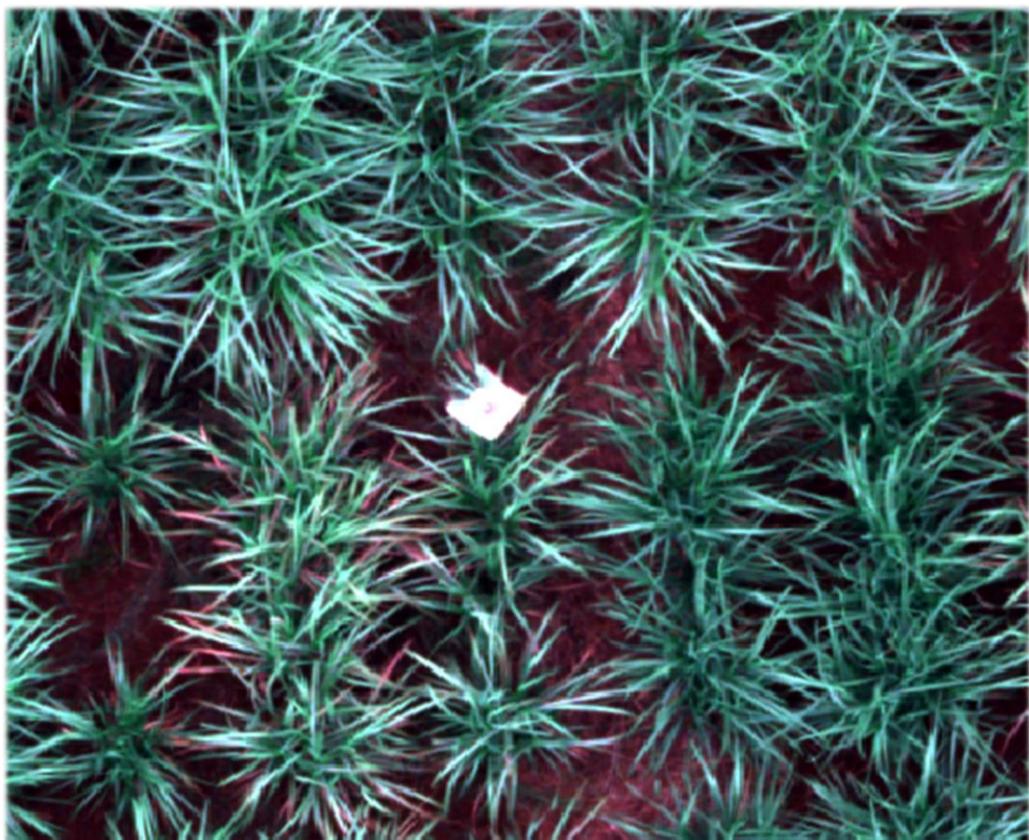
Para portar as câmeras, trabalhamos com um drone quadrirotor (G-drones Q-45, São Paulo, SP, Brasil) (Figura 20). O sistema é equipado com placa controladora para voos autônomos que possui GPS (Global Position System) e unidade de navegação inercial. Possui estabilidade de voo suficiente para realização de voo com baixas velocidade e altitude, ideal para imageamento detalhado das parcelas experimentais.



**Figura 20.** Veículo aéreo não tripulado escolhido para este estudo.

### Aquisição das imagens com VANT

As aquisições das imagens foram feitas nas mesmas datas em que foram realizadas as avaliações visuais de infecção pelas ferrugens, com total de quatro avaliações em um período de aproximadamente dois meses. O objetivo foi adquirir imagens com **resolução espacial superior a 0,5 cm** para permitir a individualização das lesões. Para tanto, investigamos os parâmetros de voo adequados: 1 - altura, 2 - sobreposição das imagens e 3 - velocidade de voo. Também foram utilizados pontos de controle em solo (Ground Control Points - GCPs) (Figura 21) para retificação e registro das imagens.

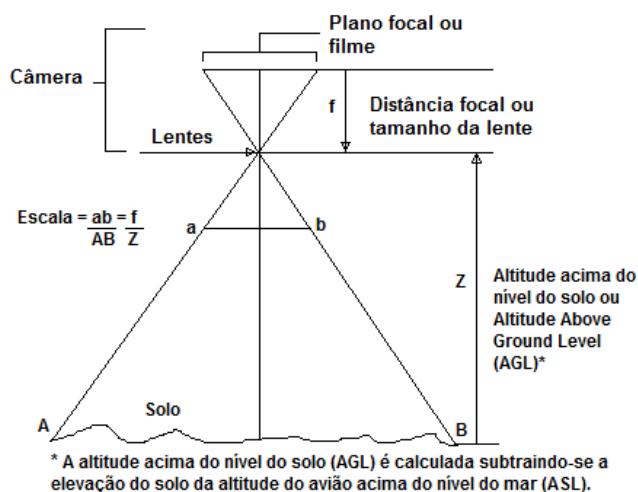


**Figura 21.** Exemplo de ponto de controle utilizado no campo experimental.

## 1 - Altura de voo

A altitude do voo é o fator crucial na capacidade do sistema em detectar os sintomas das ferrugens, possibilitando assim a estimativa da severidade de infecção. As altitudes de voo determinadas teoricamente por meio de cálculos foram testadas por meio da posterior identificação das primeiras pústulas nas imagens adquiridas. Apesar da altura teórica de voo poder ser calculada, quando o objetivo é se obter resoluções muito altas essa altura pode não fornecer a qualidade esperada, gerando a necessidade de se testar algumas alturas próximas a de cálculo até que se obtenha a resolução adequada. Além disso a altura calculada não leva em consideração a altura das plantas, portanto fez-se testes para se obter a altura ideal para esta aplicação.

Para aquisição das imagens com a **câmera digital RGB Canon G9x** a altura de voo teórica obtida por meio de cálculo da razão entre as dimensões do sensor da câmera e as dimensões do terreno compreendido na imagem (Figura 22) é de aproximadamente 50 m. Essa altura não foi adequada para detecção ou visualização de pixels puros dos sintomas, então, alturas menores como 45 e 40 m foram testadas. A altura de voo que permitiu a visualização de pústulas foi de 7 metros, porém, com essa resolução, não foi possível o mosaicingamento das imagens, uma vez que o algoritmo não foi capaz de encontrar pontos homólogos em imagens tão semelhantes. Sem a possibilidade de visualização das pústulas com a câmera RGB, que permite obter maior resolução espacial, optou-se pela continuidade do estudo com a câmera multiespectral.



**Figura 22.** Parâmetros para o cálculo da altura de voo para aquisição das imagens com câmera digital RGB.

Para a **câmera multiespectral Micasense Rededge** a altura teórica de voo para um Ground Sample Distance (GSD) ou resolução espacial de 0,5 cm é de 5,4 m de altura calculada por meio da calculadora de voo disponibilizada e indicada pelo fabricante do sensor (Figura 23) (MicaSense, Inc., Seattle, WA, EUA). Porém, assim como aconteceu com os dados da câmera RGB, com essa resolução, também não foi possível encontrar pontos homólogos entre as imagens suficientes para o mosaicingamento das mesmas. Portanto testou-se maiores alturas de voo e descartou-se a possibilidade de individualização das pústulas em pixels de imagens aéreas. Partimos então para o objetivo de trabalhar com os valores de refletância das plantas, com menor altura adequada determinada de 26

m. A sugestão do fabricante para aplicações que exigem voos a altitudes abaixo de 40 m é que se voe sobre a mesma área em pelo menos duas altitudes separadas. Primeiramente deve-se voar na altitude determinada para resolução desejada e depois a uma altitude de 1,5 a 2 vezes maior. Porém, como descrito acima, não conseguimos mosaicar as imagens de voos mais baixo.

## MicaSense Pre-Flight Calculator for RedEdge and Altum

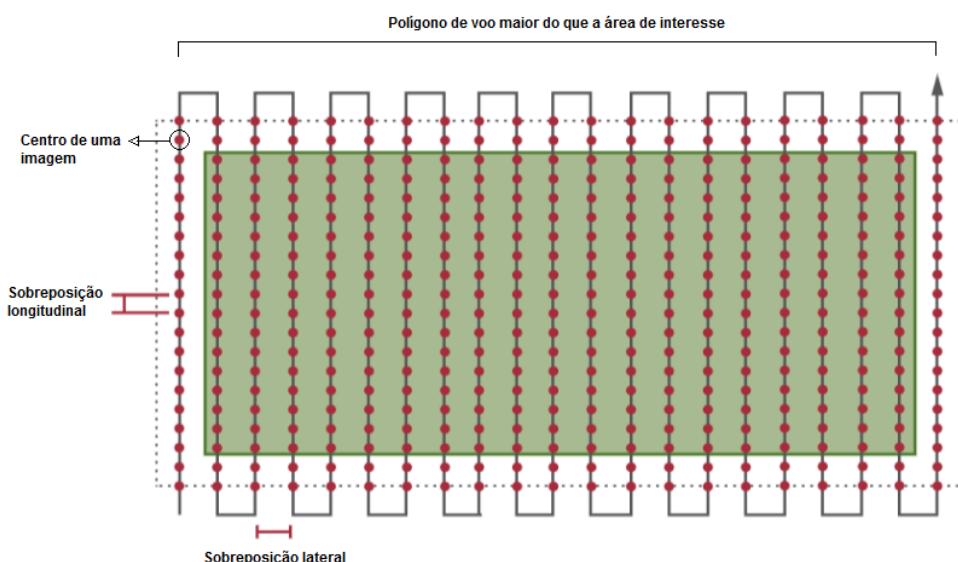
Note: Altum calculates multispectral bands only at this time.

The screenshot shows the 'Mission Input' section of the calculator. It includes fields for Camera (RedEdge), Altitude AGL (10 m), Flight Speed (1 m/s), Forward Overlap (75%), Camera Orientation (Portrait), Aircraft Type (Multi Copter), GSD (0.72 cm), Area of the Field (0.5 ha), Cross Overlap (75%), and Image Output (TIFF (16bit)). A 'Calculate' button is at the bottom right.

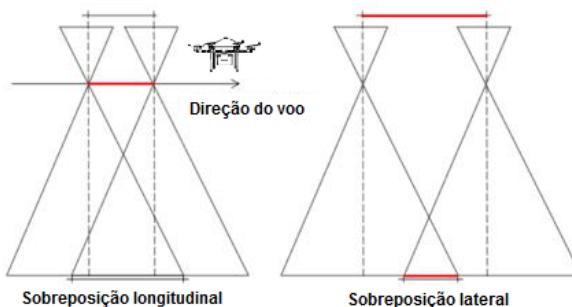
**Figura 23.** Interface da calculadora de voo da fabricante Micasense (MicaSense, Inc., Seattle, WA, EUA).

### 2 – Sobreposição das imagens

Para a coleta das imagens coloridas RGB e multiespectrais foram utilizadas as sobreposições 80% longitudinal e 80% lateral para ortomosaicos de alta resolução espacial. Também planejou-se o voo com polígono 20% maior do que a área de interesse para evitar os efeitos de distorção de bordas nos mosaicos (Figuras 24 e 25) (TURNER; LUCIEER; WATSON, 2012).



**Figura 24.** Polígono de plano de voo, com sobreposições lateral e longitudinal e com área maior do que a área de interesse (MicaSense, Inc., Seattle, WA, EUA – adaptada pela autora).



**Figura 25.** Sobreposições longitudinal e lateral das imagens (MicaSense, Inc., Seattle, WA, EUA – adaptada pela autora).

### 3 – Velocidade de voo e posição em relação ao vento

O VANT escolhido opera sob ventos de até 39 km/h. Manuais de melhores práticas (HORUS, 2018) sugerem que se planeje o voo na direção perpendicular 90° ou 45° em relação a direção do vento, porém esse fator não é tão crítico para VANTs multirotore. Então o plano de voo foi feito na direção que permitiu maior desvio dos obstáculos da área experimental como postes e outros (Figura 26). A velocidade foi de 1 m/s para o voo a 26 m de altura com a câmera multispectral.



**Figura 26.** Plano de voo realizado no software livre Mission Planner.

### 4 - Horário dos voos e condições climáticas para iluminação

Para a coleta das imagens com a câmera multispectral, a sugestão do fabricante é que se colete as imagens dentro de até 2 horas e meia a partir das 12h00. A instrução foi seguida. Os fabricantes apontam que com o céu livre de nuvens, entre 11h30 e 12h30 (sol a pino), podem ocorrer problemas de iluminação com áreas muito claras ou manchas brilhantes nos dados capturados, portanto é recomendado que se voe enquanto o sol está com ângulos menores. Portanto os voos foram realizados entre 10h00 e 14h00.

Como as épocas mais chuvosas são propícias para desenvolvimento das ferrugens na cana-de-açúcar, houve cobertura de nuvens durante os dias de avaliação e portanto a iluminação foi calibrada

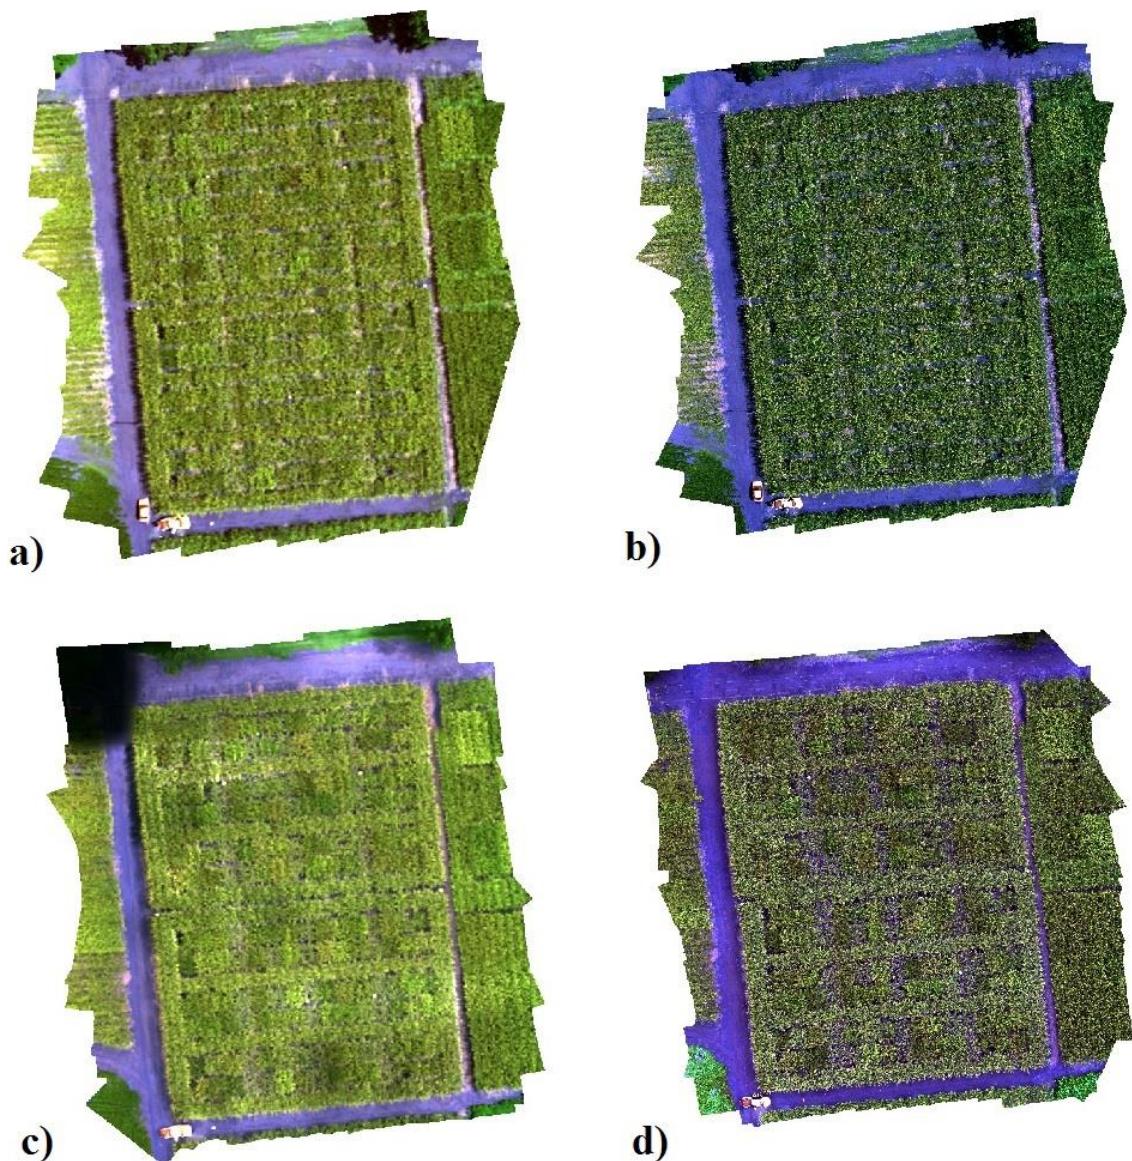
com auxílio dos dados registrados pelo sensor solar.



**Figura 27.** Foto de trabalho em campo.

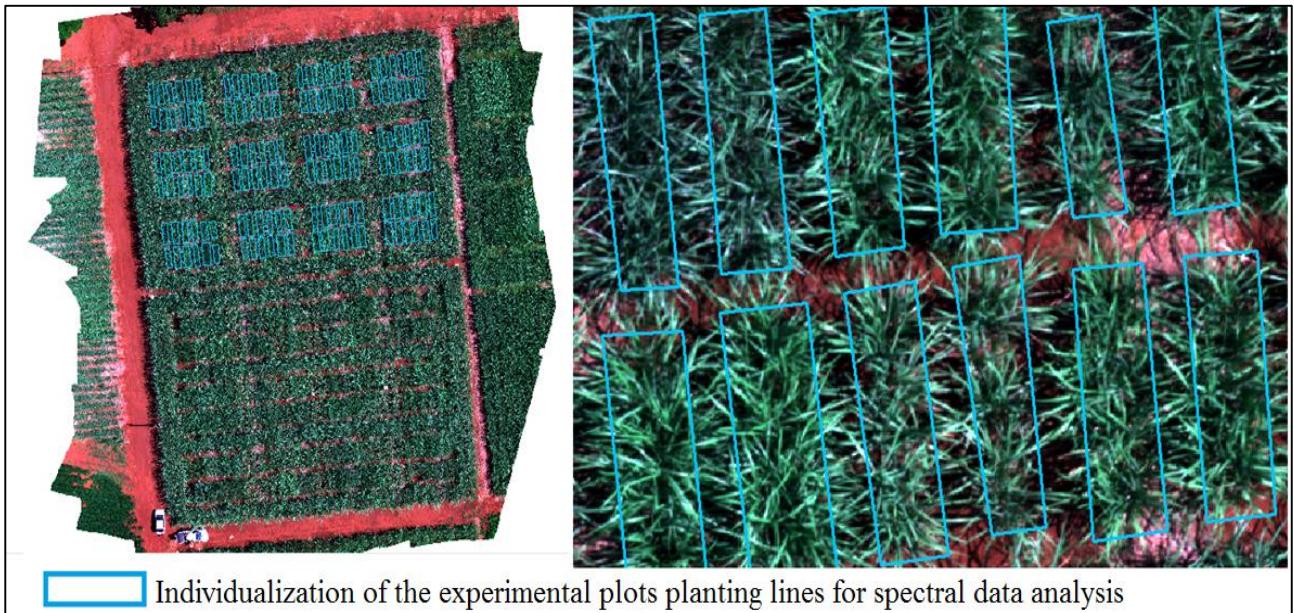
### **Processamento das imagens**

As imagens foram processadas no Software Agisoft Metashape de acordo com as instruções para trabalho com imagens multiespectrais adquiridas com sensor Micasense Rededge-MX (AGISOFT METASHAPE, 2021). As instruções incluem: procedimento para calibração de refletância (com painel solar ou sensor solar), otimização de alinhamento das imagens para geração de mosaico e cálculo dos valores de refletância. Os mosaicos das quatro avaliações foram então analisados com valores de refletância (0 a 1) (Figura 28).



**Figura 28.** Mosaicos das avaliações a) 1, b) 2, c) 3 e d) 4.

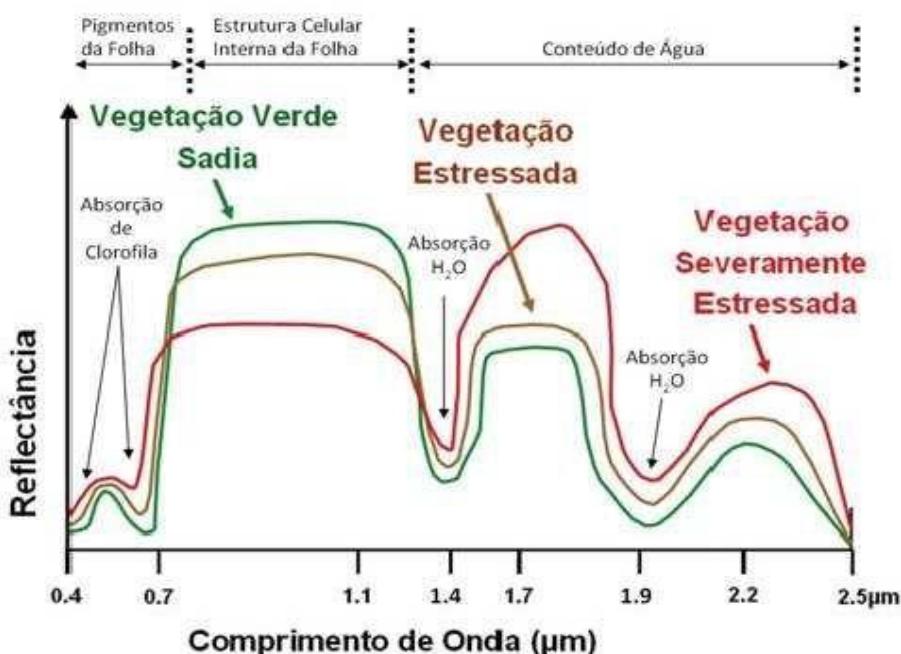
Os mosaicos foram então abertos no software Qgis para confecção do shapefile das parcelas experimentais para análise no software R (Figura 29).



**Figura 29.** Shapefile para análise de imagem das parcelas experimentais.

### Considerações adicionais sobre os resultados do capítulo 3

Conforme apresentado no capítulo 3, a banda vermelha do sensor multiespectral se mostrou mais importante que as demais variáveis preditoras ao longo das avaliações de resistência às ferrugens, tanto na relação direta com as notas de infecção quanto para a classificação fenológica pelos modelos de ML e, portanto, os dados relativos foram estudados com maior profundidade. A refletância da vegetação na banda vermelha tem relação direta com a absorção da luz nesses comprimentos de onda para realização da fotossíntese (Figura 30). Uma vez que essa é prejudicada com infecção pelas ferrugens, principalmente pela ferrugem marrom, a luz é menos absorvida e portanto mais refletida, aumentando a refletância na banda vermelha do sensor.



**Figura 30.** Assinatura espectral típica da vegetação (Filho et al., 2008).

Os gráficos da figura 31 mostram que há um aumento de refletância na banda à medida que a susceptibilidade entre as variedades aumenta, mais perceptível após os 165 DAP, quando as plantas já estão com infecção mais avançada. Esse padrão de refletância no vermelho em relação as classes de resistência atribuídas às variedades pode não ser preciso uma vez que a classificação é feita visualmente e está sujeita a viés humano. No entanto, podemos perceber que quanto mais suscetível, maior tende ser a refletância na banda ao longo das avaliações. Essa análise pode permitir uma maior confiança nos resultados finais da fenotipagem, servindo como parâmetro de confirmação da classificação e aumentando o banco de dados dos programas de melhoramento genético para possível confrontamento com dados de marcadores moleculares genéticos.



**Figura 31.** Padrão de refletância médio de três repetições de parcelas de variedades de cana-de-açúcar na banda do vermelho aos 150, 165, 180 e 195 DAP bem como o valor da AUDPC – refletância para a banda do vermelho de acordo com a classe final de resistência às ferrugens alaranjada e marrom atribuída pelo programa de melhoramento genético. Os gráficos evidenciam o aumento da refletância na banda do vermelho de acordo com a susceptibilidade das variedades a partir dos 165 DAP.

**APÊNDICE B – DETALHAMENTO EXPERIMENTAL CAPÍTULO 4**

As folhas infectadas com as ferrugens alaranjada e marrom foram fotografadas de maneira a abranger os 30 cm da área mais infectada das folhas uma vez que os sintomas das duas doenças se manifestam de formas diferentes. Os sintomas da ferrugem alaranjada tendem a se manifestar mais nas bases das folhas e os da ferrugem marrom mais do centro às pontas.

O suporte utilizado para aquisição das imagens possibilitou que a câmera ficasse a 35 cm das folhas (Figura 32). Essa altura foi suficiente para abranger os 30 cm desejados das folhas nas imagens. Essa medida também foi utilizada em alguns trabalhos para observação de folhas de cana-de-açúcar em imagens RGB digitais (KHAN; YADAV, 2017).



**Figura 32.** Suporte para câmera utilizado para aquisição de imagens de folhas de cana-de-açúcar infectadas.

A figura 33 apresenta alguns exemplos de imagens de folhas infectadas com ferrugem alaranjada e marrom adquiridas para esse estudo.

**a)****b)**

**Figura 33.** Imagens de folhas de cana-de-açúcar infectadas a) com ferrugem alaranjada e b) com ferrugem marrom.