

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

**ANÁLISE DE FALHA DE BROTAÇÃO DA CANA-DE-AÇÚCAR ATRAVÉS DE
METODOLOGIA MANUAL E GEOPROCESSAMENTO EM UM SISTEMA DE
CULTIVO MECANIZADO**

Camila Gomes Bezerra de Melo

RECIFE

2022

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

**ANÁLISE DE FALHA DE BROTAÇÃO DA CANA-DE-AÇÚCAR ATRAVÉS DE
METODOLOGIA MANUAL E GEOPROCESSAMENTO EM UM SISTEMA DE
CULTIVO MECANIZADO**

Camila Gomes Bezerra de Melo

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal Rural de Pernambuco - UFRPE, como parte dos requisitos para obtenção do Grau de Mestre em Engenharia Agrícola.

Orientador: Prof. Dr. Mário Monteiro Rolim

RECIFE

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- M528a Melo, Camila Gomes Bezerra de
 ANÁLISE DE FALHA DE BROTAÇÃO DA CANA-DE-AÇÚCAR ATRAVÉS DE METODOLOGIA MANUAL E
 GEOPROCESSAMENTO EM UM SISTEMA DE CULTIVO MECANIZADO / Camila Gomes Bezerra de Melo. -
 2022.
 49 f. : il.
- Orientador: Mario Monteiro Rolim.
 Inclui referências.
- Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia
 Agrícola, Recife, 2022.
1. agricultura de precisão. 2. cana-de-açúcar. 3. colheita mecanizada. 4. VANT. I. Rolim, Mario Monteiro, orient. II.
 Título

**ANÁLISE DE FALHA DE BROTAÇÃO DA CANA-DE-AÇÚCAR ATRAVÉS DE
METODOLOGIA MANUAL E GEOPROCESSAMENTO EM UM SISTEMA DE
CULTIVO MECANIZADO**

Eng. Agr. E Amb. Camila Gomes Bezerra de Melo

Dissertação defendida e aprovada em: 05/09/2022 pela banca examinadora:

ORIENTADOR:

Prof. Dr. Mário Monteiro Rolim
(DEAGRI – UFRPE)

EXAMINADORES:

Profa. Dra. Ana Lúcia Bezerra Candeias
(Engenharia Cartográfica CTG – UFPE)

Prof. Dr. Fabrício Marcos Oliveira Lopes
(DEPA – UFRPE)

Dedico, à Agnaldo Bezerra de Melo (in memoriam), meu pai, por todo esforço colocado em favor da minha educação, pelo amor, cuidado, incentivo e dedicação até o último momento em que pôde estar presente em minha vida.

AGRADECIMENTOS

A Universidade Federal Rural de Pernambuco (UFRPE) e ao Programa de Pós Graduação em Engenharia Agrícola (PGEA/UFRPE), pela oportunidade de cursar o Mestrado, por todo o apoio e estrutura oferecidos.

À Fundação de Amparo a Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pela concessão da bolsa durante o período do mestrado.

À Usina São José Agroindustrial S/A por nos ceder suas áreas de cultivo para condução da pesquisa.

Ao meu orientador, Prof. Dr. Mário Monteiro Rolim, por toda a parceria, desde a graduação, por acreditar na minha capacidade e por toda compreensão e paciência empregada para que eu finalizasse o mestrado.

Ao professor Dr. Fabrício Lopes e ao Dr. Renato Lima pelos conhecimentos compartilhados, pela disponibilidade em ajudar e todo auxílio prestado para finalização desse trabalho.

Aos colegas do Laboratório de Mecânica dos Solos e Aproveitamento de Resíduos: Davi Thorpe, Pedro Francisco, Roberta Cavalcanti e Talita Gouveia. Que estiveram presentes em algumas fases do desenvolvimento deste trabalho, sou inteiramente grata por toda ajuda.

Aos amigos da pós que levo para a vida, Francisco Ernesto, Gabriel Siqueira, Laís Barreto, Larissa Lino, Renato Luís, Victor Gurgel, pelos momentos de descontração, estudo e companheirismo.

Aos meus Pais, Sandra Gomes Bezerra de Melo e Agnaldo Bezerra de Melo (in memoriam), e à minha irmã Maria Eduarda Gomes Bezerra de Melo por todo apoio, amor e incentivo, por tudo que já fizeram por mim durante a minha caminhada, acadêmica e profissional, se fazendo presentes em cada conquista.

Aos meus familiares, meus avós, tios e primos por todo carinho e afeto mesmo que na distância.

Aos meus amigos do Agro é, às amigas do Cluster e aos colegas da Maxim, por me incentivarem a acreditar no meu potencial e vibrarem comigo cada conquista importante.

E por fim, a mim mesma, por ser forte e perseverante no momento de maior dificuldade da minha vida para concluir esta etapa tão almejada.

Sumário

1. Introdução	9
2. Objetivos.....	10
2.1 Objetivo geral.....	10
2.2 Objetivos específicos.....	10
3. Revisão bibliográfica	10
3.1 A cana-de-açúcar.....	10
3.2 O sistema de colheita mecanizado	11
3.3 Falhas no plantio e rebrota da cultura de cana-de-açúcar	13
3.4 Geotecnologias aplicadas na agricultura	14
3.4.1 Utilização dos VANTs, geoprocessamento e sensoriamento remoto na agricultura.....	15
4. Material e métodos.....	18
4.1 Área de estudo.....	18
4.2 Análise de falhas do plantio e brotação manual	20
4.3 Avaliação de falhas com veículo aéreo não tripulado (VANT)	21
5. Resultados e discussão.....	27
5.1 Produtos do processamento em software GIS das imagens obtidas com o VANT.....	27
5.2 Validação do método por imagem aérea	30
6. Conclusão.....	39
7. Referências.....	42

Lista de Figuras

Figura 1. Mapa do Estado de Pernambuco e localização da área experimental em que foi realizado o experimento, no município de Igarassu.	19
Figura 2. Espaçamento da cana-de-açúcar na área de estudo e zona de tráfego ideal.....	20
Figura 3. Medição das falhas manualmente na área de estudo.....	21
Figura 4. Medição das falhas manualmente na linha de plantio.....	21
Figura 5. Etapas de processamento das imagens analisadas.	23
Figura 6. Imagem RGB de março de 2017 com linhas de plantio demarcadas por um vetor de linha em tom amarelo.	24
Figura 7. Índice de vegetação GLI aplicado na imagem obtida por VANT em março de 2018 (90 dias após a colheita).	25
Figura 8. Imagem de março de 2017, classificada e vetorizada da área de estudo.	26
Figura 9. Falhas de brotação detectadas na imagem de março de 2017 após o processamento.	27
Figura 10. Mapa do índice GLI das imagens utilizadas no experimento. A, após o preparo; B, após a colheita.....	28
Figura 11. Mapas das falhas extraídas através do algoritmo de processamento proposto na imagem de VANT adquirida 90 dias após o plantio (A) e na imagem adquirida 90 dias após a primeira colheita (B).....	29
Figura 12. Distribuição das falhas observadas na Imagem do VANT (A) e medidas em Campo (B) na área após o plantio.	31
Figura 13. Número de falhas de brotação medido em campo e estimado com VANT por classe de comprimento após o plantio (A) e após a colheita (B).....	33
Figura 14. Comprimento total das falhas medido por classe após o plantio (A) e após a colheita (B).	35
Figura 15. Correlação entre os comprimentos totais de falhas medidos por linha na Imagem do VANT e medido em Campo após o plantio (A) e após a colheita (B)	37

Lista de Tabelas

Tabela 1. Especificações do VANT utilizado no experimento.	22
Tabela 2. Análise de variância dos comprimentos totais de falhas medidas por linha na Imagem do VANT e em Campo após o plantio.	36
Tabela 3. Análise de variância dos comprimentos totais de falhas medidas por linha na Imagem do VANT e em Campo após a colheita.	38

ANÁLISE DE FALHA DE BROTAÇÃO DA CANA-DE-AÇÚCAR ATRAVÉS DE METODOLOGIA MANUAL E GEOPROCESSAMENTO EM UM SISTEMA DE CULTIVO MECANIZADO

Resumo:

O ciclo de cultivo da cana-de-açúcar pode durar em média cinco anos antes do seu replantio, sendo cada corte realizado anualmente. Porém, durante os ciclos produtivos é comum o surgimento de falhas de brotação, que se intensificam após os sucessivos cortes. As “Falhas” são espaços vazios sem colmos que ocorrem nas linhas de cana-de-açúcar, sendo assim, associada à diminuição da produtividade, e sua medição/quantificação é comumente realizada manualmente em campo. Assim, este trabalho teve como objetivo propor uma metodologia alternativa para a medição das falhas do plantio e de rebrota em cultivo de cana-de-açúcar a partir de imagens adquiridas com VANT (Veículo Aéreo Não Tripulado), fazendo uso do geoprocessamento, e avaliar a qualidade da medição das falhas comparando com a medição manual realizada em campo. Em uma área experimental de um hectare, sob regime de colheita mecanizada, foi realizado o experimento para analisar o comportamento das falhas de plantio e rebrota da cana-de-açúcar. A metodologia de referência consiste na medição das distâncias contínuas sem brotação entre duas plantas ao longo de uma linha de plantio, considerando-se como falha as distâncias maiores que 0,50 m. A medição é realizada a partir de 90 dias após o plantio, momento que a cultura já está estabelecida. Enquanto para o levantamento de falhas com veículo aéreo não tripulado foram obtidas imagens aéreas do tipo RGB (Red, Green, Blue bands) de 12 megapixels (4000×3000 pixel) que foram processadas para gerar mosaicos das imagens finais. Após isto, as imagens foram processadas em algoritmo de processamento no software QGIS e os resultados comparados com os valores obtidos manualmente após o plantio e colheita. O número de falhas de brotação medidas através da imagem do VANT com comprimento entre 0,5-1,0 m se mostrou oito vezes maior se comparada com a medição em campo. Na classe das falhas entre 1-1,5 m o resultado se inverte, sendo a medição de campo aproximadamente 3 vezes maior que a medição do VANT, apresentando diferença significativa em ambas as classes. Nas outras classes de comprimento analisadas o número de falhas não apresentou diferenças representativa.

Palavras-chave: agricultura de precisão; cana-de-açúcar; colheita mecanizada; VANT.

Abstract:

The sugarcane crop cycle can last an average of five years before replanting, with each harvest being made annually or one year and a half. However, during the production cycles, it is common for sprouting row gaps to appear, which intensify after successive harvests. Sugarcane row gaps are empty spaces without stalks that occur in the sugarcane rows and are thus associated with decreased productivity, and their measurement/quantification is commonly performed on site manually. Thus, this work aimed to propose an alternative methodology for the measurement of planting and regrowth gaps in sugarcane crops from images acquired with VANT, using geoprocessing data, and to evaluate the quality of the measurement of the gap compared with the manual measurement performed in the field. In an experimental area of one hectare, under mechanized harvesting, an experiment was conducted to analyze the behavior of the sugarcane planting and regrowth gaps. The reference methodology consists in measuring the continuous distances without sprouting between two sugarcane stalks along a planting line, considering as faults those distances larger than 0.50 m. The measurement is performed 90 days after planting when the crop is already established. While in the measurement using an unmanned aerial vehicle, aerial images of RGB type (Red, Green, Blue bands) with 12 megapixels (4000×3000 pixels) were obtained and processed to generate the respective ortomosaics of the final images. After this, the images were processed with the processing algorithm in QGIS software, and the results were compared with the values obtained manually after planting and harvesting. The number of sprouting faults measured through the UAV image was higher with lengths between 0.5-1.0 m, however in the field it was lower. In the class of faults between 1-1.5 m, the result is inverted. In the other length classes analyzed the number of faults did not showed a representative difference.

Keywords: precision agriculture; sugarcane; mechanized harvest; UAV.

1. Introdução

A cana-de-açúcar vem sendo uma das culturas mais representativas em produção no Brasil, originando produtos como açúcar, etanol e energia elétrica a partir da utilização integral da planta.

O início do ciclo de cultivo da cana-de-açúcar proporciona obter uma boa produção e, de modo que a produtividade alcance o patamar esperado para a área cultivada em questão, o que demanda uma constante necessidade de aplicação de práticas inovativas que possibilitem alcançar melhor rendimento na colheita, com alta qualidade e menor custo; no entanto, alguns fatores intrínsecos do sistema de cultivo, como por exemplo a utilização da colheita mecanizada, podem vir a causar a diminuição da produtividade em uma área cultivada.

A colheita mecanizada da cana-de-açúcar tem promovido inúmeros benefícios para o sistema relacionados ao aumento da capacidade operacional, otimizando processos de produção e ainda reduzindo impactos ambientais, devido à substituição da queima da cana-de-açúcar pela colheita da cana crua com máquinas colhedoras. No entanto, estudos mostram que a forma como é realizada a colheita mecanizada nas lavouras também tem causado problemas que reduzem a qualidade do material colhido e que podem contribuir para que a área sofra perdas de produtividade no decorrer de cada corte. Isto pode acarretar no surgimento de falhas de brotação nas linhas de cultivo da cana-de-açúcar.

As falhas de brotação são espaços vazios entre colmos maiores que 0,50 m que ocorrem nas linhas de plantio, onde a cana-de-açúcar não brotou. Para a medição das falhas de brotação em áreas comerciais cultivadas com cana-de-açúcar utiliza-se a metodologia clássica de Stolf (1986), na qual a medição é realizada em campo, manualmente, linha por linha. Esse tipo de levantamento é considerado muito trabalhoso, o que dificulta a sua realização em grandes áreas cultivadas e por isso tem surgido a ideia de metodologias alternativas que fazem o uso de imagens aéreas de alta resolução obtidas com “drone” para identificar e medir as falhas de brotação, como uma forma eficaz para otimizar os insumos, utilizando abordagens específicas no local, além de auxiliar na tomada de decisão sobre a renovação do canavial para garantir a lucratividade contínua.

Diante disso, neste trabalho buscou-se aplicar as duas metodologias de medição das falhas de brotação em uma área cultivada com cana-de-açúcar, a fim de testar a qualidade de um levantamento de falhas através de imagens obtidas com VANT em comparação com

o levantamento realizado em campo e pontuar os fatores que podem influenciar na qualidade dos dois tipos de levantamento.

2. Objetivos

2.1 Objetivo geral

Avaliar a qualidade da medição das falhas do plantio e de rebrota em cultivo de cana-de-açúcar obtida a partir de imagens adquiridas com VANT, fazendo uso do geoprocessamento e comparar com as medições realizadas manualmente em campo.

2.2 Objetivos específicos

- Desenvolver um algoritmo de processamento em software de SIG – Sistema de Informação Geográfica, que possibilite a medição das falhas na imagem de VANT em método semi-automático;
- Avaliar a utilização dos VANT na identificação e quantificação, bem como a eficácia dos produtos obtidos para análise de falhas de brotação da cana-de-açúcar;
- Comparar os dois procedimentos de obtenção de dados: aéreo e terrestre (convencional).

3. Revisão bibliográfica

3.1 A cana-de-açúcar

A cana-de-açúcar (*Saccharum* sp.) tem importância agrícola e industrial no Brasil, devido ao valor da produção, área explorada e suas múltiplas utilidades (FILHO et al., 2016). Segundo a Companhia Nacional de Abastecimento - CONAB (2022), o Brasil é o maior produtor mundial, o que a torna a cultura importante para o agronegócio do país, em virtude das grandes áreas cultiváveis e condições edafoclimáticas favoráveis. Esta commodity tem sido cada vez mais relevante para a produção agrícola, por ser considerada uma das grandes alternativas para o setor de biocombustíveis, devido ao grande potencial na produção de etanol e seus respectivos subprodutos.

De acordo com a CONAB (2022) a área de cana-de-açúcar colhida em todo o território nacional está estimada em 8.209,3 mil hectares para a safra de 2022/2023, além disso, estima-se a produtividade de 72.609 kg ha⁻¹ e produção total de 596,1 milhões de toneladas colhidas. A agroindústria sucroalcooleira nacional, diferentemente do que ocorrem nos demais países, opera numa conjuntura positiva e sustentável (CONAB, 2022).

No Estado de Pernambuco, a cana-de-açúcar tem produção relevante, contribuindo para elevar a produtividade do país, com lavouras em bom desenvolvimento, que apresentam boas condições, beneficiadas, principalmente, pelo clima favorável. Em termos de produção a cana-de-açúcar no Estado representa cerca de 7% da produção nacional e 10% da área total de cultivo do país, ocupando o segundo lugar após o Centro-Oeste (CARDOSO et al., 2019) e uma área cultivada de 217,4 mil hectares (CONAB, 2022).

A cultura da cana-de-açúcar é classificada como semiperene e suas colheitas podem ser realizadas anualmente ou a cada um ano e meio. Em uma área de cultivo ela pode ser cortada em média cinco vezes antes do seu replantio, ou seja, a cada seis anos. Porém, durante os ciclos produtivos é comum o surgimento de falhas de brotação, que se intensificam após cada corte sucessivo (ROCHA et al., 2022).

3.2 O sistema de colheita mecanizado

O setor sucroenergético tem se modernizado nos últimos anos, a fim de aderir a características mais sustentáveis, e isso além de outros fatores traz relação direta com o método de colheita predominante (MARASCA et al., 2017). O sistema manual, onde o trabalhador realiza o corte manual, tem sido cada vez menos frequente no país. Portanto, a colheita mecânica, com o uso de colhedoras passou a ser mais utilizada, nesse sistema a colheita é toda realizada sem queima prévia (LANÇONI et al., 2020).

Em Pernambuco, a cana-de-açúcar abrange ampla área de tabuleiros costeiros (ORTIZ, 2020) na qual a topografia, profundidade e textura do solo beneficiam o cultivo (SOUZA, 2015). Os solos das regiões de tabuleiros caracterizam-se por solos de caráter coesivo (FARIAS et al., 2013). Desta forma, apresenta-se como um fator limitante para o desenvolvimento da planta e do sistema mecanizado (LIMA et al., 2015). Essas limitações contribuem para a perda de produtividade e requerem alta demanda de energia nas operações de tráfego agrícola.

Como estratégia para contrapor essas limitações na região utiliza-se máquinas agrícolas para executar diferentes operações em campo como o preparo do solo para melhorar suas condições físicas para o plantio, mas também se utilizam essas máquinas para a colheita da cana, facilitando e aumentando a eficiência dos processos de produção da cana-de-açúcar (ORTIZ, 2020).

No entanto, problemas relacionados ao tráfego de máquinas e a colheita mecanizada podem reduzir a longevidade do canavial, bem como diminuir a produtividade

a cada colheita (GÍRIO, 2018) em decorrência do aumento das falhas do plantio e rebrota da planta, que podem ser observadas ao longo das linhas de cultivo da cana-de-açúcar.

Os problemas começam desde a renovação do canavial, quando serão plantadas novas mudas vindas de um sistema de corte mecanizado, que produzem colmos com gemas que sofreram injúrias devido ao atrito da cana-de-açúcar com as partes da colhedora (cortador de base, rolos transportadores e picador) (MISSIO, 2016). Segundo Ripoli et al. (2006), Landell et al. (2012) e Serafim et al. (2013) é comum inclusive a utilização de uma maior quantidade de mudas no plantio, a fim de prevenir a presença de falhas que persistirão por 4 a 5 anos quando houver a ocorrência de gemas inviáveis a serem utilizadas.

Na colheita mecanizada, o tráfego de máquinas na área de cultivo expõe o solo a tensões maiores a que o mesmo pode suportar, acarretando problemas edáficos (PACHECO et al., 2011; CASTIONI et al., 2018), como a compactação do solo que envolve inicialmente alterações nas propriedades físicas (desestruturação, degradação, alta densidade), resultando em solos com baixa macroporosidade, e consequentemente, restringindo a infiltração nas camadas mais superficiais ou até mais profundas, danificando as relações dos processos do sistema solo-água-plantas (SEKI et al., 2015; PROSDOCIMI et al., 2017).

Além disso, o processo de mecanização da colheita apresenta fatores críticos relacionados ao desgaste das colhedoras agrícolas e ao sistema de tráfego não controlado que ocasionam o pisoteio das soqueiras (SANOMIA et al., 2018).

As colhedoras cortam a cana-de-açúcar em sua base por meio de um sistema de impacto, composto por um disco rotativo com múltiplas lâminas. Neste processo, o rolo defletor empurra a cana-de-açúcar para frente e o componente mecânico da colhedora, o disco, entra em contato com a cana-de-açúcar na sua parte basal e efetua o corte, deixando apenas um pequeno pedaço dos colmos denominado de soqueira (VOLTARELLI et al., 2017).

Este mecanismo pode ser considerado como o responsável por parte das perdas na lavoura em virtude da colheita mecanizada (VOLTARELLI et al., 2017). O cortador de base das colhedoras de cana-de-açúcar devido à deflexão, à deficiência no controle da altura de corte, ao desgaste das lâminas e à incorporação de solo à matéria-prima são os causadores de danos na cana-de-açúcar colhida e na soqueira da cultura, influenciando a qualidade da matéria-prima e os níveis de perdas, podendo causar redução na longevidade do canavial e na rebrota da cana, tornando-a irregular ou inexistente, resultando no

aumento das falhas e consequentemente na diminuição da produtividade (GRAY et al., 2009; GÍRIO, 2018).

3.3 Falhas no plantio e rebrota da cultura de cana-de-açúcar

De acordo com Stolf et al. (2016) “falhas” são espaços vazios sem colmos que ocorrem nas linhas de cana-de-açúcar, as quais podem ser causadas por diversos fatores oriundos do processo de produção, tais como: o preparo do solo, plantio, tratos culturais e colheita, pragas, estiagem, baixa temperatura na época de plantio, pisoteio das soqueiras.

A presença das falhas está associada à diminuição da produtividade, muito embora as falhas sejam um grande problema para o cultivo de cana-de-açúcar, no entanto os produtores não utilizavam métodos para quantificação dessas falhas, sendo realizada apenas inspeção visual para descrever se o canavial se encontra “muito falhado” ou “pouco falhado” (STOLF et al., 1991). Assim, é visto que o conhecimento de técnicas de avaliação de falhas e o aprimoramento das mesmas como forma de quantificar as falhas são de extrema necessidade.

O tamanho e a intensidade das falhas na cultura da cana-de-açúcar tem tendência a aumentar ao longo de cada corte sucessivo, o que retorna na redução da produtividade da lavoura, tornando assim, a análise de falhas um parâmetro importante para auxílio na decisão de renovação do canavial (SASSAKI, 2019).

O método de Stolf (1986) é considerado como um método de referência na medição e quantificação das falhas no cultivo da cana-de-açúcar, e consiste na medição das distâncias contínuas sem brotação entre duas canas ao longo da linha de plantio, considerando-se falhas as distâncias maiores que 0,50 m.

A medição é realizada em campo com o auxílio de uma trena, a partir de 90 dias após o plantio, no momento que a cultura já está estabelecida, de forma que o comprimento das falhas é contado de forma cumulativa da primeira à última linha de cana-de-açúcar dentro da área analisada, o percentual de falhas pode ser estabelecido estatisticamente somando o comprimento total de falhas maiores que 0,50 m no trecho de linha de plantio observado e dividir pelo comprimento do trecho multiplicado por cem (BARROS, 2018).

Nesse sistema existem dois tipos de falhas, as falhas de plantio e de rebrota. Alguns fatores podem influenciar o desenvolvimento da cana-de-açúcar ao que diz respeito à ocorrência de falhas no plantio e na rebrota, sendo eles: fatores ambientais (temperatura e umidade do solo e do ar), genéticos e fisiológicos (variedade, idade, tamanho e sanidade

das gemas) e fitotécnicos (práticas agrícolas realizadas no campo) (SERAFIM et al., 2013; LUNA et al., 2016).

As falhas no plantio são aquelas que ocorrem após a renovação do canavial, cana-planta, e além dos fatores já citados é ocasionada pelo plantio de mudas com gemas de qualidade tecnológica reduzida, provenientes de corte mecanizado, em que sofrem injúrias e contaminação por incorporação de solo devido à problemas com o cortador de base (CEBIM et al., 2012; RODRIGUES et al., 2013).

As falhas de rebrota ocorrem após a primeira colheita (socaria) e estendem-se por todos os anos de cultivo da cana-de-açúcar na área, de forma cumulativa, em que os efeitos da colheita mecanizada são somados aos outros fatores causadores das falhas, sendo eles o pisoteio das soqueiras durante o tráfego, a deflexão e à deficiência no controle da altura de corte dos cortadores de base, provocando danos na soqueira e causando perdas de matéria-prima (SALVI, 2007).

O método de Stolf utilizado para quantificar as falhas pode ser utilizado para os dois tipos, este têm sido utilizado por várias empresas agrícolas desde sua criação, no entanto, este levantamento é muito trabalhoso e pode levar dias de campo para ser concluída.

Assim, a necessidade de obtenção de dados em larga escala e que possam descrever as lavouras mais rapidamente faz com que haja a busca por novas ferramentas, deste modo, vêm sendo utilizadas técnicas para quantificação de falhas através de imagens aéreas de alta resolução, obtidas por veículos aéreos não tripulados (VANT), em que uma imagem tratada por um método computacional que possibilita obter a porcentagem de falhas (STOLF et al., 2016).

3.4 Geotecnologias aplicadas na agricultura

O comportamento crescente da demanda alimentícia mundial, acarretada pelo aumento populacional, cria oportunidade para o surgimento de grandes desafios relacionados à agricultura de forma que tem sido impulsionado o uso de tecnologias no gerenciamento e controle dos processos produtivos, em busca de garantir maior eficiência nos sistemas de produção agropecuária (FURTADO et al., 2020).

Assim, esses conceitos vêm sendo utilizados a partir da aplicação de tecnologias e práticas que tornam possível a melhoria dos resultados econômicos na lavoura, além de processos agrícolas mais eficientes, responsáveis e rastreáveis e promotores de produção mais sustentável (MOZAMBANI, 2018).

Uma dessas frentes se baseia no emprego das Geotecnologias em áreas de produção agrícola, as quais podem ser definidas como um conjunto de técnicas e tecnologias capazes de auxiliar em procedimentos de coleta, integração de dados, processamento, análise e armazenamento de informações geo-espaciais, ou seja, que possuem coordenadas geográficas (FAVRIN, 2009; SCHOLTEN et al., 2009). Segundo Andrade et al. (2019), essas tecnologias estão disponíveis de diversas formas, e podem ser aplicadas por meio de satélites, softwares, aplicativos e até embarcadas em equipamentos e sensores instalados em máquinas, implementos agrícolas e Veículos Aéreos Não Tripulados (VANT).

Com o uso desses equipamentos se faz possível a aquisição de dados em campo e o processamento de informações territoriais de um determinado tipo de produção, permitindo um melhor entendimento da dinâmica do campo e propondo uma análise espacial que contribua fortemente na tomada de decisão.

É vasta a gama de sensores remotos com características espectrais, espaciais e temporais com potencialidades para gerar coberturas de áreas agricultáveis, nos quais se destacam o emprego dos VANT pela sua versatilidade, bom custo benefício e alta capacidade para obtenção de imagens aéreas, o que permite uma avaliação mais ampla de um cultivo, identificação de problemas e, conseqüentemente, auxiliando na tomada de decisão mais precisa e criteriosa (REIS, 2020).

Esta tecnologia demanda certo conhecimento e devem seguir algumas etapas para que seja executado com qualidade, sendo elas o planejamento de voo para obtenção das imagens, o georreferenciamento, o processamento para geração do ortomosaico e operações de geoprocessamento para obtenção de produtos que traçam às características de uma cultura. Deste modo, é possível realizar monitoramento de plantas, identificação de pragas e doenças, estimar a produtividade, medir falhas no plantio e soqueira, entre outros mapeamentos agrícolas (OLIVEIRA, 2020).

3.4.1 Utilização dos VANTs, geoprocessamento e sensoriamento remoto na agricultura

O uso de veículos aéreos não tripulados (VANTs), também conhecidos como "Drones", tem crescido na agricultura (INAMASU, 2011) dada à vasta possibilidade de aplicação. O termo VANT (SDCI, 2017) é aplicado para “drones” que tenham pequena carga útil, equipado com sensores ou câmeras digitais que possibilita imagear a superfície de uma área e assim, na agricultura, permite vistoriar o campo durante o ciclo do cultivo ou

pós-safra e fornecer um diagnóstico de diversas variáveis da cultura (FERNANDES, 2016).

Essas aplicações podem auxiliar o produtor a identificar estratégias que possam aumentar a eficiência no gerenciamento da agricultura, apontando problemas e maximizando a rentabilidade das colheitas. São considerados promissores ao monitoramento da cana-de-açúcar, se utilizado em resoluções espaciais e temporais apropriadas à variável a que se pretende analisar, aliado ao geoprocessamento e ao sensoriamento remoto (PRUDKIN et al., 2019; LUNA et al., 2016).

O termo Geoprocessamento se refere a um conjunto de tecnologias que possibilitam a coleta, armazenamento e tratamento de dados espaciais (raster ou vetorial) georreferenciados, através de técnicas matemáticas, computacionais e ferramentas presentes em Sistemas de Informação Geográfica (CÂMARA, 1996).

As imagens de satélites e fotos obtidas a partir de VANTs são exemplos de dados raster, estes que são formados por uma matriz de pixels ou células que contém um valor específico e representam uma condição/característica da área coberta por tal célula (ANDRADE et al., 2019). Já os dados vetoriais, que são armazenados em arquivo *shapefile*, são a utilização de um ou mais pares de coordenadas para representar pontos, linhas e polígonos e fazer a relação dessas feições com seus diferentes atributos (CÂMARA et al., 2001).

No cultivo da cana-de-açúcar, o sensoriamento remoto, definido por Lintz et al. (1976) como forma de aquisição de dados físicos de um objeto sem tocar ou entrar em contato, assim como o geoprocessamento, é capaz de auxiliar na identificação de problemas na lavoura, como a identificação das falhas (plantio e brotação), um processo comumente realizado de forma manual, o que torna o monitoramento mais difícil, por isso, o sensoriamento remoto é uma ferramenta primordial para a sua detecção (GAIDA et al., 2020). Assim, a agricultura tem se beneficiado dessas tecnologias, trazendo resultados satisfatórios quando utilizados os seus conceitos.

Uma forma de conhecer as características dos elementos visualizados em uma imagem aérea são as metodologias de classificação, que consiste na atribuição de um significado específico aos pixels da imagem, em função de suas propriedades numéricas e características espectrais, ou seja, a assinatura espectral confirma que aquele conjunto de pixels representa um tipo específico de uso da terra (ROSA, 2009).

Esse tipo de análise é possível em virtude da existência da radiação fotossinteticamente ativa presente nas plantas, uma vez que, as mesmas utilizam somente

uma parte da radiação eletromagnética incidente para realizar a fotossíntese, essa radiação pode ser captada na região do visível. Assim, a região do visível, imagens RGB, e a região do infravermelho, são amplamente utilizadas em estudos relacionados ao imageamento da vegetação terrestre (NOVO, 2010; MENESES, 2012).

Os VANTs utilizados para imagear as áreas cultivadas com cana-de-açúcar são equipados com câmeras, tais que seus sensores possibilitam capturar o comportamento de faixas do espectro de luz em interação com as plantas, a partir das câmeras de imageamento da superfície, por exemplo, nas bandas ou faixas do vermelho (R), verde (G) e azul (B), podendo ser obtidas inúmeras informações voltadas para tomadas de decisões mais precisas em diferentes escalas (MARTELLO, 2017).

Dentre estas técnicas estão os algoritmos de classificação e a aplicação de índices de vegetação em imagens raster. A forma mais utilizada de classificação é a supervisionada, em que o operador deve identificar na imagem uma área representativa de cada classe, ou seja, que contenha as características da mesma (SILVA et al., 2019).

Existem alguns tipos de classificação supervisionadas, uma das largamente utilizadas é o algoritmo de *Maximum Likelihood*, Máxima Verossimilhança (ou *Maxver*) que utiliza o conjunto de dados oriundo da coleta de pixels empregada na etapa de aquisição das amostras de treinamento das classes do mapa e cria uma distribuição normal de probabilidades dos valores de todas as bandas para cada classe (BUOT et al., 2006).

Para classificar os pixels da imagem é calculada a probabilidade dos pixels pertencerem a cada uma das classes criadas para o mapa. Ao final, os pixels serão incluídos nas classes que possuírem os respectivos maiores valores de probabilidade.

Uma forma de auxiliar no levantamento de dados sobre o estado da cultura no campo é a aplicação dos índices de vegetação nos ortomosaicos (SHIRATSUCHI et al., 2014). Essas técnicas permitem avaliar o estado das lavouras, onde os níveis de absorção da luz, assim como da quantidade de radiação refletida pelas folhas indicam a presença de cloroplastos, como a clorofila, água e do parênquima produzido no mesófilo (TRIPICCHIO et al., 2015).

São diversos os tipos de índice de vegetação existentes, que são largamente utilizados em estudos envolvendo a identificação de estresses da vegetação. Consequentemente, esses índices podem auxiliar na classificação dos alvos, por exemplo, na discriminação da vegetação em desenvolvimento dentro da normalidade e áreas de plantio que apresentam falhas (MONTIBELLER et al., 2017; SOUZA et al., 2017).

Desenvolvido por Louhaichi, Borman e Johnson (2001), o Green Leaf Index (GLI), Índice Foliar Verde, é um dos índices de vegetação considerado por apresentar resultados satisfatórios quanto à avaliação da vegetação, este foi idealizado por seus autores com o objetivo de determinar a intensidade de degradação da vegetação por fotografia aérea. Sendo assim, resultado da diferença normalizada das reflectâncias das faixas espectrais do azul, verde e vermelho, obtido através de uma equação.

O GLI mostra-se eficiente no acompanhamento de áreas vegetadas visualizadas por meio de imagens de alta resolução, que podem ter sido obtidas com drones, satélites comerciais ou outros tipos de aerofotografias georreferenciadas (SILVA et al., 2019); a utilização deste índice demonstra alto potencial de aplicação em análises vegetais, uma vez que apresentou resultados satisfatórios para avaliação da fração da vegetação (LOUAICHI, 2001).

Neste contexto, é possível afirmar que técnicas de “machine learning” aliadas ao conhecimento prático podem ser usadas para o monitoramento e medições diversas em indústrias de cana-de-açúcar, possibilitando a tomada de decisão para melhorar seu rendimento e a qualidade (RIDWAN et al., 2021).

Por isso, vê-se nas técnicas de Geoprocessamento e Sensoriamento Remoto uma ferramenta importante na obtenção desses resultados. Observa-se que, utilizando os veículos aéreos não tripulados, os softwares adequados e os índices de vegetação é possível realizar um monitoramento do cultivo em relação às falhas de brotação da cana-de-açúcar.

4. Material e métodos

4.1 Área de estudo

O estudo foi realizado em área de cultivo de cana-de-açúcar localizada no município de Igarassu, PE, situado entre as coordenadas 7°40'21,25" S a 7°55'50,92" S e 34°54'14,25" W a 35°05'21,08" W, a 28 km da Cidade do Recife. A área de estudo (Figura 1) está localizada na Usina São José com solo classificado como Argissolo, que apresenta boas características para o desenvolvimento da agricultura, no entanto, possui baixa fertilidade natural. Há predominância de areia com baixos conteúdos de argila e é considerado suscetível ao efeito de erosão hídrica (BRADY et al., 2013; SANTOS, 2018).

A área possui condições de relevo relativamente homogêneas (inclinação < 10%). Conforme classificação de Koppen, o clima da região é classificado como As', Tropical

quente e úmido, com temperatura média anual de 24,9 °C e precipitação média anual de 1.689 mm (INMET, 2019).




Figura 1. Mapa do Estado de Pernambuco e localização da área experimental em que foi realizado o experimento, no município de Igarassu.

Em uma área experimental de um hectare cultivada com cana-de-açúcar, sob regime de colheita mecanizada, foi realizado o experimento para analisar o comportamento das falhas de plantio e rebrota da cana-de-açúcar após o plantio e após a primeira colheita.

Para dar início a um novo ciclo de cultivo na área, antes do plantio foi feita a renovação do canavial, utilizando o sistema de preparo do solo convencional com etapas de subsolagem, gradagem, nivelamento e sulcagens, fazendo uso de tratores e implementos agrícolas. No plantio foram utilizados tratores, que carregaram e distribuíram a cana-de-açúcar (variedade RB92579) pela área entre os sulcos (ORTIZ, 2020). A área esteve em sistema de cultivo desde o ano de 2018, com primeiro corte (cana planta).

A área experimental analisada foi submetida à colheita mecanizada, sem queima da palhada. O cultivo foi organizado em fileiras duplas de cana-de-açúcar com espaçamento de 0,90 m entre linhas e 1,40 m entre fileiras (Figura 2), totalizando 44 fileiras duplas de cana-de-açúcar, ou seja, 88 linhas de plantio com 100 metros de comprimento cada (ORTIZ, 2020).




Figura 2. Espaçamento da cana-de-açúcar na área de estudo e zona de tráfego ideal.

No processo de colheita da cana-de-açúcar foi utilizada uma colhedora convencional *John Deere* de aproximadamente 20 toneladas, que corta limpa, pica a cana-de-açúcar em rebolos e deposita no transbordo, equipamento tracionado por um trator responsável pelo carregamento da cana-de-açúcar, se posiciona ao lado da colhedora (ORTIZ, 2020).

4.2 Análise de falhas do plantio e brotação manual

Seguindo a metodologia clássica para identificação e medição de falhas de brotação na lavoura de cana-de-açúcar, desenvolvida por Stolf (1986), o processo de levantamento das falhas foi realizado em campo em dois momentos: 90 dias após o plantio (março de 2017) e 90 dias após a primeira colheita (março de 2018), período em que se considera que a cultura já está estabelecida.

Para o levantamento considera-se que uma falha corresponde à projeção da distância entre dois colmos consecutivos ao longo da linha de cana-de-açúcar que seja maior que 0,50 m (BARROS, 2018).

As falhas foram medidas nas 88 linhas de plantio (44 linhas duplas) com trena de 100 m de comprimento estirada ao longo da linha (Figura 3), que foi utilizada para marcar a posição da falha na linha, e com o auxílio de uma trena menor, foi medido o comprimento de cada falha (Figura 4).

Foi registrado o comprimento de cada falha medida, utilizado posteriormente para comparação dos métodos de medição. O comprimento total das falhas é contado de forma

cumulativa, ao final do procedimento o valor lido equivale à somatória do comprimento das falhas maiores que 0,50 m (STOLF, 1986).



Figura 3. Medição das falhas manualmente na área de estudo.




Figura 4. Medição das falhas manualmente na linha de plantio.

4.3 Avaliação de falhas com veículo aéreo não tripulado (VANT)

O levantamento das falhas de brotação com veículo aéreo não tripulado foi executado utilizando um “drone” da marca *DJI modelo Mavic Pro*, equipado com um sensor *FC220* cujas especificações estão listadas na Tabela 1. Este sensor possibilita capturar imagens aéreas do tipo RGB (Red, Green, Blue bands) com 12 megapixels e resolução de 4000×3000 pixels (72 ppp (pixel por polegada), que se refere à resolução da imagem, ou seja, o número de pixels da imagem por polegada). As imagens foram feitas em duas fases do ciclo da cana-de-açúcar, a primeira obtida em março de 2017, 90 dias após o plantio, e a segunda em março de 2018, 90 dias após a colheita.

Tabela 1. Especificações do VANT utilizado no experimento.

Tamanho do sensor	1/2.3" (6,16 mm x 4,55 mm), 12,35 MP
Tamanho do pixel	1,55 micrômetros
Lente (Campo de visão)	78,8°
Tamanho da imagem	4000 x 3000 pixels
Distância focal	4,74mm
Distância focal (35mm)	27,64mm
Ponto principal X, Y	1974,82 pixels; 1491,48 pixels
Coeficientes de distorção: K1, K2, K3, P1, P2	-0,001; 0,0325; -0,046, 0, 0
Foco	De 0,5 m ao infinito, foco auto/manual
ISO	100-3200 (vídeo), 100-1600 (fotografias)
Velocidade do obturador	8-1/8000s
Formato das fotografias	JPEG, DNG

Fonte: Adaptado de Stateczny et al. (2018).

Para programar os voos foi utilizada a plataforma *Dronedeploy*, utilizando como inputs as coordenadas da área, o sistema de referência (*WGS84/Pseudo Mercator*), altura de voo de aproximadamente 60 m e sobreposição frontal e lateral de 80% e 75% respectivamente, para cada captura de imagem. Depois de adquiridas as imagens foram armazenadas em uma memória *MicroSD* e processadas através da mesma plataforma para gerar os respectivos mosaicos das imagens finais de cada área experimental (ORTIZ, 2020).

Após produzir os mosaicos obtidos pelo VANT (*Veículo Aéreo Não Tripulado*), foi feito o processamento das imagens com o auxílio do software QGIS (*Open Source Geospatial Foundation*, USA), na versão 3.12.3, de acordo com as etapas elencadas na Figura 5.

Com o ortomosaico obtido a partir das imagens do VANT, foi possível iniciar o processamento da imagem. A primeira etapa realizada foi a de identificação das linhas de cana-de-açúcar, criando um arquivo *shapefile* de linhas demarcando cada linha de plantio (Figura 6) dentro do software, manualmente através da ferramenta de criação de um arquivo *shapefile* de linhas, que conterá todas as linhas de plantio presentes na área.

Etapas de processamento

Melo, C.G.B. | 2022




Figura 5. Etapas de processamento das imagens analisadas.



Figura 6. Imagem RGB de março de 2017 com linhas de plantio demarcadas por um vetor de linha em tom amarelo.

Em seguida foi aplicado o índice de vegetação GLI - *Green Leaf Index* (Equação 1), utilizando a ferramenta do QGIS, calculadora raster. O índice foi utilizado para auxiliar na identificação dos pixels da imagem que representam as regiões em que a cana-de-açúcar está presente e as partes da imagem em que o solo está exposto, as falhas ou regiões entre as linhas cultivadas com cana-de-açúcar (LOUHAICHI et al., 2001).

$$GLI = \frac{2 \times G - R - B}{2 \times G + R + B} \quad (\text{Equação 1})$$

Em que:

R: valor de refletância na faixa espectral do vermelho (0,63 a 0,69 μm);

G: valor de refletância na faixa espectral do verde (0,52 a 0,60 μm);

B: valor de refletância na faixa espectral do azul (0,45 a 0,52 μm).

Idealizado por Louhaichi, Borman e Johnson (2001) com o objetivo de determinar a intensidade de degradação da vegetação por fotografia aérea, o *Green Leaf Index* (Figura 7), calcula a diferença normalizada das refletâncias das faixas azul, verde e vermelho do espectro visível e gera uma imagem com escala em tons de cinza com intervalo de variação de -1 a 1, na qual valores negativos representam áreas de solo e valores positivos da vegetação. Este índice de vegetação é considerado um índice promissor para análise da vegetação e é capaz de auxiliar na identificação da cobertura vegetal.




Figura 7. Índice de vegetação GLI aplicado na imagem obtida por VANT em março de 2018 (90 dias após a colheita).

Com o índice de vegetação foi possível distinguir nitidamente a linha de cana-de-açúcar das entrelinhas, além de também identificar as falhas presentes na linha. Após aplicado foi realizada a classificação supervisionada da imagem pelo método de *Maximum Likelihood*, Máxima Verossimilância, utilizando o Plugin SCP (*Semi-Automatic Classification Plugin*) (CONGEDO, 2013), a fim de diferenciar a cana-de-açúcar do solo exposto e criar um raster classificado.

A classificação supervisionada é utilizada no sensoriamento remoto para distinguir elementos presentes em uma imagem, através de informações características contidas em cada pixel da imagem aérea. Neste processo os pixels são classificados a fim de diferenciar elementos específicos presentes na fotografia, distinguindo em classes definidas pelo operador (BARBOSA, 2008). A classificação ocorre quando a partir das amostras de treinamento definidas, o algoritmo escolhido extrapola as características espectrais definidas, para as outras regiões da imagem, realizando assim a classificação (CASTILLEJO-GONZÁLEZ et al., 2009). Assim, a classificação supervisionada produziu uma imagem com duas classes: cana-de-açúcar (1) e solo exposto (2).

Após a classificação supervisionada, o produto raster obtido é transformado em um produto vetorial, através da ferramenta de poligonização do QGIS, que transforma a imagem raster em um arquivo *shapefile* (Figura 8), dessa forma foi possível selecionar as regiões classificadas como cana-de-açúcar e obter um vetor cujas feições correspondem à cana-de-açúcar na linha de plantio.




Figura 8. Imagem de março de 2017, classificada e vetorizada da área de estudo.

De posse do arquivo *shapefile* das linhas de plantio e do arquivo *shapefile* da classe cana-de-açúcar, com a ferramenta de diferença (linhas de plantio – arquivo *shapefile* cana-de-açúcar = falhas), foi obtido um novo vetor de linhas que representam todos os fragmentos de linha que o algoritmo pôde visualizar o solo exposto nas linhas de cultivo. Através do algoritmo de processamento desenvolvido (Figura 5) foi possível obter as falhas de brotação observadas na imagem de forma automática.

O produto do processamento são todos os fragmentos da linha de plantio no qual o algoritmo encontrou solo exposto, cada vetor teve seu comprimento medido separadamente utilizando a ferramenta calculadora de campo, através da função \$length, na Tabela de atributos arquivo *shapefile*. Os fragmentos maiores que 0,50 m (Figura 9) classificados como falha segundo Stolf (1986) foram filtrados e mantidos na imagem, fragmentos menores que 0,50 m, foram excluídos.

Os comprimentos dos vetores, obtidos após aplicação da função \$length foram exportados para uma planilha Excel, utilizada para posterior análise dos dados.




Figura 9. Falhas de brotação detectadas na imagem de março de 2017 após o processamento.

Em ambas as abordagens, levantamento manual ou assistido por computador os operadores devem calcular manualmente as estatísticas da análise, tais como avaliar os comprimentos de falhas de brotação predominantes, os comprimentos totais de falha por linha, estimar a proporção destes valores e analisar o quanto são representativos, permitindo, assim, tomar qualquer decisão sobre a plantação, uma vez que a quantidade excessiva de falhas é indesejável, pois representa prejuízo para o produtor.

5. Resultados e discussão

5.1 Produtos do processamento em software GIS das imagens obtidas com o VANT

Para auxiliar na qualidade da classificação supervisionada das imagens obtidas pelo VANT foi aplicado o índice de vegetação GLI (Green Leaf Index – Índice Foliar Verde). Os valores de GLI (Figura 10) em ambas as imagens se mantiveram no intervalo estabelecido do índice de vegetação (-1 a 1), onde os valores representados pela cor branca indicam o solo exposto e os pela cor preta a cana-de-açúcar. O índice se mostra adequado para avaliar o comportamento das falhas de rebrota na imagem, sendo possível a distinção visual entre essas variáveis (cana-de-açúcar e solo exposto).




Figura 10. Mapa do índice GLI das imagens utilizadas no experimento. A, após o preparo; B, após a colheita.

Como produto final do processamento das imagens adquiridas com o VANT através do algoritmo desenvolvido, a ferramenta de diferença do QGIS demarcou na imagem todos os fragmentos das linhas de plantio que o algoritmo considerou como falha,

nos quais se entende como falhas, todos os fragmentos de linha de comprimento maior ou igual a 0,5 m.

A Figura 11 mostra todos os segmentos, demarcados por vetores de linha (falha), na imagem adquirida 90 dias após o plantio (A) e 90 dias após a colheita (B).




Figura 11. Mapas das falhas extraídas através do algoritmo de processamento proposto na imagem de VANT adquirida 90 dias após o plantio (A) e na imagem adquirida 90 dias após a primeira colheita (B).

Os mapas ainda mostram em detalhes as linhas de plantio demarcadas, manualmente, por um arquivo *shapefile* em tom amarelo sobrepostas das falhas encontradas na imagem, vetor de linha em tom vermelho.

Estabelecendo uma comparação entre o mapa das falhas de brotação encontradas após o plantio (Figura 11A) e após a primeira colheita (Figura 11B), visualmente já é possível identificar que o número de falhas aumentou, bem como que algumas falhas que foram medidas na primeira imagem se mantiveram também na segunda imagem, ou seja, a falha persistiu ao longo do ciclo.

Este aumento no número de falhas da cana planta para a primeira socaria pode ocorrer devido aos efeitos da colheita mecanizada no sistema de cultivo da cana-de-açúcar. Resultado também foi encontrado por Ortiz (2020) ao analisar, na mesma área, os parâmetros de análise de falhas da cana-de-açúcar estabelecidos por Stolf (1986).

Neste experimento, a ocorrência de falhas de rebrota da cana-de-açúcar aumentou em número, tamanho e porcentagem após as operações de colheita. Aumento justificado pela diminuição da qualidade do solo verificada pelo experimento, em função do tráfego das máquinas colhedoras, apresentando correlação negativa considerável com a ocorrência de falhas, pois, com a diminuição dessa qualidade, houve aumento do número de falhas.

O aumento do número de falhas da medição manual para a medição computadorizada ainda pode ser justificado pelo mecanismo de corte basal das colhedoras de cana-de-açúcar que causam danos às soqueiras e podem inclusive danificar o sistema radicular, implicando no surgimento de falhas de brotação (TOLEDO et al., 2013).

Tais conclusões foram vistas por Bernache et al. (2020) ao avaliar a qualidade do mecanismo de corte basal utilizando como indicadores os danos na soca e os índices de perdas, e verificou que à medida que o desgaste da lâmina de corte basal se intensifica, danos e perdas na soca tornam-se mais pronunciados, afetando negativamente a rebrota da cana-de-açúcar e consequentemente o desenvolvimento da cultura e a produtividade da área.

5.2 Validação do método por imagem aérea

Como proposto no presente trabalho, a avaliação das falhas da cana-de-açúcar no plantio e primeira rebrota foi realizado a partir de dois métodos: medida de campo e com técnica de geoprocessamento.

Manualmente, obtendo a medida de campo das falhas de brotação por meio da metodologia desenvolvida por Stolf (1986) e pela metodologia com processamento de

imagem obtida com VANT em software de SIG (STOLF et al., 2016). As duas formas de medição (Figura 13) foram utilizadas a fim de comparar os resultados obtidos em cada processo de levantamento e assim verificar se o algoritmo de avaliação aplicado nas imagens foi capaz de apresentar resultados satisfatórios.




Figura 12. Distribuição das falhas observadas na Imagem do VANT (A) e medidas em Campo (B) na área após o plantio.

A medição a partir da imagem do VANT ocorreu utilizando o algoritmo de processamento desenvolvido em software de SIG, que consistiu na identificação das falhas, medição do comprimento de cada uma delas e na obtenção da coordenada de posição da falha em cada linha de plantio. A mesma sistemática para análise foi também empregada em campo. Assim, foi possível conhecer as falhas medidas na imagem do VANT através

do geoprocessamento e as falhas medidas em campo manualmente, linha por linha, em dois tratamentos. Em levantamento 90 dias após o plantio e 90 dias após a primeira colheita.

Representando os dados coletados na imagem (Figura 12, A1 e B1) e em campo (Figura 12, A2 e B2) para o primeiro levantamento (após o plantio) e o segundo levantamento (após a colheita), respectivamente, é possível observar a forma como as falhas de brotação estão distribuídas ao longo da área nos dois momentos de observação.

Os eixos X e Y representam a coordenada de posição (m) da falha, o eixo X representa as linhas de plantio e o eixo Y se refere à posição da falha na linha. Cada círculo representa uma falha, de modo que os círculos maiores representam falhas de maior comprimento.

Ao observar as falhas identificadas na medição após o plantio (Figura 12, A1 e A2), em ambos os levantamentos é possível inferir que a maior quantidade de falhas encontradas são as de menor comprimento, entre 0,50 a 1,50 m, porém ao observar o número de falhas visualizadas na imagem do VANT encontra-se maior número de falhas se comparado com a medição realizada em campo. Verifica-se, ainda, que algumas falhas repetem-se em ambos os levantamentos, e têm comprimentos medidos na imagem de valor próximo aos medidos em campo, no entanto os comprimentos das falhas medidos na imagem se comparados uma a uma são menores que os medidos *in situ*.

Durante a medição de campo o operador que a realiza tende a arredondar o número medido, por isso, na medição manual encontramos maior quantidade de comprimentos de falha representados por um número inteiro, o que difere da medição da imagem. Deste modo, quanto ao comprimento, a medição pela imagem se mostra mais precisa, embora outros fatores colaborem para que essa precisão diminua.

No levantamento de falhas realizado após a colheita da cana-de-açúcar (Figura 12, B1 e B2), primeiro corte, tanto para a análise feita na imagem quanto para o levantamento de falhas em campo foi observado que o número de falhas aumentou.

Após a primeira colheita, o processo de rebrota da cana-de-açúcar é influenciado pela forma como a colheita foi manejada, em como ocorre o tráfego da colhedora e do transbordo na área e também quanto à qualidade do corte.

Estudos mostram que após a colheita mecanizada apenas 45% dos colmos de cana cortados permanecem ilesos (MANHÃES et al., 2018) pois a colheita causa danos diretos aos colmos, como rachaduras, esmagamento e possível ataque por patógenos, fatores que inabilitam a rebrota e causam aumento na ocorrência de falhas e consequente maior perda

produtiva (BRAUNACK et al., 2006; SEGATO et al., 2011; MANHÃES et al., 2014; MOLIN et al., 2016).

Os gráficos da figura detalham o número de falhas por classe de comprimento, sendo cada classe determinada por um intervalo de números maiores ou iguais ao valor da extremidade esquerda e menor que o valor da extremidade direita de cada classe (Exemplo: intervalo de classe maior ou igual a 0,50 e menor que 1,0).




Figura 13. Número de falhas de brotação medido em campo e estimado com VANT por classe de comprimento após o plantio (A) e após a colheita (B).

Assim, ao identificar e medir as falhas de brotação da cana-de-açúcar nos dois momentos avaliados (após o plantio (A) e após a colheita (B)) vemos que o número de falhas por classe de comprimento é maior na imagem do VANT do que na medição em

campo para a classe de comprimento de 0,5 a 1,0 m, porém também observamos que na segunda classe estudada esse comportamento se inverte.

Para ambas as metodologias analisadas o número de falhas observadas diminui quando o comprimento da falha aumenta. Resultados semelhantes foram encontrados por Barros (2018) ao comparar dois tipos de algoritmo de classificação de imagem, *Maxver* e *K-médias*.

Na medição após o plantio (Figura 13A) nota-se também que o número total de falhas encontrado na imagem foi maior que no levantamento realizado em campo, sendo 249 falhas observadas na imagem através do algoritmo aplicado e 143 falhas medidas em campo. Rocha et al. (2022) avaliando falhas de 40 e 80 dias após o plantio, puderam observar que o método de medição das falhas na imagem encontra um percentual maior do que realmente existe, o que corrobora com os resultados encontrados no presente trabalho.

Por outro lado, é possível observar que o número total de falhas encontrado em ambos os tipos de levantamento após a colheita são mais semelhantes (Figura 14B).

A resolução da câmera do VANT e a altura em que a imagem foi obtida são fatores cruciais para a captura de uma imagem que facilite a distinção das feições cana-de-açúcar e solo exposto em uma imagem aérea (JIN et al., 2017). Nesse sentido, a medição das falhas a partir da imagem do VANT pode ser influenciada pelo momento de realização do levantamento, relacionado ao tamanho da planta, bem como com a qualidade do sensor utilizado para obter a imagem, os resultados aqui encontrados podem estar ligados a esses fatores, que são determinantes da resolução espacial da imagem.

Os comportamentos dos gráficos repetem-se ainda quando medimos o comprimento total da falha por classe de comprimento (Figura 14). A imagem do VANT após o plantio (Figura 14A) mede um maior comprimento de falhas na classe de 0,5-1,0 m, por outro lado, a medição em campo na mesma época de observação resulta em maior comprimento total na classe de 1,0-1,5 m.

Ao quantificar as falhas de brotação medidas através da imagem do VANT após a colheita (Figura 14B), também se observou maior presença de falhas com comprimento entre 0,5-1,0 m, porém o comprimento das falhas nessa mesma classe medido em campo é menor. Nas outras classes de comprimento analisadas (1,5-2,0 m, 2,0-3,5m e > 3,5 m) o número de falhas não apresentou diferença representativa entre os dois tipos de metodologia.

O resultado observado na primeira classe analisada, em comprimentos de 0,5 a 1,0 a partir da imagem do VANT apresenta alta divergência com relação à medição de campo,

o que pode ser relacionado à capacidade de visualização de objetos de menor comprimento pelo algoritmo.




Figura 14. Comprimento total das falhas medido por classe após o plantio (A) e após a colheita (B).

A capacidade de visualização das falhas pelo algoritmo está diretamente relacionada com a qualidade da imagem, no que diz respeito ao tamanho do pixel, que é resultado das características da câmera utilizada e da altura de voo empregada para a obtenção das imagens (HU et al., 2019), neste estudo foi utilizada uma altura de aproximadamente 60 m, o que a partir das características da câmera empregada resulta em um pixel de 1,95 cm. O tamanho do pixel influencia na resolução da imagem, sendo que quanto maior for o seu tamanho, menor será a resolução da imagem, o que pode vir a dificultar a distinção entre as classes presentes na mesma (cana-de-açúcar e solo exposto).

Na medição pela imagem, a altura da planta também pode influenciar no comprimento das falhas e acabar subestimando o tamanho das mesmas, pois se muito grande o tamanho das folhas no momento do levantamento, pode ocasionar na cobertura do local onde existe a falha e resultar em uma medição pela imagem do VANT com comprimentos minorados. Hu et al. (2019) ao avaliarem a qualidade da estimativa do grau de cobertura do solo em imagens RGB com diferentes tamanhos de pixel em um cultivo de trigo, puderam observar que o tamanho do pixel influencia na qualidade da visualização da cobertura do solo ao realizar a classificação da imagem, observando que quanto maior for o tamanho do pixel há uma tendência de que o grau de cobertura seja subestimado.

Nas outras classes a diferença entre os comprimentos das falhas e o número de falhas é menor, quando comparamos a medição a partir do algoritmo criado, aplicada na imagem do VANT, e pela medição realizada em campo através da metodologia convencional. Mostrando que a medição com a imagem do VANT pode ser mais efetiva para análise de falhas de maior comprimento.

A Figura 15 traz a correlação entre o comprimento total da falha medida em cada uma das linhas e as Tabelas 2 e 3 as análises de variância desses dados nos dois tipos de levantamento.

Em ambos os levantamentos o comportamento dos gráficos de correlação observados, Figuras 15A e 15B, têm maior concentração dos pontos no início do eixo, devido à presença de falhas de menor comprimento, entre 0,5 e 2,0 m.

Tabela 2. Análise de variância dos comprimentos totais de falhas medidas por linha na Imagem do VANT e em Campo após o plantio.

ANOVA	<i>gl</i>	<i>SQ</i>	<i>MQ</i>	<i>F</i>	<i>F de significação</i>		<i>valor-P</i>
Regressão	1	255,44	255,44	161,33	7,12701E-21	Interseção	4,0521E-05
Resíduo	80	126,67	1,58			Variável X	7,12701E-21
Total	81	382,10					

Esse comportamento também foi observado por Souza et al. (2017) ao estabelecer o mesmo tipo de correlação, uma comparação entre o comprimento da falha observado em campo e o comprimento estimado pelo algoritmo de medição.




Figura 15. Correlação entre os comprimentos totais de falhas medidos por linha na Imagem do VANT e medido em Campo após o plantio (A) e após a colheita (B)

Para a análise realizada após o plantio (Figura 15A) a correlação apresentou R^2 igual a 0,68, para verificar o nível de confiança da correlação obtida nos dados foi gerada a análise de variância (ANOVA) considerando o nível de significância de 0,05 (Tabela 2), no qual p-valor, para verificar se o R^2 é significativo ao nível de confiança de 95%, obteve

resultado inferior a 5%, e, portanto, rejeita-se a hipótese de nulidade (h_0) desse teste e assim é possível inferir que há diferença significativa entre as duas formas de identificação das falhas, a realizada manualmente e em campo e a feita através da imagem do VANT.

Dados os resultados encontrados nos levantamentos realizados após a colheita foi produzido correlação dos comprimentos entre a medição do VANT e a medição em campo (Figura 15B).

Ao considerar o nível de significância de 5%, não se deve rejeitar a hipótese de médias iguais do teste (Tabela 3), pois p-valor que é igual a 0,065 é maior que 0,05, portanto é possível inferir que não há diferença significativa entre as duas metodologias de avaliação de falhas de brotação utilizadas. Correlação também observada por Rocha et al. (2022) ao avaliar o comprimento das falhas medido em imagens de VANT a partir de algoritmo automatizado.

A correlação entre o comprimento total da falha medida em cada linha de plantio entre os dois tipos de levantamento após a colheita, encontrou R^2 igual a 0,65, semelhante aos resultados encontrados por Molin et al. (2016), com R^2 igual a 0,66.

Tabela 3. Análise de variância dos comprimentos totais de falhas medidas por linha na Imagem do VANT e em Campo após a colheita.

ANOVA	gl	SQ	MQ	F	F de significação		valor-P
Regressão	1	359,11	359,11	141,39	3,40018E-19	Interseção	0,06647
Resíduo	78	198,11	2,54			Variável X	3,40018E-19
Total	79	557,22					

Barbosa Júnior (2021) conseguiu atestar em seus estudos, ao avaliar o comprimento de falhas em três imagens com tamanhos de pixel diferentes, a influência dessa característica no levantamento. No qual, a estimativa do comprimento se mostra melhor quando o tamanho do pixel é menor e por isso a medição do comprimento de falhas pelas imagens obtidas com o VANT tem resultados mais próximos do valor real quando o comprimento da falha é maior, corroborando com os resultados aqui encontrados, no qual para as menores classes de comprimento analisadas (0,5-1,0 m e 1,0-1,5 m) a diferença entre os resultados em cada tipo de levantamento é maior.

6. Conclusão

De acordo com as análises realizadas conclui-se que:

- O algoritmo de processamento produzido se mostra eficaz a avaliar as falhas de brotação de uma área cultivada com cana-de-açúcar, fazendo sua identificação e medição;
- Com a metodologia proposta é possível estimar com rapidez as falhas de brotação e permite tomar ações de correção dessas falhas sem que seja necessário trabalho de campo;
- Não houve diferença representativa entre os tipos de levantamento ao medir as falhas das classes 1,5-2,0 m, 2,0-3,5m e $> 3,5$ m, ou seja, a medição pela imagem do VANT é mais efetiva para falhas maiores;
- A qualidade da avaliação de falhas pelas imagens é influenciada pela fase de emergência que a cultura se encontra na captura da imagem e pela resolução da imagem (tamanho do pixel);
- A metodologia estatística de análise de variância dos comprimentos totais de falhas medidas por linha na Imagem do VANT e em Campo após a colheita mostra que não há diferença significativa entre a medição manual e pela imagem do VANT.

Assim, pode inferir que realizar o levantamento em condições adequadas, utilizando uma câmera com um melhor sensor e com atenção a fase de desenvolvimento ideal da cultura poderiam trazer resultados mais satisfatórios para esse estudo. Para estudos futuros a mesma metodologia poderia ser aplicada para avaliar a correlação dos resultados obtidos pela imagem e em campo com as falhas maiores que 1,5 m.

7. Referências

- Andrade, R. G.; Hott, M. C.; Magalhães Junior, W. C. P.; D'Oliveira, P. S.; Oliveira, J. S. Monitoring of Corn Growth Stages by UAV Platform Sensors. *International Journal of Advanced Engineering Research and Science*, v. 6, p. 54-58, 2019.
- Barbosa Júnior, M. R. Mapeamento de falhas em cana-de-açúcar por imagens de veículo aéreo não tripulado. Dissertação (Mestrado), Faculdade de Ciências Agrárias e Veterinárias, Unesp, 51 p. 2021.
- Barros, J. E.N. Análise de falhas no cultivo de cana-de-açúcar a partir de imagens de aeronave remotamente pilotada. Dissertação (Mestrado), Programa de Pós-Graduação em Ciências Geodésicas – UFPE, 56 p. 2018.
- Barros, J. E.N., Candeias, A. L. B., Tavares Júnior, J. R. Análise de falhas no cultivo da cana de açúcar a partir de imagens de Aeronave Remotamente Pilotada. *Journal of Hyperspectral Remote Sensing*, v. 11, p. 204-212. 2021.
- Bernache, L., Oliveira, D. T., Oliveira, L. P., Corrêa, L. N., Silva, R. P. Can basal cutting blade wear affect sugarcane regrowth? *Revista Engenharia Agrícola*, v.40, p.53-60. 2020.
- Brady, N.C.; Weil, R.R. Elementos da natureza e propriedades dos solos. Bookman, Porto Alegre, v. 3, 704 p. 2013.
- Brasil. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Boletim Técnico – Agricultura de Precisão. 36 p. 2013.
- Braunack, M.V.; Arvidsson, J.; Hakansson, I. Effect of harvest traffic position on soil conditions, and sugarcane (*Saccharum officinarum*) response to environmental conditions in Queensland, Australia. *Soil and Tillage Research*, v.89, p.103-121, 2006.
- Buot, M. L. G.; Richards, D. S. P. Counting and locating the solutions of polynomial systems of maximum likelihood equations, I. *Journal of Symbolic Computation*, v. 4, p. 234–244. 2006.
- Câmara, G.; Casanova, M. A.; Hemerly, A. S.; Magalhães, G. C.; Medeiros, C. M. B. Anatomia de Sistemas de Informação Geográfica. Instituto de Computação. UNICAMP, 1996.
- Câmara, G.; Davis, C.; Monteiro, A. M. V. Introdução à Ciência da Geoinformação. INPE. 2001.

- Cardoso, T. F.; Watanabe, M. D. B; Souza, A.; Chagas, M. F.; Cavalett, O.; Morais, E. R.; Nogueira, L. A. H; Leal, M. R. L. V; Braunbeck, O. A.; Cortez, L. A. B; Bonomi, A. A regional approach to determine economic, environmental and social impacts of different sugarcane production systems in Brazil. *Biomass and Bioenergy Journal*, v. 120, p. 9-20. 2019.
- Castillejo-González I. L.; López-Granados F.; García-Ferrer A.; Peña-Barragán J. M.; Jurado-Expósito M.; Orden M. S.; González-Audicana M. Object - and pixel-based analysis for mapping crops and their agroenvironmental associated measures using QuickBird imagery. *Computers and Electronics in Agriculture*. v. 68, p. 207-215, 2009.
- Castioni, G. A.; Cherubin, M. R.; Menandro, L. M. S.; Sanches, G. M.; Bordonal, R. O.; Barbosa, L. C.; Franco, H. C. J.; Carvalho, J. L. N. Soil physical quality response to sugarcane straw removal in Brazil: A multi-approach assessment. *Soil and Tillage Research*, v. 184, p. 301-309. 2018.
- Cebim, G.J.; Ripoli, T.C.C.; Cebim, V.L.S.M.; Oliveira, A.S.; Garcia, M.A.L. Plantio mecânico de cana-de-açúcar (*Saccharum spp.*): desempenho operacional e econômico. *STAB*, v.31, p. 40-47. 2012.
- Companhia Nacional de Abastecimento - CONAB. Acompanhamento da safra brasileira 2022/2023 - CONAB: cana-de-açúcar, segundo levantamento. 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/cana/boletim-da-safra-de-cana-de-acucar>. Acesso em: 21/08/2022
- Congedo, L. Semi-Automatic Classification Plugin for QGIS. Rome: Sapienza University. 2013.
- Delgado, A. A. Os efeitos da queima dos canaviais. *Revista STAB: Açúcar, Alcool e Subprodutos*, v. 3, p. 42-45. 1995.
- Farias, I. L., Pacheco, E. P., Viégas, P. R. A. Characterisation of the optimal hydric interval for a Yellow Argisol cultivated with sugarcane on the coastal plains of Alagoas, Brazil. *Revista Ciência Agronômica*, v. 44, p. 669-675. 2013.
- Favrin, V.G. As geotecnologias como instrumento de gestão territorial integrada e participativa. Dissertação (Mestrado), Programa de pós-graduação em Geografia Humana, USP. 231 p. 2009.
- Fernandes, P. Corn yield estimates (*Zea mays L.*) through images obtained by Unmanned Aerial Vehicle. Dissertação (Mestrado). Programa de Pós Graduação em Agricultura de Precisão, UFSM. 79 p. 2016.

- Filho, F. X. O., Miranda, N. O., Medeiros, J. F., Silva, P. C. M., Mesquita, F. O., Costa, T. K. G. Compactação de solo cultivado com cana-de-açúcar em Baía Formosa, Rio Grande do Norte. *Revista Ceres*, v. 63, p. 715-723. 2016.
- Furtado, G. F.; E. V.; Furtado, B. E. F; Palmeira, A. C. R. As geotecnologias e o agronegócio brasileiro: Um estudo de caso na produção de soja. *Revista Brasileira de Agrotecnologia*, v. 10, p. 88-96. 2020.
- Gaida, W.; Breunig, F. M.; Galvão, L. S.; Ponzoni, F. J. Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. *Revista Brasileira de Geografia Física*, v. 13, p. 229-248. 2020.
- Gírio, L. A. S. Qualidade do plantio, transplante e colheita mecanizados de rebolos e mudas pré-brotadas de cana-de-açúcar. Tese (Doutorado), Faculdade de Ciências Agrárias e Veterinárias, Unesp. 86 p. 2018.
- Gray, G. R.; Magalhães, P. S. G., Braunbeck, A. O. Suspensão pantográfica para o corte de base de cana-de-açúcar. *Revista Ciência Rural*, v. 39, p. 766-771. 2009.
- Hu, P.; Guo, W.; Chapman, S.C.; Guo, Y.; Zheng, B. Pixel size of aerial imagery constrains the applications of unmanned aerial vehicle in crop breeding. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 154, p. 1-9. 2019.
- Inamasu, R. Y.; Bernardi, A. C. C. Agricultura de precisão. In: Bernardi, A.C. C.; Naime, J.de M.; Resende, A.V. de; Bassoi, L. H. Agricultura de precisão: resultados de um novo olhar. Embrapa. p. 21-33. 2014.
- Instituto nacional de meteorologia – INMET, 2019.
- Jin, X.; Liu, S.; Baret, F.; Hemerlé, M.; Comar, A. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment*, v. 198, p. 105-114. 2017.
- Lançoni, A. A; Soares, W. M.; Carrer, C. C.; Lima, C. G. Efeito da Aplicação de um Sistema de Automação Agrícola em Colheita Mecanizada de Cana-de-Açúcar como Ferramenta de Gestão e Controle de Custo Operacional. *Revista Ensaios e Ciências*, v. 24, p. 146-152. 2020.
- Landell, M. G. A.; Campana, M. P.; Figueiredo, P.; Xavier, M. A.; Anjos, I. A.; Dinardo-Miranda, L. L.; Scarpari, M. S.; Garcia, J. C.; Bidóia, M. A. P.; Silva, D. N.; Mendonça, J. R.; Kanthack, R. A. D.; Campos, M. F.; Brancalião, S. R.; Petri, R. H.; Miguel, P. E. M. Sistema de multiplicação de cana-de-açúcar com uso de mudas pré-brotadas (MPB), oriundas de gemas individualizadas. Instituto Agrônomo de Campinas, IAC Documentos 109, 17 p. 2012.

- Lima, R. P.; Rolim, M. M.; Oliveira, V. S.; Silva, A. R.; Pedrosa, E. M. R.; Ferreira, R. L. C. Loadbearing capacity and its relationships with the physical and mechanical attributes of cohesive soil. *Journal of Terramechanics*, v. 58, p. 51-58, 2015.
- Louhaichi, M.; Borman, M. M.; Johnson, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, v. 16, p. 65–70. 2001.
- Luna, I.; Lobo, A. Mapping Crop Planting Quality in Sugarcane from UAV Imagery: A Pilot Study in Nicaragua. *Remote Sensing*, v. 8, 500 p. 2016.
- Manhães, C. M. C., Francelino, F. M. A., Araújo, R. A., Oliveira, D. G., Francelino, H. O., Silva, M. P. S., Santos, A. S., Moura Júnior, M.D. Visible Losses to the Mechanical Harvesting of Ratoon Sugarcane Using the Harvester John Deere 3520. *American Journal of Analytical Chemistry*, v. 9, p. 580-590. 2018.
- Manhães, C. M. C., Garcia, R. F., Junior, D. C., Francelino, F. M. A., Francelino, H. O. Santos, C. M. F. G. Evaluation of visible losses and damage to the ratoon cane in the mechanized harvesting of sugarcane for different displacement speeds. *American Journal of Plant Sciences*, v. 5, p. 2956-2964. 2014.
- Marasca, I.; Giadenucci, J; Spadim, E. R.; Barbosa, R. D.; Lanças, K. P. Geoestatística aplicada na determinação da compactação do solo no cultivo da cana-de-açúcar. *Revista de Agricultura Neotropical*, v. 4, p. 49-55. 2017.
- Martello, M. Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada. *Dissertação (Mestrado)*, Escola Superior de Agricultura “Luiz de Queiroz”, USP. 80 p. 2017.
- Meneses, R. P. Modelos de cores aplicados às imagens. In *Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Org. por Meneses, R. P. e Almeida, T., UnB, CNPq, p. 121- 137. 2012.
- Missio, C. Qualidade do plantio mecanizado de cana-de-açúcar. *Dissertação (Mestrado)*, Programa de pós-graduação em Engenharia Agrícola, UFGD, 51 p. 2016.
- Molin, J. P.; Veiga, J. P. S.; Cavalcante, D. S. Spatial variability of sugarcane row gaps: measurement and Measuring and mapping sugarcane gaps. *Ciência e Agrotecnologia*, v. 40, p. 347-355. 2016.
- Montibeller, B., Kmoch, A., Virro, H. et al. Increasing fragmentation of forest cover in Brazil’s Legal Amazon from 2001 to 2017. *Scientific Reports*, v. 10, p. 58. 2020.
- Mozambani, C.I. Determinantes da adoção de práticas e tecnologias de agricultura de precisão por fornecedores de cana-de-açúcar no estado de São Paulo. *Tese*

- (Doutorado), Programa de pós-graduação em Engenharia de Produção, UFSCAR. 126 p. 2021. Disponível em: <https://repositorio.ufscar.br/handle/ufscar/14578>. Acesso em: 21/08/2022.
- Musk, L. F. Book reviews: Lintz, J. and Simonett, D. S., editors, 1976: Remote sensing of environment. Reading, Massachusetts: Addison-Wesley. Progress in Physical Geography: Earth and Environment, v. 3, p. 609–611. 1979.
- Novo, M. L. M. Sensoriamento Remoto Princípios e Aplicações. Blucher São Paulo, 387 p. 2010.
- Oliveira, A. J.; Silva, G. F.; Silva, G. R.; Santos, A. A. C.; Caldeira, D.; Vilarinho, M. K. C.; Barelli, M.A.A; Oliveira, T.C. Potencialidades da utilização de drones na agricultura de precisão. Brazilian Journal of Development, v. 6, p. 64140-64149. 2020.
- Ortiz, P. F. S. Compactação e qualidade física do solo em sistemas de colheita mecanizada e semi-mecanizada de cana-de-açúcar. Tese (Doutorado), Programa de Pós Graduação em Engenharia Agrícola – UFRPE. 177 p. 2020.
- Pacheco, E. P.; Cantalice, J. R. B. Compressibilidade, resistência à penetração e intervalo hídrico ótimo de um Argissolo Amarelo cultivado com cana-de-açúcar nos Tabuleiros Costeiros de Alagoas. Revista Brasileira de Ciência do Solo, v. 35, p. 403-415. 2011.
- Prosdocimi, M.; Burguet, M.; Di Prima, S.; Sofia, G.; Terol, E.; Comino, J.R.; Cerdà, A. Tarollia, Paolo. Rainfall simulation and Structure-from-Motion photogrammetry for the analysis of soil water erosion in Mediterranean vineyards. Science of The Total Environment, v. 574, p. 204-215. 2017.
- Prudkin, G.; Breunig, F. Drones e Ciência: Teoria e aplicações metodológicas. FACOS-UFSM. v.1, 126 p. 2019.
- Reis, H.S. Utilização de veículos aéreos não tripulado para identificação de falhas no plantio na cana de açúcar. Revista Anhanguera v. 21, p. 27-45. 2020.
- Ridwan, W. M.; Sapitang, M.; Aziz, A.; Kushiar, K. F.; Ahmed, A. N.; El-Shafie, A. Rainfall forecasting model using machine learning methods: Case study Terengganu, Malaysia. Ain Shams Engineering Journal, v. 12, p. 1651-1663. 2021.
- Ripoli, T. C. C., Ripoli, M. L. C., Casagrandi, D. V. Plantio de cana-de-açúcar: estado da arte. Piracicaba: Livro Ceres, 198 p. 2006.
- Rocha, B. M.; Fonseca, A. U.; Pedrini, H.; Soares, F. Automatic detection and evaluation of sugarcane planting rows in aerial images. Information Processing in Agriculture Journal, v. 9, p. 343-474. 2022.

- Rodrigues, C.; Tufi, O.; Castilho, P.Z. Mecanização na lavoura. *Revista Canavieiros*, v. 7, p. 22-23. 2013.
- Rosa, R. Introdução ao sensoriamento remoto. EDUFU - UFU, v.7, 142 p. 2009.
- Salvi, J. V.; Matos, M. A.; Milan, M. Avaliação do desempenho de dispositivo de corte de base de colhedora de cana-de-açúcar. *Revista Engenharia Agrícola*, v. 27, p. 201-209. 2007.
- Sanomia, U. E.; Cortez, J. W.; Maiara Pusch, M.; Mauad, M.; Arcoverde, S. N. S. Qualidade do porte e corte mecanizado da cultura de cana-de-açúcar. *Revista Agrarian*, v. 11, p. 168-173. 2018.
- Santos, H. G., Jacomine, P. K. T., Dos Anjos, L. H. C., De Oliveira, V. A., Lumbreras, J. F., Coelho, M. R., Cunha, T. J. F. Sistema brasileiro de classificação de solos, Embrapa. 2018.
- Sasaki, M.H. Desenvolvimento e validação de sistema eletrônico de aquisição de imagens aéreas para detecção de falhas de estabelecimento de estande na cultura da cana-de-açúcar, Dissertação (Mestrado), Programa de Pós-Graduação em Agricultura de Precisão – UFSM. 38 p. 2019.
- Scholten, H. J.; Van de Velde, R.; Van Manen, N. Geospatial technology and the role of location in Science. New York: Springer, 2009.
- SDCI (Secretaria de Desenvolvimento e Competitividade Industrial). Estudo Sobre a Indústria Brasileira e Europeia de Veículos Aéreos Não Tripulados, v. I, 92 p. 2017.
- Segato, S. V., Daher, F. Perdas visíveis na colheita mecanizada de cana-de-açúcar crua sob velocidades de deslocamento da colhedora. *Revista Nucleus*, v.8, p. 315-326. 2011.
- Seki, A. S.; Seki, F. G.; Jasper, S. P.; Silva, P. R. A.; Benez, S. H. Efeitos de práticas de descompactação do solo em área sob sistema plantio direto. *Revista Ciência Agronômica*, v. 46, p. 460-468. 2015.
- Serafim, L. G. F.; Stolf, R.; Silva, J. R.; Silva, L. C. F.; Maniero, M. A.; Bassinello, A. I. Influência do plantio mecanizado no índice de brotação da cana-de-açúcar. *STAB*, v. 31, p. 22-25. 2013.
- Shiratsuchi, L. S.; Brandão, Z. N.; Vicente, L. E.; Victoria, D. de C.; Ducati, J. R.; Oliveira, R. P.; Vilela, M. F. Sensoriamento remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: Bernarsi, A.C. de C.; Naime, J. de M.; Resende, A. V. de; Bassoi, L. H.; Inamasu, R. Y. (Ed.). Agricultura de precisão: resultados de um novo olhar. Embrapa, 2014.

- Silva, F. V.; Ferreira, R. H. S. Classificação supervisionada por máxima verossimilhança gaussiana como ferramenta para monitoramento de áreas de vegetação em regiões metropolitanas. *Cippus – Revista de Iniciação Científica*, v. 7, p. 147-157. 2019.
- Souza, C.H.; Lamparelli, R.; Rocha, J.; Magalhães, P. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. *Journal Computers and Electronics in Agriculture*, v. 143, p. 49-56. 2017.
- Souza, W. L. S. Comportamento físico-mecânico de dois solos cultivados com cana-de-açúcar em diferentes sistemas de manejo. Tese (Doutorado), Programa de Pós-Graduação em Ciência do Solo, UFRPE. 183 p. 2015.
- Stateczny, A.; Kazimierski, W.; Burdziakowski, P.; Motyl, W.; Wisniewska, M. Shore construction detection by automotive radar for the needs of autonomous surface vehicle navigation. *International Journal of Geo-Information*, v.8, p.80. 2019.
- Stolf, R. Metodologia de avaliação de falhas nas linhas de cana-de-açúcar. *STAB. Açúcar, Alcool e Subprodutos*, v. 4, p. 22-36. 1986.
- Stolf, R. Transplântio de soqueira de cana-de-açúcar como técnica de renovação da cultura. Tese (Doutorado), Escola Superior de Agricultura “Luiz de Queiroz”, USP. 100 p. 1983.
- Stolf, R.; Garcia, T. B.; Neris, L.O.; Junior, O. T.; Reichardt, K. Avaliação de falhas em cana-de-açúcar segundo o método de stolf utilizando imagens aéreas de alta precisão obtidas por VANT. *Revista STAB*, v. 34, p. 32–39, 2016.
- Stolf, R.; Iaia, A. M.; Lee, T. S. G. Índice de falhas segundo o método de Stolf: correlação com o rendimento agrícola em cana-planta. *Brasil Açucareiro*. v. 104, p. 44-50, 1986.
- Toledo, A., Silva, R. P., Furlani, C. E. A. Quality of cut and basecutter blade configuration for the mechanized harvest of green sugarcane. *Scientia Agricola Journal*, v. 70, p. 384-389. 2013.
- Tripicchio, P.; Satler, M.; Dabisias, G.; Ruffaldi, E.; Avizzano, C. A. Towards smart farming and sustainable agriculture with drones. *International Conference on Intelligent Environments*, p. 140-143. 2015.
- Vettorazzi, C.A. Técnicas de geoprocessamento no monitoramento de áreas florestadas. *Série Técnica IPEF*, v. 10, p. 45-51. 1996.
- Voltarelli, M.A.; da Silva, R.P.; Cassia, M.T.; Daloia, J.G.M.; Paixão, C.S.S. Qualidade do corte basal de cana-de-açúcar efetuado por facas de diferentes angulações e revestimentos. *Revista Ciência Agronômica*, v. 48, p. 438-447. 2017.