

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP  
CÂMPUS DE JABOTICABAL**

**MAPEAMENTO DE FALHAS EM CANA-DE-AÇÚCAR POR  
IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO**

**Marcelo Rodrigues Barbosa Júnior  
Engenheiro Agrônomo**

**2021**

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP**

**CÂMPUS DE JABOTICABAL**

**MAPEAMENTO DE FALHAS EM CANA-DE-AÇÚCAR POR  
IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO**

**Discente: Marcelo Rodrigues Barbosa Júnior**

**Orientador: Prof. Dr. Cristiano Zerbato**

Dissertação de mestrado apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP, Câmpus de Jaboticabal, como parte das exigências para obtenção do título de Mestre em Agronomia (Produção Vegetal).

B238m                      Barbosa Júnior, Marcelo Rodrigues

                                Mapeamento de falhas em cana-de-açúcar por imagens de  
veículo aéreo não tripulado / Marcelo Rodrigues Barbosa  
Júnior. -- Jaboticabal, 2021

                                51 f. : tabs., fotos

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

                                Orientador: Cristiano Zerbato

                                1. Agricultura digital. 2. Drone. 3. Cana-de-açúcar. 4.  
Fotogrametria aérea. 5. Sensoriamento remoto. I. Título.

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

Essa ficha não pode ser modificada.

**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA DISSERTAÇÃO: MAPEAMENTO DE FALHAS EM CANA-DE-AÇÚCAR POR IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO

**AUTOR: MARCELO RODRIGUES BARBOSA JÚNIOR**

**ORIENTADOR: CRISTIANO ZERBATO**

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (PRODUÇÃO VEGETAL), pela Comissão Examinadora:



Prof. Dr. CRISTIANO ZERBATO (Participação Virtual)  
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal



Prof. Dr. ROOVERSON PEREIRA DA SILVA (Participação Virtual)  
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal



Prof. Dr. RYCHARDSON ROCHA DE ARAÚJO (Participação Virtual)  
Departamento de Engenharia Agrícola / Universidade Federal de Sergipe - São Cristóvão/SE

Jaboticabal, 22 de fevereiro de 2021

## **DADOS CURRICULARES DO AUTOR**

**MARCELO RODRIGUES BARBOSA JÚNIOR**, filho de Marcelo Rodrigues Barbosa e Maria Aparecida de Oliveira Barbosa, nasceu em Arapiraca – AL no dia 29 de outubro de 1996, município localizado no interior do Estado de Alagoas. cursou ensino fundamental e médio no município de Limoeiro de Anadia – AL, no período entre 2003 a 2013. Em 2014 iniciou o curso de bacharelado em Agronomia na Universidade Federal de Alagoas – UFAL, Câmpus de Arapiraca. Durante o curso foi membro do Grupo de Estudos Água-Solo-Planta-Atmosfera (Grupo Irriga), desenvolvendo atividades de pesquisa aplicada, extensão e inovação tecnológica em manejo de água para irrigação. Foi bolsista no Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação da Universidade Federal de Alagoas (PIBITI – CNPq/UFAL/FAPEAL) por dois anos e bolsista de extensão (PROEX) por um ano, na área de manejo de irrigação, sob a orientação do Prof. Dr. Márcio Aurélio Lins dos Santos. Atuou como Diretor de Gestão de Pessoas e Vice-Presidente na MultAgro Júnior – Projetos e Consultorias, Empresa Júnior do curso de Agronomia da UFAL. Obteve título de Engenheiro Agrônomo no ano de 2019. No mesmo ano ingressou no Programa de Pós-graduação em Agronomia (Produção Vegetal) na Universidade Estadual Paulista “Júlio de Mesquita Filho” Faculdade de Ciências Agrárias e Veterinárias, Câmpus de Jaboticabal – UNESP/FCAV, sob orientação do Prof. Dr. Cristiano Zerbato. É integrante do Laboratório de Máquinas e Mecanização Agrícola (LAMMA), participando de projetos relacionados à agricultura de precisão, agricultura digital e sensoriamento remoto, com ênfase na utilização de drones, para obtenção de informações precisas de culturas agrícolas.

“A persistência é o caminho do êxito”.

**Charles Chaplin**

Aos meus pais, Marcelo Rodrigues Barbosa e Maria Aparecida de Oliveira Barbosa, avós paternos, José Gomes Barbosa (Ié Ribeiro) e Maria Rodrigues Barbosa (*in memoriam*), avós maternos, José Cícero de Oliveira (Zé do Né) e Maria Áurea Barbosa de Oliveira.

**DEDICO!**

## **AGRADECIMENTOS**

À minha família, em nome dos meus pais, Marcelo Rodrigues Barbosa e Maria Aparecida de Oliveira Barbosa, e minha irmã, Vitória de Oliveira Barbosa, por todo apoio e incentivo nesta minha jornada.

À minha namorada Thaís Gomes, pelo grande empenho e ajuda nos estudos, trabalhos e na minha formação como um todo.

À Universidade Federal de Alagoas pelas condições dadas para a formação profissional (Engenheiro Agrônomo) e pessoal, principalmente por todos os valores adquiridos. Ao Prof. Dr. Márcio Aurélio Lins dos Santos, pela orientação durante a graduação, disponibilidade para o desenvolvimento de trabalhos, pelos conselhos e confiança. Ao conhecimento adquirido no Grupo de Pesquisa, Extensão e Inovação Tecnológica em Manejo de Água para Irrigação – Grupo Irriga, fundamental para ingressar em um curso de Pós-graduação.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Câmpus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal).

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

Ao meu orientador Prof. Dr. Cristiano Zerbato, que tenho grande admiração e consideração pelo seu trabalho. Por sua confiança e pela oportunidade de poder trabalhar com algo novo.

Aos integrantes e parceiros do Laboratório de Máquinas e Mecanização Agrícola – LAMMA. Estendo os agradecimentos a todos Professores e Funcionários do Departamento de Engenharia e Ciências Exatas.

Finalmente gostaria de agradecer a todos que, de forma direta ou indireta, contribuíram para a realização e conclusão deste trabalho. Minha sincera gratidão.

**Essa conquista também pertence a vocês!**

## SUMÁRIO

RESUMO.....	i
ABSTRACT.....	ii
LISTA DE TABELAS .....	iii
LISTA DE FIGURAS.....	iv
<b>CAPÍTULO 1 – Considerações gerais.....</b>	<b>1</b>
1. Introdução.....	1
1.1. Revisão de literatura .....	2
1.1.1. Cultura da cana-de-açúcar .....	2
1.1.2. Falhas em cana-de-açúcar .....	5
1.1.3. Métodos para avaliação de falhas .....	6
1.1.3.1. Método de avaliação manual .....	6
1.1.3.2. Método de avaliação por veículos terrestres .....	7
1.1.3.3. Método de avaliação por imagens UAV .....	8
1.1.4. Drones na agricultura .....	9
1.1.5. Processamento de imagens digitais .....	11
1.2. Referências .....	13
<b>CAPÍTULO 2 - Impacto do tamanho de pixel e altura da planta no mapeamento de falhas em cana-de-açúcar por imagens UAV.....</b>	<b>20</b>
2.1. Introdução.....	20
2.2. Material e métodos .....	22
2.2.1. Área de estudo .....	22
2.2.2. Planejamento experimental.....	22
2.2.2.1. Falhas de campo.....	22
2.2.2.2. Tamanho do pixel .....	23
2.2.2.3. Avaliações biométricas .....	24
2.2.3. Plataforma aérea e sensor.....	25
2.2.4. Processamento das imagens e extração das falhas.....	26
2.2.5. Parâmetros de validação .....	27
2.3. Resultados .....	27
2.4. Discussão .....	31
2.5. Conclusões .....	34
2.6. Referências .....	35
<b>CAPÍTULO 3 – Considerações finais.....</b>	<b>38</b>

## MAPEAMENTO DE FALHAS EM CANA-DE-AÇÚCAR POR IMAGENS DE VEÍCULO AÉREO NÃO TRIPULADO

**RESUMO** – Mapear falhas em canaviais de forma precisa por imagens UAV é um desafio, ainda mais quando não há informações sobre a qualidade das imagens e o momento ideal para capturar as imagens. Neste estudo, nós avaliamos os impactos de tamanhos de pixel e alturas de planta sobre o mapeamento de comprimentos de falha em linhas em cana-de-açúcar por imagens UAV. Este estudo fornece diretrizes para escolher tamanhos de pixel e alturas de planta apropriados para estimar falhas em cana-de-açúcar por imagens UAV. Nossos resultados mostraram que, à medida em que o tamanho do pixel e a altura de planta aumentavam, a precisão na estimativa de falhas pelas imagens tendia a diminuir, além disso, observamos que a estrutura da planta e disposição de suas folhas também influenciaram na identificação das falhas. Para mapear falhas em cana-de-açúcar, o tamanho do pixel pequeno (3,5 cm), assim como menor altura de planta (0,5 m), é sempre necessário para estimar falhas com precisão.

**Palavras-chave:** Altura de planta, Avaliação de falhas, Sensoriamento remoto, Tamanho do pixel; UAV

## MAPPING SKIP IN SUGARCANE BY UNMANNED AERIAL VEHICLE IMAGES

**ABSTRACT** – Mapping skips in sugarcane fields accurately from UAV images is a challenge, especially when there is no information about the quality of the images and the ideal time to capture them. In this study, we evaluated the impacts of pixel sizes and plant heights on the skip mapping in sugarcane using UAV images. This study provides a guideline for choosing appropriate pixel sizes and plant heights to estimate skips in sugarcane using UAV images. Our results showed that the precision in estimating skips by the images tended to decrease as the pixel size and plant height increased. Moreover, we observed that the plant structure and leaf arrangement also influenced the identification of skips. The smaller pixel size (e.g., 3.5 cm) and the lower plant height (e.g., 0.5 m) is always required to estimate and map skips accurately in sugarcane.

**Keywords:** Plant height; Skip assessment; Remote sensing; Pixel size; UAV

## LISTA DE TABELAS

<b>Tabela 1.</b> Porcentagem de falhas definindo a qualidade de plantio.....	6
<b>Tabela 2.</b> Erro percentual médio absoluto (MAPE) entre falha estimada por imagem e a falha de campo para cada tamanho de pixel e altura de planta. Também apresentamos o erro para todas as falhas somadas, na coluna “Total”, resultando em 7,5 m de falhas.....	30

## LISTA DE FIGURAS

- Figura 1.** Exemplo ilustrativo das fases de crescimento de cana-de-açúcar. O número de dias de cada fase pode variar dependendo da cultivar de cana-de-açúcar. ....5
- Figura 2.** Exemplo ilustrativo da aplicação do método manual.....7
- Figura 3.** Exemplo ilustrativo da aplicação do método por veículos terrestres. ....8
- Figura 4.** Exemplo ilustrativo da aplicação do método por imagens UAV. ....9
- Figura 5.** Exemplo ilustrativo dos elementos de uma imagem digital. (a) imageamento por plataformas de sensoriamento remoto. (b) matriz de pixels da imagem digital... 12
- Figura 6.** Informações ilustrativas. a) disposição da falha na parcela experimental. b) localização do alvo de identificação da falha. c) extremidade da falha para medição da altura das plantas. d) régua utilizada para medição da altura das plantas, exemplo de altura de planta de 0,5 m.....23
- Figura 7.** Exemplos de uma falha de 2.5 m de comprimento. As colunas representam as imagens capturadas em diferentes alturas e as linhas representam os tamanhos de pixel utilizado para capturar essas imagens. Todas as imagens são referentes a uma mesma falha em diferentes condições de avaliação. ....25
- Figura 8.** Padrão de crescimento da cana-de-açúcar. Cada caixa representa o crescimento das plantas em cada tempo de amostragem. Em média, as alturas de planta foram 0,5; 0,9; 1,0; 1,2 e 1,7 m para cada DAC, respectivamente. ....28
- Figura 9.** Diagramas de dispersão comparando o comprimento das falhas de campo e as falhas estimadas por imagens. Os pontos representam a média dos dados ( $\pm$  desvio padrão). ....29
- Figura 10.** Exemplo da sobreposição das falhas ocasionada pelas folhas da cultura; régua de 0,5 m à frente da falha, na ocasião uma falha de 0,5 m.....33

## **CAPÍTULO 1 – Considerações gerais**

### **1. Introdução**

O mapeamento de falhas em cana-de-açúcar é uma etapa importante para obter, acima de tudo, informações oportunas sobre a população de plantas na área, o que está diretamente ligado à produtividade. Diante do percentual de falhas em canavial se pode tomar decisões no gerenciamento estratégico da cultura, por um lado, para definir áreas para realizar replantio, por outro lado, definir quando será realizada reforma do canavial. Deste modo, o mapeamento preciso de falhas é necessário, pois replantio e reforma de canavial consistem em etapas mais caras de todo processo produtivo.

Metodologias para avaliação de falhas em cana-de-açúcar têm sido estudadas, dentre elas, a promissora aplicação de imagens capturadas por veículos aéreos não tripulados (UAVs), que tem se destacado devido flexibilidade e praticidade de aplicação. No entanto, diversos fatores podem influenciar no mapeamento de falhas por imagem, os principais são: a qualidade da imagem e o momento ideal para coleta de imagens por UAV na área, os quais foram nossos objetivos de estudo.

Com base nesse contexto, nesta pesquisa apresentamos uma metodologia de avaliação de falhas em cana-de-açúcar, considerando os fatores que podem influenciar na qualidade do mapeamento. Acreditamos, ainda, que a abordagem apresentada pode ser potencialmente aplicada para outras culturas, onde fatores como tamanho do pixel e a definição do momento ideal para coleta de imagens pelo UAV na área possam influenciar a precisão da coleta de informações.

A presente dissertação é dividida em 3 capítulos para melhor compreensão do trabalho: No capítulo 1 está inserido o referencial teórico utilizado para o embasamento técnico-científico para a análise dos resultados apresentados nos capítulos seguintes. Em seguida, no capítulo 2 são apresentados e discutidos os resultados de impactos de tamanho de pixel e altura de planta em mapeamento de falhas em cana-de-açúcar por imagens UAV. Por fim, no capítulo 3, temos as considerações finais do trabalho.

## 1.1. Revisão de literatura

### 1.1.1. Cultura da cana-de-açúcar

A cana-de-açúcar (*Saccharum* spp.) é uma cultura semi-perene C<sub>4</sub> cultivada em zonas subtropicais e tropicais em todo o mundo (Huang et al., 2020). Recentemente, a cana-de-açúcar atingiu 26 milhões de hectares de área plantada no mundo, sendo o Brasil o maior produtor da cultura, com aproximadamente 10 milhões de hectares (CONAB, 2020; FAO, 2020; IBGE, 2020), sobretudo, devido as condições de clima e características do solo serem favoráveis para o cultivo da cana-de-açúcar no país (Tayt'Sohn et al., 2018).

A cana-de-açúcar passou a ter importância econômica para o território brasileiro desde o período colonial, nos primórdios da economia brasileira, especialmente pela disponibilidade de terras e mão-de-obra indígena empregadas para sua produção (Rodrigues e Ross, 2020). O cenário nacional entrou em destaque na produção de cana-de-açúcar quando deixou de ser colônia e assumiu seu próprio comando, considerado como o importante abastecedor das necessidades açucareiras em praticamente todo o mundo (Araújo e Santos, 2013).

Os altos rendimentos da cana-de-açúcar é a produção de açúcar, álcoois e combustíveis, mas além disso, os subprodutos como o bagaço e a palha, gerados na indústria e no sistema de colheita mecanizada, são matérias-primas essenciais para geração de energia, produção de etanol celulósico e fertilização dos solos (Cervi et al., 2019; Silva et al., 2019). Outras aplicações incluem seu consumo fresco na alimentação humana e forragem na alimentação animal (Oliveira et al., 2018).

A área plantada de cana-de-açúcar tem aumentado a cada safra, principalmente pela demanda de biocombustíveis (Bordonal et al., 2018), destacando o Brasil que, além de maior produtor mundial da cultura e de açúcar, também é o segundo maior produtor de bioetanol (Bordonal et al., 2018; Jordão e Moretto, 2015). Outro ponto importante diante da expansão em área plantada é a caracterização da cultura como fonte de emprego e renda (Oliveira et al., 2020). No Brasil, a cana-de-açúcar é a principal fonte de biomassa para produção de etanol, nos próximos 10

anos, estima-se mudanças significativas em função dos novos avanços e incentivos públicos à produção de biocombustíveis que contribuirão para aumento de produção de cana-de-açúcar (EPE, 2019).

O Estado de São Paulo é o maior produtor nacional de cana-de-açúcar, a cultura é considerada um dos principais setores do agronegócio paulista, incorporando áreas de outras lavouras e, principalmente, de pastagens (Adami et al., 2012; Camargo et al., 2008; Rudorff et al., 2010). A área produtiva do Estado de São Paulo cresce gradativamente a cada safra, aproximadamente 4,3 milhões de hectares foi a área colhida no Estado na safra 2019/2020, alcançando produção de 342,6 milhões de toneladas e um rendimento médio de 79,6 kg ha<sup>-1</sup>, valor semelhante ao alcançado nas três últimas safras, 77,3; 72,6 e 72,5 kg ha<sup>-1</sup>, respectivamente (CONAB, 2020).

Basicamente foram dois fatores que impulsionaram a produção da cana-de-açúcar no Estado de São Paulo, inicialmente se tratou da relativa desvalorização da cultura do café na região e, posteriormente, no ano de 1933, a criação do Instituto do Açúcar e do Alcool (IAA), com intuito de fortalecer o setor sucroalcooleiro, regular a produção de açúcar por meio de cotas de produção e promover maior industrialização e consumo de etanol (Figueiredo et al., 2011).

Ao longo dos anos foram estabelecidos convênios entre o IAA e programas do governo, todos em busca de fortalecer ainda mais a produção da cultura da cana-de-açúcar no Estado, esses convênios contribuíram com realização de pesquisas e também com introdução de novas cultivares de cana-de-açúcar visando trabalhos de melhoramento genético e acompanhamento da cultura (Figueiredo et al., 2011).

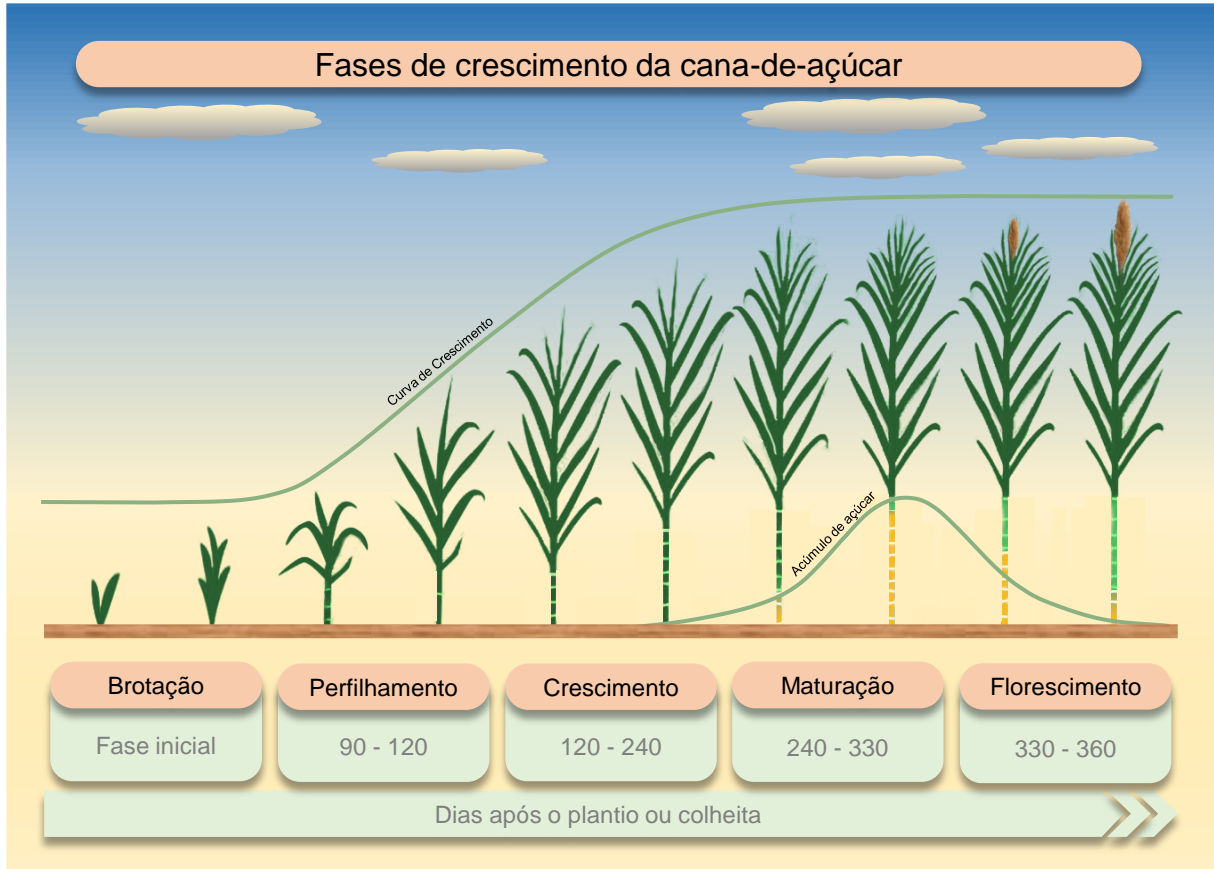
As principais cultivares de cana-de-açúcar no Estado de São Paulo são: RB867515, CTC4, CTC9001, RB966928 e IACSP95-5094, que, segundo o Instituto Agrônomo de Campinas (IAC), principal censo do setor de cana do país, são 5 das cultivares mais plantadas nos últimos anos (Braga Junior et al., 2019). Os períodos típicos de plantio na região sudeste em um ano são definidos como: Semi-seca (março – maio), Seca (junho – agosto), Semi-úmida (setembro – novembro), Úmida (dezembro – fevereiro). Em geral, um ciclo de cultivo é composto de uma safra de planta e quatro a cinco safras de soca (rebrotas) (Dinardo-Miranda et al., 2008).

A cana-de-açúcar é classificada em cinco fases de desenvolvimento. Após a implantação da cultura, por mudas de porções de colmos maduros ou tecidos de meristemas (Labanca et al., 2020), acontece a brotação; em áreas de rebrota, essa fase ocorre cerca de 10 a 15 dias após a colheita, dependendo da variedade da cana (Luna e Lobo, 2016).

A segunda fase é denominada perfilhamento. Os perfilhos surgem após a brotação e podem atingir número máximo até os 120 dias após o plantio/colheita, após isso, muitos destes morrem, isso se deve, principalmente, à competição por luminosidade e nutrientes, interrompendo o processo de crescimento e desenvolvimento, resultando na morte de perfilhos mais novos (Inman-Bamber et al., 2009).

A terceira fase é o crescimento, caracterizada pelo alongamento de caule, atingindo o crescimento máximo 240 dias após o plantio/colheita. Na quarta fase (maturação), predomina-se o armazenamento de açúcar, essa é a etapa que se deve realizar a colheita quando a finalidade é obter altos teores de açúcar. A quinta e última fase é a floração, nessa fase o crescimento vegetativo cessa e o açúcar acumulado começa a ser utilizado para o processo de floração (Dinardo-Miranda et al., 2008; Molijn et al., 2018; Shendryk et al., 2020). Na [Figura 1](#) apresentamos exemplo ilustrativo das fases de desenvolvimento da cana-de-açúcar.

Informações sobre as fases de crescimentos de cana-de-açúcar desempenham papel significativo no processo de tomada de decisão, principalmente quando se refere as estimativas de produtividade (Yu et al., 2020). Para isso, diversos estudos foram desenvolvidos com intuito de investigar melhores condições de cultivo e, posteriormente, maiores rendimentos da cana-de-açúcar (Xin et al., 2020; Xu et al., 2020). No entanto, é promissor adotar medidas de avaliação que auxiliem no processo de tomada de decisão, como a integração de dados de sensoriamento remoto (SR) e, para alto desempenho na análise de dados espaciais, principalmente quando se tem extenso banco de dados, é comumente usados sistemas de informações geográficas (SIG; Silva et al., 2021) e abordagens de aprendizado de máquinas (AM; van Klompenburg et al., 2020).



**Figura 1.** Exemplo ilustrativo das fases de crescimento de cana-de-açúcar. O número de dias de cada fase pode variar dependendo da cultivar de cana-de-açúcar.

### 1.1.2. Falhas em cana-de-açúcar

Falhas em cana-de-açúcar são trechos nas linhas de plantio sem presença de plantas. Embora as falhas sejam problema no cultivo de cana-de-açúcar, os produtores não utilizavam métodos para quantificação dessas falhas, sendo realizado apenas inspeção visual para descrever se o canavial se encontrava “muito falhado” ou “pouco falhado” (Stolf et al., 1991).

As falhas, por sua vez, são oriundas de todos os processos de produção, como: preparo do solo, plantio, tratos culturais e colheita, assim como de fatores como clima adverso, ataque de pragas e doenças e menor vigor vegetativo da soqueira (Campanhão, 2020; Matsuoka e Stolf, 2012; Santos et al., 2013).

Para avaliação de falhas em linhas de cana-de-açúcar, Stolf (1986) empregou um método, contribuindo para as estimativas de produtividade dessas áreas, pois

existe relação direta entre o índice de falhas e a produtividade do canavial (Bocca et al., 2015; Matsuoka e Stolf, 2012), além de possibilitar emprego de tecnologias que estejam voltadas a seletividade nos tratos culturais, monitorar a qualidade de plantio, definir melhores estratégias ao replantio e reforma de canavial (Luna e Lobo, 2016; Matsuoka e Stolf, 2012; Souza et al., 2017). Baseado na qualidade de plantio, Stolf (1986) elaborou um método de classificação em função da porcentagem de falhas ([Tabela 1](#)).

**Tabela 1.** Porcentagem de falhas definindo qualidade de plantio.

Porcentagem de falha	Qualidade de Plantio	Observações
0 - 10	Excelente	Condições excepcionais de brotação
10 - 20	Normal	Tipo mais comum observado
20 - 35	Regular	Possibilidade de renovação pode ser considerada
35 - 50	Ruim	Renovação pode ser considerada
> 50	Péssimo	Reformar/Replantar

Fonte: Stolf, 1986.

A seguir, mostramos os métodos para avaliação de falhas. Método de avaliação manual ([Seção 1.1.3.1](#)). Método de avaliação por veículo terrestre ([Seção 1.1.3.2](#)). Método de avaliação por imagens UAV ([Seção 1.1.3.3](#)).


### 1.1.3. Métodos para avaliação de falhas

#### 1.1.3.1. Método de avaliação manual

O método manual foi criado por Stolf (1986), definindo falhas como os espaços vazios entre dois colmos que apresentem mais de 0,5 metro de comprimento. Esse método consiste na medição de falhas por trena, contando e acumulando o comprimento das falhas, não sendo necessário anotá-lo individualmente ([Figura 2](#)). Esse método é feito de forma manual, percorrendo pontos predeterminados da área, onde os resultados irão expressar porcentagem de falhas (F%) em relação com a área total avaliada ([Equação 1](#)). A grande limitação desse método é a quantificação de

falhas apenas em pontos amostrais, sendo inviável a aplicação em grandes áreas devido ao trabalho de campo ser muito intenso (Molin e Veiga, 2016).


$$F\% = \frac{\text{comprimento total das falhas encontradas}}{\text{comprimento total do trecho de linha analisado}} \cdot 100 \quad (1)$$



**Figura 2.** Exemplo ilustrativo da aplicação do método manual.  
Fonte: Adaptado de Stolf (1986).

### 1.1.3.2. Método de avaliação por veículos terrestres

O método que usa sensores em veículos terrestres foi desenvolvido e testado por Molin e Veiga (2016), a partir do monitoramento de falhas por sensor fotoelétrico integrado a trator ([Figura 3](#)), assim podendo cobrir áreas maiores que a medição manual. O sensor fotoelétrico faz a coleta de informações de campo medindo as falhas a partir da diferença entre leituras. As falhas são georreferenciadas e representadas em forma de mapa. Essas informações são usadas para medir a distância entre plantas, definindo falhas como medição total ou como mapa de densidade que mostra quais áreas têm concentração maior de falhas. No entanto, esse método exige circulação por toda área, o que aumenta o risco de danificar a cultura, além de ser caro e demandar tempo (Luna e Lobo, 2016).



**Figura 3.** Exemplo ilustrativo da aplicação do método por veículos terrestres.  
Fonte: Adaptado de Molin (2016).


### 1.1.3.3. Método de avaliação por imagens UAV

Devido aos avanços tecnológicos, em especial ao desenvolvimento de novas tecnologias como os veículos aéreos não tripulados (UAVs), foi possível superar diversas limitações encontradas em plataforma de sensoriamento remoto orbital (satélites), dentre elas, a detecção de plantas daninhas (Kawamura et al., 2020), identificação e contagem de plantas (Calvario et al., 2020; Zhang et al., 2020) e quantificação de falhas em cana-de-açúcar, métodos propostos por (Luna e Lobo, 2016; Souza et al., 2017).

No método de quantificação de falhas de Luna e Lobo (2016), as imagens foram analisadas por *Linear Discriminant Analysis (LDA)*, enquanto Souza et al. (2017) utilizaram *Object-Based Image Analysis (OBIA)*. Em geral, ambas abordagens identificam unidades homólogas em imagens de agrupamento de pixels e, em seguida, são atribuídos métodos de classificação para definir os pixels que representam plantas e falhas. Na [Figura 4](#) apresentamos exemplo ilustrativo do método de avaliação de falhas por imagens UAV.

O método de avaliação de falhas por imagens UAV é mais eficiente devido à flexibilidade no uso do UAV. No entanto, apresenta algumas limitações quanto ao período de coleta e a qualidade das imagens, caracterizando tamanho de folha e pixel (Luna e Lobo, 2016; Souza et al., 2017). Para isso, desenvolvemos esta pesquisa no

intuito de superar essas limitações e obtermos maior precisão no mapeamento de falhas em cana-de-açúcar por imagens UAV.



**Figura 4.** Exemplo ilustrativo da aplicação do método por imagens UAV.

#### 1.1.4. Drones na agricultura

Nos últimos anos, a adoção da agricultura de precisão (AP) aprimorou a forma de trabalho nos campos produtivos, fornecendo soluções de gerenciamento de culturas que são menos subjetivas, econômicas e robustas (Valente et al., 2020), essa prática permite maior caracterização de variabilidades espaço-temporais, aprimorando a eficiência de produção e minimizando efeitos ambientais adversos (Menzies Plier et al., 2020).

Processos como a digitalização da agricultura vêm transformando os métodos produtivos agrícolas, diversos conceitos surgiram para expressar formas de digitalização em sistemas de produção agrícola, dentre eles: *Smart Farming* (Navarro et al., 2020), *Precision Farming* (Vecchio et al., 2020), *Decision Agriculture* (Raza e Salam, 2020), *Digital Agriculture* (Basso e Antle, 2020) e *Agriculture 4.0* (Rose et al., 2020). Independente do termo, a digitalização implica concentração de tipos de dados por sensores, máquinas, UAVs e satélites para monitorar animais, solo, água, plantas e humanos (Klerkx et al., 2019).

Com os recentes avanços tecnológicos, os veículos aéreos não tripulados (UAVs) ganharam popularidade no setor agrícola, tornando-se uma das tecnologias mais comentadas do mundo (Castrignanò et al., 2021). Essas plataformas aéreas se tornaram ferramentas relativamente acessíveis para uso amplo. Nos campos

agrícolas, são consideradas soluções potenciais para aquisição remota e flexível de dados (Ashpure et al., 2020; Maes e Steppe, 2019; Martinez-Guanter et al., 2020).

Embora essa tecnologia tenha evoluído rapidamente nos últimos anos, as primeiras tentativas de implantar UAVs começaram durante a Primeira Guerra Mundial, quando a *Dayton-Wright Airplane Company* inventou um conceito de torpedo aéreo não tripulado que explodiria em momento predefinido (González-Jorge et al., 2017). Durante a Segunda Guerra Mundial, foi lançado o primeiro UAV em produção de grande escala pelas indústrias *Reginald Denny*, construindo cerca de 15.000 UAVs para o exército dos EUA (González-Jorge et al., 2017). A Guerra Fria também foi grande contribuinte para a evolução dos UAVs, em 1955 foi utilizado o primeiro UAV para finalidade em captura de imagens aéreas (González-Jorge et al., 2017).

Apesar dos primeiros UAVs terem surgido para operações militares, na última década a rápida evolução de novas tecnologias, como sensores de imagem, sistemas globais de navegação por satélite (GNSS), além da redução de preços etc., possibilitou a implementação de UAVs em aplicações civis, capazes de auxiliar na evolução de múltiplos campos, como geomática, logística, monitoramento de infraestrutura e agricultura de precisão (González-Jorge et al., 2017; Radoglou-Grammatikis et al., 2020).

O UAVs equipados com sensores ópticos, radar e térmicos em associação com sistemas de georreferenciamento permite apoiar investigações científicas na agricultura (Amaral et al., 2020; Raparelli e Bajocco, 2019), monitorando anomalias e tendências que, se observadas do solo ou por meios tradicionais, nem sempre são tão evidentes (Adão et al., 2017).

Diferente das observações espaciais via satélite, UAV pode obter imagens com resolução espacial muito alta, a quantidade de pixels por imagem é elevada, minimizando problemas de homogeneidade (Khaliq et al., 2019). Por isso, UAV pode ser utilizado sempre que necessário, o que o torna ferramenta eficiente para monitoramento rápido de recursos terrestres (Böhler et al., 2020).


Contudo, antes de realizar mapeamentos aéreos com UAVs, vários parâmetros precisam ser otimizados. O verdadeiro desafio operacional do mapeamento aéreo baseado em UAVs, é determinar a altura de voo ideal e os parâmetros do sensor. O objetivo é atingir a melhor qualidade na reconstrução das imagens sem aumentar excessivamente o tempo de voo e de processamento de imagem, o que aumenta a eficiência da operação e pós-processamento do UAV (Seifert et al., 2019).

#### **1.1.5. Processamento de imagens digitais**

Com o surgimento de câmeras digitais, o sensoriamento remoto passou a ter mais uma ferramenta disponível para avaliações agrônômicas, devido ao fornecimento de imagem digital (Haghshenas e Emam, 2019). O uso de imagem digital é impulsionado pelo fato de que a imagem digital é relativamente barata, pode ser implantado de maneira escalonável e pode ser facilmente integrado com plataformas manuais, terrestres e aéreas, visando duplicar o papel da visão humana (Mahajan et al., 2015; Zhuang et al., 2020).

Imagem digital é representada por matriz de pixels, elementos que possuem propriedades comuns e específicas, como: dimensão e cor, respectivamente ([Figura 5](#); Pérez-Rodríguez e Gómez-García, 2019). A cor da imagem digital é uma propriedade importante para análise da imagem, a verdadeira cor é vital para garantir as características físicas, químicas e superficiais do objeto (Sunoj et al., 2018).

O uso de imagem digital na agricultura aumentou consideravelmente, que, por técnicas de processamento, as imagens são usadas para as mais diversas aplicações, como: nutrição de plantas (Xiong et al., 2019), crescimento da cultura (Aasen et al., 2020), estimativa de rendimento (Tedesco-Oliveira et al., 2020), área foliar (Guan et al., 2020), estresse hídrico (Kandylakis et al., 2020) etc.



**Figura 5.** Exemplo ilustrativo dos elementos de imagem digital. (a) imageamento por plataformas de sensoriamento remoto. (b) matriz de pixels da imagem digital.

Os avanços em processamento de imagens têm sido amplamente integrados à agricultura de precisão, possibilitando aplicações promissoras para comunidade científica, disponibilizando informações úteis à tomada de decisão (Sabzi et al., 2017; Santos et al., 2020; Singh et al., 2018). O processamento de imagens, em geral, consiste na utilização de dados brutos da imagem, que são fornecidos para extração de recursos que resultam na melhor identificação e classificação de padrão (Chandel et al., 2020).

No processo de extração de informações de imagens é necessário, primeiramente, que as imagens adquiridas tenham alto nível de precisão em termos de forma, tamanho e cor dos objetos em estudo. Para isso, deve-se levar em consideração o tipo de técnica de aquisição de imagem, fonte de excitação e tipo de detector (Mahajan et al., 2015). A captura das imagens com variação nas variáveis de intensidade de luz, sombreamento, oclusão, etc. apresentaram menor qualidade e aumenta a complexidade do processamento de imagens (Singh et al., 2018).

## 1.2. Referências

- Aasen H, Kirchgessner N, Walter A, Liebisch F. (2020) Phenocams for field phenotyping: Using very high temporal resolution digital repeated photography to investigate interactions of growth, phenology, and harvest traits. **Frontiers in Plant Science** 11:593.
- Amaral LR, Zerbato C, Freitas RG, Barbosa Júnior MR, Simões IOPS. (2020) UAV applications in Agriculture 4.0. **Revista Ciência Agronômica** 51:1–15.
- Adami M, Rudorff BFT, Freitas RM, Aguiar DA, Sugawara LM, Mello MP. (2012) Remote sensing time series to evaluate direct land use change of recent expanded sugarcane crop in Brazil. **Sustainability** 4:574–585.
- Adão T, Hruška J, Pádua L, Bessa J, Peres E, Morais R, Sousa JJ. (2017) Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. **Remote Sensing** 9:30.
- Araújo ES, Santos JAP. (2013) O desenvolvimento da cultura da cana-de-açúcar no Brasil e sua relevância na economia nacional. **FACIDER** 1–16.
- Ashapure A, Jung J, Chang A, Oh S, Yeom J, Maeda M, Maeda A, Dube N, Landivar J, Hague S, Smith W. (2020) Developing a machine learning based cotton yield estimation framework using multi-temporal UAS data. **ISPRS Journal of Photogrammetry and Remote Sensing** 169:180–194.
- Basso B, Antle J. (2020) Digital agriculture to design sustainable agricultural systems. **Nature Sustainability** 3:254–256.
- Bocca FF, Rodrigues LHA, Arraes NAM. (2015) When do I want to know and why? Different demands on sugarcane yield predictions. **Agricultural Systems** 135:48–56.
- Böhler JE, Schaepman ME, Kneubühler M. (2020) Crop separability from individual and combined airborne imaging spectroscopy and UAV multispectral data. **Remote Sensing** 12:1256.
- Bordonal RO, Carvalho JLN, Lal R, Figueiredo EB, Oliveira BG, La Scala N. (2018) Sustainability of sugarcane production in Brazil. A review. **Agronomy for Sustainable Development** 38:1–23.
- Braga Junior RLC, Landell MGA, Silva DN, Bidóia MAP, Silva TN, Thomazinho Júnior JR, Silva VHP, Anjos IA. (2019) **Censo varietal IAC de cana-de-açúcar - safra 2017/18 e na região centro-sul - safra 2018/19**. Campinas, 64 p. (Boletim técnico IAC - Documento, 221).

Calvario G, Alarcón TE, Dalmau O, Sierra B, Hernandez C. (2020) An agave counting methodology based on mathematical morphology and images acquired through unmanned aerial vehicles. **Sensors (Switzerland)** 20:1–21.

Camargo AMMP, Caser DV, Camargo FP, Olivette MPA, Sachs RCC, Torquato SA. (2008) Dinâmica e tendência da expansão da cana-de-açúcar sobre as demais atividades agropecuárias, Estado de São Paulo, 2001-2006. **Informações Econômicas** 38:47-66.

Campanhão JM. (2020) **Produtividade Agrícola: Falhas no Canavial e Replanteio**. Piracicaba, 20 p. (Caderno Canaplan).

Castrignanò A, Belmonte A, Antelmi I, Quarto R, Quarto F, Shaddad S, Sion V, Muolo MR, Ranieri NA, Gadaleta G, Bartocchetti E, Riefolo C, Ruggieri S, Nigro F. (2021) A geostatistical fusion approach using UAV data for probabilistic estimation of *Xylella fastidiosa* subsp. pauca infection in olive trees. **Science of the Total Environment** 752:141814.

Cervi WR, Lamparelli RAC, Seabra JEA, Junginger M, van der Hilst F. (2019) Bioelectricity potential from ecologically available sugarcane straw in Brazil: A spatially explicit assessment. **Biomass and Bioenergy** 122:391–399.

Chandel NS, Chakraborty SK, Rajwade YA, Dubey K, Tiwari MK, Jat D. (2020) Identifying crop water stress using deep learning models. **Neural Computing and Applications** 1–15.

CONAB. (2020) **Safra Brasileira de Cana-de-Açúcar**. Brasília, 62 p. (Observatório Agrícola, 3).

Dinardo-Miranda LL, Vasconcelos ACM de, Landell MGA. (2008) Cana-de-açúcar. Campinas, 882 p. Instituto Agrônômico de Campinas (IAC).

EPE. (2019) **Investimentos e custos operacionais e de manutenção no setor de biocombustíveis: 2020 - 2030**. Rio de Janeiro, 3 p. (CAPEX, capital expenditure).

FAO. (2020) **Crops**. Disponível em: <<http://www.fao.org/faostat/en/#data>>. Acesso em 09 dez. 2020.

Figueiredo P, Landell MGA, Campana MP, Scapari MS, Xavier MA, Anjos IA. (2011) **O Instituto Agrônômico (IAC) e fatos históricos relacionados ao desenvolvimento da cultura da cana-de-açúcar até o fim do século XX**. Campinas: 47 p. (Documentos IAC, 103).

González-Jorge H, Martínez-Sánchez J, Bueno M, Arias P. (2017) Unmanned aerial systems for civil applications: A review. **Drones** 1:1–19.

Guan Z, Abd-Elrahman A, Fan Z, Whitaker VM, Wilkinson B. (2020) Modeling strawberry biomass and leaf area using object-based analysis of high-resolution images. **ISPRS Journal of Photogrammetry and Remote Sensing** 163:171–186.

Haghshenas A, Emam Y. (2019) Evidence for relative grain yield simulation by red color level of beneath-canopy soil at wheat booting phase: An unexpected observation using image processing. **Computers and Electronics in Agriculture** 162:1028–1034.

Huang J, Khan MT, Perecin D, Coelho ST, Zhang M. (2020) Sugarcane for bioethanol production: Potential of bagasse in Chinese perspective. **Renewable and Sustainable Energy Reviews** 133:110296.

IBGE. (2020) **Levantamento sistemático de produção agrícola**. Disponível em: <<https://sidra.ibge.gov.br/tabela/1618#resultado>> Acesso em: 09 dez. 2020.

Inman-Bamber NG, Bonnett GD, Spillman MF, Hewitt ML, Xu J. (2009) Source-sink differences in genotypes and water regimes influencing sucrose accumulation in sugarcane stalks. **Crop and Pasture Science** 60:316–327.

Jordão CO, Moretto EM. (2015) The environmental vulnerability and the territorial planning of the sugarcane cultivation. **Ambiente e Sociedade** 18:75–92.

Kandylakis Z, Falagas A, Karakizi C, Karantzalos K. (2020) Water stress estimation in vineyards from aerial SWIR and multispectral UAV data. **Remote Sensing** 12:2499.

Kawamura K, Asai H, Yasuda T, Soisouvanh P, Phongchanmixay S. (2020) Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. **Plant Production Science** 00:1–18.

Khaliq A, Comba L, Biglia A, Ricauda Aimonino D, Chiaberge M, Gay P. (2019) Comparison of satellite and uav-based multispectral imagery for vineyard variability assessment. **Remote Sensing** 11:436.

Klerkx L, Jakku E, Labarthe P. (2019) A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. **NJAS - Wageningen Journal of Life Sciences** 90–91:100315.

Labanca ERG, Andrade SAL, Kuramae EE, Silveira APD. (2020) The modulation of sugarcane growth and nutritional profile under aluminum stress is dependent on beneficial endophytic bacteria and plantlet origin. **Applied Soil Ecology** 156:103715.

Luna I, Lobo A. (2016) Mapping Crop Planting Quality in Sugarcane from UAV Imagery: A Pilot Study in Nicaragua. **Remote Sensing** 8:500.

Maes WH, Steppe K. (2019) Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. **Trends in Plant Science** 24:152–164.

Mahajan S, Das A, Sardana HK. (2015) Image acquisition techniques for assessment of legume quality. **Trends in Food Science and Technology** 42:116–133.

Martinez-Guanter J, Agüera P, Agüera J, Pérez-Ruiz M. (2020) Spray and economics assessment of a UAV-based ultra-low-volume application in olive and citrus orchards. **Precision Agriculture** 21:226–243.

Matsuoka S, Stolf R. (2012) Sugarcane tillering and ratooning: Key factors for a profitable cropping, in: **Sugarcane: Production, Cultivation and Uses**. Araras, p. 138–157.

Menzies Puer EG, Robinson DT, Meinen BU, Macrae ML. (2020) Pairing soil sampling with very-high resolution UAV imagery: An examination of drivers of soil and nutrient movement and agricultural productivity in southern Ontario. **Geoderma** 379:114630.

Molijn RA, Iannini L, Rocha JV, Hanssen RF. (2018) Data descriptor: Ground reference data for sugarcane biomass estimation in São Paulo state, Brazil. **Scientific Data** 5:180150.

Molin JP, Veiga JPS. (2016) Spatial variability of sugarcane row gaps: Measurement and mapping. **Ciência e Agrotecnologia** 40:347–355.

Navarro E, Costa N, Pereira A. (2020) A systematic review of iot solutions for smart farming. **Sensors (Switzerland)** 20:1–29.

Oliveira LA de, Miranda JH de, Cooke RAC. (2018) Water management for sugarcane and corn under future climate scenarios in Brazil. **Agricultural Water Management** 201:199–206.

Oliveira IA, Medeiros LSA, Gonçalves MC, Jesus Pereira H, Alcântara Neto F, Silva Matos K, Beserra JEA. (2020) A survey of causal agents associated with sugarcane yellowing in Northeast Brazil. **Crop Protection** 138:105326.

Pérez-Rodríguez F, Gómez-García E. (2019) Codelplant: Regression-based processing of RGB images for colour models in plant image segmentation. **Computers and Electronics in Agriculture** 163:104880.

Radoglou-Grammatikis P, Sarigiannidis P, Lagkas T, Moscholios I. (2020) A compilation of UAV applications for precision agriculture. **Computer Networks** 172:107148.

Raparelli E, Bajocco S. (2019) A bibliometric analysis on the use of unmanned aerial vehicles in agricultural and forestry studies. **International Journal of Remote Sensing** 40:9070–9083.

Raza U, Salam A. (2020) Zenneck Waves in Decision Agriculture: An empirical verification and application in EM-Based underground wireless power transfer. **Smart Cities** 3:308–340.

Rodrigues GSSC, Ross JLS. (2020) A trajetória da cana-de-açúcar no Brasil: perspectivas geográfica, histórica e ambiental, A trajetória da cana-de-açúcar no Brasil: perspectivas geográfica, histórica e ambiental. Minas Gerais, 222 p. (Edufu).

Rose DC, Wheeler R, Winter M, Lobley M, Chivers CA. (2020) Agriculture 4.0: Making it work for people, production, and the planet. **Land Use Policy** 100:104933.

Rudorff BFT, Aguiar DA, Silva WF, Sugawara LM, Adami M, Moreira MA. (2010) Studies on the rapid expansion of sugarcane for ethanol production in São Paulo state (Brazil) using Landsat data. **Remote Sensing** 2:1057–1076.

Sabzi S, Abbaspour-Gilandeh Y, Javadikia H. (2017) Machine vision system for the automatic segmentation of plants under different lighting conditions. **Biosystems Engineering** 161:157–173.

Santos LM, Ferraz GA e. S, Barbosa BDS, Diotto AV, Maciel DT, Xavier LAG. (2020) Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture** 21:1227–1241.

Santos MAL, Silva S, Zocoler JL, Teodoro I, Dantas Neto J, Sousa JS. (2013) Avaliação de falhas na brotação da cana-de-açúcar em função da disponibilidade hídrica. **Agropecuária científica no semiárido** 9:30–35.

Seifert E, Seifert S, Vogt H, Drew D, van Aardt J, Kunneke A, Seifert T. (2019) Influence of drone altitude, image overlap, and optical sensor resolution on multi-view reconstruction of forest images. **Remote Sensing** 11:1–19.

Shendryk Y, Sofonia J, Garrard R, Rist Y, Skocaj D, Thorburn P. (2020) Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal of Applied Earth Observation and Geoinformation** 92:102177.

Silva AGB, Lisboa IP, Cherubin MR, Cerri CEP. (2019) How much sugarcane straw is needed for covering the soil? **Bioenergy Research** 12:858–864.

Silva GJ, Berg EC, Calijuri ML, Santos VJ, Lorentz JF, Carmo Alves S do. (2021) Aptitude of areas planned for sugarcane cultivation expansion in the state of São Paulo, Brazil: a study based on climate change effects. **Agriculture, Ecosystems and Environment** 305:107164.

Singh AK, Ganapathysubramanian B, Sarkar S, Singh A. (2018) Deep learning for plant stress phenotyping: Trends and future perspectives. **Trends in Plant Science** 23:883–898.

Souza CHW de, Lamparelli RAC, Rocha JV, Magalhães PSG. (2017) Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture** 143:49–56.

Stolf R. (1986) Methodology for gap evaluation on sugarcane lines. **STAB** 4:12–20.

Stolf R, Iaiá AM, Lee TSG. (1991) Índice de falhas segundo o método de STOLF: correlação com o rendimento agrícola em soqueiras de cana-de-açúcar. **Álcool e Açúcar** 11:12–16.

Sunoj S, Igathinathane C, Saliendra N, Hendrickson J, Archer D. (2018) Color calibration of digital images for agriculture and other applications. **ISPRS Journal of Photogrammetry and Remote Sensing** 146:221–234.

Tayt'Sohn FCO, Nunes AMB, Pereira AO. (2018) Assessing sugarcane expansion to ethanol production under climate change scenarios in Paranaíba river basin – Brazil. **Biomass and Bioenergy** 119:436–445.

Tedesco-Oliveira D, Silva RP, Maldonado W, Zerbato C. (2020) Convolutional neural networks in predicting cotton yield from images of commercial fields. **Computers and Electronics in Agriculture** 171:105307.

Valente J, Sari B, Kooistra L, Kramer H, Múcher S. (2020) Automated crop plant counting from very high-resolution aerial imagery. **Precision Agriculture** 21:1366–1384.

van Klompenburg T, Kassahun A, Catal C. (2020) Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture** 177:105709.

Vecchio Y, Agnusdei GP, Miglietta PP, Capitanio F. (2020) Adoption of precision farming tools: The case of Italian farmers. **International Journal of Environmental Research and Public Health** 17:869.

Xin F, Xiao X, Cabral OMR, White PM, Guo H, Ma J, Li B, Zhao B. (2020) Understanding the land surface phenology and gross primary production of sugarcane plantations by Eddy flux measurements, MODIS images, and data-driven models. **Remote Sensing** 12:1–20.

Xiong X, Zhang J, Guo D, Chang L, Huang D. (2019) Non-invasive sensing of nitrogen in plant using digital images and machine learning for *brassica campestris* ssp. *Chinensis* L. **Sensors** 19:2448.

Xu J-X, Ma J, Tang Y-N, Wu W-X, Shao J-H, Wu W-B, Wei S-Y, Liu Y-F, Wang Y-C, Guo H-Q. (2020) Estimation of sugarcane yield using a machine learning approach based on UAV-LiDAR data. **Remote Sensing** 12:2823.

Yu D, Zha Y, Shi L, Jin X, Hu S, Yang Q, Huang K, Zeng W. (2020) Improvement of sugarcane yield estimation by assimilating UAV-derived plant height observations. **European Journal of Agronomy** 121:126159.

Zhang C, Atkinson PM, George C, Wen Z, Diazgranados M, Gerard F. (2020) Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning. **ISPRS Journal of Photogrammetry and Remote Sensing** 169:280–291.

Zhuang S, Wang P, Jiang B. (2020) Vegetation extraction in the field using multi-level features. **Biosystems Engineering** 197:352–366.

## **CAPÍTULO 2 - Impacto do tamanho de pixel e altura da planta no mapeamento de falhas em cana-de-açúcar por imagens UAV**

### **2.1. Introdução**

A cana-de-açúcar (*Saccharum* spp.) é uma cultura semi-perene cultivada em mais de 100 países, somente o Brasil e a Índia correspondem a mais de 50% de toda produção mundial (Carpio e Souza, 2017). De acordo com as estatísticas agrícolas da Organização das Nações Unidas para a Agricultura e Alimentação (FAO), 26,3 milhões de ha produziram 1,9 bilhão de toneladas de cana-de-açúcar em 2018, atingindo produtividade média mundial de 72 t ha<sup>-1</sup>, longe do potencial genético da cultura que é de aproximadamente 300 t ha<sup>-1</sup> (Waclawovsky et al., 2010).

A produtividade de cana-de-açúcar depende de vários fatores como: área de cultivo, condições climáticas, doenças, manejo de fertilizantes e vigor vegetativo (CONAB, 2020; Shendryk et al., 2020). Além desses fatores, a presença de falhas em meio as linhas de plantio também pode influenciar no rendimento da cultura devido à redução da população de plantas.

Falhas em canavial são caracterizadas pelos espaços vazios, maiores que 0,5 m, entre dois colmos. Embora indesejáveis, falhas são naturalmente encontradas nos cultivos, presentes em variados tamanhos e quantidade (Stolf, 1986). Diversos fatores podem ocasionar falhas no canavial como erros durante o plantio, incidência de pragas e doenças, menor vigor vegetativo das soqueiras (Molin e Veiga, 2016; Santos et al., 2013), pisoteio e danos e abalos às soqueiras por uso desordenado de máquinas agrícolas (Matsuoka e Stolf, 2012; Raper, 2005; Zhao et al., 2019).

É de grande importância estimar falhas em canaviais, pois existe relação direta entre o índice de falhas e a produtividade do canavial (Bocca et al., 2015; Matsuoka e Stolf, 2012). Além disso, essa informação pode auxiliar à tomada de decisão, permitindo definir melhores estratégias para analisar a qualidade do plantio, orientar o replantio e a reforma do canavial (Luna e Lobo, 2016; Matsuoka e Stolf, 2012; Souza et al., 2017). Diante disso, para auxiliar a estimativa das falhas, métodos direto e indireto foram propostos.

O método direto foi desenvolvido por Stolf (1986), que embora seja preciso, pois a medição é realizada manualmente em campo, seu uso é inviável para avaliações em grandes áreas, pois impõe esforço de campo muito intenso, havendo necessidade de monitorar fisicamente os cultivos, o que requer muito tempo (Bocca et al., 2015). Como alternativa, métodos indiretos foram propostos por Luna e Lobo (2016) e Souza et al. (2017), que utilizaram veículo aéreo não tripulado (UAV) para capturar imagens do canavial e, posteriormente, por meio do processamento das imagens, identificar e medir falhas. A vantagem desse método é a capacidade de obter informações com detalhamento em grandes áreas, de forma rápida e objetiva. No entanto, ainda não é conhecido o momento ideal para captura das imagens, uma vez que, quando as plantas crescem seu dossel sobrepõem as falhas e dificultam a identificação dessas falhas, assim como também não há informações sobre a qualidade das imagens a serem utilizadas.

A qualidade de imagens UAV é influenciada por vários fatores como parâmetros do sensor (tamanho, balanço de branco, distância focal e resolução), configurações de UAV (estabilidade e tempo de voo) e atributos de voo (altura, velocidade e direção), de maneira geral, o tamanho do pixel é o atributo principal (Hu et al., 2019). Impactos de tamanhos de pixel em imagens UAV foram estudados em estimativas de cobertura vegetal em culturas como trigo (Hu et al., 2019; Jin et al., 2017), milho (Li et al., 2018; Yan et al., 2019) e colza (Zhang et al., 2020). Mas até onde sabemos, nenhum estudo avaliou se tamanhos de pixel afetam a estimativa de falhas em cana-de-açúcar.

Com base nesse contexto, acreditamos que o tamanho de pixel ideal e a definição do momento correto para captura de imagens resultará em mapeamento de falhas preciso. Em nosso estudo exploramos como melhorar a abordagem baseada em imagens UAV para estimar falhas em cana-de-açúcar, considerando os parâmetros de aerolevanteamento e as condições da lavoura sendo fatores de influência na qualidade do mapeamento de falhas. Deste modo, os objetivos deste estudo são i) testar eficiência de tamanhos de pixel para estimar falhas por imagens UAV. ii) determinar altura de planta ideal para identificação dessas falhas. iii) analisar se a estimativa de falhas varia de acordo com o comprimento de falha em campo.

## **2.2. Material e métodos**

Nesta seção, apresentamos as condições da área de estudo ([Seção 2.2.1.](#)), planejamento experimental ([Seção 2.2.2.](#)), plataforma aérea e sensor embarcado para aquisição das imagens ([Seção 2.2.3.](#)), processamento das imagens adquiridas para extração das falhas ([Seção 2.2.4.](#)) e por fim, os parâmetros que adotamos para avaliação do desempenho de estimativa de falhas ([Seção 2.2.5.](#)).

### **2.2.1. Área de estudo**

A área utilizada neste estudo está localizada próximo ao município de Santa Rita do Passa Quatro, no interior do Estado de São Paulo, Brasil (21°14'29" N, 48°17'18" W). O solo da região é classificado como LATOSSOLO VERMELHO Distroférico típico, A moderado ou proeminente, textura argilosa e relevo suave ondulado (0 a 8% de declive; Rossi, 2017). A região de estudo tem altitude média de aproximadamente 600 m com classificação climática do tipo 'Aw', considerado como clima tropical com estação seca de inverno, segundo o critério de classificação de Köppen (Alvares et al., 2013).


A área experimental foi constituída de 10 ha com cana-de-açúcar cv. CTC-4, plantada em espaçamento de 1,4 m de distância entre linhas. As primeiras imagens UAV e medições de altura de planta da cultura foram adquiridas em 28 de setembro de 2019, no segundo ano de cultivo, quando a cana-de-açúcar estava na fase de perfilhamento, 30 dias após a colheita (DAC). As demais aquisições de imagens e medições de altura de planta foram realizadas aos 45, 60, 75 e 90 DAC. A seguir detalhamos como foi realizada cada etapa de coleta de dados.

### **2.2.2. Planejamento experimental**

#### **2.2.2.1. Falhas de campo**

Para este estudo, foram analisados 5 comprimentos de falha: 0,5; 1,0; 1,5; 2,0 e 2,5 m, cada comprimento de falha foi replicado aleatoriamente cinco vezes na área.

As falhas foram confeccionadas manualmente, eliminando as soqueiras na linha de cana-de-açúcar para se obter o comprimento de falha desejado, com distância mínima de 10 m entre cada comprimento de falha. Para identificação das falhas por imagens aéreas, foram posicionados alvos de identificação ao lado de cada falha de acordo com o posicionamento do projeto no croqui experimental ([Figura 6](#)).



**Figura 6.** Informações ilustrativas. a) disposição da falha na parcela experimental. b) localização do alvo de identificação da falha. c) extremidade da falha para medição da altura de plantas. d) régua utilizada para mediação da altura de plantas, exemplo de altura de planta de 0,5 m.

### 2.2.2.2. Tamanho do pixel

Para captura das imagens foram adotados os tamanhos de pixel de 3,5; 6,0 e 8,2 cm. Para obter os tamanhos de pixel analisados, utilizamos a [Equação 2](#), que considera as especificações da câmera e tamanho do pixel desejado, resultando na altura de voo a ser utilizada.

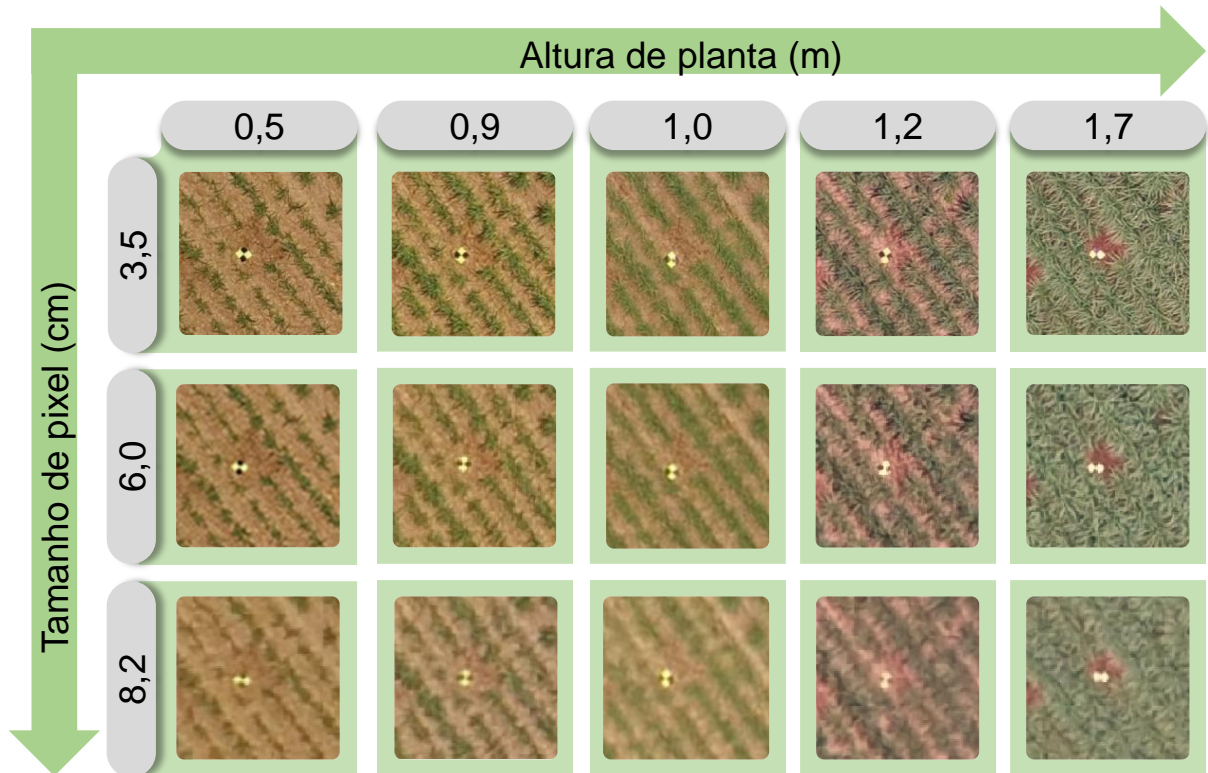
$$FL = \frac{PS \cdot f}{\left[ \frac{\left( \frac{SL}{IL} \right) + \left( \frac{SH}{IH} \right)}{2000} \right]} \quad (2)$$

Em que, FL: altura de voo (m), PS: tamanho do pixel (m), f: distância focal do sensor (m), SL: comprimento do sensor (mm), SH: altura do sensor (mm), IL: comprimento da imagem (pixels), IH: altura da imagem (pixels).

Entretanto, o resultado dessa equação pode apresentar variação em relação ao tamanho do pixel desejado e o obtido na imagem, pois o UAV delimita altura de voo a partir do ponto de decolagem, assim, qualquer ponto de desnível no terreno pode variar a distância entre sensor e o terreno, alterando o tamanho do pixel na imagem. Com base nessa informação, todos os voos foram iniciados de um mesmo ponto do terreno e o tamanho do pixel considerado para análise foi o obtido pela imagem. Exemplos de falha de 2,5 m são apresentados na [Figura 7](#), para cada tamanho de pixel e altura de planta.

### **2.2.2.3. Avaliações biométricas**

Para analisar os impactos das condições da lavoura na identificação da falha pelas imagens, em cada dia de análise foram biometricamente coletadas alturas de plantas. As plantas analisadas foram as que estavam próximas das extremidades da falha, em distância máxima de 0,5 m ([Figura 6](#)), essas plantas são as que sobrepõem as falhas devido sua estrutura, assim dificultando a identificação da falha pela imagem. Para se determinar a altura média das plantas foi utilizada régua, medindo a planta mais alta presente em cada extremidade da falha, totalizando 50 plantas analisadas a cada dia de coleta. A medição levou em consideração a curvatura formada pela folha como o ponto mais alto da planta. Exemplos de falha de 2,5 m são apresentados na [Figura 7](#), para cada tamanho de pixel e altura de planta.



**Figura 7.** Exemplos de uma falha de 2,5 m de comprimento. As colunas representam as imagens capturadas em diferentes alturas e as linhas representam os tamanhos de pixel utilizado para capturar essas imagens. Todas as imagens são referentes a uma mesma falha em diferentes condições de avaliação.

### 2.2.3. Plataforma aérea e sensor

Um UAV (DJI Inspire 1, Shenzhen, China) foi utilizado para captura das imagens. O UAV pesa aproximadamente 3 kg e é alimentado por uma bateria com capacidade de 4500 mAh, o que lhe confere autonomia de voo de aproximadamente 20 min, atingindo até  $79 \text{ km h}^{-1}$  e altitudes de até 4500 m, resistindo a velocidades de ventos de até  $36 \text{ km h}^{-1}$ . Esse UAV consta com receptor GNSS (Sistema Global de Navegação por Satélite), o que garante precisão vertical de 0,5 m e horizontal de 2,5 m. Os voos foram realizados de forma autônoma, utilizando o aplicativo da DroneDeploy (San Francisco, EUA) em tablet.

Um sensor RGB (câmera DJI Zenmuse X3 - FC350, Shenzhen, China) foi acoplado ao UAV, a câmera é estabilizada por um gimbal de 3 eixos, tem 12 mega pixels de resolução espacial. Possui distância focal de 20 mm (equivalente a formato de 35 mm) e sensor CMOS de 1 / 2,3". As imagens foram capturadas usando velocidade do obturador de 1/8000, com o intuito de evitar erros por vibrações. Definições de exposição e foco foram configuradas de forma automática no aplicativo de plano de voo. As imagens foram armazenadas em cartão de memória inserido na própria câmera. As imagens UAV foram capturadas com sobreposição frontal de 75 %, sobreposição lateral de 70 % e velocidade de voo de 7,0 m s<sup>-1</sup>. As alturas de voo utilizadas foram 80, 150 e 200 m, para atingir aos objetivos propostos em relação os tamanhos de pixel desejados ([Seção 2.2.2.](#)).

#### **2.2.4. Processamento das imagens e extração das falhas**

O processamento das imagens brutas para geração do ortomosáico foi realizado a partir de uma plataforma de processamento em nuvem, DroneDeploy (San Francisco, EUA). A primeira etapa do processamento consiste no alinhamento das imagens. Essa etapa utiliza as informações homólogas de múltiplas imagens sobrepostas e em seguida gera nuvem de pontos. A seguir ocorre a geração do modelo digital de elevação (DEM), que é a interpolação a partir da nuvem de pontos. Posteriormente é gerado o ortomosáico a partir deste DEM.

A identificação das falhas nas imagens foi realizada por um software comercial, Inforow (Piracicaba, Brasil), que utiliza inteligência artificial para a interpretação de pixels, reconhecendo padrões em imagens obtidas por UAV. O algoritmo identifica, em agrupamento de pixels, a presença de plantas na linha de plantio, assim reconhece os padrões de fileiras e faz a reconstrução geográfica das linhas. A partir das linhas reconstruídas, utiliza-se de inteligência de reconhecimento local para a separação de partes da linha com falhas de vegetação e, posteriormente, essas linhas são convertidas em arquivo vetorial (shapefile) que tem informações de comprimento e posição geográfica.

### 2.2.5. Parâmetros de validação

Para validação, o comprimento das falhas estimado pelas imagens UAV foi comparado com o das falhas medidas em campo. Nós adotamos por critério o coeficiente de determinação ( $R^2$ ; [Equação 3](#)) e erro percentual médio absoluto (MAPE; [Equação 4](#)) para estabelecer a precisão e acurácia, respectivamente, entre os valores de cada comprimento de falha de campo e estimadas pela imagem.

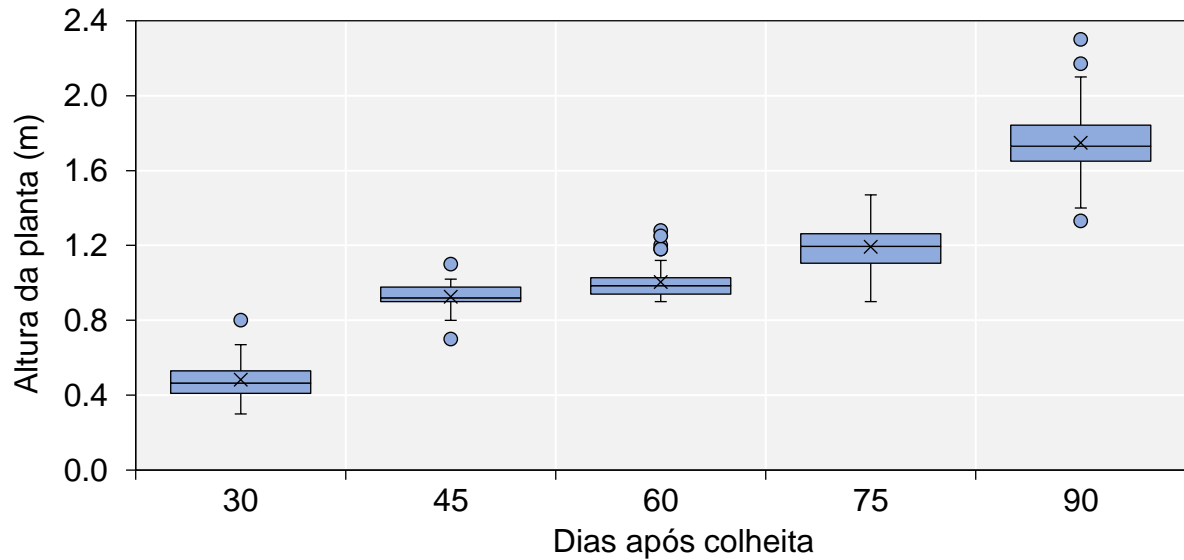
$$R^2 = \frac{\sum(\hat{y}_i - \bar{y})^2}{\sum(y_i - \bar{y})^2} \quad (3)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\% \quad (4)$$

Em que,  $y_i$  representa o comprimento da falha de campo,  $\hat{y}_i$  representa o comprimento da falha estimada na imagem UAV e  $\bar{y}$  é o valor médio.

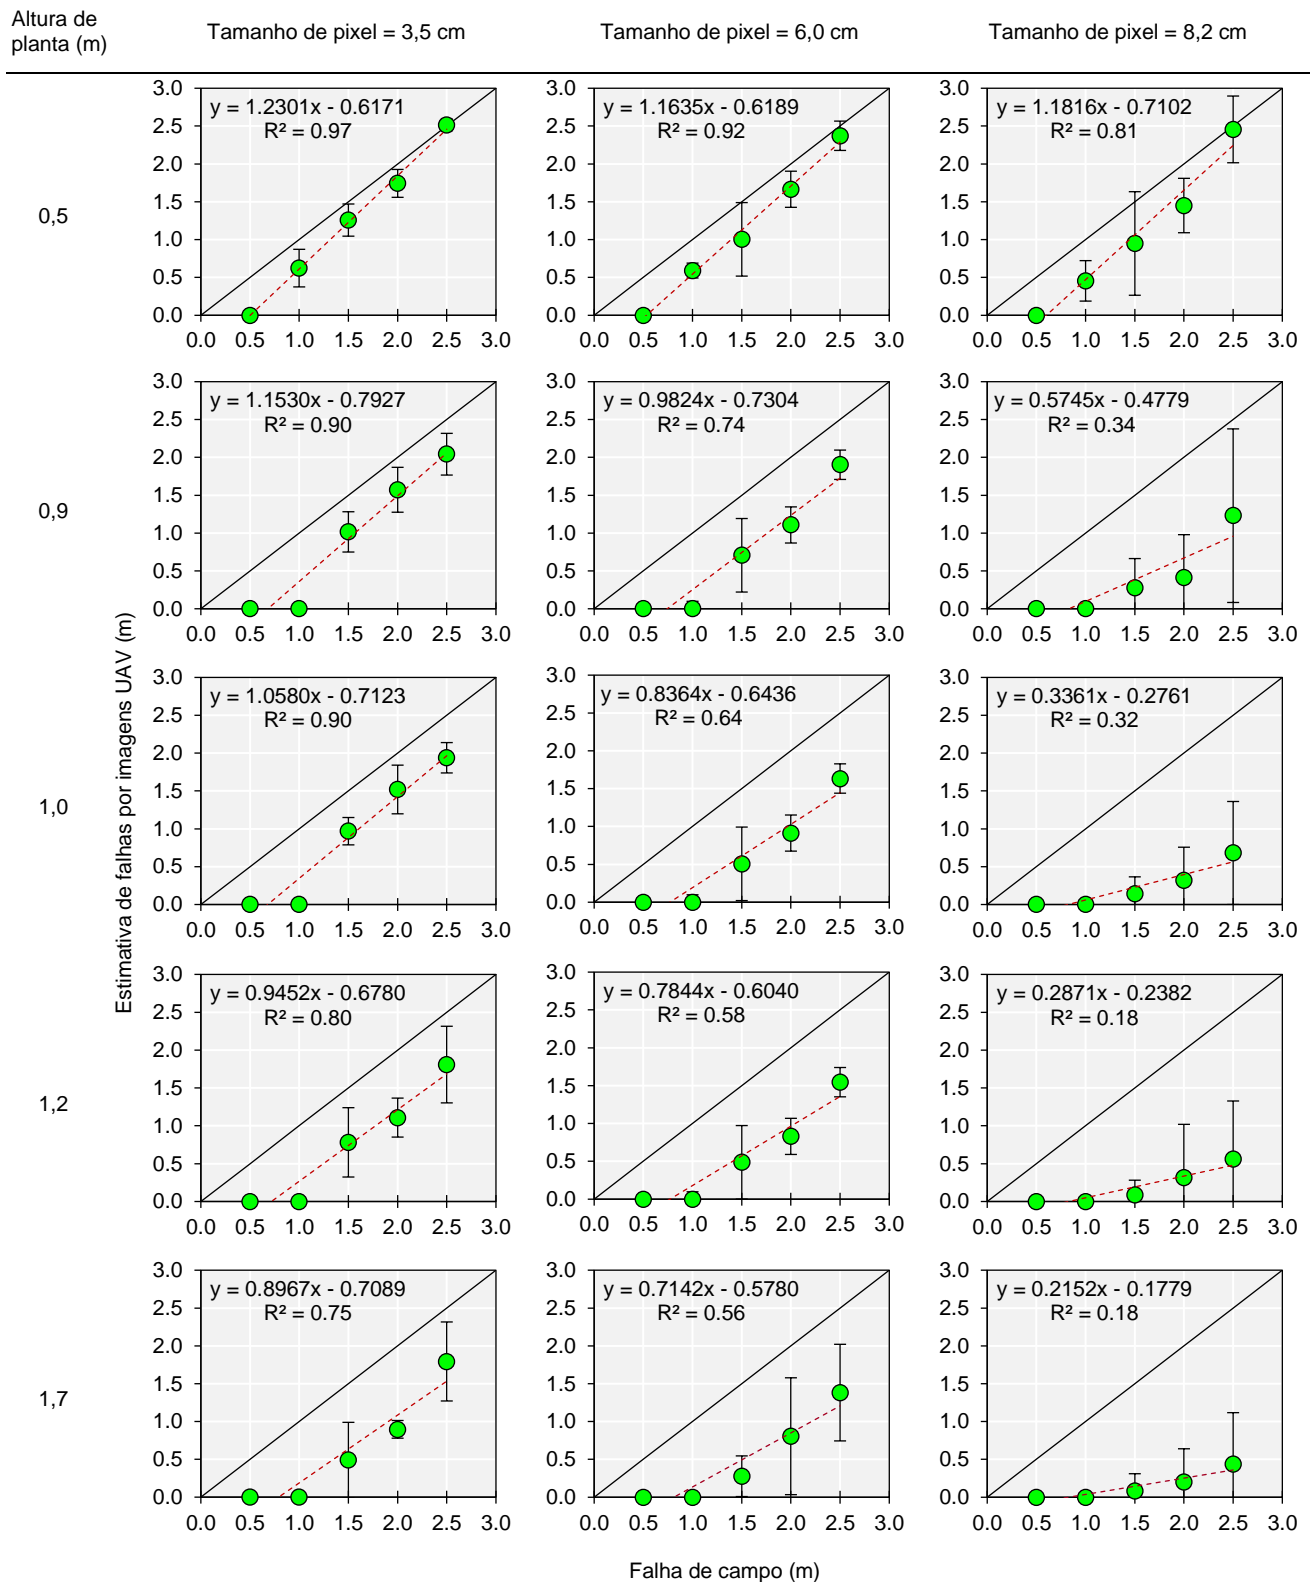
### 2.3. Resultados

Antes de testar a abordagem proposta, dados de alturas de planta de cana-de-açúcar foram coletados no experimento em campo, iniciando as avaliações aos 30 dias após a colheita (DAC) e se estendendo aos 90 DAC ([Figura 8](#)). A altura das plantas aumentou rapidamente de  $0,5 \text{ m} \pm 0,06 \text{ m}$  aos 30 DAC para  $0,9 \text{ m} \pm 0,6 \text{ m}$  aos 45 DAC, no entanto, até os 75 DAC o crescimento se manteve estável e, aos 90 DAC as plantas atingiram altura média de  $1,7 \text{ m} \pm 0,14 \text{ m}$ .



**Figura 8.** Padrão de crescimento da cana-de-açúcar cv. CTC-4. Cada caixa representa o crescimento das plantas em cada tempo de amostragem. Em média, as alturas de planta foram 0,5; 0,9; 1,0; 1,2 e 1,7 m para cada DAC, respectivamente. Total de 50 plantas foram analisadas em cada DAC.

Na [Figura 9](#), o comprimento das falhas estimadas por imagens e as falhas de campo são comparadas em função dos tamanhos de pixel e altura de planta. As colunas estão distribuídas por tamanho de pixel e as linhas por altura de planta, sendo que, cada diagrama de dispersão apresenta um comparativo para cada comprimento da falha. Observamos que quanto menor o tamanho do pixel e a altura de planta analisada, melhor foi a estimativa das falhas, independente do comprimento da falha. Entretanto, a estimativa de falhas foi melhor para o maior comprimento de falha (2,5 m), sendo reduzida à medida que o comprimento da falha de campo diminuiu. De maneira geral, os resultados apresentam fortes evidências de que é possível determinar as melhores condições para o mapeamento de falhas em canavial por imagens UAV.



**Figura 9.** Diagramas de dispersão comparando o comprimento das falhas de campo e as falhas estimadas por imagens. Os pontos representam a média dos dados ( $\pm$  desvio padrão).

Como visto nos diagramas de dispersão, foi possível estimar pelas imagens todos os comprimentos de falha, exceto para falha de 0,5 m. Para as falhas de 1,0 m, a estimativa das falhas foi possível somente na primeira data de aquisição de imagem (aos 30 DAC, quando a altura média das plantas foi de 0,5 m), para todos os tamanhos de pixel. Nas demais condições, a estimativa de falhas manteve o padrão, ou seja, a medida em que aumentou o tamanho do pixel e a altura das plantas, houve diminuição na precisão para estimativa das falhas. No geral, nas condições em que o tamanho do pixel e a altura de planta são menores, a precisão é alta ( $R^2 = 0,97$ ), indicando que, quando aumenta o tamanho do pixel e a planta cresce, diminui a precisão da estimativa das falhas. Maiores detalhes sobre a diferença entre os comprimentos das falhas feita no campo e as estimadas pelas imagens para cada uma das condições é apresentado na [Tabela 2](#).

**Tabela 2.** Erro percentual médio absoluto (MAPE) entre falha estimada por imagem e a falha de campo para cada tamanho de pixel e altura de planta. Também apresentamos o erro para todas as falhas somadas, na coluna “Total”, resultando em 7,5 m de falhas.

Tamanho do pixel (cm)	Altura da planta (m)	Comprimento da falha (m)					Total
		0,5	1,0	1,5	2,0	2,5	
3,5	0,5	100,00	37,65	16,12	12,86	0,62	19,24
	0,9	100,00	100,00	32,29	21,40	18,33	38,27
	1,0	100,00	100,00	35,41	24,02	22,45	40,97
	1,2	100,00	100,00	47,90	44,58	27,65	50,68
	1,7	100,00	100,00	67,27	55,18	28,26	57,59
6,0	0,5	100,00	40,86	33,09	16,75	5,12	25,23
	0,9	100,00	100,00	52,90	44,63	23,90	50,45
	1,0	100,00	100,00	66,19	54,33	34,63	59,27
	1,2	100,00	100,00	67,52	58,51	38,15	61,82
	1,7	100,00	100,00	81,50	59,70	44,70	67,12
8,2	0,5	100,00	54,48	36,73	27,47	1,75	33,23
	0,9	100,00	100,00	81,55	79,35	50,81	74,41
	1,0	100,00	100,00	90,68	84,03	72,78	84,80
	1,2	100,00	100,00	94,20	84,25	77,58	87,17
	1,7	100,00	100,00	94,34	89,85	82,54	90,34

## 2.4. Discussão

Neste estudo, avaliamos a eficiência de tamanhos de pixel e alturas de planta para o mapeamento de falhas em cana-de-açúcar por imagens UAV. Até o momento não se conhecia quais eram os impactos de tamanhos de pixel e alturas de planta na estimativa de falhas no canavial, uma vez que, os resultados podem ser imprecisos.

Obter resultados precisos, de modo a reduzir os erros na estimativa de falhas, parte da aquisição de imagens de boa qualidade e no momento ideal (Luna e Lobo, 2016; Souza et al., 2017). A qualidade das imagens, por exemplo, é diretamente influenciada pelo tamanho do pixel, que altera conforme o modelo de câmera e da altura de voo empregada para a captura das imagens (Hu et al., 2019). Em nosso estudo, os resultados sofreram influência de tamanhos de pixel e de alturas de planta, principalmente pelo fato em que, ao aumentar o tamanho do pixel ocorre redução na resolução das imagens. Isto é, ocorre o agrupamento de pixels, o que dificulta a distinção entre vegetação e solo e, posteriormente, identificação das linhas com falhas. Em relação à altura de plantas, os erros ocorrem principalmente pelo fato em que, à medida que a planta cresce aumenta também o comprimento e o número de folhas, o que pode ocasionar a sobreposição das plantas sobre as falhas.

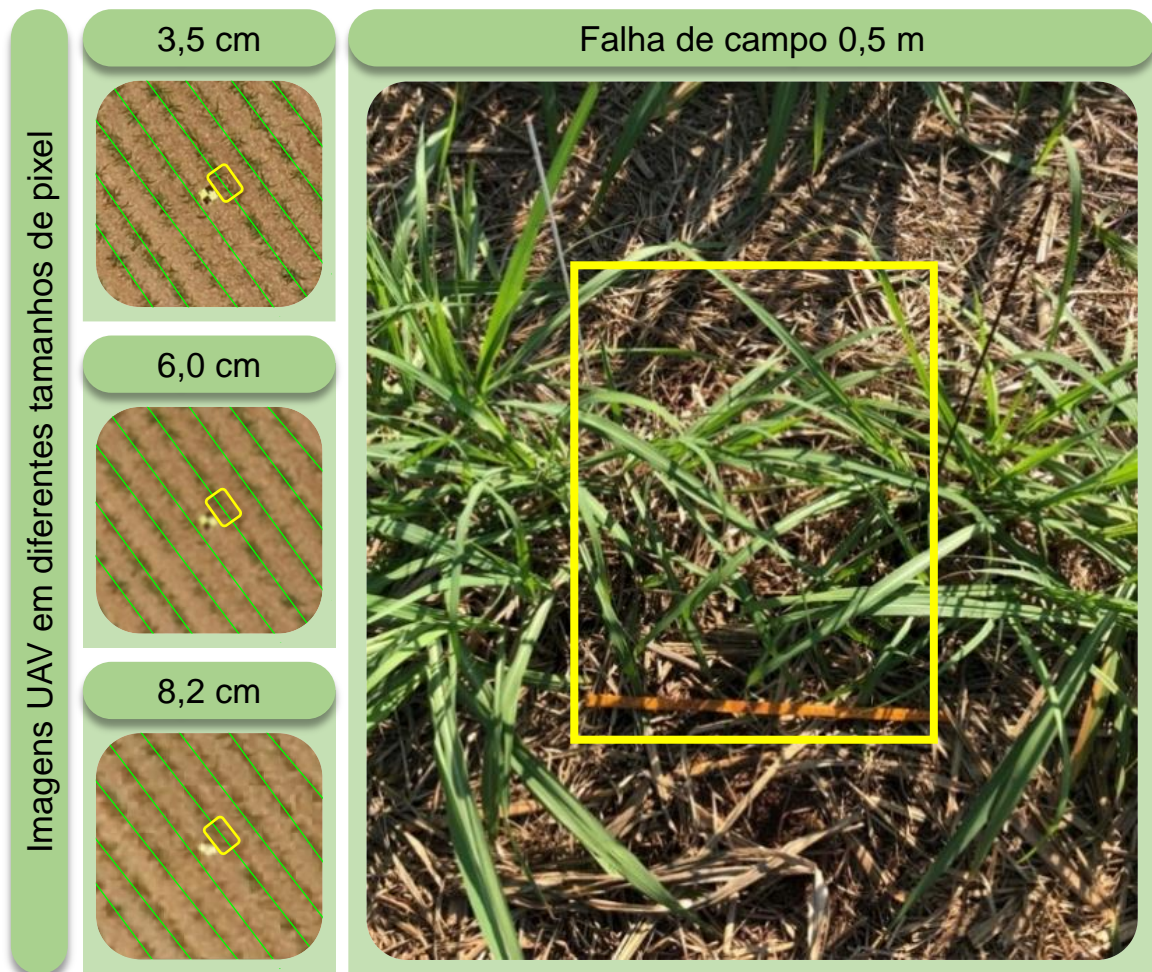
Os impactos de tamanhos do pixel também foram relatados no mapeamento de espécies de pastagens, densidade de plantas e cobertura do solo no contexto de melhoramento de plantas e fenotipagem de alto rendimento (Hu et al., 2019; Jin et al., 2017; Li et al., 2018; Lopatin et al., 2017; Yan et al., 2019; Zhang et al., 2020). Os estudos relatam que os problemas relacionados ao tamanho dos pixels podem ser solucionados a partir da escolha de alturas de voo menores ou maior qualidade das câmeras, no entanto, em nosso estudo observamos que a qualidade do mapeamento de falhas também pode ser influenciada pela altura de planta.

Nós constatamos que a altura de planta é um dos aspectos que mais influencia na estimativa de falhas, além disso, à medida que as plantas crescem, ocorre sobreposição do solo pelas folhas, o que diminui a área visível para identificação das linhas com falhas. As estimativas de falha realizadas com a maior resolução das imagens (tamanho do pixel 3,5 cm), os erros foram de ~57,6 % para alturas de plantas

com 1,7 m e de ~19,2 % para alturas de planta com 0,5 m. Nas condições mais desafiadoras avaliadas em nosso estudo, quando tamanho de pixel e altura de planta foram maiores, o erro atingiu ~90,4 % para todos os comprimentos de falhas. De maneira geral, o maior tamanho de pixel apresenta ~1,8 vezes mais erro, quando comparado ao pixel de menor tamanho, enquanto a maior altura de planta apresenta ~2,8 vezes mais erro que a menor altura.

Nossos resultados tenderam a subestimar os reais comprimentos de falhas pelas imagens UAV, principalmente em falhas de menor comprimento (0,5 m). Uma das razões para não identificação destas falhas poderia ser explicada pelo tamanho do pixel. No entanto, acreditamos que o pixel de 3,5 cm seria suficiente para identificar as falhas no comprimento de 0,5 m, pois, segundo estudo realizado por Hu et al. (2019), indica que para obter resultados satisfatórios, o tamanho de pixel deve ter cerca de 10 % do tamanho do objeto a ser identificado.

Contudo, desde a primeira avaliação, as plantas que estavam ao lado das falhas de 0,5 m, apresentavam folhas cobrindo toda a superfície da área de falha ([Figura 10](#)), assim dificultando a visualização da falha. Dificilmente as falhas estarão totalmente visíveis, pois a arquitetura da planta e a disposição de suas folhas pode cobrir parte ou totalmente a área onde a falha está localizada, dessa forma, as falhas de menor comprimento são mais afetadas. Um exemplo apresentando essa condição para todos os tamanhos de pixel avaliados sob a falha de 0,5 m em campo é mostrado na [Figura 10](#).



**Figura 10.** Exemplo da sobreposição das falhas ocasionada pelas folhas da cultura; régua de 0,5 m à frente da falha, na ocasião uma falha de 0,5 m.

Outra possível razão pela qual a estimativa de falhas poderia ter subestimado os valores reais observados em campo é a presença de plantas daninhas, esse fato foi evidenciado por Randelović et al. (2020), em avaliação de densidade de plantas de soja. O que não ocorreu em nosso estudo, pois durante o crescimento da cultura foi cuidado para que as parcelas experimentais estivessem livres de plantas daninhas no momento de aquisição das imagens. Em sentido prático, maiores erros também podem ocorrer na estimativa de falhas nas extremidades da área, devido ao crescimento irregular da cana-de-açúcar. Erros como esse foram apresentados por Xu et al. (2020), que destacou influência das atividades humanas e pisoteio por veículos, representando a melhor explicação para essa observação.

A estimativa precisa de falhas em canaviais é necessária para avaliação da uniformidade de brotação e perfilhamento e a consequente formação de colmos, pois essas características estão diretamente relacionadas com a produtividade (Bocca et al., 2015; Luna e Lobo, 2016; Matsuoka e Stolf, 2012). Além disso, a estimativa de falhas fornece suporte para melhorar a tomada de decisão quanto ao replantio ou reforma do canavial (Souza et al., 2017), permitindo avaliar sua rentabilidade e longevidade (Keerthipala e Dharmawardene, 2000; Matsuoka e Stolf, 2012).

Podemos relatar também que, informações adquiridas através da estimativa de falhas, caso não sejam adotadas para tomada de decisões no primeiro ano de cultivo, podem também ser potencialmente empregada nos demais anos de cultivo. Outra aplicação promissora é a utilização de sistemas de correção de posicionamento (*Real Time Kinematic - RTK, Post-Processed Kinematic - PPK ou Ground Control Points - GCPs*) para o mapeamento de falhas, dessa forma, os resultados chegam à precisão de posicionamento centimétrica ( $\pm 2,5$  cm). Assim, os resultados deste mapeamento podem ser estrategicamente utilizados em outros equipamentos agrícolas, possibilitando o replantio preciso e manejo sustentável de fertilizantes sobre as falhas.

A estimativa de falhas é importante para definição dos impactos na produtividade do canavial. Uma limitação do nosso estudo foi para estimativa de falhas de 0,5 m, no entanto, verificamos que um dos motivos foi devido as plantas presente ao lado das falhas interferirem nessa estimativa ([Figura 10](#)), o que não havia sido relatado em estudos anteriores. Portanto, mais estudos são necessários para verificar os impactos que os comprimentos de falhas causam na produtividade, principalmente ao longo prazo, visto que, essa é uma cultura semi-perene, dessa forma seria possível determinar o comprimento de falha que impactaria negativamente o cultivo, do ponto de vista produtivo e econômico.

## **2.5. Conclusões**

Neste artigo, abordamos os impactos de tamanhos de pixel e alturas de planta para o mapeamento de falhas em canavial. O presente estudo propôs interação entre esses fatores para obter alta relação entre a estimativa de falhas por imagens UAV e falhas em campo. Nós demonstramos os impactos da qualidade de um mapeamento

de falhas em canavial por imagens UAV sob condições ideais e desafiadoras. Nossos resultados confirmaram que é necessário utilizar o tamanho de pixel ideal e definir o momento correto para captura de imagens. Se pudermos mapear falhas com alturas de planta de até 0,5 m e planejar altura de voo para atingir tamanho de pixel de no máximo 3,5 cm, isso resolverá grande parte do erro. Além disso, observamos que quanto menor o comprimento da falha de campo, menor é a acurácia do mapeamento, em que, a grande limitação desse estudo foi mapear falhas de 0,5 m. Acreditamos, portanto, que embora a abordagem apresentada nesta pesquisa seja desenvolvida para mapeamento de falhas em cana-de-açúcar, pode ser potencialmente aplicada para outras culturas, em que fatores como tamanho de pixel e altura de planta possam influenciar a precisão da coleta de informações.

## 2.6. Referências

Alvares CA, Stape JL, Sentelhas PC, Gonçalves JLM, Sparovek G. (2013) Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift** 22:711–728.

Bocca FF, Rodrigues LHA, Arraes NAM. (2015) When do I want to know and why? Different demands on sugarcane yield predictions. **Agricultural Systems** 135:48–56.

Carpio LGT, Souza FS de. (2017) Optimal allocation of sugarcane bagasse for producing bioelectricity and second generation ethanol in Brazil: Scenarios of cost reductions. **Renewable Energy** 111:771–780.

CONAB. (2020) **Safra Brasileira de Cana-de-Açúcar**. Brasília, 62 p. (Observatório Agrícola, 3).

Hu P, Guo W, Chapman SC, Guo Y, Zheng B. (2019) Pixel size of aerial imagery constrains the applications of unmanned aerial vehicle in crop breeding. **ISPRS Journal of Photogrammetry and Remote Sensing** 154:1–9.

Jin X, Liu S, Baret F, Hemerlé M, Comar A. (2017) Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. **Remote Sensing of Environment** 198:105–114.

Keerthipala AP, Dharmawardene N. (2000) Determination of optimal replanting cycles for sugarcane production in Sri Lanka. **Sugar Tech** 2:9–19.

Li L, Mu X, Macfarlane C, Song W, Chen J, Yan K, Yan G. (2018) A half-Gaussian fitting method for estimating fractional vegetation cover of corn crops using unmanned aerial vehicle images. **Agricultural and Forest Meteorology** 262:379–390.

Lopatin J, Fassnacht FE, Kattenborn T, Schmidlein S. (2017) Mapping plant species in mixed grassland communities using close range imaging spectroscopy. **Remote Sensing of Environment** 201:12–23.

Luna I, Lobo A. (2016) Mapping crop planting quality in sugarcane from uav imagery: A pilot study in nicaragua. **Remote Sensing** 8:500.

Matsuoka S, Stolf R. (2012) Sugarcane tillering and ratooning: key factors for a profitable cropping, in: **Sugarcane: Production, Cultivation and Uses**. Araras, p. 138–157.

Molin JP, Veiga JPS. (2016) Spatial variability of sugarcane row gaps: Measurement and mapping. **Ciência e Agrotecnologia** 40:347–355.

Ranđelović P, Đorđević V, Milić S, Balešević-Tubić S, Petrović K, Miladinović J, Đukić V. (2020) Prediction of soybean plant density using a machine learning model and vegetation indices extracted from rgb images taken with a uav. **Agronomy** 10:1108.

Raper RL. (2005) Agricultural traffic impacts on soil. **Journal of Terramechanics** 42:259–280.

Rossi M. (2017) Mapa pedológico do Estado de São Paulo: revisado e ampliado. São Paulo, 118 p. Instituto Florestal.

Santos MAL, Silva S, Zocoler JL, Teodoro I, Dantas Neto J, Sousa J da S. (2013) Avaliação de falhas na brotação da cana-de-açúcar em função da disponibilidade hídrica. **Agropecuária científica no semiárido** 30–35.

Shendryk Y, Sofonia J, Garrard R, Rist Y, Skocaj D, Thorburn P. (2020) Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal of Applied Earth Observation and Geoinformation** 92:102177.

Souza CHW de, Lamparelli RAC, Rocha JV, Magalhães PSG. (2017) Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture** 143:49–56.

Stolf R. (1986) Methodology for gap evaluation on sugarcane lines. **STAB** 4:12–20.

Waclawovsky AJ, Sato PM, Lembke CG, Moore PH, Souza GM. (2010) Sugarcane for bioenergy production: An assessment of yield and regulation of sucrose content. **Plant Biotechnology Journal** 8:263–276.

Xu J-X, Ma J, Tang Y-N, Wu W-X, Shao J-H, Wu W-B, Wei S-Y, Liu Y-F, Wang Y-C, Guo H-Q. (2020) Estimation of sugarcane yield using a machine learning approach based on UAV-LiDAR data. **Remote Sensing** 12:2823.

Yan G, Li L, Coy A, Mu X, Chen S, Xie D, Zhang W, Shen Q, Zhou H. (2019) Improving the estimation of fractional vegetation cover from UAV RGB imagery by colour unmixing. **ISPRS Journal of Photogrammetry and Remote Sensing** 158:23–34.

Zhang J, Xie T, Yang C, Song H, Jiang Z, Zhou G, Zhang D, Feng H, Xie J. (2020) Segmenting purple rapeseed leaves in the field from UAV RGB imagery using deep learning as an auxiliary means for nitrogen stress detection. **Remote Sensing** 12:1403.

Zhao P, Guo J, Gao X, Liu G, Li Y, Burner DM, Yang L. (2019) Small-scale mechanical harvesting and tractor-caused soil compaction reduce early growth in sugarcane. **Agronomy** 9:830.

### **CAPÍTULO 3 – Considerações finais**

Mapear falhas em canaviais é de extrema importância. Neste estudo conseguimos fechar parte da lacuna da metodologia de mapeamento de falhas por imagens UAV. Mostramos que é possível estimar falhas em linhas de cana-de-açúcar de forma precisa e exploramos os principais fatores que garantem esses resultados. Até então, os métodos de avaliação de falhas por imagens apresentados na literatura não obtinham informações suficiente para que sejam aplicados de tal forma a garantir estimativa precisa de falhas nos canaviais.

A utilização de UAV por si só no mapeamento falhas não é a solução dos problemas. Sendo necessário definir o momento ideal para captura das imagens e a qualidade das imagens. A altura de planta acima do ideal, aliada a maiores tamanhos de pixel da imagem podem ser considerados os principais causadores da subestimação dos valores reais de falhas.

Em estudos futuros avaliaremos os impactos de comprimentos de falha na produtividade de cultivares de cana-de-açúcar, analisando os efeitos a curto e longo prazo. Uma das limitações do presente estudo foi identificar falhas de 0,5 m, no entanto, ainda não conhecemos os impactos que esse comprimento de falha pode ocasionar, em termos produtivos e econômicos.

Também será testada a eficiência de implantar manejo sustentável de nutrientes sobre falhas, de modo a minimizar os impactos econômicos e ambientais. A aplicação de fertilizantes nas falhas ocasiona desperdício de insumos, causando impacto econômico, colaborando com a proliferação de plantas daninhas e também afetando o meio ambiente. No entanto, as plantas próximas às falhas podem compensar, em parte, a redução da produtividade. É possível que essas plantas absorvam os nutrientes contidos nas falhas.

A potencial implementação de plataformas de fenotipagem de alto rendimento (HTPPs) é útil para explorar o desenvolvimento da cana-de-açúcar. Sensores espectrais embarcado em UAV serão utilizados para avaliação do estado da cultura em condições de falhas. Assim, fornecendo compreensão clara do estado do crescimento e desenvolvimento fenológico das plantas.