



UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

CARLOS ANDRÉ DE SOUZA SÁ

**SENSORIAMENTO REMOTO APLICADO EM CULTIVOS NO
SUBMÉDIO SÃO FRANCISCO POR IMAGEAMENTO AÉREO COM
DRONES**

JUAZEIRO – BA

2022

CARLOS ANDRÉ DE SOUZA SÁ

**SENSORIAMENTO REMOTO APLICADO EM CULTIVOS NO
SUBMÉDIO SÃO FRANCISCO POR IMAGEAMENTO AÉREO COM
DRONES**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da UNIVASF, como requisito para obtenção do título de Mestre em Engenharia Agrícola.

Orientador(a): Prof.^a Dra. Magna Soelma Beserra de Moura

JUAZEIRO – BA

2022

S111s Sá, Carlos André de Souza.
Sensoriamento remoto aplicado em cultivos no submédio São Francisco por imageamento aéreo com drones / Carlos André de Souza Sá, Juazeiro-BA, 2022.
xiv, 97 f.: il.; 29 cm.

Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal do Vale do São Francisco, Campus Juazeiro-BA, 2022.

Orientador (a): Profa. Dra. Magna Soelma Beserra de Moura.

1. Sensoriamento remoto. 2. Processamento digital de imagens. 3. Índice de vegetação. I. Título. II. Moura, Magna Soelma Beserra de. III. Universidade Federal do Vale do São Francisco.

CDD 621.3678

UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

FOLHA DE APROVAÇÃO

Carlos André de Souza Sá

SENSORIAMENTO REMOTO APLICADO EM CULTIVOS DO SUBMÉDIO SÃO FRANCISCO POR IMAGEAMENTO AÉREO COM DRONES

Dissertação apresentada ao curso de Pós-Graduação *Strito Sensu* em Engenharia Agrícola da Universidade Federal do Vale do São Francisco – UNIVASF, como requisito parcial para obtenção do título de mestre.

Aprovado em: Juazeiro-BA, 22 de junho de 2022.

Banca Examinadora

Documento assinado digitalmente
 MAGNA SOELMA BESERRA DE MOURA
Data: 22/06/2022 18:26:27-0300
Verifique em <https://verificador.iti.br>

Magna Soelma Beserra de Moura, Profa. DSc.
(PPGEA/EMBRAPA-Semiárido)

Documento assinado digitalmente
 MIGUEL JULIO MACHADO GUIMARAES
Data: 01/07/2022 17:11:53-0300
Verifique em <https://verificador.iti.br>

Miguel Júlio Machado Guimarães, Prof. DSc.
(PPGEA/IFMA)

Documento assinado digitalmente
 JOSICLEDA DOMICIANO GALVINCIO
Data: 30/06/2022 11:10:40-0300
Verifique em <https://verificador.iti.br>

Josiclêda Domiciano Galvêncio, Profa. DSc.
(UFPE)

A Deus e à Virgem Maria; aos meus pais, José Carlos (*In memoriam*) e Maria Andrelite; à minha irmã Maria Clara; à minha companheira Maria Francileide; avós e aos demais familiares.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus e à Virgem Maria, pela saúde e proteção divina, por sempre me abençoar e por todas as oportunidades que me fizeram acreditar na minha fé e na minha capacidade.

Aos meus familiares, em especial aos meus pais, José Carlos de Souza (*In memoriam*) e Maria Andrelite de Sá Souza e minha irmã Maria Clara de Souza Sá, pelo amor, apoio e ensinamentos, certamente serei eternamente grato, principalmente, ao meu pai, pelo exemplo de humildade e fonte de minha inspiração.

À Maria Francileide Barros de Melo, minha noiva, amiga e companheira, agradeço em especial, pela paciência, confiança, apoio e cuidados; sou grato por me incentivar e sempre acreditar no meu potencial.

À minha orientadora Prof.^a Dra. Magna Soelma Beserra de Moura, pelos conhecimentos e experiências proporcionados, obrigado pela paciência, compreensão, por me incentivar e acreditar na minha capacidade, certamente vossas contribuições foram imensamente significativas e fundamentais para a minha formação profissional.

Aos professores Dra. Josiclêda Domiciano Galvêncio, Dr. Miguel Júlio Machado Guimarães e Dr. Rodrigo de Queiroga Miranda pelas contribuições e todo apoio proporcionado para a execução do projeto; e Dr. Mário de Miranda Vilas Boas Ramos Leitão pela experiência repassada.

A Universidade Federal do Vale do São Francisco (UNIVASF) e ao Programa de Pós-graduação em Engenharia Agrícola (PPGEA) pela oportunidade de realização do mestrado e formação profissional. Ao corpo docente do PPGEA, em especial, aos professores Drs. Dian Lourençoni, Mário de Miranda, Miguel Júlio, Clóvis Ramos, José Aliçandro, pelos ensinamentos e experiências repassados; e a Carolina Torres pelo apoio, conselhos e colaboração durante todo mestrado, obrigado a todos.

À Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) pela concessão da bolsa de estudos e apoio financeiro para essa pesquisa.

À Embrapa Semiárido pelas contribuições e subsídios para a execução desta pesquisa e aos colegas do grupo ET-VANT e Agromet Ativa, Bento, Célia, Clóvis, Hérica, Joabe, Melk e Saulo, pelas experiências de campo, apoio e trabalhos desenvolvidos.

Enfim, a todos deixo os meus sinceros e eternos agradecimentos.

Tudo tem o seu tempo determinado e há tempo para todo o propósito debaixo do céu:

Há tempo de nascer e tempo de morrer, tempo de plantar e tempo de arrancar o que se plantou.

Eclesiastes 3: 1-2

RESUMO

O Sensoriamento Remoto possui diversas aplicações e tecnologias que podem ser utilizadas na agricultura. Entre essas técnicas está a análise de imagens aéreas para a caracterização e monitoramento de cultivos. A utilização de veículos aéreos não tripulados (VANT) ou drones para captura dessas imagens é bastante promissora devido à alta resolução temporal e espacial que a tecnologia oferece. Nesse contexto, objetivou-se avaliar o potencial de dados coletados por drones e técnicas de sensoriamento remoto a partir da detecção semiautomática de árvores e uso de índices de vegetação, para a caracterização e monitoramento de cultivos irrigados localizados no município de Juazeiro-BA, submédio do Vale do São Francisco. Nesse trabalho foi analisado o potencial de *softwares* e *plugins* acessíveis para detecção semiautomática de árvores. Foi avaliado o desempenho dos índices de vegetação GLI, RGBVI, NGRDI, MGRVI, RI, ExG, ExR, ExGR e NDVI. As coletas de dados e imagens foram realizadas nos meses de março e junho de 2021. Também foi verificado diferentes tratamentos e qualidades de processamento das imagens, para a obtenção de produtos digitais em tempo hábil. Os resultados obtidos foram avaliados utilizando os índices de Precisão, Revocação e F1-Score. Também foram utilizadas análises de estatística descritiva, técnicas para análise visual de imagens e histogramas. Entre as qualidades de processamento de imagens testadas, o processamento em qualidade média promoveu os melhores resultados e em tempo hábil. Quanto aos *softwares* e *plugins* avaliados, o SAGA GIS obteve melhor desempenho para a detecção semiautomática de árvores. Os resultados obtidos pelos índices de vegetação GLI, RGBVI, ExG e ExGR foram visualmente equivalentes. O índice RGBVI foi mais sensível na discriminação dos alvos e obteve o melhor desempenho. Conclui-se que o sensoriamento remoto aplicado com drones possibilita uma gestão mais eficiente dos cultivos agrícolas.

Palavras-chave: Detecção de árvores. Índice de vegetação. Processamento digital de imagens.

ABSTRACT

Remote Sensing has several applications and technologies that can be used in agriculture. Among these techniques is the analysis of aerial images for the characterization and monitoring of crops. The use of unmanned aerial vehicles (UAV) or drones to capture these images is very promising due to the high temporal and spatial resolution that the technology offers. In this context, the objective was to evaluate the potential of data collected by drones and remote sensing techniques from the semi-automatic detection of trees and use of vegetation indices, for the characterization and monitoring of irrigated crops located in the municipality of Juazeiro-BA, sub-middle of the San Francisco Valley. In this work, the potential of accessible software and plugins for semi-automatic tree detection was analyzed. The performance of vegetation indices GLI, RGBVI, NGRDI, MGRVI, RI, ExG, ExR, ExGR and NDVI was evaluated. Data and image collections were carried out in March and June 2021. Different treatments and image processing qualities were also verified, in order to obtain digital products in a timely manner. The results obtained were evaluated using the Precision, Recall and F1-Score indices. Descriptive statistical analysis, techniques for visual analysis of images and histograms were also used. Among the image processing qualities tested, processing at medium quality provided the best and timely results. As for the evaluated software and plugins, the SAGA GIS performed better for the semi-automatic detection of trees. The results obtained by the vegetation indices GLI, RGBVI, ExG and ExGR were visually equivalent. The RGBVI index was more sensitive in target discrimination and had the best performance. It is concluded that remote sensing applied with drones enables a more efficient management of agricultural crops.

Keywords: Tree detection. Vegetation index. Digital Image Processing.

LISTA DE FIGURAS

Figura 1 – Parâmetros utilizados para o cálculo da escala da fotografia	27
Figura 2 – Esquema de cobertura aerofotogramétrica para tomada de imagens com região de sobreposição frontal (esquerda) e lateral (direita)	28
Figura 3 – Parâmetros utilizados para cálculo do GSD (<i>Ground Sample Distance</i>) em imagens aéreas	29
Figura 4 – Fases do mapeamento aerofotogramétrico	29
Figura 5 – Parâmetros de entrada do <i>Gaussian filter</i> dentro do software SAGA	33
Figura 6 – Representação do funcionamento do <i>plugin</i> Tree Density Calculator (esquerda) e sua interface com os parâmetros de entrada (direita)	34
Figura 7 – Localização dos pomares (lotes) experimentais de mangueira e citrus utilizados para detecção semiautomática de árvores no município de Juazeiro, Bahia	44
Figura 8 – Etapas de aquisição de imagens, pré-processamento e produtos digitais obtidos a partir de VANT em pomares de frutíferas no Vale do São Francisco	47
Figura 9 – Etapas do processamento para geração do <i>shape point</i> por meio do <i>Tree Density Calculator</i> e Saga GIS	49
Figura 10 – Modelos digitais de superfície obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C)	52
Figura 11 – Modelos digitais do terreno obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C)	52
Figura 12 – Modelos digitais de altura obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C)	53
Figura 13 – Árvores demarcadas por inspeção visual nos lotes de mangueira (L1 à L6) e citrus (L7) localizados no município de Juazeiro, Vale do São Francisco	54
Figura 14 – Percentuais de pontos detectados corretamente para as áreas de manga (L1 à L6) e citrus (L7) para diferentes qualidades de processamento utilizando o SAGA GIS e o <i>Tree Density Calculator</i>	55
Figura 15 – Percentuais de pontos detectados incorretamente para as áreas de manga (L1 à L6) e citrus (L7) para diferentes qualidades de processamento utilizando o SAGA GIS e o <i>Tree Density Calculator</i>	57

Figura 16 – Fatores que interferem na detecção individual de árvores: A) Presença de outras plantas na mesma área; B) Árvores muito desuniformes; C) Árvore com copas isoladas; D) Copa com abertura e E) Conjunto de copas/árvores.....	59
Figura 17 – Localização da área de estudo no município de Juazeiro-BA	66
Figura 18 – Ortomosaicos em composição RGB, gerado a partir de imagens obtidas em veículo aéreo não tripulado (VANT), para área de cana-de-açúcar no município de Juazeiro, Bahia	70
Figura 19 – Índices de vegetação da área de cana-de-açúcar, em Juazeiro, Bahia, obtidos por imagem de VANT em 26/03/2021 (A, B, C, ..., I) e pela imagem Landsat 8 (J) em 17/03/2021	72
Figura 20 – Detalhamento de área de cultivo de cana-de-açúcar para identificação de alvos da superfície com base na alta resolução da imagem VANT e na classificação de índices de vegetação para o dia 26/03/2021, em Juazeiro, Bahia	74
Figura 21 – Índices de vegetação da área de cana-de-açúcar, em Juazeiro, Bahia, obtidos por imagem de VANT em 18/06/2021 (A, B, C, ..., I) e pela imagem Landsat 8 (J) em 20/05/2021	75
Figura 22 – Detalhamento de área de cultivo de cana-de-açúcar para identificação de alvos da superfície com base na alta resolução da imagem VANT e na classificação de índices de vegetação para o dia 18/06/2021, em Juazeiro, Bahia	76
Figura 23 – Histograma dos índices de vegetação obtidos em 26/03(A) e 18/06 de 2021(B), em área de cana-de-açúcar, em Juazeiro, Bahia	78

LISTA DE TABELAS

Tabela 1 – Sumário com alguns dos principais índices espectrais da literatura	39
Tabela 2 – Informações dos pomares estudados	45
Tabela 3 – Resultado do processamento digital em diferentes qualidades	51
Tabela 4 – Resultado do estande teórico e número real de plantas para cada pomar	54
Tabela 5 – Índices de precisão, revocação e F1-Score para avaliação de plugin e qualidade de processamento de imagens de VANT's obtidas em pomares de mangueira no Submédio do Vale São Francisco	57
Tabela 6 – Características do sensor OLI do satélite Landsat 8	67
Tabela 7 – Índices de vegetação utilizados para avaliação do cultivo de cana-de-açúcar, Juazeiro, Bahia	68
Tabela 8 – Estatística descritiva dos índices de vegetação obtidos para área de cana-de-açúcar em Juazeiro, Bahia	79

LISTA DE SÍMBOLOS

ABC	Agricultura de Baixo Carbono
AP	Agricultura de Precisão
API	Programação de Aplicativos
ARVI	<i>Atmospherically Resistant Vegetation Index</i>
ASP	<i>American Society of Photogrammetry</i>
ASPRS	<i>American Society of Photogrammetry and Remote Sensing</i>
CONAB	Companhia Nacional de Abastecimento
DL	<i>Deep Learning</i>
DT	<i>Decision Tree</i>
ExG	<i>Excess Green Index</i>
ExGR	<i>Excess Green minus Excess Red</i>
ExR	<i>Excess Red Vegetative Index</i>
FOSS	<i>Free Open Source Software</i>
GARI	<i>Green Atmospherically Resistant Index</i>
GCP	<i>Ground Control Points</i>
GEE	<i>Google Earth Engine</i>
GLI	<i>Ground Level Image Analysis</i>
GNU	Licença Pública Geral
GPS	Sistema de Posicionamento Global
GSD	<i>Ground Sample Distance</i>
GSD	<i>Ground Sample Distance</i>
GUI	Interface gráfica de Usuário
IA	Inteligência Artificial
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
ISP	<i>International Society for Photogrammetry</i>
ISPRS	<i>International Society for Photogrammetry and Remote Sensing</i>
L	Fator de ajuste para o substrato do dossel vegetativo
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MDE	Modelo Digital de Elevação
MDH	Modelo Digital de Altura

MDS	Modelo Digital de Superfície
MDT	Modelo Digital do Terreno
ML	<i>Machine Learning</i>
MNDWI	<i>Modification of Normalized Difference Water Index</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NGRDI	<i>Normalized Green Red Difference Index</i>
NIR	Espectroscopia de infravermelho próximo
ONU	Organização das Nações Unidas
OSGeo	<i>Open Source Geospatial Foundation</i>
RF	<i>Random Forest</i>
RGB	Espectroscopia com bandas vermelho, verde e azul
RI	<i>Redness Index</i>
RNA	Rede Neural Artificial
SAGA	<i>System for Automated Geoscientific Analyses</i>
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SIG	Sistema de Informação Geográfica
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machines</i>
SWIR	Espectroscopia de infravermelho médio
TGI	<i>Triangular Greenness Index</i>
UAV	<i>Unmanned Aerial Vehicles</i>
VANT	Veículo Aéreo Não Tripulado
VARI	<i>Visible Atmospherically Resistant Index</i>
VSF	Vale do São Francisco

SUMÁRIO

1 INTRODUÇÃO GERAL	16
2 OBJETIVOS	18
2.1 OBJETIVO GERAL	18
2.2 OBJETIVOS ESPECÍFICOS	18
3 ESTRUTURA DO TRABALHO DE DISSERTAÇÃO	18
4 REFERENCIAL TEÓRICO	19
4.1 A FRUTICULTURA NO VALE DO SÃO FRANCISCO	19
4.2 AGRICULTURA DE PRECISÃO	21
4.3 SENSORIAMENTO REMOTO	24
4.4 AEROFOTOGRAMETRIA	26
4.5 PROCESSAMENTO E PRODUTOS DIGITAIS	30
4.6 MÉTODOS PARA DETECÇÃO SEMIAUTOMÁTICA DE ÁRVORES	32
4.7 ÍNDICES ESPECTRAIS	34
5 CAPÍTULO I - DETECÇÃO SEMIAUTOMÁTICA DE ÁRVORES EM POMARES IRRIGADOS NO VALE DO SÃO FRANCISCO UTILIZANDO VANT	41
RESUMO	41
5.1 INTRODUÇÃO	42
5.2 MATERIAL E MÉTODOS	44
5.3 RESULTADOS E DISCUSSÃO	50
5.4 CONCLUSÕES	59
5.5 REFERÊNCIAS	60
6 CAPÍTULO II - ÍNDICES DE VEGETAÇÃO APLICADOS EM IMAGENS OBTIDAS POR DRONES PARA AVALIAÇÃO DE CULTIVO DE CANA-DE-AÇÚCAR	63
RESUMO	63
6.1 INTRODUÇÃO	64
6.2 MATERIAL E MÉTODOS	66
6.3 RESULTADOS E DISCUSSÃO	69
6.4 CONCLUSÕES	84
6.5 REFERÊNCIAS	85
7 CONSIDERAÇÕES	89
REFERÊNCIAS GERAIS	91

1 INTRODUÇÃO GERAL

Os sistemas agrícolas irrigados colocaram o Brasil entre os dez principais países que fazem uso da irrigação e, diversos estudos indicam que ainda existe grande potencial de desenvolvimento desse setor no país, trazendo demandas de pesquisa sob diferentes aspectos. Particularmente, no Semiárido brasileiro, onde a grande variabilidade espacial e temporal das chuvas, associada aos elevados níveis de radiação interferem negativamente no balanço hídrico, o uso da irrigação é imprescindível para o desenvolvimento agrícola, principalmente, em escala comercial. Assim, com as águas represadas do Rio São Francisco, no Lago de Sobradinho, que está localizado no estado da Bahia, o Submédio do Vale São Francisco se destaca pelo desenvolvimento de uma fruticultura irrigada altamente tecnificada, onde maior parte da área (irrigada) é ocupada com mangueiras, videiras e cana-de-açúcar (SILVA, DE ALMEIDA e VIEIRA, 2019).

Nessas áreas, é de extrema relevância o entendimento do comportamento da vegetação em função do clima da região, para que haja sucesso no planejamento e tomada de decisão. Por isso, informações sobre a magnitude e a variação espaço-temporal das necessidades hídricas das culturas por meio de tecnologias remotas se tornam essenciais para o gerenciamento eficiente e eficaz dos recursos hídricos em sistemas agrícolas (SILVA *et al.*, 2019).

Com o desenvolvimento de novas tecnologias, o estudo e o monitoramento da vegetação em ambientes agrícolas se tornou um dos temas mais abordados e discutidos no sensoriamento remoto (GAIDA *et al.*, 2020), contudo para fins de manejo de água e monitoramento da dinâmica do estado hídrico da vegetação, o ideal é que se associe alta resolução temporal e espacial, o que não tem sido possível com imagens de satélite. Com o advento da agricultura de precisão e, mais recentemente, dos veículos aéreos não tripulados (VANT's) ou *Unmanned Aerial Vehicles* (UAV's), mais comumente conhecidos como drones, detectou-se uma alternativa viável, especialmente, quando a área de interesse é comparativamente pequena, como em nível de propriedade agrícola, para o imageamento aéreo.

Para Cruzan *et al.* (2016) e Manfreda *et al.* (2018), o monitoramento com VANT's fornece dados com uma resolução espacial muito alta e uma relativa facilidade de implantação, possibilitando agir rapidamente durante o manejo ou imprevistos que aconteçam durante o cultivo. O uso de drones, associado a análises

de dados, tem grande potencial para apoiar e resolver alguns dos principais problemas enfrentados na agricultura, principalmente, por permitir acesso a dados de qualidade em tempo quase real. O produtor pode manter os olhos em sua produção, observando tudo que acontece na mesma, além de definir estratégias de manejo a serem adotadas na área cultivada. Os avanços tecnológicos têm permitido o desenvolvimento e colocado no mercado drones cada vez menores e de baixo custo, capazes de realizar voos mais longos equipados com sensores para detecção de importantes respostas espectrais dos alvos, como as culturas agrícolas. Ao mesmo tempo, o processamento e a análise de dados de imagem encontram-se em estado de constante mudança e desenvolvimento.

Dentre as faixas do espectro eletromagnético as bandas RGB (abreviação dos nomes vermelho, verde e azul, em inglês) se referem as faixas que para o olho humano são possíveis de observar e acopladas em drones e/ou sensores provenientes de satélites, as máquinas fotográficas comuns também dispõem destas faixas, de modo que as novas tecnologias e a facilidade em adquirir veículos aéreos não tripulados, máquinas fotográficas profissionais e drones para o monitoramento de ambientes específicos, abrem um novo espaço para as análises do Sensoriamento Remoto como um todo (SILVA *et al.*, 2019).

Levando em consideração a importância de se buscar alternativas que garantam resultados satisfatórios semelhantes ou de qualidade superior aos obtidos pelos métodos tradicionais, a utilização de drones pode ser uma técnica apropriada para o monitoramento e caracterização dos pomares irrigados presentes no Vale do São Francisco, principalmente, por acompanhar o estado hídrico das culturas frutíferas nessa região, visto que há a possibilidade de alta acurácia dos resultados e potencial de redução do tempo para obtenção de dados e informações dos plantios. Sendo assim, a utilização de informações temporais e espaciais obtidas a partir do processamento de imagens alcançadas por drones, pode fornecer subsídios para acompanhar pomares com bastante eficiência, tornando os sistemas de monitoramento e previsão de safras da cultura mais precisos, de modo a impactar positivamente a produção da fruticultura no Vale do São Francisco.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Objetivou-se avaliar o potencial da aplicação de dados coletados por sensores passivos embarcados em Veículos Aéreos Não Tripulados (VANT's) para a caracterização e o monitoramento de pomares irrigados no Submédio do Vale São Francisco.

2.2 OBJETIVOS ESPECÍFICOS

- Avaliar o processamento de imagens coletadas por VANT's para obtenção de modelos digitais de boa qualidade, de forma acessível e em tempo hábil;
- Analisar técnicas para identificação e quantificação de árvores em pomares, por meio de softwares e plugins acessíveis;
- Obter e comparar os resultados dos índices espectrais gerados a partir de diferentes metodologias.

3 ESTRUTURA DO TRABALHO DE DISSERTAÇÃO

A organização desta dissertação compreende os aspectos introdutórios, objetivos e referencial teórico sobre o tema do trabalho, que envolve informações gerais sobre a Fruticultura no Vale do São Francisco; Agricultura de Precisão; Sensoriamento Remoto; Aerofotogrametria; Processamento e Produtos Digitais; Métodos para Detecção Semiautomática de Árvores e Índices Espectrais. Na sequência são apresentados os capítulos 1 e 2, contendo artigos elaborados para submissão em periódicos indexados. O Capítulo 1 se intitula “Detecção semiautomática de árvores em pomares irrigados no Vale do São Francisco utilizando VANT”, enquanto o capítulo 2 aborda “Índices de vegetação aplicados em imagens obtidas por drones para avaliação de cultivo de cana-de-açúcar”. Ambos os capítulos contêm introdução, material e métodos, resultados e discussão e conclusões. Enfim, a dissertação apresenta as considerações gerais sobre o tema abordado no trabalho.

4 REFERENCIAL TEÓRICO

4.1 A FRUTICULTURA NO VALE DO SÃO FRANCISCO

A fruticultura irrigada no Vale do São Francisco (VSF) tem papel fundamental no desenvolvimento e crescimento da região, pois com a implantação da irrigação a agricultura local se desenvolveu expandindo-se, de tal maneira, que passou a atrair novos investimentos e abriu diversas oportunidades de emprego, além das condições climáticas favoráveis para produção de frutas, o que a acelerou ainda mais o desenvolvimento da fruticultura irrigada na região (OLIVEIRA, 2021).

O polo Juazeiro-Petrolina está situado às margens do Rio São Francisco, na zona mais árida do nordeste brasileiro, precisamente no extremo Norte da Bahia e Oeste de Pernambuco; formado por oito municípios, sendo eles, Juazeiro, Sobradinho, Casa Nova e Curaçá na Bahia; e Petrolina, Lagoa Grande, Santa Maria da Boa Vista e Orocó em Pernambuco, é a região referência para a fruticultura irrigada no VSF (BARBOSA; LIMA; FERREIRA, 2021). Segundo estes mesmos autores, o polo representa o mais expressivo exemplo dos impactos modernizantes da agricultura irrigada nordestina, caracterizando-o como sendo uma área pioneira na implantação dos grandes projetos públicos e privados de irrigação com poderosa infraestrutura de suporte ao processo modernizante.

Barbosa, Lima e Ferreira (2021) afirmam que a região do VSF historicamente enfrentou diversas mudanças em sua macroeconomia em épocas distintas, enfatizando que houve períodos em que agroindústrias processadoras se instalaram na região adquirindo a produção hortícola local. Contudo, posteriormente, em função de crises econômicas, tais agroindústrias migraram para outros locais de modo que a região passou então a dedicar-se fortemente a fruticultura, visando a exportação.

Dados sobre a exportação nacional de frutas da ABRAFRUTAS (2018) mostram que foram gerados cerca de US\$ 785,66 milhões na economia brasileira no ano de 2018, além dos mais de 5 milhões de empregos gerados nesse setor, ressaltando a grande importância da produção e exportação de frutas para o país. Neste mesmo ano, dados do IBGE (2018) mostram que a produção frutícola do Brasil rendeu mais de R\$ 36,34 bilhões, um incremento de 1% em relação ao ano de 2017 que registrou uma receita bruta de R\$ 35,98 bilhões, destacando a importância do setor para a economia nacional.

Dentro da fruticultura no Vale do São Francisco (VSF), manga e uva de mesa são as culturas de maior destaque, devido à renda e ao número de empregos gerados, por isso, as condições de mercado e o desempenho econômico das duas frutas estão fortemente correlacionadas com a economia da região. A região Nordeste é responsável pela grande maioria da produção brasileira, estimando-se um total de 637,5 mil toneladas de frutas na safra de 2020 (CONAB, 2020). As variedades de manga 'Tommy Atkins', 'Keitt', 'Kent' e 'Palmer' são as que mais se destacam, sendo responsáveis pela maior parte das exportações brasileiras (DEMARTELAERE *et al.*, 2021). Tratando-se da cultura da uva, Mello (2018) explica que em 2017 a área plantada com videiras no Brasil foi de 78.028 ha, da qual, 73,95% desse total estava concentrada na região Sul. Na região Nordeste, mais precisamente no Vale do São Francisco, enquanto na Bahia ocorreu redução de 11,57% na área com videiras em relação ao ano anterior, em Pernambuco houve aumento de 26,75%. Segundo dados do IBGE (2020), a produção de uva na região Nordeste, para o ano de 2020, foi de 4.907.958 toneladas, sendo que desse total o estado da Bahia produziu cerca de 607.104 toneladas da fruta, ficando atrás apenas do estado de Pernambuco, com um total de 4.259.860 ton. Além do cultivo de manga e uva, a cana-de-açúcar, citrus e outras culturas também se destacam no VSF.

Segundo Lopes (2017), a produção da cana-de-açúcar é amplamente estimulada por meio do incentivo ao consumo de biocombustíveis ou Combustíveis Renováveis, a exemplo do etanol. Isso torna a produção brasileira de grande relevância com relação aos demais países que produzem etanol, pois a utilização de combustíveis renováveis permite reduzir a emissão de gases do efeito estufa, corroborando com a utilização de fontes energéticas que visam a sustentabilidade ambiental e a produção de energia limpa.

O Brasil é considerado o maior produtor do complexo sucroalcooleiro do mundo (SANTOS *et al.*, 2021) e de acordo com os dados da Companhia Nacional de Abastecimento (CONAB, 2021) o volume da produção nacional de cana-de-açúcar no ciclo 2020/21 totalizou 654,8 milhões de toneladas, 1,8% superior ao da safra 2019/20, enquanto a área colhida ficou em 8,62 milhões de hectares, aumento de 2,1% se comparada também a safra anterior. Já no estado da Bahia, estes mesmos dados apontam que a colheita, em aproximadamente 50,4 mil hectares, destinados à produção de cana-de-açúcar representou um incremento de 7,2% em relação à temporada anterior, especialmente, em substituição de áreas antes direcionadas às

pastagens ou que estavam em pousio. Este fato implica na expansão econômica do setor agrícola no Nordeste, mostrando a importância de estudos detalhados das condições atuais, a fim de incrementar a produtividade e, conseqüentemente, a produção da cana-de-açúcar nesta região.

Os elevados números associados a produção agrícola irrigada nessa região, a necessidade permanente de redução dos custos de cultivo e otimização do uso da mão-de-obra, tem conduzido esforços para implementação de ferramentas inteligentes dentro das propriedades. Estas ferramentas permitem um controle de informações por diversos usuários, como também, a tomada de decisões que podem facilitar o manejo da cultura, assim como, a produção de relatórios gerenciais precisos sobre as diversas culturas, lotes, talhões, etc. Para que isso seja mais eficaz, um adequado sistema de informações da propriedade precisa ser conhecido. Os mapas da área, das culturas, solos, sistemas de irrigação, datas de poda e outros tratamentos culturais, dentre outros, precisam ser bem apresentados para permitir o uso de outros sistemas integrados tanto no manejo como no rastreamento das atividades na propriedade agrícola. Uma das formas mais eficazes para mapear a área das fazendas se dá pelo uso de imageamento aéreo, seja por meio de satélites de alta resolução ou por drones ou veículos aéreos não tripulados (VANT's) (MANFREDA *et al.*, 2018).

4.2 AGRICULTURA DE PRECISÃO

Diante das grandes conseqüências em função do aquecimento global, diversas ações foram adotadas para minimizar os efeitos do mesmo e na agricultura, uma das principais medidas adotadas pelos governos foi a criação do programa de Agricultura de Baixo Carbono (ABC), tornando os meios de produção mais eficiente e sustentável. Por meio desse programa, agricultores podem acessar diversas linhas de crédito para financiamento na aquisição de novas tecnologias e serviços em seus sistemas de manejo e produção agrícola, buscando aumentar a produção agrícola, além de reduzir a emissão de gases de efeito estufa (OLIVEIRA *et al.*, 2020).

Segundo Oliveira *et al.* (2020), com o advento de novas tecnologias aliadas a boas práticas de cultivo buscou-se um modelo de agricultura que fosse capaz de otimizar os sistemas produtivos, por meio do uso eficiente dos recursos naturais, reduzindo os impactos ao meio ambiente e maximizando a produtividade das lavouras. Nesse contexto, a Agricultura de Precisão ganhou destaque como modelo

de agricultura que busca a padronização eficiente dos manejos adotados na área cultivada para a otimização da produção agrícola, diminuindo então a variação e mudança dentro do cultivo.

Segundo Esperidião, Santos e Amarante (2019), o século XX representa um marco para a evolução e melhoria da agricultura, nomeada primeiramente como Agricultura 1.0 a partir do momento que passou a utilizar a tração animal para auxiliar no manejo das atividades agrícolas. Logo, ao substituir a tração animal por motores a combustão por meio de máquinas e implementos agrícolas foi posteriormente nomeada para Agricultura 2.0. Em seguida, diante do avanço tecnológico, inclusive com a criação do Sistema de Posicionamento Global (GPS) surge a Agricultura 3.0, fortemente utilizada para o gerenciamento das fazendas até os dias de hoje.

Ainda que os demais modelos de agricultura sejam adotados em diversas propriedades rurais, o mais novo modelo nomeado como Agricultura 4.0 vem se destacando cada vez mais, ao adotar a conectividade e automação em diversas operações de campo, utilizando máquinas, implementos, veículos aéreos não tripulados (VANT's) ou drones, robôs e diversos tipos de sensores para o monitoramento das lavouras. Ainda no final do século XX a Agricultura de Precisão (AP), uma ferramenta da Agricultura 4.0, veio a disponibilizar novas tecnologias como o Sensoriamento Remoto, Sistemas de Informação Geográfica (SIG's), GPS, drones e geoestatística, as quais associadas a máquinas e implementos agrícolas capazes de realizar a aplicação de insumos em taxa variável e o monitoramento da colheita em tempo real.

Lamparelli, Rocha e Borghi (2016) definem Agricultura de Precisão (AP) como um conjunto de técnicas que, seguindo alguns aspectos como localização, fertilidade do solo e outros fatores, são capazes de realizar um manejo localizado nos cultivos, permitindo a otimização dos insumos e alcançando melhor rendimento da cultura.

No Brasil a AP foi inicialmente adotada por volta de 1996, contudo sofreu forte resistência por parte dos produtores, sendo taxada como uma ferramenta possível e aplicável apenas em grandes propriedades (OLIVEIRA *et al.*, 2020). Apesar de ser tratada como um tema consideravelmente novo entre os produtores agrícolas, a AP apresenta grandes potencialidades para alavancar a produção brasileira, uma vez que os produtores, ao utilizar este modelo para gestão de suas lavouras, estão alcançando maiores produtividades de forma mais eficiente. Esta evolução revela a importância da pesquisa científica para produção de mais estudos relacionados à área.

Segundo Pontes e Cavichioli (2018), para aderir a Agricultura de Precisão (AP), a interação de quatro etapas são fundamentais para o cálculo dos índices de produção e indicação quanto ao tipo ideal de manejo a ser adotado. Dentre as quais a primeira etapa contempla o monitoramento intensivo da lavoura para coleta de dados; a segunda, a produção e uso de mapas agrícolas; a terceira, o manejo do cultivo por meio de uma modelagem sistêmica; e a quarta, o gerenciamento eficiente dos insumos, sendo realizados no local, momento e quantidades necessárias.

De acordo com Molin (2002) e Coelho (2005), a etapa da coleta de dados se justifica na quantificação da variabilidade existente dentro da lavoura, a fim de identificar tanto a sua localidade específica dentro do campo como os fatores que influenciam o manejo a ser adotado, para que associado a aplicação adequada de insumo haja um gerenciamento estratégico capaz de responder suficientemente a correção das anormalidades verificadas.

Dentre os diversos modelos de aplicação da AP, o uso de veículos aéreos não tripulados (VANT's) ou drones vem auxiliando na gestão das áreas agrícolas, principalmente, pela portabilidade dos equipamentos, baixo custo de aquisição e pela necessidade de otimização da produção. Isso se deve ao fato de a AP possibilitar ao agricultor um suporte para uma tomada de decisão mais assertiva na escolha de um manejo adequado, por meio do uso de modernas tecnologias desde a coleta, processamento e análise de múltiplas fontes de dados, em uma alta resolução espacial e temporal (OLIVEIRA *et al.*, 2020).

Na Agricultura de Precisão (AP) o Sensoriamento Remoto (SR) torna-se fundamental para um gerenciamento agrícola eficiente, em função de suas diversas aplicações. O SR possibilita o acesso a dados em alta resolução temporal e espacial, seja por meio de sensores proximais, capazes de obter informações do objeto alvo sem a necessidade de contato direto; ou por meio de sensores ativos de reflectância e câmeras multiespectrais, que inclusive abordo de aeronaves não tripuladas tipo drones, permitem os registros dos dados de coordenada de posicionamento geográfico durante a obtenção de dados da superfície imageada (RABELLO, BERNARDI e INAMASU, 2014).

O uso dessas tecnologias está justificado na busca de soluções inovadoras da instrumentação agrícola para a gestão eficiente dos parâmetros de produção das lavouras. Segundo Mainardi (2015), a AP tende a se destacar diante do modelo de agricultura tradicional, pois os produtores buscam alternativas que auxiliem nessa

gestão eficiente das lavouras, visando maior produtividade e, conseqüentemente, maior retorno financeiro. Assim como, uma das alternativas dentro do SR o uso de veículos aéreos não tripulados ganha espaço entre outras tecnologias, principalmente, por permitir a coleta e transmissão das informações dos cultivos em tempo quase real.

4.3 SENSORIAMENTO REMOTO

O avanço tecnológico de baixo custo levou à popularização e difusão das imagens aéreas e, conseqüentemente, os termos que acompanham o Sensoriamento Remoto (SR) e a Fotogrametria (MELO *et al.*, 2021). Sobre o surgimento do termo SR e sua atuação com os avanços da tecnologia, é possível verificar que:

O termo sensoriamento remoto apareceu pela primeira vez na literatura científica em 1960 e significava simplesmente a aquisição de informações sem contato físico com os objetos. Desde então esse termo tem abrigado tecnologia e conhecimentos extremamente complexos, derivados de diferentes campos que vão desde a física até a botânica e desde a engenharia eletrônica até a cartografia (LADWING *et al.*, 2011, p. 132).

Segundo Ladwing *et al.* (2011), no início do SR houve forte ligação com os avanços da fotogrametria e à pesquisa espacial, de tal modo, que as fotografias aéreas foram exatamente os primeiros produtos obtidos a partir da aplicação do sensoriamento remoto. O autor destaca que o SR representou a convergência de conhecimento para duas grandes linhas de pesquisa: a primeira em que tratava da aplicação da aerofotogrametria e fotointerpretação; e uma segunda linha para os avanços tecnológicos, resultando na criação de sensores mais sensíveis, para estudo de regiões espectrais ampliadas. Mesmo com o avanço das tecnologias, a relação entre o sensoriamento remoto e tais linhas de pesquisa continua evidente e promissora.

Outros autores como Dong e Chen (2017) e Reichhardt (2006), relatam que o termo Sensoriamento Remoto surgiu na década de 1950, e informam que Evelyn Pruitt e Walter Bailey o definiram como uma ciência e arte capaz de observar, identificar e inferir medições sobre um determinado objeto, mas de forma distante a este, ou seja, sem o contato direto, trazendo como proposta em substituição à fotogrametria (MELO *et al.*, 2021). Entretanto, mesmo diante de tais conceitos, Melo *et al.* (2021) relatam que Garcia (1982), Chuvieco (2002) e Jensen (2014) fundamentaram seus estudos

com base no que se diz sobre a Fotogrametria. De acordo com Konecny (2014) e Lillesand e Kiefer (1994), a definição mais completa para o sensoriamento remoto foi apresentada por Pruitt e Bailey. Jensen (2014) qualifica essa definição como ideal devido sua simplicidade para assimilação e memorização. Já Campbell e Wynne (2011), explicam que esta definição está pautada na obtenção de informações por meio de um sistema de sensores, sendo que para Melo *et al.* (2021), não há menção ou descrição de como ou de que forma essas informações são coletadas e, por isso, observa-se que essa definição é muito mais ampla, pelo fato de existir diversos meios para acesso às informações de um objeto alvo.

Segundo Jensen (2014) e Novo (2010), equipamentos como rádio, ecobatímetro, sismógrafo, gravímetro, magnetômetro, cintilômetro e/ou radiográfico podem ser utilizados para aquisição de diversas informações, sem que haja contato físico com o objeto estudado, pois estes equipamentos monitoram o comportamento dos alvos através de ondulações e podem ser aplicados em sensoriamento remoto. Contudo, de acordo com a *National Aeronautics and Space Administration* (NASA, 2016), este movimento pode acontecer de forma mecânica ou eletromagnética. Nessa circunstância, Garcia (1982), Sabins (1996) e a Organização das Nações Unidas (ONU, 1986), informam que a aquisição de informações no sensoriamento remoto deve ser restrita ao uso de sensores que detectam a radiação eletromagnética. Melo *et al.* (2021), explicam que para essa restrição, as definições de SR e fotogrametria apresentam pontos divergentes, por exemplo, na fotogrametria a metodologia adotada se baseia na fotointerpretação para produção de documentos cartográficos, enquanto para extração de informações no SR, utiliza-se de métodos de modelagem, medições espectrais e processamento digital, fazendo-se então a necessidade de estudar o conceito de fotogrametria.

De acordo com a *American Society of Photogrammetry* – ASP (1942), o conceito de Fotogrametria foi apresentado como uma ciência e arte de obter informações métricas confiáveis por meio de fotografias, destacando a diferença entre fotos obtidas pelo processo fotogramétrico das fotos tradicionais. Segundo Cowell (1997), nitidamente as sociedades internacionais que incorporavam o termo fotogrametria em seus nomes, como a *American Society of Photogrammetry* (ASP) e a *International Society for Photogrammetry* (ISP), após iniciar os estudos sobre o sensoriamento remoto, em 1980, alteraram seus nomes, passando a se chamar *American Society of Photogrammetry and Remote Sensing* (ASPRS) e *International*

Society for Photogrammetry and Remote Sensing (ISPRS). De acordo com Pinto (2012), o Sensoriamento Remoto (SR) pode ser resumido como a arte e ciência pautada na obtenção de informações de um objeto sem estar em contato físico direto com este.

4.4 AEROFOTOGRAMETRIA

Diversas são as contribuições da aerofotogrametria, com destaque para a elaboração de mapas em conjunto com outras ciências, pois neste campo, as imagens servem como base para mapear pontos na superfície terrestre, identificando objetos que serão, posteriormente, utilizados para estudos diversos (ANDRADE, 1998). Segundo o mesmo autor, o mapeamento por meio da aerofotogrametria pode ser realizado basicamente pelo método da Triangulação Fotogramétrica ou Aerotriangulação; e para a produção de carta ou mapa utiliza-se o método de Restituição Fotogramétrica.

De acordo com Andrade (1998), fototriangulação (triangulação fotogramétrica) consiste em incluir a definição das coordenadas em pontos de interesse no espaço escolhido com o objetivo de obter coordenadas precisas de um ponto que sejam suficientes para seu posicionamento. Deste modo, o modelo fotogramétrico pode restaurar ou produzir ortofotos, mas, para isso, é necessário ter posse de informações sobre a relação geométrica entre fotos adjacentes; o controle de campo por meio de pontos de apoio; e o conjunto de valores aproximados dos parâmetros, para que se obtenha a fototriangulação. Mendonça (2019) explica que os pontos normalmente utilizados para fototriangulação são denominados por pontos de ligação ou *'tie points'* - inclusive de grande importância no processamento digital; e como pontos de apoio terrestre.

Segundo Brito e Coelho Filho (2007), a definição de restituição fotogramétrica está na interpretação das inúmeras feições geográficas do terreno por meio das coordenadas de pontos no sistema 'espaço-objeto'. Segundo os autores entende-se pelo termo espaço-objeto, qualquer objeto (ou conjunto) tridimensional imageado, podendo o sensor imageador estar localizado em qualquer plataforma. Neste processo, os autores explicam que o número de imagens envolvidas no processo é variável, sendo capturadas por pelo menos dois ângulos diferentes e com área de sobreposição, buscando viabilizar a visão tridimensional do espaço-objeto.

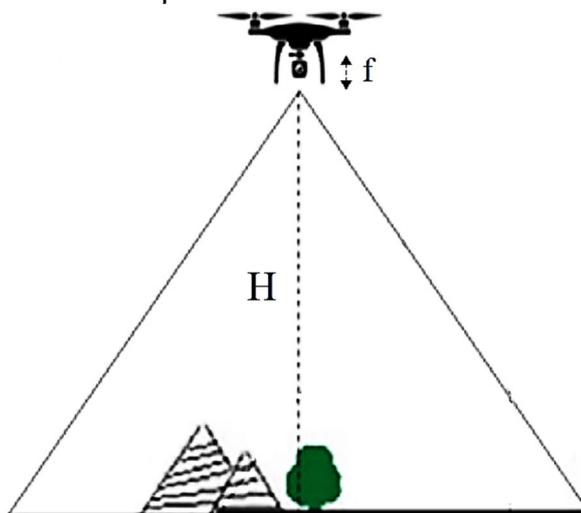
Em relação a geometria de um objeto fotografado, existem três classificações para uma imagem: i) alto oblíqua e ii) baixo oblíqua, quando as tomadas de fotografias ocorrem com eixo não perpendicular ao terreno; e iii) vertical quando a foto é tirada com o eixo óptico voltado perpendicularmente ao terreno (WOLF, 1995). Entretanto, Ruy (2008) explica que embora o uso de imagens capturadas e classificadas como alto e baixo oblíquas apresentem algumas vantagens para a representação de áreas extensas, sua aplicação não é adequada para mapeamento justamente por limitações geométricas e excesso de distorções.

As fotografias verticais (aéreas) permitem obter uma relação geométrica entre a própria fotografia e o objeto imageado (MENDONÇA, 2019). Neste contexto, Silva Júnior (2019) ressalta que as características (elevações) da superfície sobrevoada podem interferir no resultado, uma vez que as variações de escala são mais significativas pelo fato da altura do voo não ser constante. Assim, o autor destaca a relação matemática que expressa a escala da fotografia por meio da Equação 1 e Figura 1:

$$E = \frac{f}{H} \quad (1)$$

Onde E, f e H correspondem a escala, distância focal e altura do voo, respectivamente.

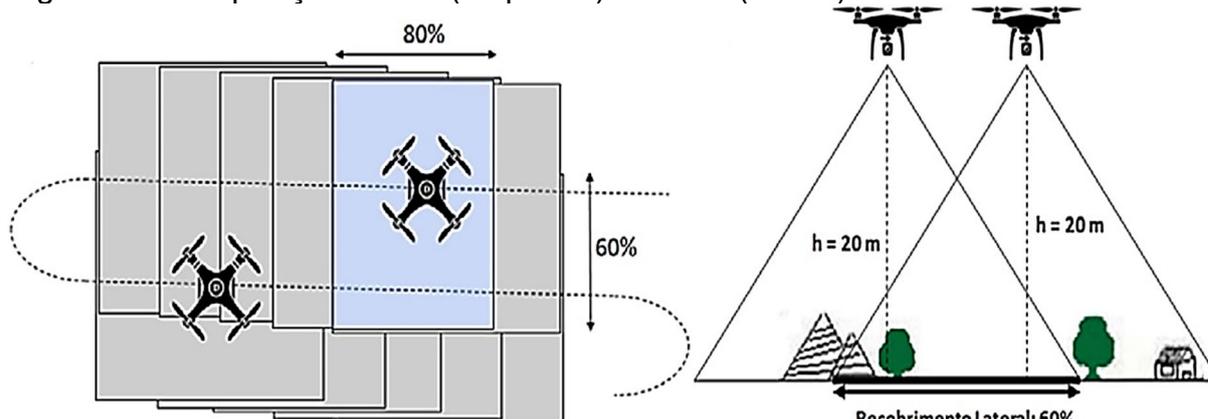
Figura 1. Parâmetros utilizados para o cálculo da escala da fotografia aérea.



Fonte: Adaptado de Menezes, Santos e Senra (2019)

De acordo com Silva Júnior (2019), a cobertura aerofotogramétrica, outro fator analisado na aerofotogrametria, é a representação do terreno por meio de fotografias capturadas, sequencialmente, ao longo de uma direção de voo (faixa de voo). O autor explica que a sucessão de imagens ocorre em intervalo de tempo de forma que entre a captura de duas fotografias haja uma superposição longitudinal de pelo menos 60% (formando uma faixa) e nas faixas laterais dispostas paralelamente para compor a cobertura da área, é respeitado uma distância entre faixas de voo para que haja uma superposição lateral de pelo menos 30%. Deste modo, alguns pontos da superfície são fotografados várias vezes evitando vazios durante a cobertura aerofotogramétrica, tornando possível extrair as suas medidas tridimensionais, conforme apresentado na Figura 2:

Figura 2. Esquema de cobertura aerofotogramétrica para tomada de imagens com região de sobreposição frontal (esquerda) e lateral (direita).



Fonte: Adaptado de Menezes, Santos e Senra (2019)

Segundo Mendonça (2019), quando a relação entre o pixel e a escala do objeto fotografado, representa uma distância real na superfície observada, determina-se então a resolução da imagem ou o GSD (*Ground Sample Distance*). De acordo com Cunha *et al.* (2016), o GSD tem relação direta entre a altura da tomada da fotografia em relação ao solo, por meio da distância focal da câmara e o tamanho do pixel no sensor (Figura 3), deste modo, a cada altura de voo, tem-se um valor diferente para o GSD. Para determinar o GSD utiliza-se da Equação 2 e os seguintes parâmetros:

$$GSD = \frac{(hg * b)}{f} \quad (2)$$

Onde:

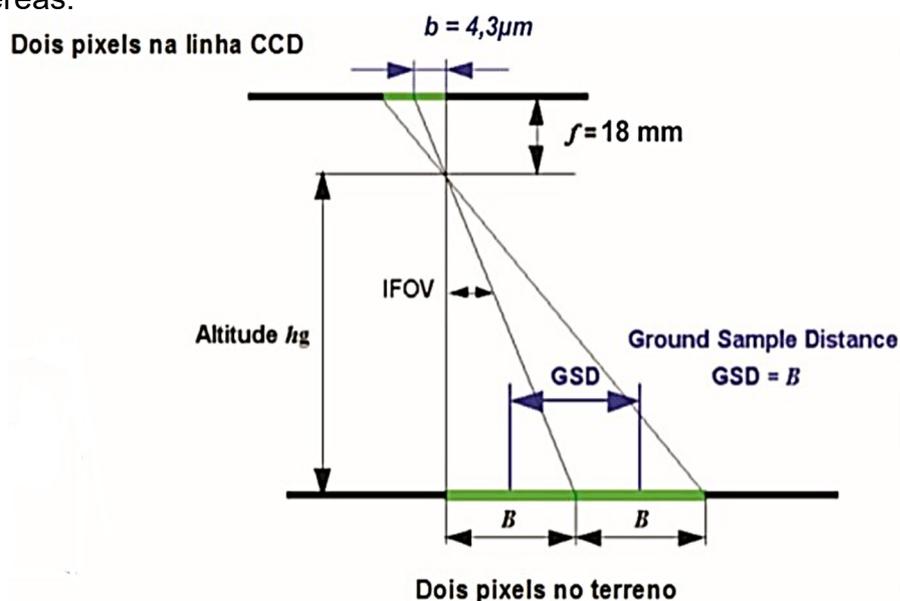
b – Tamanho do pixel do sensor

f – Distância focal da lente

h_g – Altura do voo

GSD – *Ground Sample Distance* – Distância entre o centro de dois pixels vizinhos

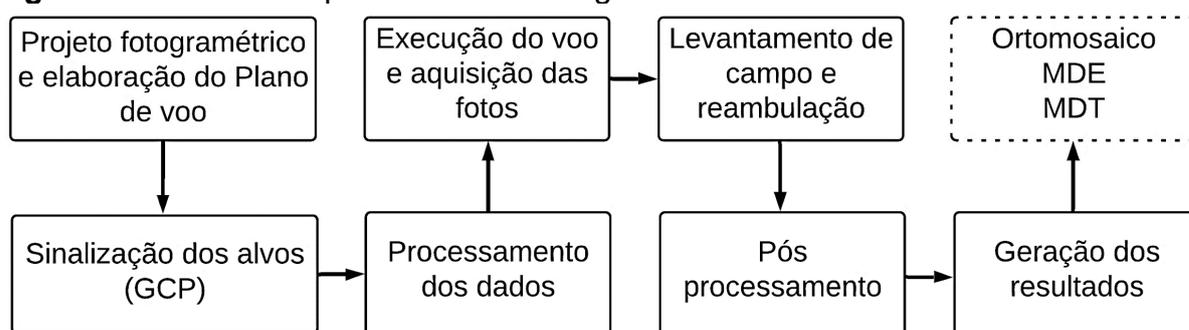
Figura 3. Parâmetros utilizados para cálculo do GSD (*Ground Sample Distance*) em imagens aéreas.



Fonte: Adaptado de Neto (2015)

Santos da Silva (2018) explica que o mapeamento aerofotogramétrico ocorre em várias etapas subsequentes realizadas após o planejamento da operação, por meio de um estudo detalhado com todas as especificações do tipo de cobertura a ser executado, conforme apresentado na Figura 4.

Figura 4. Fases do mapeamento aerofotogramétrico.



Fonte: Adaptado de Santos da Silva (2018).

Existem diversos softwares disponíveis para o processamento dos dados obtidos por aerolevamento, entretanto, nesta pesquisa foi utilizado o software Agisoft Metashape® versão 1.5.2 (AGISOFT, 2021), um programa de computador fotogramétrico para geração automática de nuvens de pontos densos, texturizados, modelos poligonais, ortomosaicos georreferenciados, modelo digital de terreno (MDT) e modelo digital de superfície (MDS), utilizando uma licença de avaliação, fornecida pela fabricante do software.

Para o Pós-processamento das imagens foram utilizados o software QGIS versão 3.10.8 'A Coruña' (QGIS Development Team, 2019), um programa licenciado sob a Licença Pública Geral (GNU), projeto oficial da *Open Source Geospatial Foundation* (OSGeo) e o software SAGA *System for Automated Geoscientific Analyses* versão 2.3.2 (CONRAD *et al.*, 2015), ambos são programas de Sistema de Informação Geográfica (SIG) do tipo *Free Open Source Software* (FOSS).

4.5 PROCESSAMENTO E PRODUTOS DIGITAIS

De acordo com Herreros (2015), os produtos digitais obtidos pelo mapeamento aerofotogramétrico consistem em dados ou modelos com duas dimensões ou tridimensionais. As nuvens de pontos e os modelos digitais de elevação e de terreno são resultados possíveis em ambiente tridimensional, por outro lado as ortofotos e o ortomosaico são produtos com duas dimensões.

Para Wolf, Dewitt e Wilkinson (2014), ortofotos são fotografias do terreno corrigidas, que mostram imagens de objetos em suas verdadeiras posições ortográficas de modo que o aspecto perspectivo da fotografia acaba sendo removido durante o processo de correção. Giovanini (2021a) explica que para obter uma ortofoto é necessário realizar a ortorretificação, que trata do processo de correção pixel a pixel utilizado para corrigir os diferentes erros da imagem, fazendo com que os objetos ocupem posições relativas as ocupadas no mundo real. O mesmo autor destaca que o produto obtido da união das ortofotos de um mapeamento aéreo é denominado ortomosaico.

Segundo Hyslop *et al.* (2020), existem basicamente três tipos de modelos digitais que podem ser obtidos com o processamento das imagens obtidas por satélites ou VANT's: Modelo Digital de Elevação (MDE), que capta a elevação, assim como o dossel vegetal; Modelo Digital de Terreno (MDT), que capta a elevação com

base no terreno, ignorando as elevações sobre o solo; e o Modelo Digital de Superfície (MDS), que capta todas as elevações sobre o solo (como edificações, ruas, árvores etc.).

O resultado desses produtos depende de vários fatores, desde antes do processamento, como resolução, sobreposição frontal e lateral das fotografias, luminosidade e altitude do VANT na coleta das imagens, assim como, a escolha da qualidade de processamento das imagens dentro do software. Parte dessas informações são analisadas a partir do *Ground Sample Distance*, apresentado também no relatório final de processamento, emitido pelo próprio software. O *Ground Sample Distance*, ou GSD, é a representação do pixel da imagem em unidades de terreno e está associado à qualidade final do processamento por meio do nível de detalhamento do levantamento aéreo. O valor dado por meio do GSD é inversamente proporcional ao nível de detalhamento, ou seja, quanto maior o GSD, menor é o nível de detalhamento, e quanto menor for o GSD, maior é o nível de detalhamento (GIOVANINI, 2021b).

Com o avanço da tecnologia e contribuição da inteligência artificial (IA), o método de *Machine Learning* (ML), pode ser utilizado para a resolução de problemas de classificação e regressão no processamento das imagens aerofotogramétricas. O programa tem a aptidão de aprender o funcionamento interno de um sistema, utilizando algoritmos – dentre os mais comuns o *Decision Tree* (DT), *Random Forest* (RF), *Support Vector Machines* (SVM) e Rede Neural Artificial (RNA); a partir de um determinado número de dados sem possuir o conhecimento prévio desse sistema, em função de sua capacidade de modelar sistemas complexos, com uma grande gama de variáveis de entrada sem precisar assumir a distribuição normal dos dados, fazendo com que estas sejam as principais razões que o tornam popular (SILVA, 2021).

Outro método a contribuir além do ML é o *Deep Learning* (DL), sendo uma subárea da IA, o DL é uma rede neural que possui diversas camadas escondidas, mais camadas que uma rede neural normal, possuindo também diversas operações, onde cada camada vai ser responsável por extrair determinada característica. Com a junção de todas as camadas obtém-se o resultado final, que possibilita uma rede DL processar uma camada exponencial de dados (GOODFELLOW, BENGIO e COURVILLE, 2016).

4.6 MÉTODOS PARA DETECÇÃO SEMIAUTOMÁTICA DE ÁRVORES

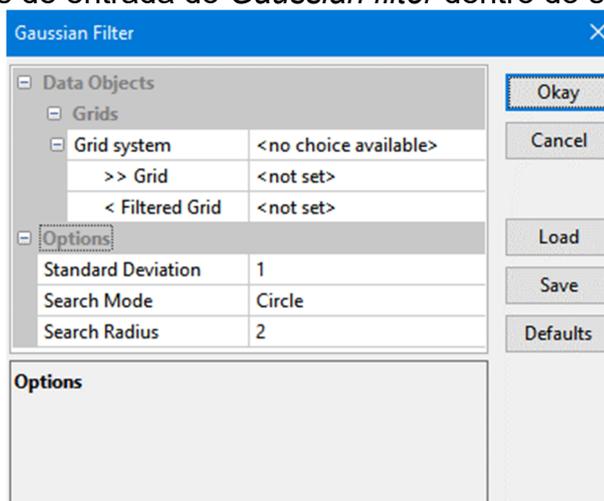
Para analisar o desempenho de ferramentas utilizadas no processo de detecção de árvores a partir dos dados aerolevantados por drones é necessário conhecer os ambientes disponíveis para a operação das ferramentas, entender os parâmetros utilizados para detecção em cada método e munir-se de informações para comparação e comprovação dos resultados obtidos.

Nessa pesquisa foram utilizados o software *SAGA System for Automated Geoscientific Analyses* versão 2.3.2 (CONRAD *et al.*, 2015) e o plugin *Tree Density Calculator* versão 1.5.7 (CRABBÉ *et al.*, 2020) no processo de detecção semiautomática de árvores. Este plugin é disponibilizado na biblioteca de complementos do QGIS. Como ferramentas gratuitas e de fácil utilização, ambos foram avaliados quanto a sua capacidade de detecção de árvores dos pomares estudados.

O SAGA foi codificado na linguagem de programação C++, orientada a objetos e com suporte para implementação de novas funções com uma Interface de Programação de Aplicativos (API). Ele está organizado como módulos em bibliotecas de estrutura em módulos independentes e podem ser acessadas via Interface Gráfica de Usuário (GUI) do SAGA ou de vários ambientes de *script* (scripts shell, Python, R, outros), podendo ser executado no Linux, bem como, em sistemas operacionais Windows.

Para detecção de árvores a partir do SAGA, o *Gaussian filter* é um dos principais recursos necessários. Trata-se de um operador de alisamento que é utilizado para 'suavizar' o conjunto de dados e remover detalhes e ruídos. O grau de suavização é determinado pelo desvio padrão. Para desvios padrão mais altos, o usuário precisa aplicar um raio de pesquisa maior. A Figura 5 contém os principais parâmetros apresentados na interface do filtro.

Figura 5. Parâmetros de entrada do *Gaussian filter* dentro do software SAGA.



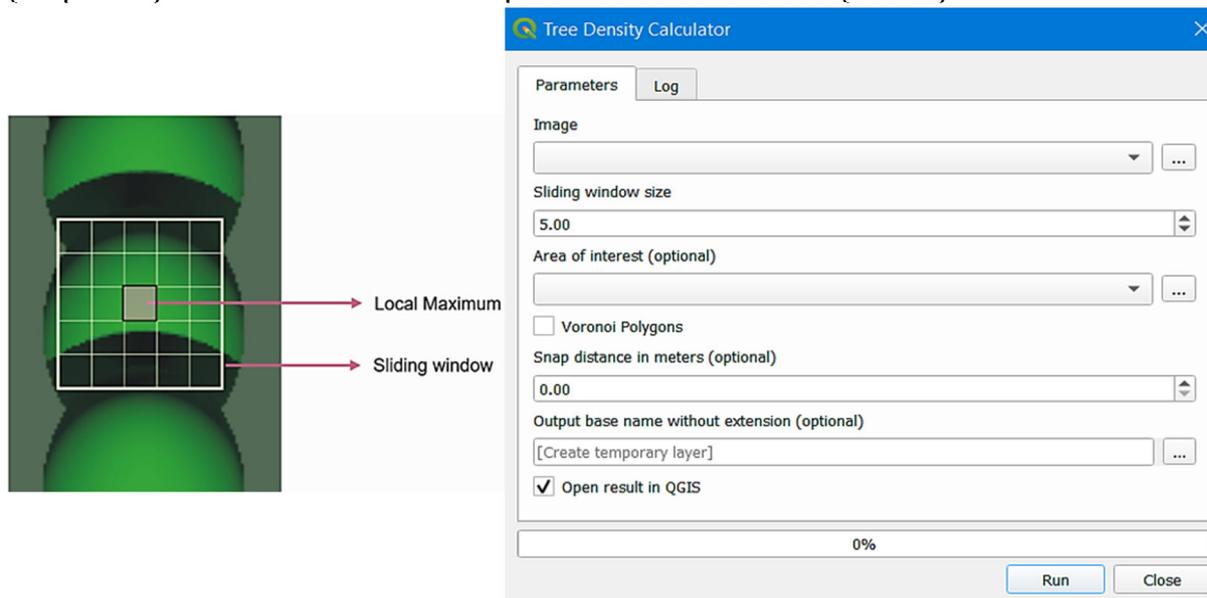
Fonte: Software SAGA GIS.

Para a execução de qualquer ferramenta é necessária a definição de alguns parâmetros. Esses parâmetros podem ser obrigatórios ou opcionais, de entrada ou de saída, e podem apresentar um valor *default* (padrão) que é utilizado caso o usuário não altere o valor. O parâmetro *Standard Deviation* ou desvio padrão, utilizado como porcentagem do raio do kernel, determina o grau de suavização da malha do conjunto de dados, e dentre os valores possíveis, estão o valor mínimo de 0,0001 e *default* (padrão) de 1. Já o parâmetro *Search Radius* ou raio de pesquisa, determina o raio do núcleo nas células, podendo atuar com os valores mínimo de 1 e padrão de 3.

O funcionamento do plugin *Tree Density Calculator*, parte da suposição de que uma copa da árvore é a parte mais brilhante de uma árvore inteira observada em imagens de sensoriamento remoto. O *Tree Density* usa o *Sliding Window*, uma janela deslizante para mover-se sobre a imagem. Para cada posição da janela, o plugin verifica se o pixel central é o mais brilhante da janela, se assim for, o pixel é marcado como *Local Maximum*, ou máximo local. Deste modo, para o funcionamento do plugin basta determinar apenas um parâmetro: o tamanho da janela deslizante, em *Sliding Window*.

A Figura 6 apresenta a simulação do funcionamento do plugin *Tree Density Calculator*, de modo que ele escolhe a copa da árvore como o máximo local em brilho dentro da janela de 5 x 5 pixels, e a interface do plugin para determinação do parâmetro *Sliding Window*.

Figura 6. Representação do funcionamento do plugin Tree Density Calculator (esquerda) e sua interface com os parâmetros de entrada (direita).



Fonte: Software QGIS.

O parâmetro *Sliding Window* utiliza como *default* o valor 5, e segundo recomendações dos desenvolvedores, dependendo da resolução das imagens e do tamanho das copas das árvores, é um processo de tentativa e erro encontrar o tamanho correto da janela.

4.7 ÍNDICES ESPECTRAIS

Diante das diversas aplicações proporcionadas pelo Sensoriamento Remoto (SR), a delimitação de áreas de estudo por meio de algoritmos, modelos matemáticos e índices espectrais permite que a ciência evolua constantemente. Segundo Silva (2018) índices espectrais são combinações de níveis de reflectância de duas ou mais bandas de radiação que indicam relativamente a abundância de determinadas características de interesse, geralmente, utilizados para aplicações agrícolas, mas também, presente em estudos ambientais (preservação, impactos, queimadas, entre outros).

Santos, Padolfi e Ramaldes (2018) explicam que o termo índice de vegetação, amplamente utilizado, também é resultado da combinação aritmética entre duas ou mais bandas e que ao evidenciar algum componente de interesse na geração de uma imagem multiespectral, permite a comparação entre diversas propriedades biométricas da vegetação. Neste trabalho, foram selecionados índices espectrais e de

vegetação que melhor refletem a presença/ausência de água na planta, permitindo um diagnóstico sobre o estado hídrico dos pomares irrigados, que também são muito relacionados com a produção de biomassa na vegetação.

Tucker (1979), ao observar o comportamento de alguns índices utilizados no SR aplicados em dados coletados em solo por meio de espectralradiômetro, os relacionou com as faixas espectrais do infravermelho/vermelho e os comparou com as faixas do verde/vermelho aliado ao comportamento da vegetação. Como resultado, obteve-se a primeira aparição do Índice Verde/Vermelho por Diferença Normalizada (NGRDI - Normalized Green Red Difference Index), apresentado na Equação 3.

$$NGRDI = \frac{\rho_G - \rho_R}{\rho_G + \rho_R} \quad (3)$$

Onde ρ_G e ρ_R representam a reflectância das bandas do verde e vermelho, respectivamente.

Entretanto, ao comparar resultados aplicando o índice NGRDI e outros índices utilizando o infravermelho próximo, Tucker (1979) percebeu a preeminência na aplicação dos índices NIR. Outros índices foram observados também no século XX, mais precisamente, na década de 1990. Dentre os quais, destacam-se aqueles desenvolvidos com as bandas RGB (vermelho, verde e azul), como o *Excess Green Index* (ExG), *Excess Red Vegetative Index* (ExR), *Excess Green minus Excess Red* (ExGR) resultado da combinação entre os índices ExG e ExR; e o *Redness Index* (RI). Diante da complexidade em identificar plantas em ambientes naturais andinos e áridos por meio do índice NDVI (*Normalized Difference Vegetation Index*), Escadafal e Huete (1991) propuseram o *Redness Index* (RI) ou índice de vermelhidão. Este índice apresenta alta correlação com o índice SAVI (*Soil-Adjusted Vegetation Index*), e sua facilidade de aplicação se deve pelo fato de utilizar uma razão simples entre as bandas verde e vermelho, conforme apresentado na Equação 4:

$$RI = \frac{\rho_R - \rho_G}{\rho_R + \rho_G} \quad (4)$$

Onde ρ_G e ρ_R representam a reflectância das bandas do verde e vermelho, respectivamente.

Woebbecke *et al.* (1995), buscando detectar a presença de plantas daninhas em diferentes tipos ambientes, com presença de iluminação/sombreamento, resíduos e diferentes tipos de solos, realizou a aplicação de índices de vegetação que resultaram na distinção da vegetação de outros materiais não-vivos. Eles geraram um produto imageado próximo a binarização, onde os valores representam e delinham as regiões de interesse das plantas, inclusive atingindo bom desempenho para aplicação em ambientes sombreados e não protegidos, ou para o monitoramento de pragas agrícolas. Dessa forma, os autores propuseram o *Excess Green Index* (ExG), apresentado pela Equação 5:

$$ExG = 2 * g - r - b \quad (5)$$

Onde g, r e b representam os valores das bandas normalizadas verde, vermelho e azul; obtidos pelas equações 6, 7 e 8, respectivamente (PONTI, 2012).

$$g = \frac{\rho G}{(\rho R + \rho G + \rho B)} \quad (6)$$

$$r = \frac{\rho R}{(\rho R + \rho G + \rho B)} \quad (7)$$

$$b = \frac{\rho B}{(\rho R + \rho G + \rho B)} \quad (8)$$

Onde ρR , ρG e ρB representam a reflectância das bandas do vermelho, verde e azul, respectivamente.

Segundo Demarchi, Piroli e Zimback (2011), o NDVI (Normalized Difference Vegetation Index) é um dos índices indicadores de vegetação mais conhecidos por destacar a biomassa a partir da mensuração da quantidade de clorofila e da absorção de energia por unidade de área. Para Rodrigues e Rodrigues (2012), o princípio de funcionamento do NDVI considera que quanto mais ativo for o processo de trabalho da clorofila nos tecidos vegetais, maior é a absorção de radiação na região do vermelho, por outro lado, as estruturas celulares das folhas provocarão maior reflexão da radiação na região do infravermelho, conforme apresentado pela Equação 9:

$$NDVI = \frac{(\rho NIR - \rho R)}{(\rho NIR + \rho R)} \quad (9)$$

Onde ρ_{NIR} e ρ_R representam a reflectância das bandas do infravermelho próximo e vermelho, respectivamente.

Segundo Câmara, Davis e Monteiro (2001), o NDVI apresenta valores entre -1 e +1, de modo que solos expostos sem cobertura são representados por valores próximos a zero, podendo inclusive ser negativos quando não há presença de atividade fotossintética, no entanto valores acima de zero indicam presença de vegetação no ambiente e quanto maior for o resultado do NDVI, maior é a reflectância da banda infravermelho e isso está diretamente ligado a vegetação mais densa e com pleno vigor de crescimento. Contudo, destaca-se que o estudo do potencial produtivo das culturas agrícolas pode ser aplicado em qualquer estágio de desenvolvimento e que ao longo do ciclo da cultura o valor do índice calculado terá sempre um comportamento dinâmico de acordo com a fase fenológica (RISSINI, KAWAKAMI e GENÚ, 2015).

Buscando avaliar danos em plantações de arroz utilizando o NDVI, Arai *et al.* (2016) estudaram metodologias para estimava de reflectância NIR a partir de faixas do visível e descobriram que existe uma alta correlação entre a refletância NIR e a refletância da cor verde. Assim, para obtenção da banda do Infravermelho Próximo - NIR utilizando a banda verde do visível, estes autores propuseram o seguinte modelo, conforme apresentado na Equação 10.

$$\rho_{NIR} = \frac{(360,6 - \rho_G)}{1,1941} \quad (10)$$

Onde ρ_{NIR} e ρ_G representam a reflectância das bandas do infravermelho próximo e verde, respectivamente.

O Índice de Vegetação Ajustado para o Solo (SAVI – *Soil-Adjusted Vegetation Index*), desenvolvido por Huete (1988), se destaca por minimizar as influências do solo no processo de caracterização do dossel das culturas agrícolas, podendo ser expresso pela Equação 11, conforme Eastman (2006).

$$SAVI = \left[\frac{(\rho_{NIR} - \rho_R)}{(\rho_{NIR} + \rho_R + L)} \right] * (1 + L) \quad (11)$$

Onde ρ_{NIR} e ρ_R representam a reflectância das bandas do infravermelho próximo e vermelho, respectivamente, enquanto L é o fator de ajuste para o substrato do dossel vegetativo.

Segundo Huete (1988), em condições de baixa cobertura vegetal sugere-se para o fator L o valor de 1,0; enquanto para uma cobertura vegetal de altura intermediária o fator $L = 0,5$; e para alta densidade de vegetação, o fator $L = 0,25$. Segundo o mesmo autor, ainda em condições que o valor de L for igual a zero, logo o índice SAVI será equivalente ao índice NDVI.

Baseando-se nos índices ARVI – *Atmospherically Resistant Vegetation Index* (KAUFMAN e TANRE, 1992); GARI – *Green Atmospherically Resistant Index* (GITELSON, KAUFMAN e MERZLYAK, 1996); SAVI (HUETE, 1988) e NDVI (ROUSE *et al.*, 1974), Gitelson *et al.* (2002) propuseram o VARI – *Visible Atmospherically Resistant Index* (Equação 12), índice que mesmo estando nas faixas do visível, contém uma correção atmosférica para melhoramento do produto (SILVA *et al.*, 2019):

$$VARI_{green} = \frac{\rho_G - \rho_R}{\rho_G + \rho_R - \rho_B} \quad (12)$$

Onde ρ_G , ρ_R e ρ_B representam a reflectância das bandas do verde, vermelho e azul, respectivamente.

Além dos índices de vegetação, existem índices espectrais voltados para o estudo da água nos diferentes tipos de ambientes, como exemplo o NDWI - *Normalized Difference Water Index* (McFEETERS, 1996) (Equação 13). Segundo o mesmo autor este índice foi projetado para maximizar a refletância da água utilizando o comprimento de onda verde, e como resultado, as características da água têm valores positivos, portanto, são aprimoradas, enquanto a vegetação e o solo têm valores zero ou negativos, por isso, são suprimidos. Gao (1996) e Xu (2006) propuseram modificações do NDWI para melhorar a detecção de recursos hídricos removendo de forma eficiente ruído do solo acumulado, bem como, o ruído da vegetação e do solo.

$$NDWI_{(McFeeters\ 1996)} = \frac{\rho_G - \rho_{NIR}}{\rho_G + \rho_{NIR}} \quad (13)$$

Onde ρ_G e ρ_{NIR} representam as reflectâncias das bandas do verde e NIR, respectivamente.

Dessa forma, há índices de vegetação que podem ser obtidos com as bandas visíveis do espectro eletromagnético, e outros que necessitam da banda infravermelha. A facilidade de obtenção de imagens RGB tem popularizado o uso de índices de vegetação na região do visível, porém, sabe-se que aqueles que utilizam a reflectância no NIR são amplamente mais difundidos e reconhecidos para aplicações em agricultura. A Tabela 1 resume os índices de vegetação listados anteriormente, incluindo outros índices espectrais disponíveis na literatura aplicados nesta pesquisa.

Tabela 1. Sumário com alguns dos principais índices espectrais da literatura

	Índice espectral	Tipo*	Fórmula	Referência
1	Normalized Green Red Difference Index	RGB	$NGRDI = \frac{\rho_G - \rho_R}{\rho_G + \rho_R}$	Tucker (1979)
2	Redness Index	RGB	$RI = \frac{\rho_R - \rho_G}{\rho_R + \rho_G}$	Escadafal e Huete (1991)
3	Excess Green Index	RGB	$ExG = 2 * g - r - b$	Woebbeck e <i>et al.</i> (1995)
4	Normalized Difference Vegetation Index	NIR	$NDVI = \frac{(\rho_{NIR} - \rho_R)}{(\rho_{NIR} + \rho_R)}$	Rouse <i>et al.</i> (1974)
5	Soil-Adjusted Vegetation Index	NIR	$SAVI = \left[\frac{(\rho_{NIR} - \rho_R)}{(\rho_{NIR} + \rho_R + L)} \right] * (1 + L)$	Huete (1988)
6	Red Green Blue Vegetation Index	RGB	$RGBVI = \frac{\rho_G^2 - (\rho_R * \rho_B)}{\rho_G^2 + (\rho_R * \rho_B)}$	Bendig <i>et al.</i> (2015)
7	Modified Green Red Vegetation Index	RGB	$MGRVI = \frac{\rho_G^2 - \rho_R^2}{\rho_G^2 + \rho_R^2}$	Bendig <i>et al.</i> (2015)
8	Normalized Difference Index	RGB	$NDI = 128 * \left[\left(\frac{\rho_G - \rho_R}{\rho_G + \rho_R} \right) + 1 \right]$	Woebbeck e <i>et al.</i> (1992)
9	Visible Atmospherically Resistant Index	RGB	$VARI_{green} = \frac{\rho_G - \rho_R}{\rho_G + \rho_R - \rho_B}$	Gitelson <i>et al.</i> (2002)

10	Atmospherically Resistant Vegetation Index	NIR	$ARVI = \frac{[\rho NIR - \rho R + \gamma * (\rho B - \rho R)]}{[\rho NIR + \rho R - \gamma * (\rho B - \rho R)]}$	Kaufman e Tanre (1992)
11	Green Atmospherically Resistant Index	NIR	$GARI = \frac{\{\rho NIR - [\rho G - \lambda(\rho B - \rho R)]\}}{\{\rho NIR + [\rho G - \lambda(\rho B - \rho R)]\}}$	Gitelson et al. (1996)
12	Excess Red Vegetative Index	RGB	$ExR = 1.4 \rho R - \rho G$	Meyer et al. (1998)
13	Excess Green minus Excess Red	RGB	$ExGR = ExG - ExR$	Camargo-Neto (2004)
14	Normalized difference water index	NIR	$NDWI_{(McFeeters,1996)} = \frac{(\rho G - \rho NIR)}{(\rho G + \rho NIR)}$	McFeeters (1996)
15	Normalized difference water index	NIR	$NDWI_{(Gao,1996)} = \frac{(\rho NIR - \rho SWIR)}{(\rho NIR + \rho SWIR)}$	Gao (1996)
16	Modification of Normalized Difference Water Index	SWIR	$MNDWI = \frac{(\rho G - \rho SWIR)}{(\rho G + \rho SWIR)}$	Xu (2006)
17	Ground Level Image Analysis	RGB	$GLI = \frac{((\rho G - \rho R) * (\rho R - \rho B))}{(\rho G + \rho R + \rho G + \rho B)}$	Louhaichi et al. (2001)
18	Ground Level Image Analysis	RGB	$GLI = \frac{(2 * \rho G - \rho R - \rho B)}{(2 * \rho G + \rho R + \rho B)}$	Hunt et al. (2011)
19	Triangular Greenness Index	RGB	$TGI = -0,5[(\lambda R - \lambda B)(\rho R - \rho G) - (\lambda R - \lambda G)(\rho R - \rho B)]$	Hunt et al. (2011)
20	IAF _{Miranda (2017)}	RGB	$IAF = -25,838(\sqrt{\rho R} + \rho B^2 - \sqrt{\rho G}) + 2,354$	Miranda (2017)
21	IAF _{Miranda (2017)}	RGB	$IAF = -0,2013\left(e^{\rho B} + \frac{\log_2 \rho G}{\log_{10} \rho R}\right) + 3,8408$	Miranda (2017)
22	IAF _{Miranda (2017)}	NIR	$IAF = -3,8673\left(\frac{\frac{\rho R}{\sqrt{\rho NIR}}}{\sqrt{\rho G}}\right) + 4,3275$	Miranda (2017)

*RGB = Índices que mantêm as faixas RGB (vermelho, verde, azul); NIR = Índices que mantêm relação com o infravermelho próximo; SWIR= Índices que mantêm relação com o infravermelho médio.

5 CAPÍTULO I

DETECÇÃO SEMIAUTOMÁTICA DE ÁRVORES EM POMARES IRRIGADOS NO VALE DO SÃO FRANCISCO UTILIZANDO VANT

RESUMO

O monitoramento da população de plantas em áreas agrícolas é fundamental para acompanhar a produtividade, auxiliar no planejamento e na tomada de decisão. Essas informações são tradicionalmente adquiridas por meio da contagem manual, a qual requer maior tempo; ou automatizada, necessitando de mão de obra especializada, serviços pagos e métodos complexos de identificação de árvores com inteligência artificial. Nesse contexto, objetivou-se avaliar metodologias de processamento de imagens aéreas obtidas com drones para detecção remota de árvores, em pomares irrigados no Submédio do Vale São Francisco, a partir de softwares e plugins acessíveis. O estudo foi desenvolvido em pomares experimentais de mangueira e citrus localizados no município de Juazeiro-BA. Para a identificação das árvores foram utilizados modelos digitais dos pomares obtidos a partir imagens aéreas capturadas nas bandas do visível (RGB) em câmera acoplada em VANT. Foram avaliados os *plugins Tree Density Calculator* e SAGA GIS, enquanto a validação ocorreu por meio da contagem manual das árvores de cada pomar. Os resultados obtidos foram avaliados utilizando os índices de Precisão, Revocação e F1-Score. Observou-se que o uso do software SAGA GIS apresentou melhor desempenho para a detecção semiautomática de árvores, com precisão de 98,5%. O uso das metodologias avaliadas se mostraram eficientes para detecção de árvores, assim podendo também ser testadas em pomares com diferentes dimensões e espécies.

Palavras-chave: Identificação de árvores. Fruticultura. Sensoriamento remoto. Veículo aéreo não tripulado.

5.1 INTRODUÇÃO

O Brasil se destaca com elevada produção agrícola, principalmente, devido às propícias condições edafoclimáticas e aos investimentos públicos e privados em infraestrutura, pesquisa e tecnologia para maximizar a produção (PASSOS, FONTES e NASCIMENTO, 2020). Com a expansão das áreas frutíferas, informações sobre o número exato de árvores são fundamentais, tanto para estimar a taxa de sobrevivência das plantas, quanto para acompanhar sua produtividade (WEIJIA LI *et al.*, 2016; MASCHLER, ATZBERGER e IMMITZER, 2018); inclusive sendo útil para cálculo de estoques de carbono (ZHANG, 2019); estudos sobre o vigor das plantas (BARNES *et al.*, 2017), percentual de cobertura verde (HERNÁNDEZ-HERNÁNDEZ *et al.*, 2016), dentre outros como estado nutricional e hídrico, que juntos auxiliam nas tomadas de decisão dentro da propriedade.

A produção de dados georreferenciados sobre os pomares é extremamente útil para o desenvolvimento da agricultura 4.0. Normalmente, o processo de contagem de plantas ocorre de forma manual por trabalhadores rurais, que apesar da eficácia quanto a identificação, torna-se bastante ineficiente pela alta demanda de tempo e mão de obra (ABIDIN *et al.*, 2017). Por sua vez, o sensoriamento remoto torna-se uma importante alternativa para automatizar o processo de contagem de plantas a partir da aquisição de informações sem o contato direto com os alvos, a partir de imagens com alta resolução espacial (YANAN LI *et al.*, 2016). Neste sentido, buscando melhorar a qualidade no levantamento de dados de áreas agrícolas, o uso de veículos aéreos não tripulados (VANT's) torna-se uma importante alternativa, pois fornece informações aéreas por meio de técnicas de sensoriamento remoto e aerofotogrametria com altas resoluções temporais e espaciais, além de custos mais baixos para coberturas de pequenas e médias áreas quando comparados às plataformas aéreas tradicionais.

Por meio do uso dos VANT's é possível adquirir dados georreferenciados das culturas, a depender do tipo de sensor utilizado; além de explorar as diferentes partes do espectro eletromagnético utilizando o processamento digital das imagens (PÁDUA *et al.*, 2020). Segundo este mesmo autor, as imagens georreferenciadas podem ser utilizadas para calcular resultados ortorretificados por meio do processamento fotogramétrico, como: mosaico de ortofotos, modelos digitais de elevação (DEM), índices espectrais, dentre outros, tendo como subprodutos, a

identificação e quantificação de árvores.

O sucesso na identificação e quantificação do conjunto de árvores frutíferas depende da resolução espacial da imagem; da dominância da árvore dentro do pomar quanto à sobreposição; união de copas; separação de galhos e geometria do alvo; topografia do terreno e; principalmente, do tipo de sensor utilizado no processo de aquisição das imagens (OJEDA-MAGAÑA *et al.*, 2020). Todos esses fatores podem atuar como facilitadores ou dificultar a contagem de árvores.

De acordo com Arantes *et al.* (2020), para identificação da vegetação e validação dos resultados, não há uma única metodologia específica, mas sim, diversos estudos utilizando o sensoriamento remoto. Neste sentido, dispõe-se de diferentes metodologias para identificar árvores e seus elementos, ou mesmo parâmetros métricos (diâmetro da copa, altura da planta, etc.). Contudo a análise comparativa torna-se difícil devido à necessidade dos dados de referência e da métrica de avaliação (YANAN LI *et al.*, 2016). Isso ocorre, porque alguns métodos são baseados em classes espectrais, redes neurais de detecção, aprendizagem profunda e algoritmos para técnicas de análise de dados 'auto-organizados'. Em contrapartida, os resultados da detecção das árvores também podem ser validados, simplesmente, comparando-os com resultados manuais, conforme Wagner *et al.* (2018) e Weinstein *et al.* (2019). No entanto, essas metodologias não são acessíveis para a maioria dos usuários, principalmente, pela exigência de conhecimento científico e máquinas com maior capacidade de execução.

Torna-se relevante investigar o potencial de ferramentas e tecnologias para obtenção de produtos digitais a partir de imagens coletadas por VANT's, para uso na gestão de áreas agrícolas, de forma acessível e em tempo compatível para o processamento e a disponibilização do produto aos tomadores de decisão dentro da propriedade. Nesse sentido, esta pesquisa objetivou avaliar metodologias de processamento de imagens aéreas obtidas com drones para detecção remota de árvores, em pomares irrigados no Submédio do Vale São Francisco, a partir de softwares e plugins acessíveis.

5.2 MATERIAL E MÉTODOS

5.2.1 Área de estudo

O estudo foi desenvolvido em pomares irrigados localizados no Campo Experimental de Mandacaru (09°24'S 40°26'W), pertencente à Embrapa Semiárido, no município de Juazeiro-BA (Figura 7). O clima da região é tropical, quente e seco, com temperatura média anual de 26,2 °C (EMBRAPA, 2015).

Foram selecionados sete pomares experimentais, sendo seis cultivados com mangueira e um com citrus. Tais lotes foram escolhidos por apresentar diferentes estágios de desenvolvimento, diferentes espaçamentos e extensões das áreas de cultivo (Tabela 2).

Figura 7. Localização dos pomares (lotes) experimentais de mangueira e citrus utilizados para detecção semiautomática de árvores no município de Juazeiro, Bahia.

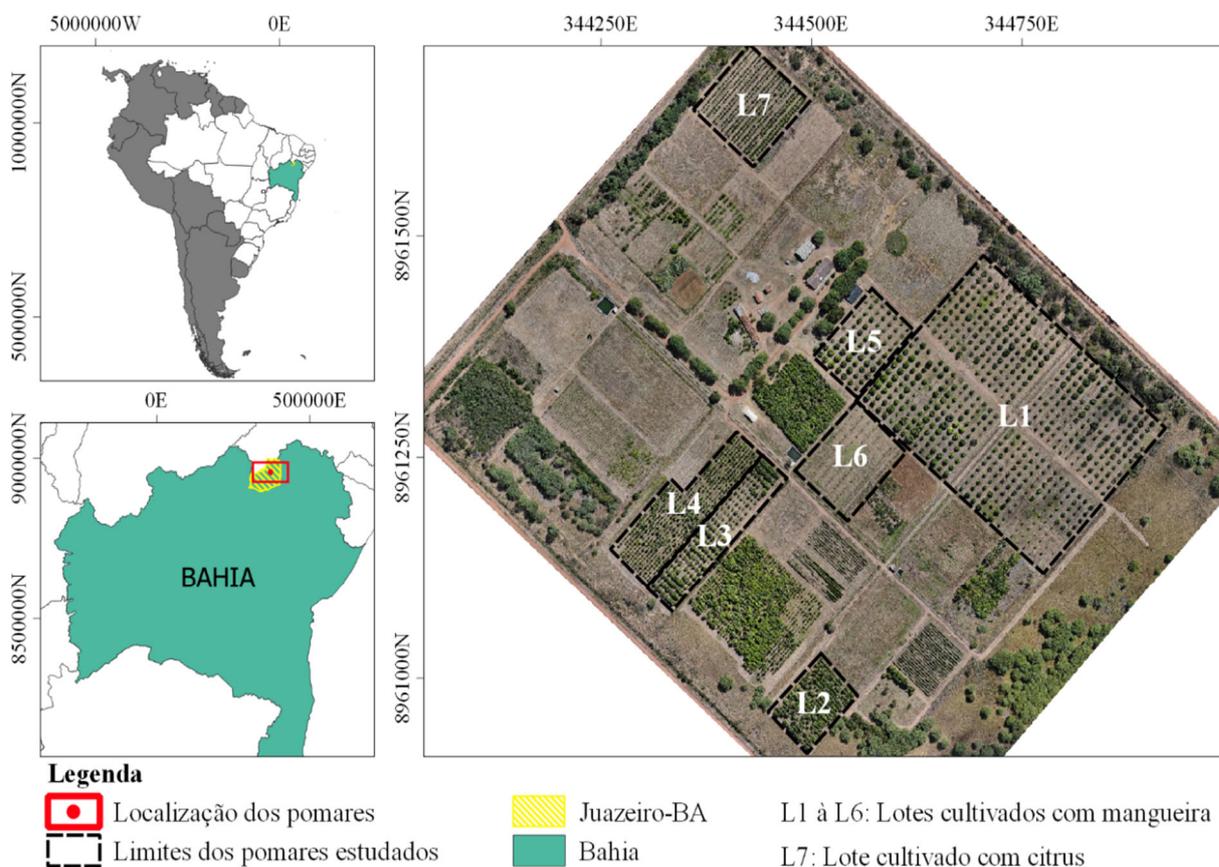


Tabela 2. Informações dos pomares experimentais de mangueira e citrus, Juazeiro, Bahia.

Cultivo	Lote	Instalação pomar	Espaçamento (m)	Área (ha)	Coordenadas (UTM / 24L)	
					Longitude (m)	Latitude (m)
Mangueira	L1	06/1994	10 x 10	5,880	344739.9 E	8961294.6 S
	L2	02/2002	4 x 4	0,480	344503.3 E	8960973.2 S
	L3	05/2009	8 x 5	0,652	344377.9 E	8961154.8 S
	L4	03/2012	4 x 4	0,981	344344.6 E	8961197.7 S
	L5	05/2007	8 x 10	0,560	344558.7 E	8961377.0 S
	L6	05/2007	10 x 10	0,800	344542.1 E	8961245.6 S
Citrus	L7	06/2013	6 x 4x4	0,730	344422.5 E	8961649.1 S

Fonte: Autor (2022).

5.2.2 Aquisição e processamento de imagens aéreas

5.2.2.1 Equipamentos de imageamento e processamento

O imageamento ocorreu em 18 de junho de 2021, às 09:49h tempo local, utilizando o drone comercial DJI Mavic 2 Enterprise Dual, embarcado com câmera modelo FC2103_4.5_4056x3040, sensor CMOS 1/2.3" de 12 Mp, FOV: 85°, 24 mm (formato equivalente a 35 mm), abertura de f/2; e câmera termográfica com sensor Microbolômetro VOx sem ventilação, HFOV: 57° e abertura de f/1.1, para captura de imagens nas bandas do vermelho, verde e azul (RGB) e termal (TIR).

A aeronave utilizada possui registro segundo as normas brasileiras, assim como, o plano de voo foi realizado obedecendo a legislação, com voo realizado a 120 m altura, adotando sobreposição lateral e frontal de 70% para garantir o fechamento do ortomosaico e câmera posicionada com ângulo de 90° em relação ao drone, ou seja, diretamente apontado ao solo e configuração em modo manual de acordo com a iluminação da cena.

Para o processamento das imagens e desenvolvimento das demais etapas deste trabalho foi utilizado um computador com processador Intel Core i5-8265U 1.6GHz com 4 núcleos de processamento e 8 Threads; unidades de armazenamento do tipo SSD com 120Gb e HD com 1Tb; placa gráfica NVIDIA modelo GeForce MX110 com 2 Gb; e memória RAM de 8 Gb. Apesar de ser extremamente importante a utilização de computadores mais robustos para o processamento das imagens, os resultados deste experimento foram apresentados de forma que a análise da

eficiência das metodologias propostas seja válida para aplicações em equipamentos com configurações básicas, mas também, podendo apresentar melhor desempenho em computadores com características mais avançadas. Ressalta-se que o tempo de processamento é diretamente proporcional a capacidade de desempenho da máquina.

5.2.2.2 Geração dos produtos digitais

Foi utilizado o software Agisoft Metashape® versão 1.5.2 (AGISOFT, 2021a) para o processamento das imagens e geração dos produtos digitais. Utilizou-se a versão disponibilizada para testes por novos usuários durante o período de 30 dias. O pós-processamento foi realizado utilizando o software QGIS versão 3.10.8 'A Coruña'. O software *SAGA System for Automated Geoscientific Analyses* versão 2.3.2 (CONRAD *et al.*, 2015) e o plugin *Tree Density Calculator* versão 1.5.7 (CRABBÉ *et al.*, 2020) foram utilizados para o processo de detecção semiautomática de árvores. Para os parâmetros *Standard Deviation* e *Search Radius* do software SAGA, foram adotados os valores 1 e 20, respectivamente. Já no parâmetro *Sliding Window* do *Tree Density* foi utilizado o valor 1.

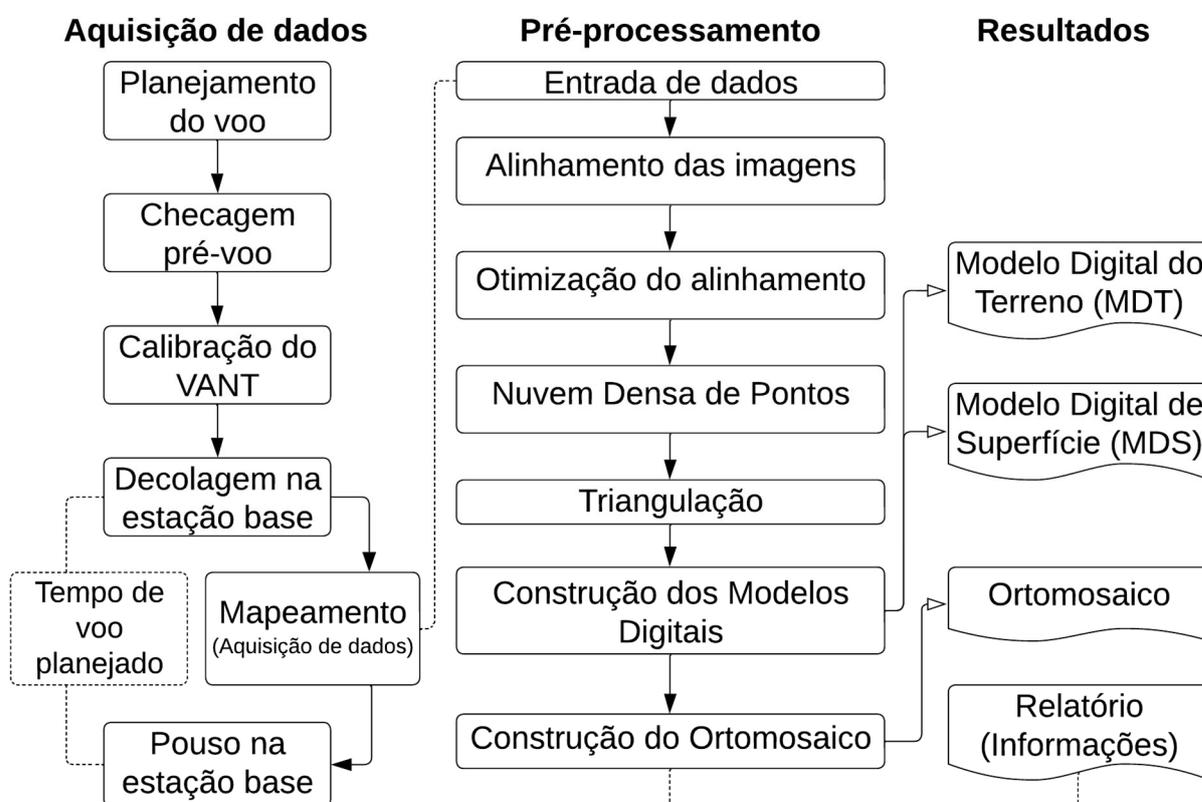
Nesse trabalho foi utilizada a definição de Felgueiras e Erthal (1988) para o modelo digital do terreno (MDT), que considera a modelagem de qualquer variável associada a um ponto específico superfície terrestre, com coordenadas conhecidas; e para o modelo digital de superfície (MDS), que considera a modelagem da altitude do relevo, com vegetação e infraestrutura, ou seja, o relevo e tudo que está acima dele (OLIVEIRA e TOMMASELLI, 2014). Deste modo, para gerar o MDS foram considerados todos os pontos classificados, considerando também os pontos acima da superfície do terreno, enquanto no MDT, foram excluídos os pontos que correspondiam a feições acima da superfície como vegetação e construções.

No software Agisoft Metashape, foram gerados o MDT, MDS e o ortomosaico a partir do processamento das imagens coletadas pelo VANT. Na etapa de alinhamento, as configurações da qualidade de processamento adotadas dizem respeito à alocação dessas imagens, no qual o software usa mais ou menos pontos de referência para fazer o alinhamento das fotografias, de acordo com a opção desejada. De acordo com seu manual (AGISOFT, 2021b), no processamento em qualidade elevada o software trabalha com as fotos no tamanho original; na

configuração média, o software faz com que a imagem seja reduzida por um fator de 4; e em baixa os arquivos de origem são reduzidos por um fator de 16. Deste modo, foi realizado o processamento das imagens em três qualidades de processamento baixa, média e elevada, a fim de investigar a relação entre a qualidade final dos produtos digitais e o tempo de processamento.

As etapas que envolvem a obtenção das imagens, o pré-processamento e os produtos obtidos estão apresentados na Figura 8.

Figura 8. Etapas de aquisição de imagens, pré-processamento e produtos digitais obtidos a partir de VANT em pomares de frutíferas no Vale do São Francisco.



Fonte: Autor (2022).

Para geração dos produtos digitais foi realizada a classificação automática da nuvem densa de pontos, utilizando os valores 15°; 0,10 e 50 m para os parâmetros 'ângulo', 'distância máxima' e 'tamanho da célula', respectivamente. Segundo o manual do usuário do software (AGISOFT, 2021b), o parâmetro 'ângulo' está relacionado ao ângulo entre um ponto no terreno ao ponto a ser classificado, se o ângulo for menor que 6° ele classifica como terreno e se for maior não classifica. O parâmetro 'distância máxima' define a limitação para a distância entre dois pontos,

quando menor que 1 m o software classifica como terreno e se for maior não classifica. Já o 'tamanho da célula' está relacionado ao maior objeto que não faz parte do terreno, pode ser o dossel de uma vegetação, construções, veículos, entre outros.

Para localizar pontos com alto erro de reprojeção dentro da nuvem densa e assim remover aqueles que representam grande quantidade de ruído, foi utilizada a ferramenta *Gradual Selection* do Agisoft Metashape. Essa ferramenta é capaz de realizar a limpeza da nuvem densa de pontos, filtrando a partir de critérios previamente determinados.

Alto erro de reprojeção, geralmente, indica baixa precisão de localização das projeções de pontos correspondentes, e a remoção desses pontos pode melhorar a precisão da etapa de otimização subsequente, para isso utilizou-se o critério *Reprojection error* dentro da ferramenta. Já com o critério *Reconstruction uncertainty* é possível remover pontos que reconstruídos a partir de fotos próximas com uma linha de base pequena, podem desviar-se visivelmente da superfície do objeto, formando uma espécie de ruído.

Outros dois critérios disponibilizados na ferramenta *Gradual Selection* do Agisoft Metashape e úteis para limpeza da nuvem densa, são *Image count* e *Projection Accuracy*. Durante o processamento o Agisoft reconstrói todos os pontos que são visíveis em pelo menos duas fotos, no entanto, os pontos visíveis apenas em duas fotos, provavelmente, serão localizados com baixa precisão, logo a filtragem utilizando o critério *Image count* permite remover esses pontos não confiáveis da nuvem. Por último, com o *Projection Accuracy* é possível filtrar pontos cujas projeções foram relativamente menos localizadas devido ao seu maior tamanho.

Em seguida, a partir do MDS e do MDT obteve-se o Modelo Digital de Altura (MDH). O MDH, conforme apresentado por Zamarrón *et al.* (2008), é obtido a partir da diferença entre MDS e MDT, para o qual foi utilizado o *software* QGIS. Primeiramente, foi criado um '*shape*' (arquivo) com os limites da área a ser estudada, e por meio da ferramenta '*Raster*' foi realizado o recorte com base na 'camada de máscara' (arquivos com os limites da área), obtendo-se como produto os mesmos modelos digitais, porém agora recortados para a área de estudo. Por outro lado, a geração do MDH foi realizada também pela ferramenta '*Raster*', todavia, neste caso, utilizou-se a '*Calculadora Raster*', utilizando-se os arquivos MDS e MDT (recortados) e a equação $MDH = MDS - MDT$. Posteriormente, procedeu-se ao recorte do Ortomosaico,

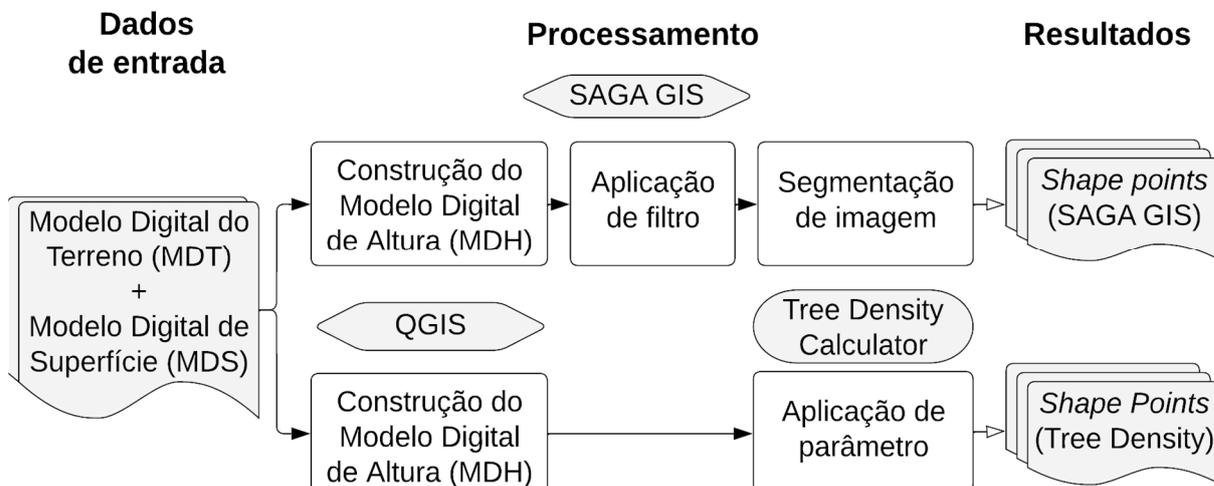
necessário para a contagem manual das árvores. Essa contagem foi essencial para validar os resultados, e é uma exigência para o processo de contagem automatizada.

Após obter todos os produtos digitais (modelos digitais e ortomosaico), foram gerados relatórios, emitidos pelo próprio *software*, com informações sobre erro de projeção, tempo de processamento, valores de *Ground Sample Distance* (GSD), entre outras informações, as quais necessárias para comparação dos resultados obtidos.

5.2.2.3 Contagem de plantas

Após obtenção dos produtos digitais, foi realizado o processamento para identificação das árvores utilizando o Software SAGA GIS (a partir do MDS e MDT) e do plugin *Tree Density Calculator* (a partir do MDH), sendo gerados ao final dois arquivos com os pontos detectados, denominados como *shape points*, um para cada método de detecção (Figura 9). Primeiramente, foram contabilizados o total de pontos gerados por cada método (pontos detectados correta e incorretamente). Todos os pontos foram considerados, para poder calcular a precisão dos métodos. Em seguida, foi realizada a identificação e a demarcação manual de cada árvore presente em todos os pomares, com o propósito de auxiliar na comparação dos resultados obtidos. A partir do cálculo da população de plantas levando em consideração o espaçamento da cultura, foram obtidos o estande teórico e o real, além de verificar a quantidade de árvores faltantes em cada pomar.

Figura 9. Etapas do processamento para geração do *shape point* por meio do *Tree Density Calculator* e Saga GIS.



Fonte: Autor (2022).

5.2.3 Índices de avaliação dos procedimentos de contagem de plantas

O potencial de cada técnica proveniente da qualidade do processamento (baixa, média e elevada) e dos plugins (SAGA e Tree Density) foi avaliado utilizando os índices de Precisão, Revocação e F1-Score (Equações 14, 15 e 16 respectivamente), onde árvores detectadas, pontos incorretos e árvores não detectadas correspondem aos números de verdadeiros positivos (VP), falsos positivos (FP) e falsos negativos (FN), respectivamente, em uma tabela de contingência.

$$Precisão = \frac{VP}{(VP + FP)} \quad (14)$$

$$Revocação = \frac{VP}{(VP + FN)} \quad (15)$$

$$F1 - Score = 2 * \frac{(Precisão * Revocação)}{(Precisão + Revocação)} \quad (16)$$

As diferenças estatísticas entre os valores médios de *Ground Sample Distance* (GSD) do ortomosaico e MDE entre as áreas de estudo e qualidades de processamento foram avaliadas usando ANOVA One-way. Todas as estatísticas foram realizadas usando o programa estatístico RStudio® (RStudio Team, 2020).

5.3 RESULTADOS E DISCUSSÃO

Para a geração do ortomosaico foram utilizadas 311 imagens do visível (Red – 660 nm, Green – 550 nm, Blue – 470 nm), que compuseram uma ortofoto de aproximadamente 68.000 m². O tempo de processamento e os valores de GSD dos produtos digitais obtidos para cada qualidade de processamento encontram-se na Tabela 3. Apesar de ter-se verificado igualdade entre os valores do GSD do ortomosaico processado nas qualidades média e elevada, houve considerável diferença entre o tempo de processamento das imagens nas respectivas qualidades adotadas. Neste caso, a qualidade de processamento em média se destaca por permitir obter produtos de qualidade superior, similar ao processamento realizado em qualidade alta, em tempo de processamento inferior. Destaca-se ainda que o GSD do

ortomosaico gerado com as diferentes qualidades de processamento foi muito similar, o que já se esperava em função dos mesmos parâmetros de câmera e de altura de voo. Por sua vez, o GSD produzido para o MDS praticamente teve incrementos de 100% entre uma qualidade de processamento e outra, passando de 8,12 cm/pixel na qualidade elevada para 16,3 cm/pixel na qualidade média, e para 32,9 cm/pixel na qualidade baixa. Essas diferenças são muito importantes, e podem refletir na capacidade de identificação das árvores.

Tabela 3. Parâmetros do processamento digital de imagens aéreas obtidas por VANT sobre pomares de frutíferas no Vale do São Francisco.

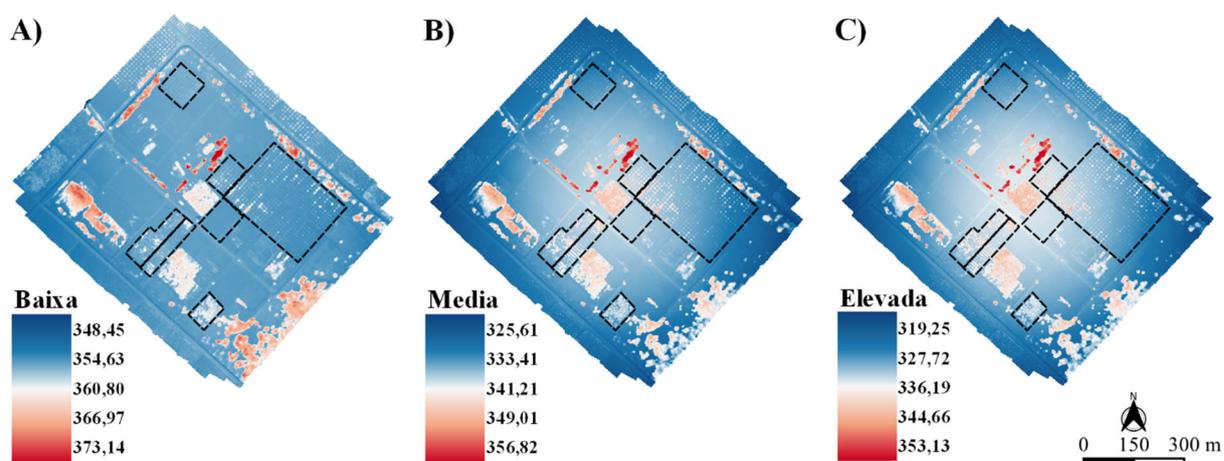
Qualidade do Processamento	Tempo de Processamento	GSD do MDS (cm/pixel)	GSD do Ortomosaico (cm/pixel)
Baixa	0h 27min 54s	32,9	4,11
Média	1h 25min 15s	16,3	4,06
Elevada	4h 25min 47s	8,12	4,06

Fonte: Autor (2022).

Segundo Figueira e Oliveira (2013), a alta resolução das imagens obtidas a partir de aeronaves remotamente pilotada deve-se a aproximação do sensor (câmera) ao objeto (terreno). Deste modo, a altura de realização do voo do VANT contribui para geração de produtos com alto grau de detalhamento e boa qualidade, mas, por outro lado, as imagens e modelos são mais pesados que os convencionais, o que implica em maior tempo de processamento e computadores mais robustos (CÂNDIDO, 2016). Segundo a mesma autora, dependendo do tamanho da área, em muitos casos há necessidade de máquinas com configurações especiais para trabalhar com produtos oriundos de VANT, por esse motivo recomenda-se aplicá-los em pequenas áreas.

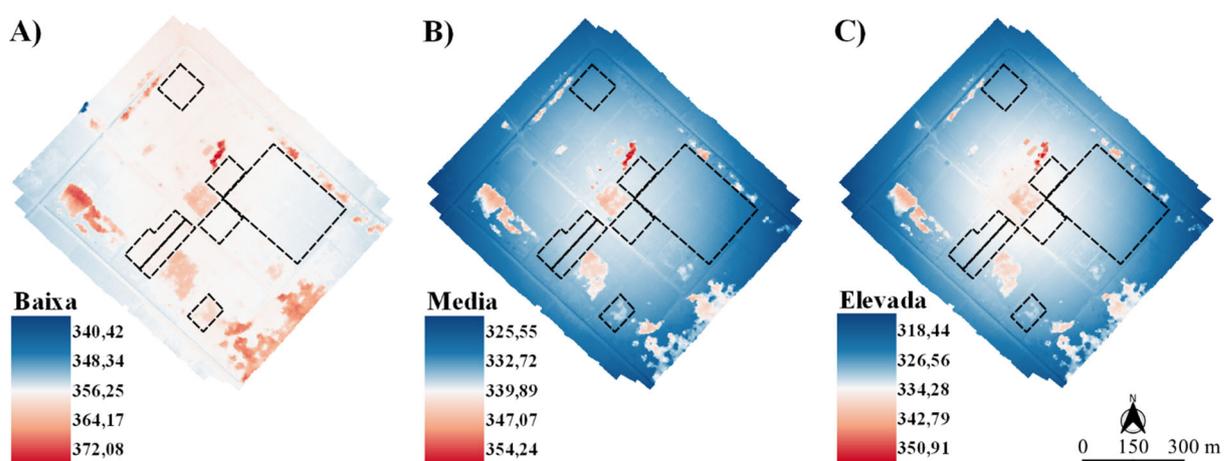
A aquisição das ortofotos com recobrimento lateral e frontal entre fotos de 70% possibilitou, para cada qualidade de processamento, a aquisição de nuvens densa de pontos com milhares de pontos, com coordenadas tridimensionais e alta densidade de pontos por metro quadrado. Essas nuvens geoprocessadas resultaram em modelos digitais de superfície (MDS) e do terreno (MDT) da área, representados nas Figuras 10 e 11 pelos mapas hipsométricos correspondentes.

Figura 10. Modelos digitais de superfície obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C).



Fonte: Autor (2022).

Figura 11. Modelos digitais do terreno obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C).

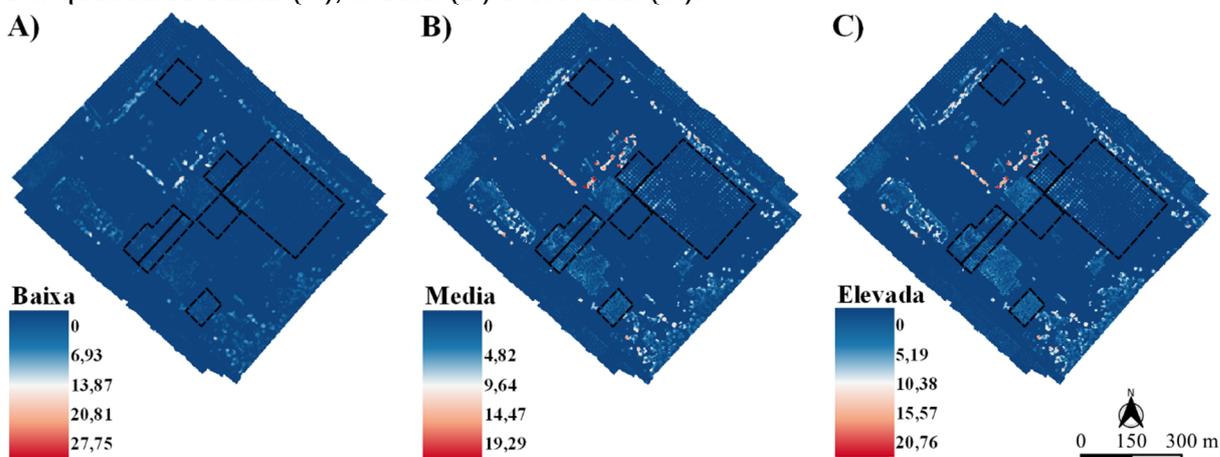


Fonte: Autor (2022).

Nos mapas, os maiores valores de elevação foram representados pela cor vermelha, enquanto os menores valores foram representados pela cor azul. As regiões indicadas pela cor vermelha mais intensa, são compostas em sua maioria por espécies arbóreas de grande porte, que não correspondem aos pomares avaliados. Também há construções como galpões e salas de escritório. Por outro lado, o restante das áreas indicada pela cor azul corresponde as regiões planas, de baixa altitude, ou seja, o solo.

A partir da diferença entre o MDS e o MDT das Figuras 10 e 11, foi possível gerar o modelo digital de altura (MDH) da área, conforme apresentado na Figura 12.

Figura 12. Modelos digitais de altura obtidos a partir do processamento de imagens em qualidade baixa (A), média (B) e elevada (C).



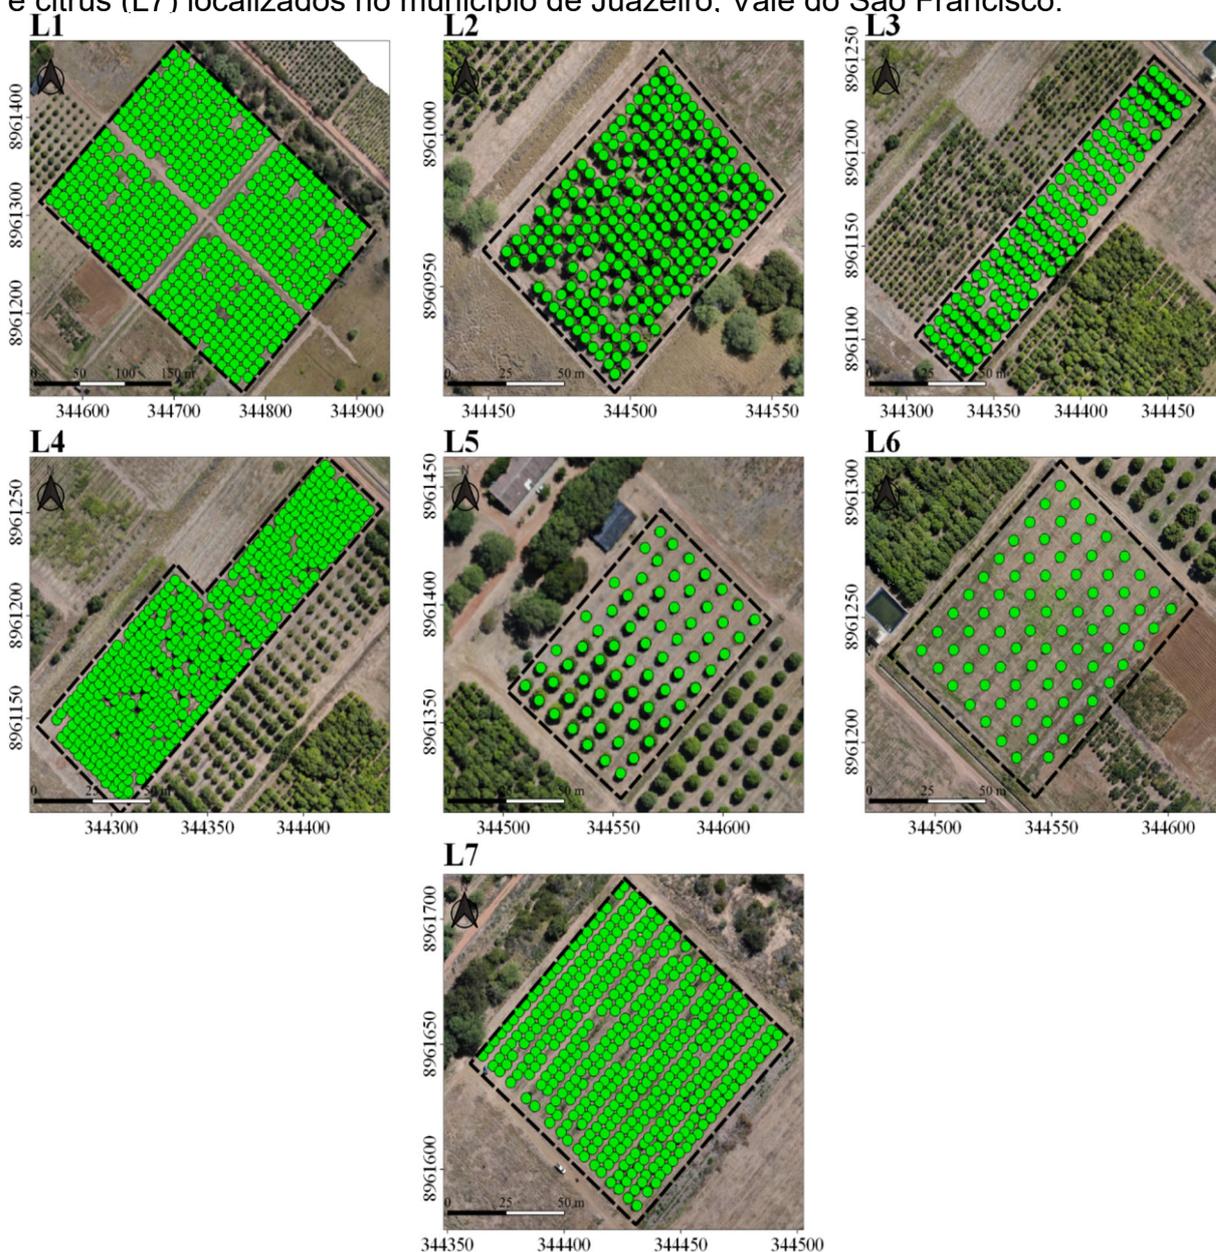
Fonte: Autor (2022).

Após a geração dos modelos digitais e ortomosaico para cada qualidade de processamento, foi realizada identificação e a demarcação manual de cada árvore de cada lote para a avaliação dos resultados da detecção semiautomática obtidos pelas metodologias, conforme Wagner *et al.* (2018) e Weinstein *et al.* (2019).

A demarcação manual das plantas foi realizada no software QGIS utilizando como produto digital o ortomosaico. Nesse processo são adicionados pontos, um a um, sobre cada árvore identificada visualmente.

Na Figura 13, são apresentados os resultados da identificação manual das árvores. Verificou-se que no Lote 1, de mangueira com espaçamento de 10 x 10 m, existem 554 plantas, quando o estande normal deveria apresentar 588 plantas, ou seja, há uma diferença de 34 plantas, que pode ser perceptível na Figura 13 (L1). De forma similar, foi realizado o cálculo da população real e teórica de plantas, conforme apresentado na tabela 4.

Figura 13. Árvores demarcadas por inspeção visual nos lotes de mangueira (L1 à L6) e citrus (L7) localizados no município de Juazeiro, Vale do São Francisco.



Fonte: Autor (2022).

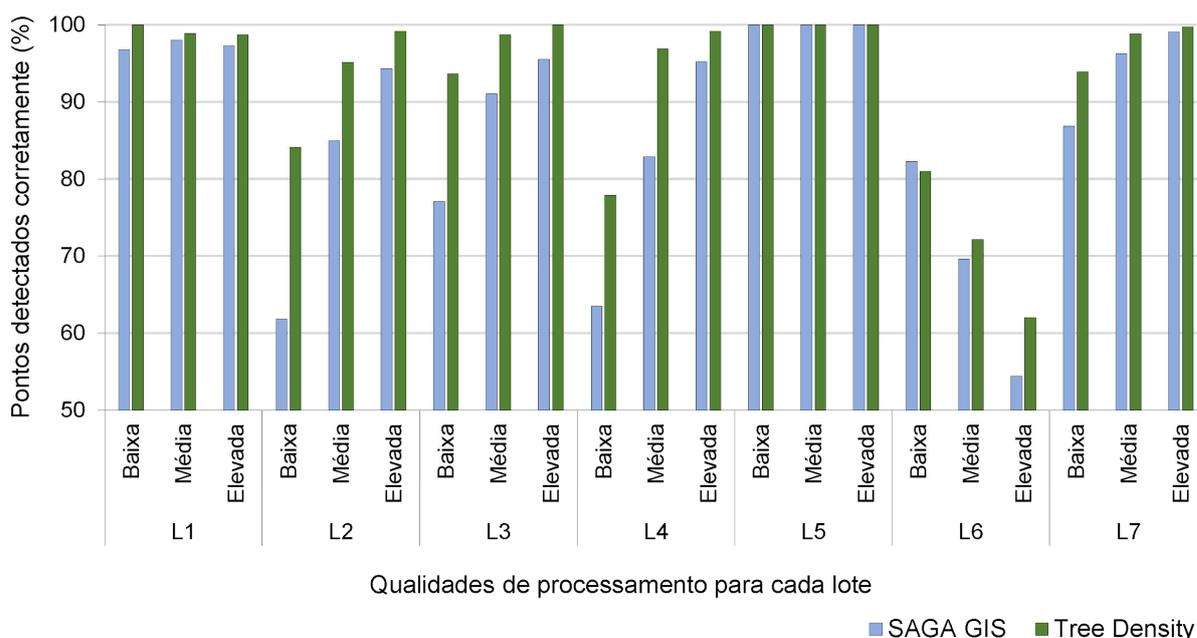
Tabela 4. Resultado do estande teórico e número real de plantas para cada pomar

Cultivo	Lote	Espaçamento (m)	Área (ha)	Estande teórico	Estande real	Diferença
Mangueira	L1	10 x 10	5,880	588	554	34
	L2	4 x 4	0,480	300	246	54
	L3	8 x 5	0,652	163	157	6
	L4	4 x 4	0,981	613	479	134
	L5	8 x 10	0,560	70	67	3
	L6	10 x 10	0,800	80	79	1
Citrus	L7	6 x 4 x 4	0,730	456	426	30

Fonte: Autor (2022).

Após realizar um censo com o levantamento de dados de campo para obter o número exato de árvores, foi realizada a detecção semiautomática utilizando o software SAGA GIS e o plugin *Tree Density* para cada qualidade de processamento, a partir do MDH. Observa-se que na maioria das análises, o plugin *Tree Density* apresentou maior percentual de pontos detectados corretamente comparado ao plugin SAGA GIS (Figura 14). Esse percentual de pontos corresponde ao número de pontos que foram alocados sobre as árvores de forma correta, ou seja, sem repetições em uma única árvore, excluindo-se também os pontos detectados no ambiente. Embora esse resultado demonstre maior destaque para o plugin *Tree Density*, torna-se necessário avaliar também o percentual de pontos detectados incorretamente.

Figura 14. Percentuais de pontos detectados corretamente para as áreas de manga (L1 à L6) e citrus (L7) para diferentes qualidades de processamento utilizando o SAGA GIS e o *Tree Density Calculator*.



Fonte: Autor (2022).

Observa-se no lote L5 que o desempenho dos plugins foi máximo, inclusive para as três qualidades de processamento. O desempenho para detecção semiautomática de árvores pelas metodologias utilizadas está diretamente relacionado a reconstrução tridimensional dos alvos, e na área L5, possivelmente, a interação entre os fatores espaçamento e altura das árvores, podem ter influenciado positivamente na reconstrução e, conseqüentemente, nos resultados. Em outras palavras, em função da altura de voo ter sido realizada a 80 m, era esperado a melhor reconstrução tridimensional nas regiões com maior espaçamento entre plantas e

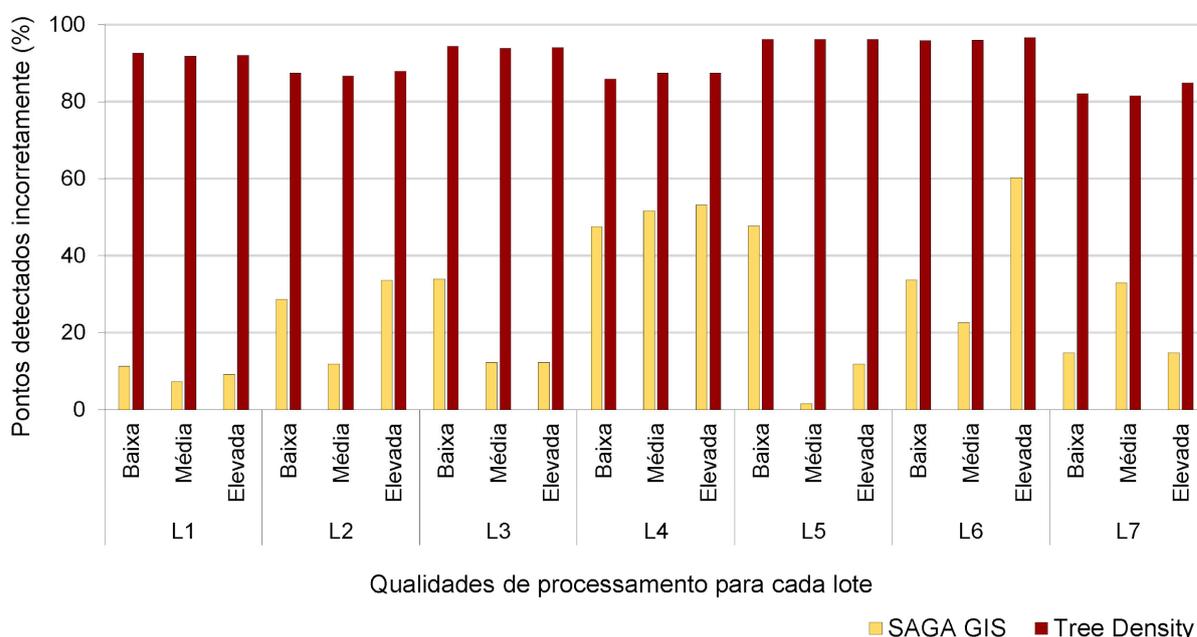
árvores com maior porte. O desempenho satisfatório dos plugins também foi observado no lote L1, o qual também apresentava a configuração de maior espaçamento entre plantas.

Os menores percentuais de pontos detectados corretamente foram observados nos lotes L2 e L4 para o processamento em qualidade baixa e no lote L6 para o processamento em qualidade elevada. Ao contrário dos lotes L1 e L5 citados anteriormente, os lotes L2 e L4 detinham os menores valores de espaçamento de plantas (4 x 4 m), conseqüentemente, nessas duas áreas também foi observado que a reconstrução tridimensional durante o processamento não foi satisfatória. Já o lote L6 apesar de ser caracterizado com um espaçamento maior, nesse caso 10 x 10 m, também não apresentou desempenho satisfatório e, possivelmente, esse fator está ligado ao porte reduzido das plantas. Ao considerar a altura de voo realizado pelo drone durante a captura das imagens, o porte reduzido das árvores nesse lote pode ter prejudicado a reconstrução tridimensional e, conseqüentemente, os resultados da detecção pelos plugins.

Ao comparar o desempenho das metodologias a partir das qualidades de processamento, observa-se que há uma diferença expressiva entre o percentual de árvores detectadas para o processamento em qualidade baixa e elevada, exceto para os lotes L1 e L5, dos quais este último não houve diferença entre os tratamentos, ressaltando a importância dos fatores espaçamento e altura de plantas, únicos fatores que os diferem dos demais lotes.

Na figura 15, é apresentada a relação do percentual de pontos detectados incorretamente para cada qualidade de processamento, onde se verifica que o plugin *Tree Density* apresentou maior percentual de pontos detectados incorretamente. Conforme esperado o comportamento observado do *Tree Density* não foi satisfatório, comprovando que para detectar mais árvores (conforme observado na figura 14) o mesmo plugin teve maior número de chances. Deste modo, espera-se que mais pontos lançados na cena pelo plugin, sejam capazes de identificar mais árvores, contudo, para tal, torna-se necessário maior tempo de processamento e maior desempenho da máquina utilizada. Neste caso, comprova-se desempenho satisfatório para o plugin SAGA GIS, que embora tenha detectado um menor percentual de árvores, este necessitou de menos tempo de processamento e menor tempo para eliminação dos pontos incorretos, tratamento aplicado aos produtos digitais após a detecção semiautomática.

Figura 15. Percentuais de pontos detectados incorretamente para as áreas de manga (L1 à L6) e citrus (L7) para diferentes qualidades de processamento utilizando o SAGA GIS e o *Tree Density Calculator*.



Fonte: Autor (2022).

Na Tabela 5, são apresentados os valores para os índices de precisão, revocação e F1-Score considerando os tratamentos analisados. Os índices de Precisão e Revocação foram mais elevados para o processamento em qualidade média, na maioria dos lotes e tratamentos avaliados, indicando que quanto maior a qualidade do processamento, maior e a chance de acertar na contagem de árvores, uma vez que, os modelos digitais obtidos apresentam maior densidade de pontos. Analisando as metodologias adotadas para detecção de árvores, o tratamento que possibilitou maior precisão para detecção de árvores foi obtido com o software SAGA GIS com processamento em qualidade média das imagens do lote L5, com precisão de 98,5%.

Tabela 5. Índices de precisão, revocação e F1-Score para avaliação de plugin e qualidade de processamento de imagens de VANT's obtidas em pomares de frutíferas no Vale do São Francisco.

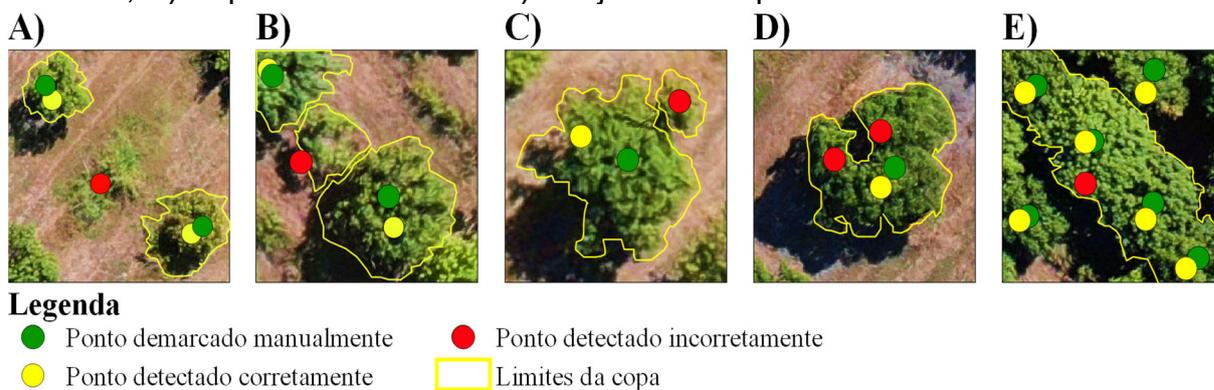
Lote	Plugin	Qualidade	Precisão	Revocação	F1-Score
L1	SAGA GIS	Baixa	0,887	0,968	0,926
		Média	0,928	0,980	0,953
		Elevada	0,909	0,973	0,940
	Tree Density	Baixa	0,074	1,000	0,138
		Média	0,083	0,989	0,152
		Elevada	0,080	0,987	0,148

L2	SAGA GIS	Baixa	0,714	0,618	0,662
		Média	0,882	0,850	0,865
		Elevada	0,665	0,943	0,780
	Tree Density	Baixa	0,125	0,841	0,218
		Média	0,133	0,951	0,234
		Elevada	0,121	0,992	0,215
L3	SAGA GIS	Baixa	0,661	0,771	0,712
		Média	0,877	0,911	0,894
		Elevada	0,877	0,955	0,915
	Tree Density	Baixa	0,057	0,936	0,107
		Média	0,062	0,987	0,117
		Elevada	0,059	1,000	0,111
L4	SAGA GIS	Baixa	0,526	0,635	0,575
		Média	0,484	0,829	0,611
		Elevada	0,469	0,952	0,629
	Tree Density	Baixa	0,141	0,779	0,239
		Média	0,125	0,969	0,222
		Elevada	0,126	0,992	0,224
L5	SAGA GIS	Baixa	0,523	1,000	0,687
		Média	0,985	1,000	0,993
		Elevada	0,882	1,000	0,937
	Tree Density	Baixa	0,038	1,000	0,073
		Média	0,038	1,000	0,074
		Elevada	0,038	1,000	0,073
L6	SAGA GIS	Baixa	0,663	0,823	0,734
		Média	0,775	0,696	0,733
		Elevada	0,398	0,544	0,460
	Tree Density	Baixa	0,041	0,810	0,079
		Média	0,041	0,722	0,077
		Elevada	0,034	0,620	0,064
L7	SAGA GIS	Baixa	0,853	0,869	0,860
		Média	0,671	0,962	0,791
		Elevada	0,853	0,991	0,916
	Tree Density	Baixa	0,180	0,939	0,302
		Média	0,185	0,988	0,311
		Elevada	0,152	0,998	0,263

Fonte: Autor (2022).

Na Figura 16, são apresentados alguns fatores que interferem na detecção semiautomática de árvores. Observa-se que o erro no processo de detecção ocorre pela demarcação incorreta de pontos em função da reconstrução tridimensional, por isso que automatizar o processo de análise de imagens digitais é bastante complexo, tendo em vista os parâmetros morfométricos das árvores e as condições naturais.

Figura 16. Fatores que interferem na detecção individual de árvores: A) Presença de outras plantas na mesma área; B) Árvores muito desuniformes; C) Árvore com copas isoladas; D) Copa com abertura e E) Conjunto de copas/árvores.



Fonte: Autor (2022).

Partindo do princípio da estereoscopia conforme explicado por Silva Júnior (2019), foi observada a importância da reconstrução tridimensional das árvores para o melhor desempenho dos métodos de detecção utilizados. Deste modo, entende-se que o aumento dos valores de sobreposição aliado a redução da altitude de voo, pode promover mais pontos de referência e; conseqüentemente, com a elevação da qualidade de processamento e da densidade de pontos gerados, melhor será a reconstrução tridimensional da copa da planta e maior a diferença entre o MDS e MDT, favorecendo o processo de detecção das árvores pelos métodos utilizados.

5.4 CONCLUSÕES

Entre as qualidades de processamento das imagens, o processamento em qualidade média obteve o melhor desempenho, com resultados equivalentes aos obtidos em qualidade elevada e em menor tempo, o que permite a entrega de produtos de imageamento aéreo com VANT's com maior rapidez aos usuários e tomadores de decisão dentro da propriedade agrícola.

As ferramentas avaliadas que permitem a detecção semiautomática das árvores ainda necessitam da interferência, ou da ação, de um operador para realizar o processamento em suas diversas etapas. A depender das características do voo e das áreas imageadas, por exemplo, pomares com menor densidade e com árvores mais altas podem ter o processamento facilitado e a obtenção de resultados com maior rapidez, por necessitar de menor ação do operador. Entretanto, os *plugins* avaliados também apresentaram bom desempenho para detecção de árvores em

lotes de maior densidade de plantas e com menor tamanho, comprovando seu potencial para aplicação em áreas com diferentes dimensões. O melhor desempenho para a detecção semiautomática de árvores foi obtido pelo SAGA GIS, com 98,5% de precisão, sendo este mais recomendado para aplicações semiautomáticas e de fácil acesso em pomares de frutíferas.

5.5 REFERÊNCIAS

ABIDIN, H. *et al.* Evaluation of eCognition software for oil palm tree counting under different planting conditions and ages. **International Conference on Big Data Applications in Agriculture**, 2017.

AGISOFT. **Agisoft Metashape. v. 1.5.2.** Petersburg, 2021. Disponível em: <https://www.agisoft.com>. Acesso em: 25 nov. 2021a.

AGISOFT. **Agisoft Metashape User Manual.** Professional Edition, v.1.5. Disponível em: https://www.agisoft.com/pdf/metashape-pro_1_5_en.pdf. Acesso em: 25 nov. 2021b.

ARANTES, B. H. T. *et al.* Análise de eficiência do uso de algoritmo de correspondência de modelo para contagem de plantas. **Research, Society and Development**, v. 9, n. 7, p. e668974576-e668974576, 2020.

BARNES, C. *et al.* Individual tree crown delineation from airborne laser scanning for diseased larch forest stands. **Remote Sensing**, v. 9, n. 3, p. 231, 2017.

CÂNDIDO, A. K. A. A. **Aplicações ambientais de veículo aéreo não tripulado.** 2016 96 f. Tese (Doutorado) – Programa de Pós-Graduação em Tecnologias Ambientais, Universidade Federal do Mato Grosso do Sul.

CONRAD, O. *et al.* System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. **Geoscientific Model Development**, v. 8, n. 7, p. 1991-2007, 2015.

CRABBÉ, A. H. *et al.* **Tree Density Calculator Software**, v. 1.5.3. 2020. Disponível em: <https://bitbucket.org/kul-reseco/localmaxfilter>. Acesso em: 25 nov. 2021.

EMBRAPA. Centro de Pesquisa Agropecuária do Trópico Semiárido. **Médias anuais da estação agrometeorológica de Mandacaru (Juazeiro-BA 09°24'S, 40°26'W): período 1975 - 2014.** Petrolina, 2015. Disponível em: <http://www.cpatsa.embrapa.br:8080/servicos/dadosmet/cem-anual.html>. Acesso em: 25 nov. 2021.

FELGUEIRAS, C. A.; ERTHAL, G. J. Aplicações de modelos numéricos de elevação e integração com imagens digitais. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 5, p. 485-490, 1988.

FIGUEIRA, N. M.; OLIVEIRA, L. C. DE. Super resolução: técnicas existentes e possibilidade de emprego às imagens do VANT VT-15. **Revista Militar de Ciência e Tecnologia**, v. 30, p. 3-19, 2013.

HERNÁNDEZ-HERNÁNDEZ, J. L. *et al.* Optimal color space selection method for plant/soil segmentation in agriculture. **Computers and Electronics in Agriculture**, v. 122, p. 124-132, 2016.

MASCHLER, J.; ATZBERGER, C.; IMMITZER, M. Individual tree crown segmentation and classification of 13 tree species using aerial hyperspectral data. **Remote Sensing**, v.10, n.8, p.1218, 2018.

OJEDA-MAGAÑA, B. *et al.* Automatic identification of the area covered by acorn trees in the dehesa (pastureland) Extremadura of Spain. **Computers and electronics in agriculture**, v. 172, p. 105289, 2020.

OLIVEIRA, R. A. DE; TOMMASELLI, A. M. G. Avaliação de uma técnica para geração de modelos digitais de superfície utilizando múltiplas imagens. **Boletim de Ciências Geodésicas**, v. 20, p. 257-278, 2014.

PÁDUA, L. *et al.* Individual grapevine analysis in a multi-temporal context using UAV-based multi-sensor imagery. **Remote Sensing**, v. 12, n. 1, p. 139, 2020.

PASSOS, F. G.; FONTES, C. H. O.; NASCIMENTO, A. N. Avaliação da eficiência de uma empresa exportadora de manga do Vale do São Francisco: um modelo em análise envoltória de dados. **Revista Agronegócios online**, v. 16, p. 105-141, 2020.

QGIS Development Team. QGIS Geographic Information System. **Open-Source Geospatial Foundation Project**, 2019. Disponível em: <http://www.qgis.org>. Acesso em: 25 nov. 2021.

RStudio Team. **RStudio: Integrated Development for R**. Boston, 2020. Disponível em: <http://www.rstudio.com>. Acesso em: 05 nov. de 2021.

SILVA JÚNIOR, E. E. de A. **Geotecnologias e planejamento urbano: proposta metodológica e avaliação de dados obtidos por Aeronaves Remotamente Pilotadas (RPA) como contribuição à cartografia geotécnica. 2019.** Tese (Doutorado) – Programa de Pós-Graduação em Geotecnia, Universidade de Brasília.

WAGNER, F. H. *et al.* Individual tree crown delineation in a highly diverse tropical forest using very high-resolution satellite images. **ISPRS journal of photogrammetry and remote sensing**, v. 145, p. 362-377, 2018.

WEIJIA LI *et al.* Deep Learning based oil palm tree detection and counting for high-resolution remote sensing images. **Remote Sensing**, v. 9, n. 1, p. 22, 2016.

WEINSTEIN, B. G. *et al.* Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. **Remote Sensing**, v. 11, n. 11, p. 1309, 2019.

YANAN LI *et al.* In-field cotton detection via region-based semantic image segmentation. **Computers and Electronics in Agriculture**, v. 127, p. 475-486, 2016.

ZAMARRÓN, A. R. *et al.* Proyecto LINHE: “Desarrollo de nuevos protocolos de integración de sensores LiDAR, cámara digital, infrarrojo cercano e hiperspectral”. **Madrid: CONAMA 9**, 2008.

ZHANG, X. Quick Aboveground Carbon Stock Estimation of Densely Planted Shrubs by Using Point Cloud Derived from Unmanned Aerial Vehicle. **Remote Sensing**, v. 11, n. 24, p. 2914, 2019.

6 CAPÍTULO II

ÍNDICES DE VEGETAÇÃO APLICADOS EM IMAGENS OBTIDAS POR DRONES PARA AVALIAÇÃO DE CULTIVO DE CANA-DE-AÇÚCAR

RESUMO

O uso de drones, associado a análises de dados, tem grande potencial para apoiar e resolver alguns dos principais problemas enfrentados na agricultura, como o uso da água. Para isso, importante se faz conhecer o status hídrico da vegetação. Nesse sentido, os drones precisam comportar sensores imageadores leves e que operem em várias faixas espectrais, principalmente, no visível (RGB), infravermelho próximo (NIR) e termal (TIR). Isso tem sido possível com a diversidade de sensores disponíveis e o aumento da capacidade de processamento de dados. Esses avanços tem causado euforia crescente na comunidade científica, particularmente, de sensoriamento remoto, por permitir aplicações agrícolas de precisão. Deste modo, o objetivo desse estudo foi comparar índices espectrais para detecção do estresse hídrico em cana-de-açúcar irrigada, no Submédio do Vale São Francisco, com base em imageamento aéreo com drone e sensores multiespectrais. O estudo foi desenvolvido na Usina Agrovale, no município de Juazeiro, Bahia. Índices de vegetação foram aplicados em imagens obtidas utilizando VANT de modelo comercial, com sensor de captura nas bandas no visível (RGB) e termal (TIR), cujo resultado foi comparado com os produtos obtidos a partir de imagens do sensor do satélite Landsat 8. Também foi adotado a metodologia para estimativa da banda NIR a partir das bandas RGB, para aplicação de índices espectrais em imagens de alta qualidade. O processamento das imagens foi realizado no *software* Agisoft Metashape e QGIS. Os resultados foram analisados a partir da análise da estatística descritiva, percentis e histogramas. Os produtos dos índices GLI, RGBVI, ExG e ExGR foram visualmente equivalentes. O índice RGBVI foi mais sensível na discriminação dos alvos e obteve o melhor desempenho. As metodologias utilizadas para a estimativa do NDVI mostraram ser bastante promissoras.

Palavras-chave: Índice espectral. Sensoriamento remoto. VANT.

6.1 INTRODUÇÃO

Na porção central do Semiárido brasileiro encontra-se o polo de fruticultura irrigada centrado nos municípios de Petrolina – PE e Juazeiro – BA, no Submédio do Vale São Francisco. Esta área se comporta como um oásis com várias culturas irrigadas que ocupam espaços onde originalmente existia vegetação nativa de caatinga. Marcado por grandes variações climáticas, principalmente, pelas irregularidades das chuvas, baixos índices pluviométricos e constantes estiagens; calor extremo, durante a maior parte do ano e; elevada disponibilidade de energia solar; o sucesso da produção agrícola nessa região se deve, dentre outros fatores, ao uso da irrigação.

Os sistemas agrícolas irrigados colocaram o Brasil entre os dez principais países que fazem uso da irrigação, e diversos estudos indicam que ainda existe grande potencial de desenvolvimento desse setor no país. O cultivo da cana-de-açúcar destaca-se no município de Juazeiro-BA, com aproximadamente 17,2 mil ha irrigados durante todo ano, resultando nos maiores índices de produtividade do país (IBGE, 2019). Nessas áreas, informações sobre a magnitude e a variação espaço-temporal da produção se tornam importantes e diretamente relacionadas a receita bruta das propriedades, sendo o seu monitoramento essencial para o planejamento agrícola.

Entre os principais métodos para o monitoramento e estimativa da produtividade da cana-de-açúcar, estão presentes o método tradicional (GEIPEL, LINK e CLAUPEIN, 2014), o método de amostragem destrutivo (OLIVEIRA, 2021), modelos de simulação (LEDA, GOLÇALVES e LIMA, 2019; MISHRA *et al.*, 2021), técnicas de sensoriamento remoto com dados de satélites (PANDEY *et al.*, 2019) e com dados levantados com veículos aéreos não tripulados (VANT's) ou drones (ALEMÁN-MONTES *et al.*, 2021). A estimativa da cana realizada por métodos tradicionais é baseada em dados históricos, registros de produções, inspeção visual e pequenas amostragem de parcelas, o que pode tornar o processo lento, laborioso e impreciso (SANCHES *et al.*, 2018; SOM-ARD *et al.*, 2018).

De acordo com Sumesh, Ninsawat e Som-Ard (2021), imagens de satélite têm sido utilizadas para prever a produtividade da cana-de-açúcar por meio da implementação de diferentes técnicas, com vantagens em relação ao método tradicional devido à possibilidade de monitorar grandes áreas, além da variabilidade

espacial, no entanto as suas principais limitações se devem a baixa resolução espacial, cobertura de nuvens e interferência atmosférica. Mais recentemente, pesquisas com sensoriamento remoto tem utilizado drones devido às diversas vantagens que a tecnologia proporciona, entre elas, alta resolução das imagens, operados em baixa altitude, sem atenuação atmosférica por nuvens, voos sob demanda, sensores compatíveis, baixo custo e fáceis de configurar (TSOUROS, BIBI e SARIGIANNIDIS, 2019).

Dentre as metodologias que utilizam o sensoriamento remoto, destacam-se aquelas propostas por Moriya, Imai e Tommaselli, 2017; Kharuf-Gutierrez *et al.*, 2018; e Galvêncio e Naue, 2019. Elas têm em comum o uso de índices de vegetação, principalmente, com base nas bandas RGB e NIR. Essas pesquisas tem verificado que a aplicação de índices de vegetação em imagens de alta resolução aerolevantadas com drones demonstram um potencial significativo para monitorar e mapear a variabilidade espacial da biomassa para estimar a produtividade da cana-de-açúcar (SUMESH, NINSAWAT e SOM-ARD, 2021).

Vale ressaltar a importância do monitoramento durante várias épocas do ano a fim de detectar previamente a ocorrência de pragas e doenças, déficit hídrico, problemas nutricionais, dentre outros, que podem ocasionar falhas na área de cultivo e afetar diretamente o desempenho fisiológico e a produtividade da cana-de-açúcar. Com essas informações, o produtor toma decisões sobre atividades de manejo no canavial, inclusive aquelas relacionadas ao ciclo seguinte de cultivo, como a rebrota ou renovação do plantio.

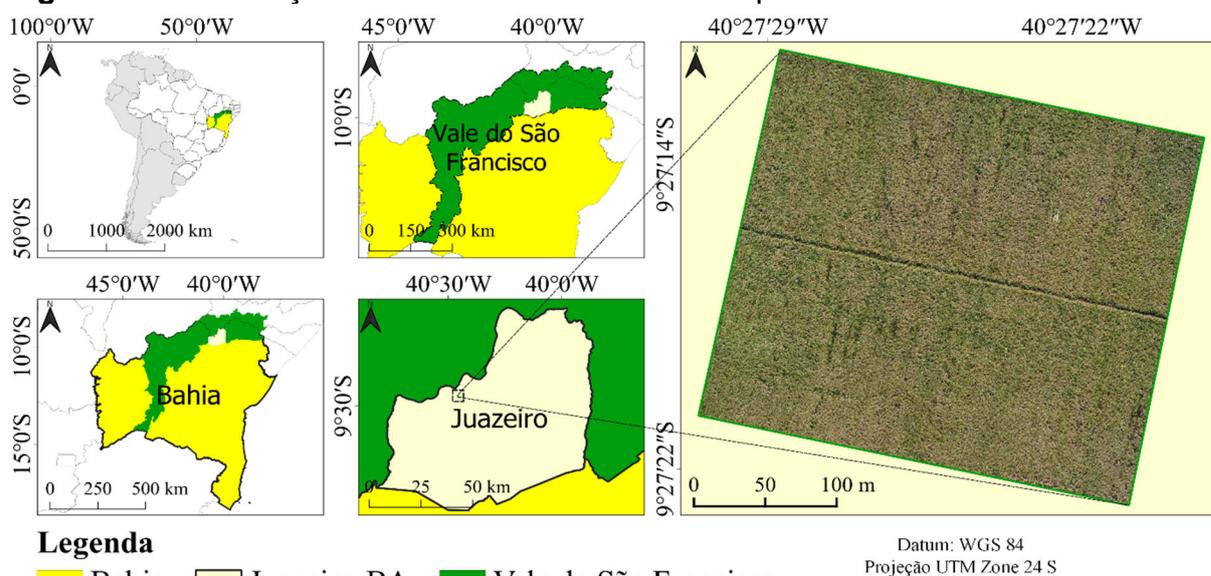
Com o advento da agricultura de precisão e, mais recentemente, dos modelos de drones, detectou-se uma alternativa viável, especialmente, quando a área de interesse é comparativamente pequena, como em nível de propriedade agrícola, para o imageamento aéreo. Os métodos utilizados se baseiam no computo de uma série de índices que se utilizam das bandas RGB e NIR, principalmente. Suas aplicações tem ocorrido para outras culturas ou regiões (ARAI *et al.*, 2016; XUE e SU, 2017; ANDRADE *et al.*, 2019; XU *et al.*, 2019), sendo ainda inexistentes nas áreas cultivadas com cana-de-açúcar irrigada no norte da Bahia, em Juazeiro. Assim, objetivou-se comparar o desempenho de índices espectrais para monitoramento de cultivo de cana-de-açúcar irrigada no Submédio do Vale São Francisco com base em imageamento aéreo com drone.

6.2 MATERIAL E MÉTODOS

6.2.1 Área de estudo

O estudo foi desenvolvido na área de cultivo agrícola de cana-de-açúcar pertencente à empresa Agroindústria do Vale São Francisco, no município de Juazeiro-BA, sob as coordenadas 09°27'S; 40°27'O (Figura 17). O solo da área foi classificado como Vertissolo e o cultivo instalado em fileiras de espaçamento duplo, irrigado com gotejamento subsuperficial. A região caracteriza-se por apresentar clima BSh, quente e seco, com temperatura média anual de 26,2 °C (EMBRAPA, 2015).

Figura 17. Localização da área de estudo no município de Juazeiro-BA



Fonte: Autor (2022).

6.2.2 Aquisição de dados

O imageamento ocorreu, em 26 de março e 18 de junho de 2021, utilizando o drone comercial DJI Phantom 4 Pro v2 e DJI Mavic 2 Enterprise Dual, na primeira e segunda data de voo, respectivamente, sendo a primeira aeronave embarcada com câmera visual (RGB), sensor CMOS 1" de 20 Mp, FOV 84° 8,8 mm/24 mm (formato equivalente a 35 mm) e abertura de f/2.8-f/11; e a segunda embarcada com câmera modelo FC2103_4.5_4056x3040, sensor CMOS 1/2.3" de 12 Mp, FOV: 85°, 24 mm (formato equivalente a 35 mm), abertura de f/2 para captura de imagens nas bandas do vermelho ou *Red* – 660 nm, verde ou *Green* – 550 nm e azul ou *Blue* – 470 nm.

As aeronaves utilizadas possuem registro segundo as normas brasileiras, assim como, o plano de voo foi realizado obedecendo a legislação, com voos a 120 m altura, adotando sobreposição lateral e frontal de 70% para garantir o fechamento do ortomosaico e câmera posicionada com ângulo de 90° em relação ao drone, ou seja, diretamente apontado ao solo e configuração de acordo com a iluminação da cena.

A avaliação do talhão foi realizada utilizando dados espectrais adquiridos com os sensores embarcados nos VANT e com imagens do sensor do satélite Landsat 8 (LANDSAT/LC08/C01/T1_RT_TOA), sensor OLI - (Operational Land Imager), disponibilizadas na plataforma do *Google Earth Engine* (GEE). O sensor OLI do satélite Landsat 8 apresenta imagens nas bandas multiespectral (Bandas 1-7 e 9) e pancromático (Banda 8) (EMBRAPA TERRITORIAL, 2018), cujas características encontram-se na tabela 6. Foram adquiridas imagens de satélite no dia 17 de março e 20 de maio de 2021, em razão da indisponibilidade de imagens sem cobertura de nuvens nas mesmas datas dos voos com os drone.

Tabela 6. Características do sensor OLI do satélite Landsat 8.

Bandas espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal
(B1) Costal	0.433 - 0.453 μm		
(B2) Azul	0.450 - 0.515 μm		
(B3) Verde	0.525 - 0.600 μm		
(B4) Vermelho	0.630 - 0.680 μm	30 m	
(B5) Infravermelho Próximo	0.845 - 0.885 μm		16 dias
(B6) Infravermelho Médio	1.560 - 1.660 μm		
(B7) Infravermelho Médio	2.100 - 2.300 μm		
(B8) Pancromático	0.500 - 0.680 μm	15 m	
(B9) Cirrus	1.360 - 1.390 μm	30 m	

Fonte: Embrapa Territorial, 2018.

6.2.3 Processamento de imagens e índices de vegetação

O pré-processamento das imagens digitais foi executado no *software* Agisoft Metashape, obedecendo, hierarquicamente, as etapas de entrada de dados, importando as imagens adquiridas pelo sensor embarcado no VANT; alinhamento de imagens, extraíndo as características e os descritores correspondentes entre as imagens (Geotags). Em seguida calculando as posições das imagens entre si (orientação externa relativa), com relação ao terreno (orientação externa absoluta),

gerando o modelo de nuvem de pontos esparsos; nuvem densa de pontos, gerada a partir de novos pontos de profundidade obtidos das posições estimadas das imagens e nos pontos esparsos; aerotriangulação, gerando uma malha triangular irregular (TIN – do inglês *Triangular Irregular Network*) a partir da nuvem de pontos densa; construção e exportação do ortomosaico e relatório de processamento.

Após a geração dos ortomosaicos, já na etapa de processamento, foram computados índices de vegetação utilizados para estudar o vigor das culturas agrícolas, os quais foram sumarizados na Tabela 7. Em seguida, os índices de vegetação foram comparados aplicando-se aritmética de bandas espectrais no ambiente do *software* de código aberto QGIS – versão o 3.10.8 - A Coruña.

Tabela 7. Índices de vegetação utilizados para avaliação do cultivo de cana-de-açúcar, Juazeiro, Bahia.

	Índice espectral	Tipo*	Fórmula**	Referência
1	Ground Level Image Analysis	RGB	$GLI = \frac{(2 * \rho G - \rho R - \rho B)}{(2 * \rho G + \rho R + \rho B)}$	Hunt <i>et al.</i> (2011)
2	Red Green Blue Vegetation Index	RGB	$RGBVI = \frac{\rho G^2 - (\rho R * \rho B)}{\rho G^2 + (\rho R * \rho B)}$	Bendig <i>et al.</i> (2015)
3	Normalized Green Red Difference Index	RGB	$NGRDI = \frac{\rho G - \rho R}{\rho G + \rho R}$	Tucker (1979)
4	Modified Green Red Vegetation Index	RGB	$MGRVI = \frac{\rho G^2 - \rho R^2}{\rho G^2 + \rho R^2}$	Bendig <i>et al.</i> (2015)
5	Redness Index	RGB	$RI = \frac{\rho R - \rho G}{\rho R + \rho G}$	Escadafal e Huete (1991)
6	Excess Green Index	RGB	$ExG = 2 * g - r - b$	Woebbecke <i>et al.</i> (1995)
7	Excess Red Vegetative Index	RGB	$ExR = 1.4 \rho R - \rho G$	Meyer <i>et al.</i> (1998)
8	Excess Green minus Excess Red	RGB	$ExGR = ExG - ExR$	Camargo-Neto (2004)
9	Normalized Difference Vegetation Index	NIR	$NDVI = \frac{(\rho NIR - \rho R)}{(\rho NIR + \rho R)}$	Rouse <i>et al.</i> (1974)

* Índices que mantêm as faixas RGB do vermelho, verde e azul (RGB) e índices que mantêm relação com o infravermelho próximo (NIR).

** Como usual, para o presente estudo, utilizou-se o valor do número digital de cada pixel, obtido em 8 bits nas imagens RGB dos drones, ao invés da refletância espectral (ρ), onde R = Red ou vermelho; G = Green ou verde; B = Blue ou Azul; NIR = infravermelho próximo

Para obtenção do produto do NDVI com base em imagens do drone (NDVI*) foi utilizada a metodologia baseada na estimativa da reflectância da banda do

infravermelho próximo (NIR) a partir das imagens da banda verde capturadas pelo próprio VANT (Arai *et al.*, 2016).

O processamento das imagens do Landsat 8 visando o computo do NDVI foi realizado por meio de programação utilizando-se a plataforma de processamento em nuvem do GEE, denominada *Code Editor*. Também foi aplicado um filtro na coleção importada, considerando a imagem com menor percentual de nuvens. As camadas de NDVI foram exportadas para o QGIS, onde foram georreferenciadas e reprojctadas.

6.2.4 Análises Estatísticas

Para avaliar o desempenho dos índices de vegetação, os mesmos foram comparados com o produto do NDVI estimado para o VANT e com o NDVI determinado nas imagens do Landsat 8. A análise dos resultados ocorreu por meio de parâmetros de estatística descritiva e do histograma dos dados.

6.3 RESULTADOS E DISCUSSÃO

6.3.1 Análise visual do ortomosaico em composição RGB

Os ortomosaicos do canalial foram avaliados para duas datas (26/03/2021 e 18/06/2021) do ciclo produtivo, apresentando diferença de 84 dias entre os voos. Os ortomosaicos apresentaram resolução espacial de 0,021 e 0,041 m pixel⁻¹ para o primeiro e segundo voo, respectivamente, resultando em alto grau de detalhamento dos alvos presentes na paisagem da área de estudo (Figura 18). Segundo Santos, Padolfi e Ramaldes (2018), isso está diretamente relacionado com a altura de voo, de modo que quanto mais próximo do alvo menor a resolução espacial e mais detalhes terá a imagem. A partir da análise visual dos ortomosaicos, percebe-se haver diferença entre o porte da cultura entre as datas de realização do voo. Em se tratando da cana-de-açúcar irrigada nas condições de Juazeiro, BA, há rápido desenvolvimento da cultura, cujo crescimento é acelerado, e a depender da cultivar e do sistema de irrigação, pode apresentar por volta de 93-94% de cobertura do solo aos 106 dias após o corte (CARMO *et al.*, 2017) ou aos 150 dias após o corte (SILVA *et al.*, 2011), respectivamente para sistema de irrigação subsuperficial ou por tubos janelados.

Figura 18. Ortomosaicos em composição RGB, gerado a partir de imagens obtidas em veículo aéreo não tripulado (VANT), para área de cana-de-açúcar no município de Juazeiro, Bahia.

A) 26/03/2021



B) 18/06/2021



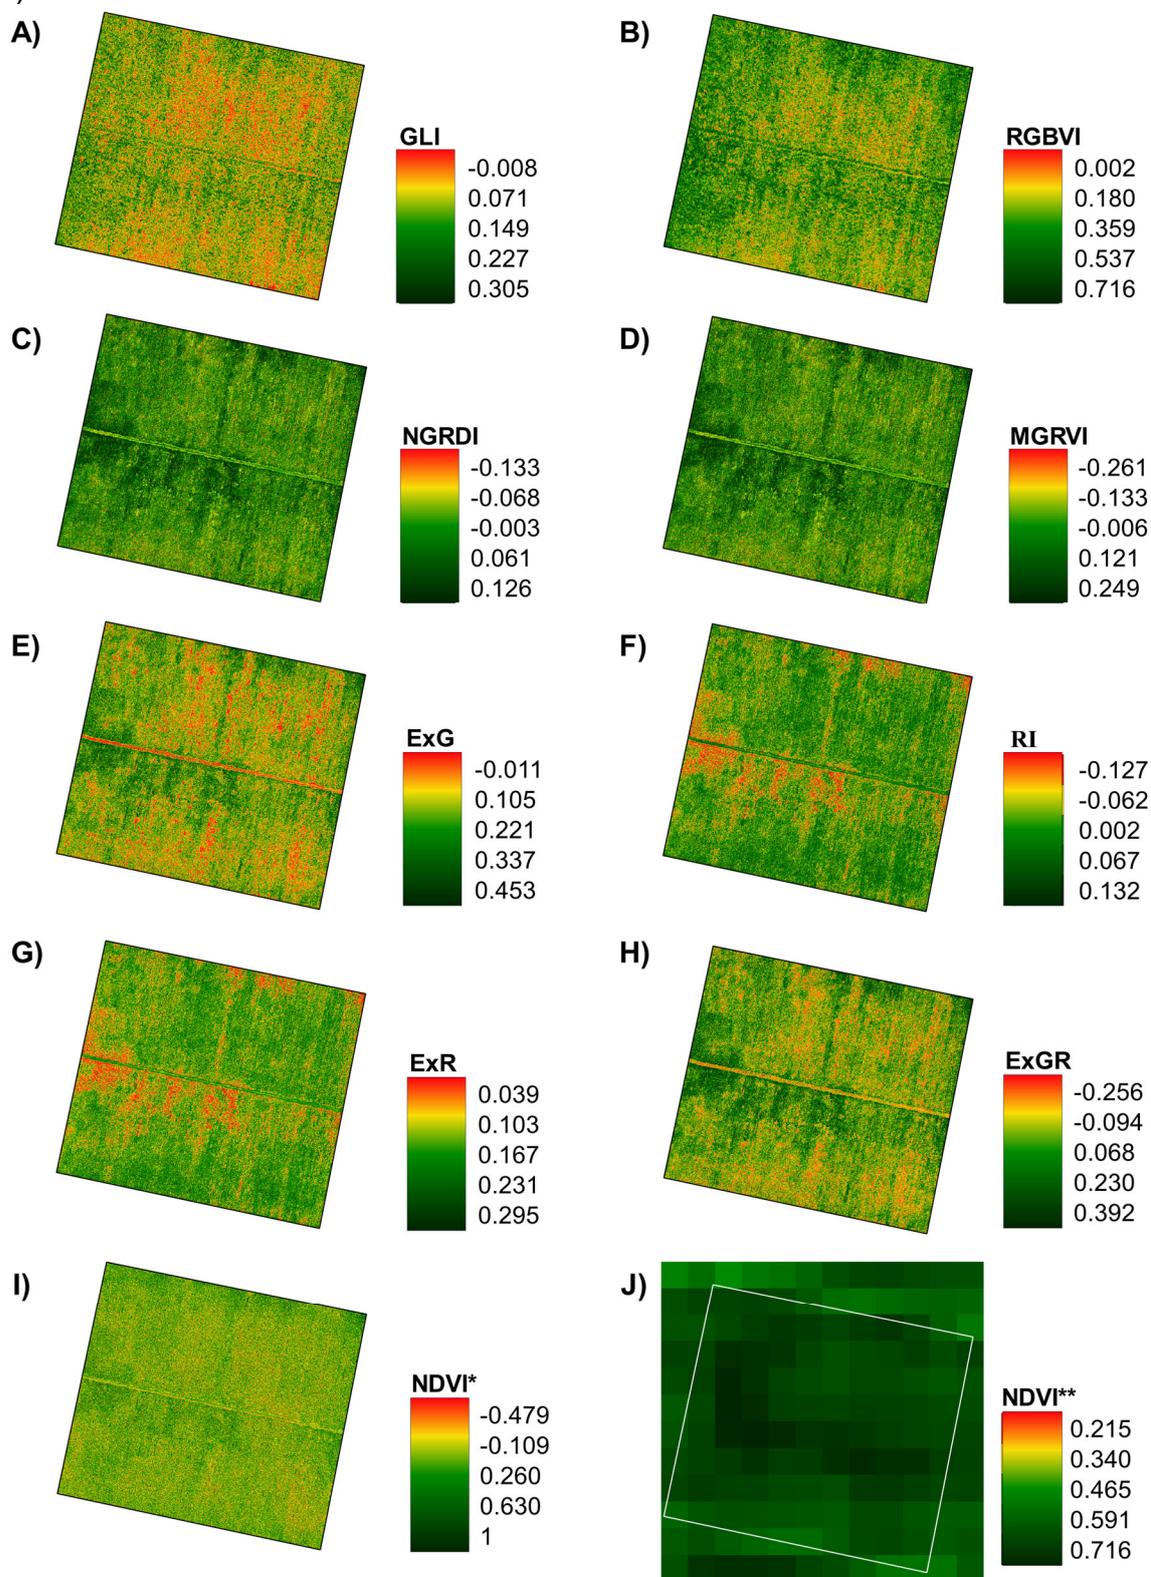
Fonte: Autor (2022).

Observa-se distinção entre os alvos que compreendem a vegetação e os outros elementos da cena (alvos abióticos), como solo exposto e áreas com água na superfície do solo ou solos expostos com excesso de umidade, como também, pode-se observar que há falhas no cultivo e presença de plantas daninhas, particularmente, no ortomosaico do mês de março (Figura 18A). Já no recorte do ortomosaico com maiores detalhes para o mês de junho (Figura 18B), percebem-se regiões com alta densidade de plantas daninhas, a partir do alto vigor e coloração mais verde escura destas, em contraste com a cultura da cana-de-açúcar. Essa distinção entre alvos da superfície imageada e do vigor da cana-de-açúcar são mais bem visualizados por meio dos índices de vegetação (IVs).

6.3.2 Variação espacial dos índices de vegetação

Na Figura 19, são apresentados os mapas e valores dos IVs para o voo realizado no dia 26 de março de 2021, na área de cana-de-açúcar. Observa-se que o índice RGBVI obteve melhor desempenho para a primeira data do voo, uma vez que, além de separar as classes mais densas (pixels mais escuros) das menos densas (pixels mais claros) corretamente, também obteve valores mais próximos ao NDVI** (produto gerado com imagem Landsat 8, pela plataforma GEE e utilizado nesta pesquisa como parâmetro para comparação dos demais índices de vegetação). A separação das classes diz respeito à identificação dos alvos no ambiente (vegetação, solo e água) e outros índices como GLI, ExG e ExGR também apresentaram desempenho semelhante. Os demais índices NGRDI, MGRVI, RI, ExR e inclusive o NDVI* (computado a partir das bandas RGB), não conseguiram distinguir os diferentes alvos da superfície corretamente, sejam eles abióticos (solo exposto e água) ou bióticos, como vegetação.

Figura 19. Índices de vegetação da área de cana-de-açúcar, em Juazeiro, Bahia, obtidos por imagem de VANT em 26/03/2021 (A, B, C, ..., I) e pela imagem Landsat 8 (J) em 17/03/2021.



NDVI*: Modelo estimado; NDVI**: Modelo obtido.

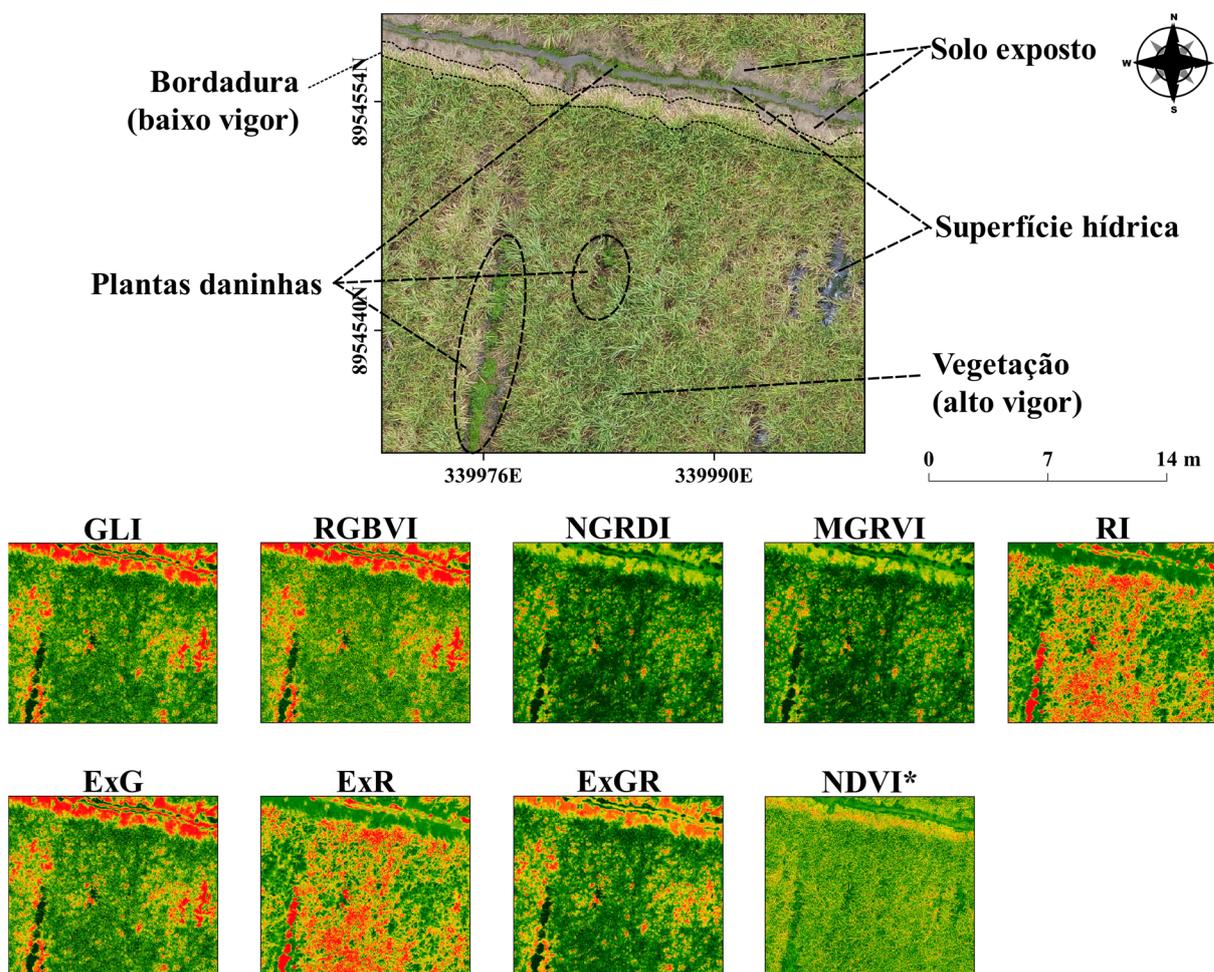
Fonte: Autor (2022).

Para realçar o desempenho dos IVs na classificação dos alvos, foi selecionada uma área menor, cuja visualização foi ampliada para verificação de detalhes da superfície, para análise em cada data de voo do VANT. Buscou-se um exemplar com o máximo de características, com áreas de vegetação e bordadura, que representam regiões com alto e baixo vigor, respectivamente; áreas com solo exposto ou água na superfície; assim como áreas ocupadas por plantas daninhas.

A Figura 20 contém o ortomosaico da área aproximada para a análise do desempenho dos IVs visando detecção e separação dos alvos presentes no ambiente. Conforme descrito, apesar dos índices GLI, ExG e ExGR terem apresentado desempenho satisfatório na detecção dos alvos, o índice RGBVI se destaca por apresentar valores próximos aos valores observados para o NDVI** (Figura 19). Há de se considerar que a alta resolução dos produtos resultantes do imageamento com drone proporcionam um nível de detalhamento da área de estudo impossível de ser detectado via imagens de satélite Landsat 8, que tem pixel com 30 m de resolução espacial; logo, a aproximação com escala de 14 m impossibilita a visualização de contraste na área selecionada para avaliação de detalhes da superfície.

Os índices NGRDI e MGRVI obtiveram desempenho satisfatório ao destacar áreas de vegetação com maior vigor, principalmente, com presença de plantas daninhas. Por outro lado, não conseguiram distinguir a vegetação das áreas com solo exposto e superfície hídrica, inclusive nessas áreas observa-se a coloração verde mais forte do que na área de bordadura (baixo vigor). Semelhante aos resultados dos IVs anteriores, o NDVI* conseguiu destacar áreas com plantas daninhas, porém com menor intensidade, além disso, não conseguiu distinguir nitidamente os demais alvos (Figura 20). Por sua vez, os índices RI e ExR detectaram os alvos de forma contrária aos demais IVs, com maior intensidade da cor vermelha para a vegetação de maior vigor e maior intensidade da cor verde para regiões abióticas. Isso se deve pela própria definição dos referidos índices, que destacam a resposta espectral da cor vermelha.

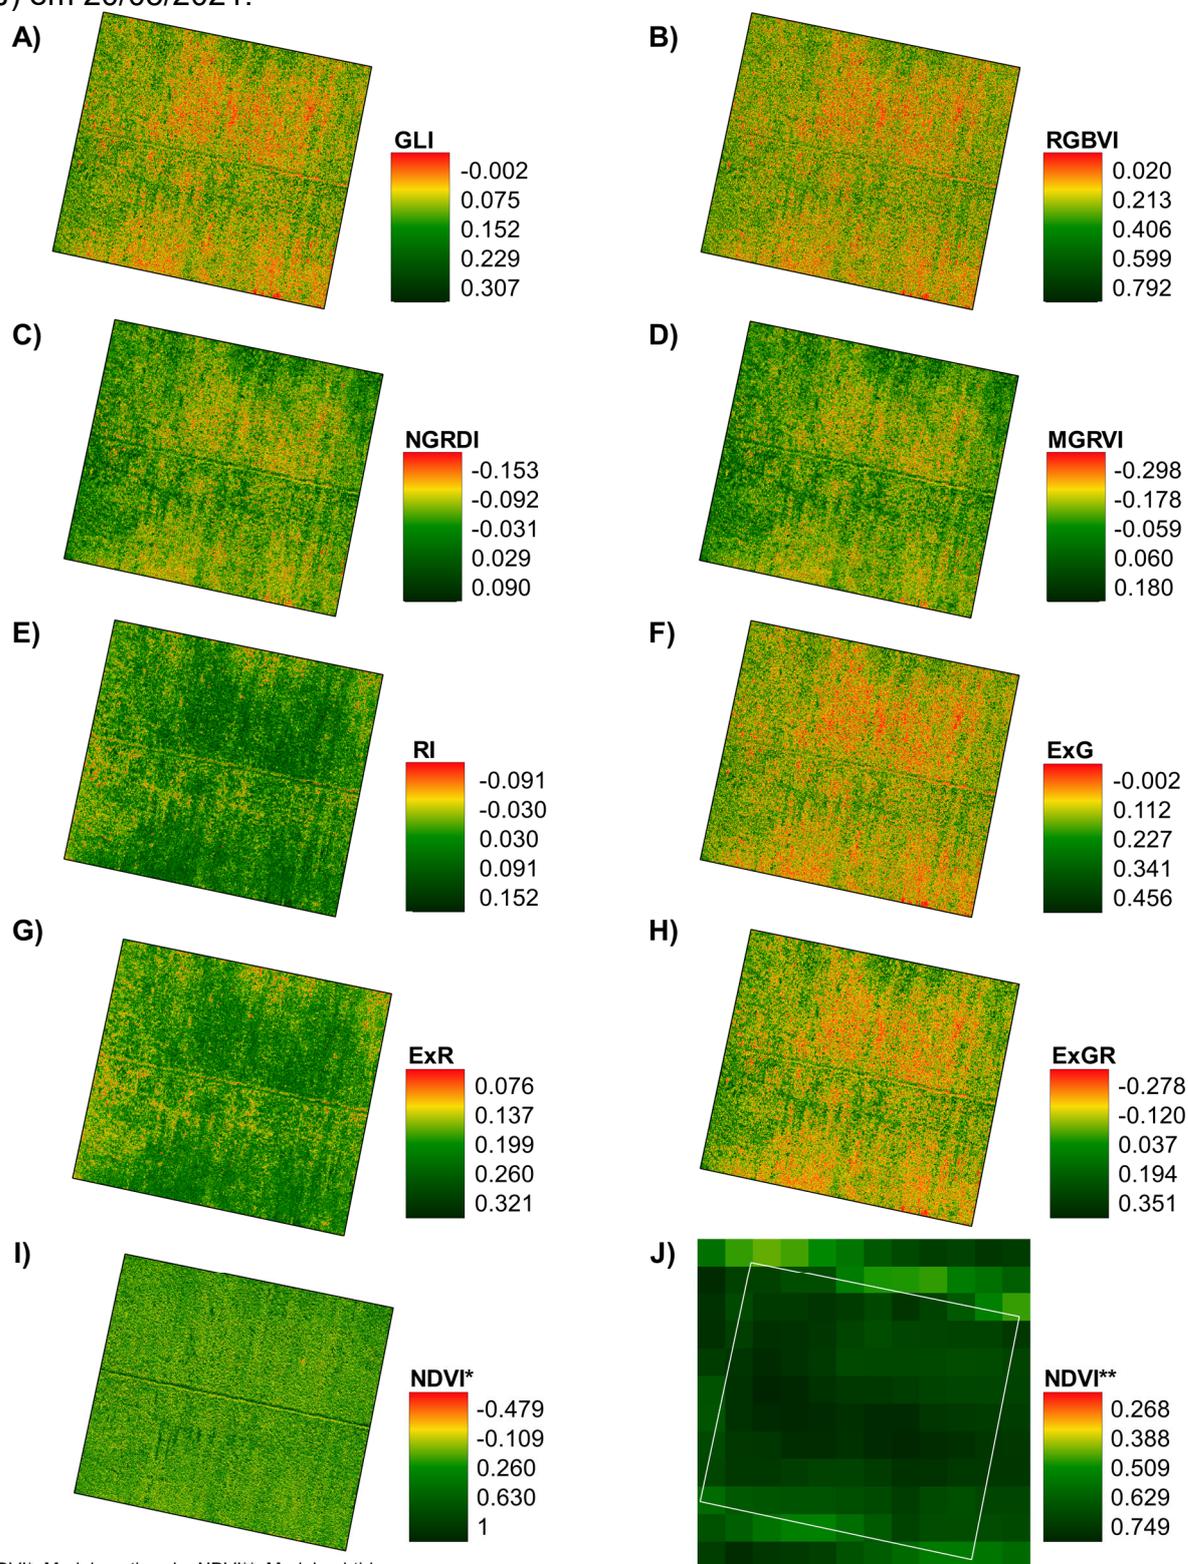
Figura 20. Detalhamento de área de cultivo de cana-de-açúcar para identificação de alvos da superfície com base na alta resolução da imagem VANT e na classificação de índices de vegetação para o dia 26/03/2021, em Juazeiro, Bahia.



Fonte: Autor (2022).

Na Figura 21, são apresentados os mapas e valores dos IVs para o voo do VANT realizado no dia 18 de junho de 2021. Observa-se que os resultados diferem entre si quanto a padronização das cores, com destaque para áreas de maior vigor. Em análise mais detalhada, na Figura 21, percebe-se que, embora cada índice tenha seu rigor, todos apresentaram desempenho satisfatório para distinção das áreas de maior vigor, com destaque novamente para o RGBVI. Apesar do baixo contraste, este índice apresentou valores com variação de escala próximos ao NDVI**. Os IVs GLI, ExG e ExGR foram capazes de gerar imagens semelhante ao RGBVI.

Figura 21. Índices de vegetação da área de cana-de-açúcar, em Juazeiro, Bahia, obtidos por imagem de VANT em 18/06/2021 (A, B, C, ..., I) e pela imagem Landsat 8 (J) em 20/05/2021.



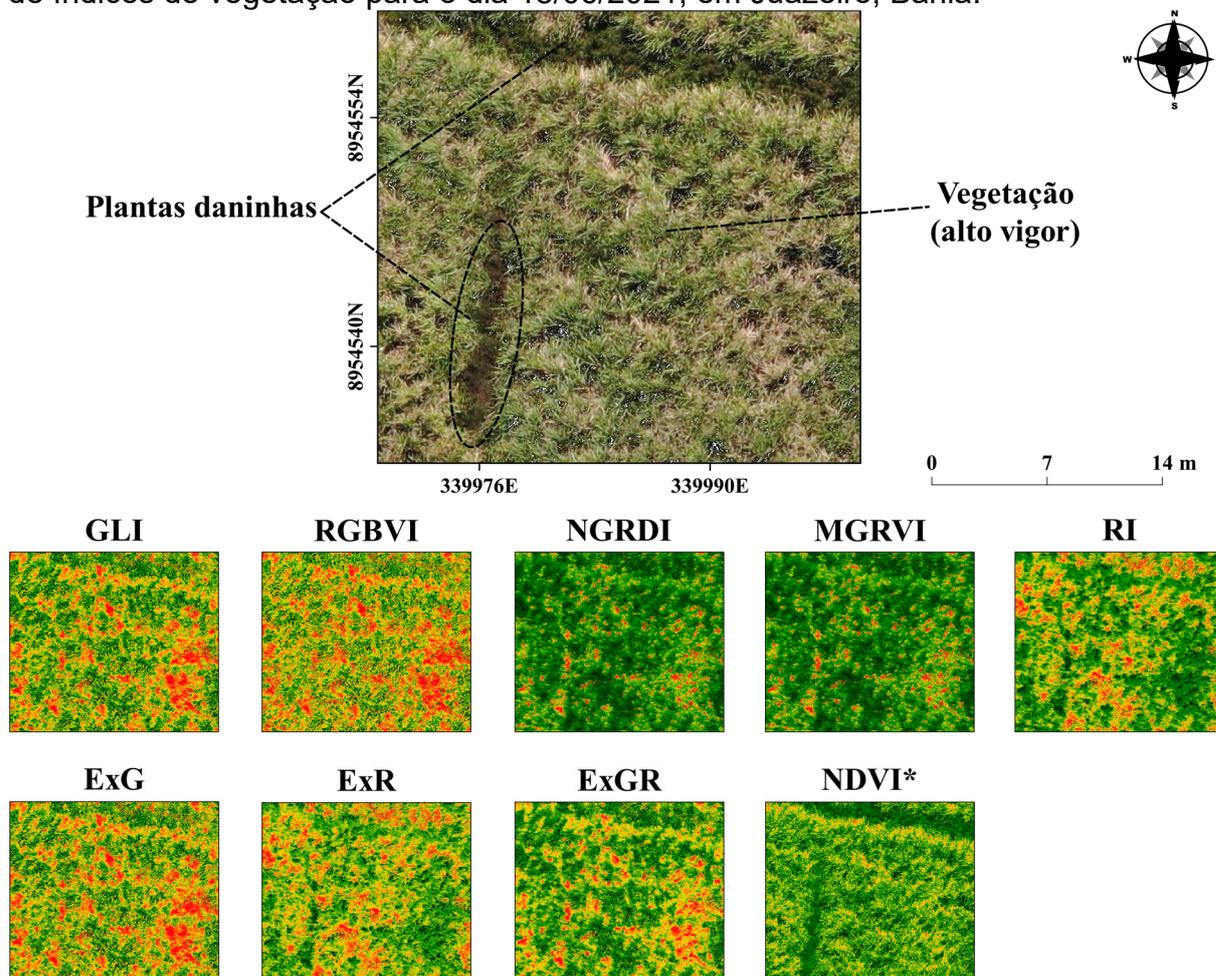
NDVI*: Modelo estimado; NDVI**: Modelo obtido.

Fonte: Autor (2022).

Os índices NGRDI e MGRVI apresentaram resultados com mais contraste do que os demais, podendo ser mais sensíveis na detecção de áreas, possivelmente, estressadas, por utilizar-se das bandas vermelho e verde. Já os índices RI e ExR caracterizaram de forma contrária conforme a paleta de cores sugere, isso porque as áreas de coloração verde mais intensas nesses índices representam as áreas de menor vigor observado. Por sua vez o NDVI* conseguiu destacar muito bem as áreas com presença de plantas daninhas, inclusive se sobressaindo entre os demais IVs para este desempenho. Contudo, dado a amplitude dos valores observados, este também teve menor relação com os valores limites obtidos com o NDVI** (Figura 21).

Conforme ocorrido para o primeiro voo, foi realizado um recorte na área de estudo para maior detalhamento dos alvos da superfície visando melhor análise do desempenho de cada IVs (Figura 22).

Figura 22. Detalhamento de área de cultivo de cana-de-açúcar para identificação de alvos da superfície com base na alta resolução da imagem VANT e na classificação de índices de vegetação para o dia 18/06/2021, em Juazeiro, Bahia.



Fonte: Autor (2022).

Pode-se observar que o NDVI* foi muito mais eficiente na detecção e delimitação de áreas com plantas daninhas. Com a aproximação das áreas para a análise dos IVs na segunda data de voo, observa-se também o ganho em detalhes, contudo esse nível de detalhamento não auxiliou na análise visual do desempenho dos IVs. Deste modo, para uma observação mais precisa sobre o comportamento dos índices, torna-se necessário a análise do agrupamento dos *pixels* e seus respectivos valores, a partir de histogramas.

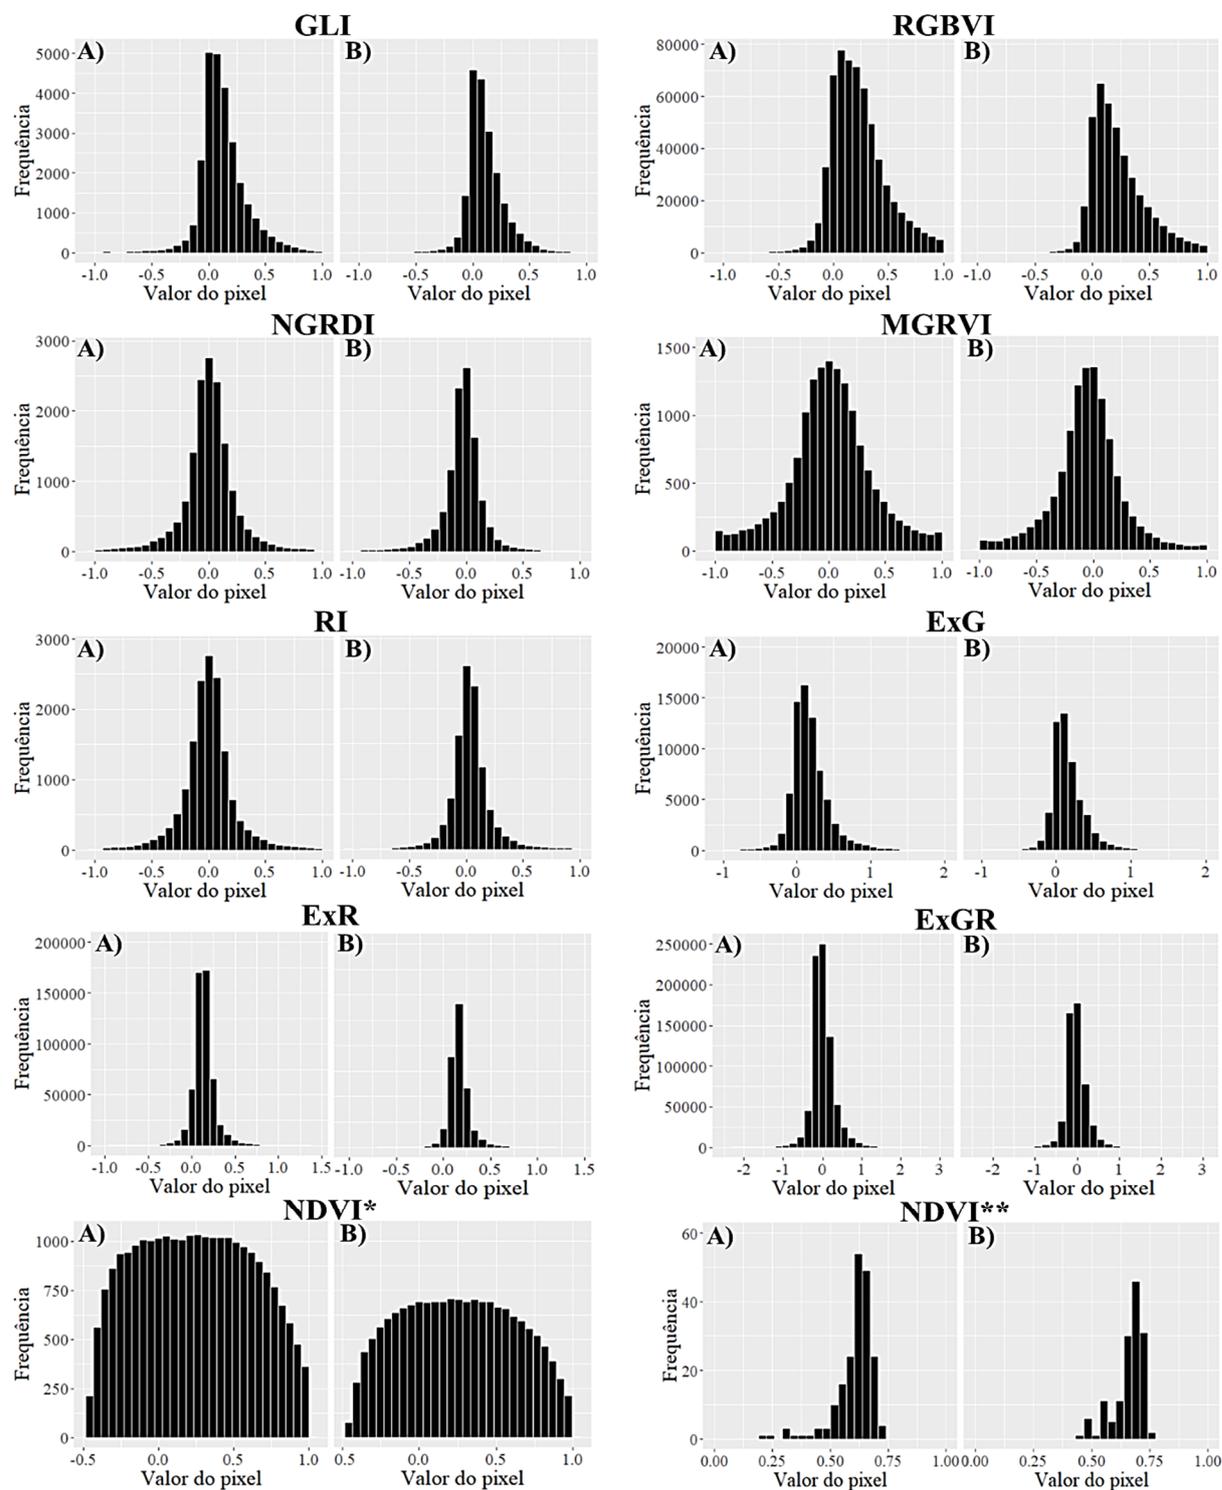
6.3.3 Métricas dos índices de vegetação

De acordo com Silva e Galvêncio (2012) os histogramas, quando utilizados para a análise de mapas de IVs, podem auxiliar na compreensão e interpretação destes índices. Deste modo, na Figura 23, são apresentados os histogramas obtidos a partir dos índices de vegetação computados no presente estudo.

Observa-se que na maioria dos índices de vegetação os valores médios se encontram entre 0 e 0,5 com exceção do NDVI**, cujos valores foram distribuídos, praticamente, entre 0,5 e 0,75. O NDVI* também se comportou diferente dos demais índices, apresentando distribuição bem uniforme, com uma frequência de *pixels* inferior aos demais índices RGB, mas também, alcançando valores superiores ao NDVI**.

A partir dos valores médios observados nos histogramas, destacaram-se nos mapas dos IVs apenas áreas de vegetação densa; enquanto abaixo dos valores médios positivos foram observadas áreas com baixo vigor, bordadura e áreas cobertos com palhada (cobertura morta). Embora, visualmente, não tenham sido observadas muitas áreas com solo exposto ou lâmina de água, nos histogramas foram verificados muitos valores próximos a zero, os quais representam alvos abióticos. Neste caso, com o elevado volume de palha, a alta reflectância promovida pela coloração deste material e, associada a alta resolução dos ortomosaicos, presume-se que estes fatores sejam responsáveis pelos valores baixos observados nos histogramas dos IVs.

Figura 23. Histograma dos índices de vegetação obtidos em 26/03(A) e 18/06 de 2021(B), em área de cana-de-açúcar, em Juazeiro, Bahia.



Fonte: Autor (2022).

Conforme as equações da tabela 1, nem todos os índices computados resultam em valores variando de -1 a +1. Nos histogramas observa-se que os índices ExG e ExR resultaram em valores acima de 1, e o índice ExGR apresentou valores abaixo

de -1, obtendo maior amplitude comparado aos demais IVs. Segundo Brasileiro *et al.* (2014) este comportamento tem como vantagem uma melhor representação da vegetação regional, bem como a simplicidade no cálculo, contudo também é possível ocorrer divisão por zero gerando uma escala de medida não-linear. Segundo o mesmo autor, o NDVI produz escalas de medidas lineares variando de -1 a 1 com o zero representando áreas sem vegetação e valores negativos nos corpos d'água, minimizando os problemas de divisão por zero.

Conforme esperado, o NDVI** foi o único que obteve apenas valores positivos para ambas as datas de passagem do satélite, pois dada a resolução da imagem em função da área por *pixel* este resultado comprova o alto vigor e uniformidade da cultura estudada. Apesar das diferenças entre os valores máximos e mínimos encontrados pelos índices, no geral, estes apresentaram comportamento semelhante entre si.

Os resultados utilizados para os histogramas também foram submetidos à análise estatística descritiva (valor mínimo, valor máximo, intervalo, média, desvio padrão, soma e percentil) para o conhecimento detalhado do desempenho dos IVs, conforme apresentado na Tabela 8. Segundo Santos, Pereira Filho e Kuplich (2019) a estatística descritiva contribui para a análise previa dos dados e revela-se importante antes de se aplicar qualquer técnica que visa estabelecer relação entre variáveis.

Tabela 8. Estatística descritiva dos índices de vegetação obtidos para área de cana-de-açúcar em Juazeiro, Bahia.

Índice	Voo	Valor		Intervalo	média	D.P.	Soma	Percentil				
		mín.	máx.					5	25	50	75	95
GLI	1	-1	1	2	0,12	0,08	5616709,71	-0,12	0,00	0,09	0,21	0,50
	2	-1	1	2	0,11	0,07	5012761,41	-0,09	0,01	0,08	0,18	0,41
RGBVI	1	-1	1	2	0,28	0,17	12922902,60	-0,08	0,06	0,20	0,36	0,72
	2	-1	1	2	0,26	0,18	12277651,58	-0,05	0,06	0,17	0,35	0,70
EXG	1	-1	2	3	0,17	0,11	7939815,32	-0,13	0,02	0,13	0,28	0,65
	2	-1	2	3	0,15	0,11	7066491,04	-0,11	0,02	0,11	0,25	0,53
EXR	1	-1	1,4	2,4	0,15	0,06	7028471,80	-0,04	0,08	0,13	0,19	0,35
	2	-1	1,4	2,4	0,17	0,06	8108027,47	0,02	0,11	0,16	0,21	0,36
EXGR	1	-2,4	3	5,4	0,02	0,16	911343,52	-0,36	-0,16	-0,03	0,13	0,52
	2	-2,4	3	5,4	-0,02	0,15	-1041536,43	-0,36	-0,17	-0,05	0,08	0,39
NGRDI	1	-1	1	2	0,00	0,06	203056,95	-0,36	-0,10	0,01	0,11	0,36
	2	-1	1	2	-0,02	0,06	-882709,71	-0,32	-0,10	-0,02	0,05	0,22
MGRVI	1	-1	1	2	0,01	0,12	415932,56	-0,64	-0,19	0,01	0,22	0,65
	2	-1	1	2	-0,04	0,11	-1740973,36	-0,58	-0,20	-0,05	0,10	0,42
RI	1	-1	1	2	0,00	0,06	-203056,95	-0,36	-0,11	-0,01	0,10	0,36
	2	-1	1	2	0,02	0,06	882709,71	-0,22	-0,05	0,02	0,10	0,32
NDVI *	1	-0,485	1	1,485	0,15	0,23	27020107,11	-0,35	-0,08	0,24	0,55	0,86
	2	-0,480	1	1,480	0,28	0,24	13107526,37	-0,33	-0,05	0,25	0,55	0,85
NDVI **	1	0,469	0,716	0,25	0,62	0,05	89,67	0,53	0,60	0,63	0,65	0,69
	2	0,461	0,749	0,29	0,66	0,07	95,03	0,52	0,64	0,68	0,70	0,73

NDVI*: Método estimado; NDVI**: Método obtido; D.P: Desvio padrão.

Fonte: Autor (2022).

A análise da estatística descritiva permite constatar a dissimilaridade entre os valores dos índices RGB e o NDVI** para todos os parâmetros avaliados, exceto para o desvio padrão. Observa-se, neste caso, o baixo grau de dispersão dos valores, principalmente, para os índices ExR, NGRDI e RI cujo valor de desvio padrão foi de 0,06 nos resultados para ambas as datas, valor próximo ao NDVI** que foi de 0,05 e 0,07 para a primeira e segunda data de voo, respectivamente.

Segundo Oliveira *et al.* (2019), o desvio padrão é uma medida que expressa o grau de dispersão de um conjunto de dados, ou seja, o desvio padrão indica o quanto um conjunto de dados é uniforme, o quanto mais próximo de 0 for o desvio padrão, mais preciso são os dados. Neste caso, embora seja observado a dissimilaridade entre a amplitude dos valores obtidos, o conjunto de dados para cada índice foram homogêneos.

A partir da análise dos percentis foi possível comparar o desempenho entre os índices RGB e o NDVI**. Segundo Camargo (2017), os percentis são medidas estatísticas de posição representados pelo valor do índice, onde a porcentagem de pontos que estão abaixo desse valor corresponde ao respectivo valor do percentil, ou seja, o percentil 95 seria o valor do índice em que 95% dos valores observados se encontram abaixo desse valor.

Observou-se que os percentis (5, 25, 50, 75 e 95) apresentaram tendência de aumento em função do crescimento da vegetação existente sobre a área, sendo os maiores valores para o percentil 95 foram observados nos resultados do RGBVI, NDVI* e NDVI**. Contudo, o índice RGBVI se destacou por obter no percentil 95 os valores 0,72 e 0,70 para a primeira e segunda data de voo, respectivamente, valores mais próximos ao NDVI** que foi de 0,69 e 0,73 para as mesmas datas. O NDVI* superou estes valores, enquanto aos demais índices foi observado valores bem inferiores a estes.

Analisando ainda os valores da tabela relativo aos percentis 5 e 95 dos índices RGB, é notória a existência de variabilidade na área de estudo para o dia 26 de março e 18 de junho de 2021, principalmente, para a primeira data, onde observa-se maior amplitude entre o valor maior e menor do índice, cujo período coincide com a fase de desenvolvimento ainda inicial da cultura.

A resolução das imagens RGB também está ligada à detecção da variabilidade dentro da área, pois devido à alta resolução espacial das imagens de satélite, não foi observada variabilidade significativa dos mesmos percentis para o NDVI**. Marques

(2018) analisando a potencial utilidade agrônômica dos satélites a partir do NDVI, observou a existência de variabilidade na parcela estudada para os percentis 20 e 80 do NDVI, dos quais em um intervalo de apenas 24 dias observou-se que as plantas menos desenvolvidas apresentavam valores de NDVI de 0,35 enquanto que as mais desenvolvidas se situavam nos 0,54, comprovando que para o intervalo de tempo o nível de desenvolvimento entre plantas dentro da mesma parcela era bastante heterogêneo.

A variabilidade dos valores obtidos entre índices calculados a partir de dados do VANT e satélite também é explicada por Santos *et al.* (2021). Segundo os autores ao visualizar os dados de alta resolução coletados a partir dos sensores acoplados em VANT's, percebe-se que as imagens de satélites apresentam limitações para detecção de alvos específicos em função de sua resolução espacial, podendo ter como consequências a alteração de valores pela influência de outros alvos, o que pode causar interferências negativas na radiância adquirida pelas imagens e, conseqüentemente, dificultar a avaliação geral.

Quanto aos valores negativos observados para os índices RGB, Khaliq *et al.* (2019) explicam que em se tratando de análises dentro da agricultura, a presença de solo exposto em contraste com a vegetação da área cultivada, tem potencial para influenciar significativamente nos cálculos dos índices de vegetação, ficando comprovado que para o estudo de áreas pequenas, o uso de maiores resoluções espaciais permite uma melhor identificação dos alvos existentes.

6.3.4 Discussão

Os resultados mostraram a maior diferença entre os valores dos índices de vegetação na primeira data de voo em 26 de março de 2021, momento em que a cultura da cana-de-açúcar não se encontrava no pico da fase de desenvolvimento vegetativo. Por isso, foram identificados mais alvos nas cenas, o que possibilitou melhor avaliar o desempenho dos IVs.

Em geral os melhores resultados interpretados, visualmente, foram obtidos pelos índices GLI, RGBVI, ExG e ExGR, principalmente, na primeira data de voo, momento em que a cultura se encontrava em meio a fase de desenvolvimento e era observado solo e lâmina de água expostos. Hamuda, Glavin e Jones (2016), a partir da interpretação visual da imagem resultante após os cálculos dos IVs, concluíram

que o ExG também obteve desempenho satisfatório quanto a separação de classes de densidade da cana-de-açúcar. Upendar *et al.* (2021), estudando índices de vegetação e intensidade de iluminação, observaram que os índices ExG, ExR e ExGR obtiveram desempenho satisfatório e concluíram que o ExGR pode ser usado para melhor segmentação e identificação de material vegetal e não vegetal em sistema de identificação de plantas daninhas baseado em imagem, o que explica a resposta satisfatória no destaque de plantas daninhas observados nas imagens dessa pesquisa.

Sob condições experimentais distintas, Xu *et al.* (2019) concluíram que os índices RGBVI, MGRVI, NGRDI, ExG e ExGR possuem baixa densidade de contraste, além de apresentar alto ruído nas imagens. Apesar de tais conclusões, observou-se nessa pesquisa que os índices supracitados apresentaram alto contraste entre a vegetação, sendo possível identificar regiões de maior vigor e regiões com plantas daninhas; além de realçar áreas de baixo vigor, com bordaduras e áreas com solo exposto e superfícies de água.

De acordo com Andrade *et al.* (2019) o índice de folha verde GLI (LOUHAICHI; BORMAN e JOHNSON, 2001), tem sido utilizado nos estudos para distinção entre vegetação fotossinteticamente ativa e vegetação seca com exposição de solo e nesta pesquisa o índice GLI conforme proposto obteve uma resposta sensível na discriminação das classes da vegetação e das áreas com exposição do solo, principalmente na primeira data de voo. Segundo os autores, a formulação do índice pode explicar a sensibilidade à vegetação verde, devido ao fato da banda espectral do verde ter peso 2 em relação às bandas do azul e vermelho, deste modo, espera-se que o GLI destaque melhor as características de folhas e caules verdes.

Conforme apresentado, o RGBVI se destacou entre os demais índices de vegetação, principalmente, nos resultados referentes a primeira data de voo, momento em que a cultura da cana-de-açúcar se encontrava em fase de desenvolvimento. Visando capturar reflectâncias em função da absorção de clorofila, Bendig *et al.* (2015) explicam que o RGBVI foi proposto como sendo uma alternativa para avaliação de biomassa, cujos resultados são mais promissores para culturas que se encontrem em estágios iniciais de desenvolvimento. Este fato explica também o comportamento inverso dos índices para a segunda data de voo, os quais foram menos sensíveis no contraste da densidade da vegetação, devido ao estágio avançado da cultura.

Ao estudar a relação densidade de plantio da cana-de-açúcar e índices de vegetação RGB, Cruz (2020) observou que semelhante aos resultados obtidos nessa pesquisa, o índice NGRDI mostrou bom desempenho na distinção de plantas daninhas, denominada pelo autor por classe mato-competição, contudo para a distinção dos demais objetos não houve resposta satisfatória. O autor relata que parte dos resultados de pixels foram levados para o branco, tornando-se *outliers*, o que acaba distanciando dos valores esperados. Assim, como o autor supracitado sugere, o índice NGRDI neste caso pode ser utilizado para outras pesquisas relacionadas à investigação de plantas daninhas, como por exemplo, para identificação automática desta classe em imagens de VANT's para aplicação de defensivos agrícolas.

O índice RI, embora proposto para identificação de plantas daninhas em ambientes áridos e com solos distintos, nessa pesquisa buscou-se avaliar seu comportamento apenas para com a presença de invasoras. Contudo, semelhante apenas ao ExR e inversamente aos demais índices, o RI obteve uma resposta particular, pois deu destaque com valores mais positivos para regiões de baixo vigor e o inverso também se confirma. Este resultado foi observado pela aplicação da escala de cores, onde regiões de maior vigor foi classificado pelo índice com a coloração vermelha enquanto regiões de baixo vigor foi classificado com forte cor verde. Ao inverter a escala de cores concluiu-se que o índice conseguiu distinguir os objetos na cena, embora diferentemente dos demais índices.

O índice de excesso de verde ExG, conforme proposto, apresentou desempenho satisfatório ao separar bem as classes de vegetação densa de áreas com menos vigor, também destacou áreas com solo exposto e com plantas daninhas.

Meyer *et al.* (1998) comparando o desempenho do índice ExG com o ExR, observaram que o método ExR foi capaz de separar *pixels* de plantas, contudo também teve um desempenho ruim na segmentação da vegetação, quando comparado ao método ExG. Corroborando com tais resultados, o desempenho do ExR nessa pesquisa embora também tenha conseguido separar parte dos alvos não conseguiu distinguir o que representava a vegetação de acordo com a sua densidade ou vigor, contrário ao ExG.

Nessa pesquisa o índice ExR não obteve um desempenho satisfatório para segmentação da vegetação dos demais alvos na área, pois as amostras de vegetação e solo apresentaram valores semelhantes. Upendar *et al.* (2021) encontraram resultados semelhantes para o mesmo índice e segundo os autores esse

comportamento também é evidente ao observar o intervalo reduzido do ExR entre as manchas de cor verde e do solo. Nessa pesquisa, os valores limites observados na escala de cores do ExR foram 0,039 a 0,295 na primeira data de voo e 0,076 a 0,321 na segunda data. Fica nítido que a baixa amplitude dos valores comprova a dificuldade na segmentação da área.

Os produtos NDVI* obtidos pela estimativa da reflectância NIR a partir de imagens do visível, utilizando o modelo proposto por Arai *et al.* (2016), demonstraram ser promissores em ambas as datas analisadas, apesar de não ter superado os resultados dos demais índices nessa pesquisa, de modo a ser necessário o estudo de mais procedimentos para tratamento e calibração das imagens, em busca de elevar a precisão e a qualidade dos produtos finais.

Ao avaliar a estimativa do NDVI a partir de imagens do visível também utilizando o modelo proposto por Arai *et al.* (2016), Galvêncio e Naue (2019) obtiveram produtos NDVI com 64% de acerto utilizando apenas o modelo proposto e 95% utilizando o mesmo modelo, porém aplicando também equações de calibração radiométricas, bastantes difundidas para uso do satélite Landsat 5. Ao aplicar as devidas calibrações obtiveram um incremento de 31% no NDVI corrigido. Logo, corroborando com os autores, conclui-se que é de suma importância a calibração radiométrica das imagens obtidas com drones, para que elas possibilitem estimativas mais precisas do NDVI. Por outro lado, existem índices de vegetação computados com as bandas RGB que são capazes de detectar diversos alvos e o estado das plantas.

6.4 CONCLUSÕES

Índices de vegetação utilizando as bandas vermelho, verde e azul foram computados a partir de ortomosaicos gerados com imagens aéreas capturadas por veículo aéreo não tripulado (VANT) em área de cana-de-açúcar. Verificou-se que os índices GLI - *Ground Level Image Analysis*; RGBVI - *Red Green Blue Vegetation Index*; ExG - *Excess Green Index* e ExGR - *Excess Green minus Excess Red* foram, visualmente, equivalentes entre si, sendo o índice RGBVI mais sensível na discriminação dos diferentes alvos da superfície, desta forma, um dos mais indicados para monitoramento da cana-de-açúcar.

Há necessidade da continuidade dos estudos envolvendo aplicações de VANT em diversas culturas do Submédio do Vale São Francisco, visando o monitoramento para identificação prévia de diversos aspectos relacionados aos cultivos, como: detecção de falhas de plantio; estimativas da produtividade; detecção de pragas, doenças e plantas invasoras; identificação de falhas no sistema de irrigação; monitoramento nutricional; determinação da evapotranspiração e apoio ao manejo de irrigação; dentre outros. Aplicações de índices obtidos com imagens no espectro visível são de simples obtenção, mas necessitam validação antes de indicação para uso.

6.5 REFERÊNCIAS

ALEMÁN-MONTES, B. *et al.* Yield estimation of sugarcane (*Saccharum officinarum*) from photogrammetry with unmanned aerial vehicles (UAV). **Agronomía Costarricense**, v. 45, n. 1, p. 67-80, 2021.

ANDRADE, R. *et al.* Uso de veículo aéreo não tripulado (VANT) no monitoramento dos estádios de desenvolvimento da cultura do milho. **Engenharia Sanitária e Ambiental**, p. 225-234, 2019.

ARAI, K. *et al.* Method for NIR Reflectance Estimation with Visible Camera Data based on Regression for NDVI Estimation and its Application for Insect Damage Detection of Rice Paddy Fields. **International Journal of Advanced Research in Artificial Intelligence**, v. 5, n. 11, 2016.

BENDIG, J. *et al.* Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.

BRASILEIRO, F. G. *et al.* Comparação de três índices de vegetação utilizando imagem landsat-8 nas imediações do Açude Orós, Ceará, Brasil. **Enciclopédia Biosfera**, v. 10, n. 19, 2014.

CAMARGO, A. P. **Estratificação de povoamentos de *Eucalyptus* spp. em classes de idade por escaneamento a laser aerombarcado**. 2017. 87 f. Tese (Doutorado) – Programa de Pós-Graduação em Recursos Florestais, Universidade de São Paulo, 2017.

CAMARGO-NETO, J. A. **Combined Statistical-Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems**. 2004. 170 f. Dissertação (Mestrado) – Departamento de Engenharia de Sistemas Agrícolas e Biológicos, University of Nebraska, Lincoln, 2004.

CARMO, J. F. A. *et al.* Balanço de radiação da cana-de-açúcar irrigada por gotejamento subsuperficial no Submédio do Vale São Francisco. **Agrometeoros**, v.25, n.1, p.91-100, 2017.

CRUZ, A. C. **Estimativa da densidade de plantação de cana de açúcar utilizando o espaço de cor cie lab em imagens de alta resolução espacial providas de VANT's**. 2020. 63 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Ciências Ambientais, Universidade Estadual Paulista Júlio de Mesquita Filho, 2020.

EMBRAPA TERRITORIAL. Satélites de Monitoramento. **LANDSAT - Land Remote Sensing Satellite**. Campinas, 2018. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>. Acesso em: 22 ago. 2022.

EMBRAPA. Centro de Pesquisa Agropecuária do Trópico Semiárido. **Médias anuais da estação agrometeorológica de Mandacaru (Juazeiro-BA 09°24'S, 40°26'W): período 1975 - 2014**. Petrolina, 2015. Disponível em: <http://www.cpatia.embrapa.br:8080/servicos/dadosmet/cem-anual.html>. Acesso em: 25 nov. 2021.

ESCADAFAL, R.; HUETE, A. Etude des propriétés spectrales des sols arides appliquée à l'amélioration des indices de végétation obtenus par télédétection. **Comptes rendus de l'Académie des sciences. Série II. Mécanique, Physique, Chimie, Sciences de l'univers, Sciences de la Terre**. v. 312, n. 11, p. 1385-1391, 1991.

GALVÍNCIO, J. D.; NAUE, C. R. Estimation of NDVI with visible images (RGB) obtained with drones. **Journal of Hyperspectral Remote Sensing**, v. 9, n. 6, p. 407-420, 2019.

GEIPEL, J.; LINK, J.; CLAUPEIN, W. Combined spectral and spatial modeling of corn yield based on aerial images and crop surface models acquired with an unmanned aircraft system. **Remote sensing**, v. 6, n. 11, p. 10335-10355, 2014.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and electronics in agriculture**, v. 125, p. 184-199, 2016.

HUNT, E. R. *et al.* Remote sensing leaf chlorophyll content using a visible band index. **Agronomy journal**, v. 103, n. 4, p. 1090-1099, 2011.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Sistema IBGE de Recuperação Automática (SIDRA): Produção agrícola municipal**, 2019. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>. Acesso em: 03 mai. 2021.

KHALIQ, A. *et al.* Comparison of satellite and UAV-based multispectral imagery for vineyard variability assessment. **Remote Sensing**, v. 11, n. 4, p. 436, 2019.

KHARUF-GUTIERREZ, S. *et al.* Multispectral aerial image processing system for precision agriculture. **Sistemas y telemática**, v. 16, n. 47, 2018.

LEDA, V. C.; GOLÇALVES, A. K.; LIMA, N. DA S. Sensoriamento remoto aplicado a modelagem de produtividade da cultura da cana-de-açúcar. **Energia na Agricultura**, v. 34, n. 2, p. 263-270, 2019.

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, n. 1, p. 65-70, 2001.

MARQUES, F. J. M. **Utilidade agronômica dos índices NDVI e NDWI obtidos por imagem dos satélites Sentinel-2: estudos de caso nas culturas de trigo, brócolis e arroz**. 2018. 91 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Agrônômica, Universidade de Évora, 2018.

MEYER, G. E.; HINDMAN, T. W.; LAKSMI, K. Machine vision detection parameters for plant species identification. In: **Precision agriculture and biological quality**. SPIE, 1998. p. 327-335.

MISHRA, P. *et al.* Modeling and forecasting of sugarcane production in India. **Sugar Tech**, v. 23, n. 6, p. 1317-1324, 2021.

MORIYA, É. A. S.; IMAI, N. N.; TOMMASELLI, A. M. G. Avaliação do potencial de índices de vegetação para detecção de doença na cana-de-açúcar em imagens hiperespectrais adquiridas por VANT. In: **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto – SBSR**. Santos: INPE, p. 886-893, 2017.

OLIVEIRA, C. G. *et al.* Desvio padrão e imprecisão de leitura: Paquímetro. **Caderno de Graduação-Ciências Exatas e Tecnológicas-UNIT-SERGIPE**, v. 5, n. 3, p. 27-27, 2019.

OLIVEIRA, M. M. A. DE. **Raquitismo-das-soqueiras: métodos de diagnose, influência da idade da cana-de-açúcar para detecção e efeito da termoterapia em dois títulos de Leifsonia xyli subsp. xyli**. 2021. Monografia – Departamento de Engenharia Agrônômica, Universidade Federal de São Carlos, 2021.

PANDEY, S. *et al.* Discrimination of sugarcane crop and cane yield estimation using Landsat and IRS resourcesat satellite data. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS)**, v.42, n.3, p. 229-233, 2019.

QGIS Development Team. QGIS Geographic Information System. **Open-Source Geospatial Foundation Project**, 2019. Disponível em: <http://www.qgis.org>. Acesso em: 25 nov. 2021.

ROUSE, J. W. *et al.* **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Texas: A&M University, 1974.

SANCHES, G.M. *et al.* The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields. **International journal of remote sensing**, v. 39, n. 15-16, p. 5402-5414, 2018.

SANTOS, A. DA S. *et al.* Previsão e construção de indicadores operacionais da produção de cana-de-açúcar por meio de séries temporais. In: **Anais do XII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. SBC, p. 117-126, 2021.

SANTOS, M. A. G.; PEREIRA FILHO, W.; KUPLICH, T. M. Correlação entre índices de vegetação gerados a partir de dados de espectroradiômetro. **XIX Simpósio Brasileiro de Sensoriamento Remoto**, Santos, p. 3031-3033, 2019.

SANTOS, O. L. DOS; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v. 14, n. 1, p. 145-165, 2018.

SILVA, L. G.; GALVÍNCIO, J. D. Análise Comparativa da Variação nos Índices NDVI e SAVI no Sítio PELD-22, em Petrolina-PE, na Primeira Década do Século XXI. **Revista Brasileira de Geografia Física**, v. 5, n. 6, p. 1446-1456, 2012.

SILVA, T. G. F. *et al.* Variação do balanço de radiação e de energia da cana-de-açúcar irrigada no semiárido brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, p. 139-147, 2011.

SOM-ARD, J. *et al.* Pre-harvest sugarcane yield estimation using UAV-based RGB images and ground observation. **Sugar Tech**, v. 20, n. 6, p. 645-657, 2018.

SUMESH, K. C.; NINSAWAT, S.; SOM-ARD, J. Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. **Computers and Electronics in Agriculture**, v. 180, p. 105903, 2021.

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on UAV-based applications for precision agriculture. **Information**, v. 10, n. 11, p. 349, 2019.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

UPENDAR, K. *et al.* Greenness identification using visible spectral colour indices for site specific weed management. **Plant Physiology Reports**, v. 26, n. 1, p. 179-187, 2021.

WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

XU, J. *et al.* Spatial pattern analysis of Haloxylon ammodendron using UAV imagery- A case study in the Gurbantunggut Desert. **International Journal of Applied Earth Observation and Geoinformation**, v. 83, p. 101891, 2019.

XUE, J.; SU, B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, v. 2017, 2017.

7 CONSIDERAÇÕES FINAIS

A aplicação de técnicas e produtos de sensoriamento remoto e aerofotogrametria em imagens obtidas por meio câmeras RGB a bordo de veículos aéreos não tripulados (VANT's) para cultivos agrícolas tem despertado cada vez mais interesse. Aplicações em agricultura de precisão e na chamada Agricultura 4.0 tem como objetivos tanto o reconhecimento detalhado da área agrícola visando a elaboração de mapas precisos, como também, melhorias no monitoramento da propriedade e dos cultivos visando a tomada de decisões em busca da eficiência na aplicação dos recursos.

No Submédio do Vale do São Francisco, onde se realizam atividades agrícolas altamente tecnificadas, a presença de VANT's tem avançado nas propriedades e, há uma demanda crescente por estudos científicos que possam ser aplicados nas principais culturas, como as espécies frutíferas e a cana-de-açúcar.

A partir da avaliação das metodologias estudadas para detecção remota de árvores e caracterização dos pomares, percebe-se que o monitoramento da população de plantas em áreas agrícolas é imprescindível para acompanhar a produtividade, auxiliar no planejamento e a tomada de decisão. Tradicionalmente, essas informações adquiridas por meio da contagem manual ou automatizada, necessitam de mão de obra especializada, serviços pagos ou métodos mais complexos de identificação de árvores com inteligência artificial. Contudo, conclui-se que a detecção semiautomática de árvores a partir dos softwares acessíveis e metodologias aplicadas nessa pesquisa se mostraram bastante promissoras.

De forma geral, os índices de vegetação se apresentaram como potencial alternativa para o monitoramento da cana-de-açúcar por meio dos sensores RGB de baixo custo a bordo dos VANT's. Estes também podem ser aplicados em outras espécies cultivadas, como mangueira e videira, a partir de novas avaliações de campo.

Os mapas gerados nessa pesquisa apresentaram-se como fonte de informações que possibilitam a verificação da variabilidade espacial das áreas estudadas, fornecendo dados úteis para gestão e manejo adequado da cultura.

Por fim, conclui-se que o sensoriamento remoto aplicado juntamente com uso de veículos aéreos não tripulados para coleta de informações das lavouras, facilitam as tomadas de decisão, o controle da produtividade e permitem conhecer melhor os

canaviais a partir das relações das imagens aéreas com os fenômenos naturais, tais como saúde da planta, falhas de plantio, densidade do plantio, competição e manejo da cultura.

REFERÊNCIAS GERAIS

- ABRAFRUTAS – ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES EXPORTADORES DE FRUTAS E DERIVADOS. **Fruticultura: setor em expansão**, 2018. Disponível em: <https://abrafrutas.org/2018/08/14/fruticultura-setor-em-expansao>. Acesso em: 01 ago. 2021.
- AGISOFT. **Agisoft Metashape. v. 1.5.2**. Petersburg, 2021. Disponível em: <https://www.agisoft.com>. Acesso em: 25 nov. 2021.
- ANDRADE, J. B. de. Fotogrametria. **Curitiba: SBEE**, v. 258, 1998.
- ARAI, K. *et al.* Method for NIR Reflectance Estimation with Visible Camera Data based on Regression for NDVI Estimation and its Application for Insect Damage Detection of Rice Paddy Fields. **International Journal of Advanced Research in Artificial Intelligence**, v. 5, n. 11, 2016.
- ASP - AMERICAN SOCIETY OF PHOTOGRAMMETRY. **Definitions of terms used in Photogrammetric Surveying and Mapping**: preliminary report. Photogrammetric Engineering, v. 8, n. 4, p. 247-283, 1942.
- BARBOSA, G DOS S.; LIMA, J. R. F. DE; FERREIRA, M. DE O. Tipificação de produtores por nível de inovação: análise na fruticultura do vale do São Francisco. **Revista de Economia e Agronegócio**, v. 18, n. 3, p. 1-21, 1 jul. 2021.
- BENDIG, J. *et al.* Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.
- BRITO, J. L. N. e S.; COELHO FILHO, L. C. T. **Fotogrametria Digital**. Rio de Janeiro: EdUERJ, 2007.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A.M. **Introdução à Ciência da Geoinformação**. São José dos Campos: Divisão de Processamento de Imagens (DPI) e Instituto Nacional de Pesquisas Espaciais (INPE), p.324, 2001.
- CAMARGO-NETO, J. A. **Combined Statistical-Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems**. 2004. 170 f. Dissertação (Mestrado) – Departamento de Engenharia de Sistemas Agrícolas e Biológicos, University of Nebraska, Lincoln, 2004.
- CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. 5º ed. New York: The Guilford Press, 2011.
- CHUVIECO, E. Teledetección ambiental: La observación de la Tierra desde el espacio. **Editora Ariel Ciencia**, 2002.
- COELHO, A. M. Agricultura de precisão: manejo da variabilidade espacial e temporal dos solos e culturas. **Sete Lagoas: Embrapa Milho e Sorgo**, 2005.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Boletim técnico sobre a safra da cana 2020/21**. Disponível em: <https://www.conab.gov.br/info-agro/safras/cana>. Acesso em: 02 ago. 2021.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Programa de Modernização do Mercado Hortigranjeiro (Prohort)**, 2020. Disponível em: <http://dw.prohort.conab.gov.br/pentaho/Prohort>. Acesso em: 10 jan. 2020.

CONRAD, O. *et al.* System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. **Geoscientific Model Development**, v. 8, n. 7, p. 1991-2007, 2015.

COWELL, R. N. History and place of photographic interpretation II. In: **Manual of photographic interpretation**, 1997.

CRABBÉ, A. H. *et al.* **Tree Density Calculator Software**, v. 1.5.3. 2020. Disponível em: <https://bitbucket.org/kul-reseco/localmaxfilter>. Acesso em: 25 nov. 2021.

CRUZAN, M. B. *et al.* Small unmanned aerial vehicles (micro-UAVs, drones) in plant ecology. **Applications in Plant Sciences**, v. 4, n. 9, p. 1600041, 2016.

CUNHA, A. A. *et al.* Controle de qualidade posicional de ortofoto gerada pelo RPA (Remotely Piloted Aircraft) Phantom 3 com receptor GNSS embarcado. In: **COBRAC**, 2016.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo–SP usando imagens LANDSAT-5. **Raega-O Espaço Geográfico em Análise**, v. 21, p. 234-271, 2011.

DEMARTELAERE, A. C. F. *et al.* Utilização de extratos no controle da antracnose em pós-colheita de *Mangifera indica* / Extracts utilization to control postharvest anthracnose in *Mangifera indica*. **Brazilian Journal of Development**, v. 7, n. 1, p. 4872–4892, 20 jan. 2021.

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. Boca Raton: CRC Press, 2017.

EASTMAN, J. R. **IDRISI Andes: Guide to GIS and Image Processing**. 1º ed. Worcester: Clark University, p.327, 2006.

ESCADAFAL, R.; HUETE, A. Etude des propriétés spectrales des sols arides appliquée à l'amélioration des indices de végétation obtenus par télédétection. **Comptes rendus de l'Académie des sciences. Série II. Mécanique, Physique, Chimie, Sciences de l'univers, Sciences de la Terre**. v. 312, n. 11, p. 1385-1391, 1991.

ESPERIDIÃO, T. L.; SANTOS, T. C. DOS; AMARANTE, M. DOS S. Agricultura 4.0: agricultura 4.0: software de gerenciamento de produção. **Revista Pesquisa e Ação**, v. 5, n. 4, p. 122-131, 2019.

GAIDA, W. *et al.* Correção atmosférica em sensoriamento remoto: uma revisão. **Revista Brasileira de Geografia Física**, v. 13, n. 01, p. 229-248, 2020.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, v. 58, n. 3, p. 257-266, 1996.

GARCIA, G. J. **Sensoriamento remoto: princípios e interpretação de imagens**. Nobel, 1982.

GIOVANINI, A. **Ortomosaico, ortorretificação e ortofoto: o que são?**. Blog, 2021a. Disponível em: <https://adenilsongiovanini.com.br/blog/ortomosaico-ortorretificacao-e-ortofoto-o-que-sao>. Acesso em: 12 nov. 2021a.

GIOVANINI, A. **GSD: o que é e quais valores utilizar?**. Blog, 2021b. Disponível em: <https://adenilsongiovanini.com.br/blog/gsd-descubra-o-que-e>. Acesso em: 02 ago. 2021b.

GITELSON, A. A. *et al.* Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v.80, n.1, p.76-87, 2002.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, 1996.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Blog, 2016. Disponível em: <http://www.deeplearningbook.org>. Acesso em: 12 nov. 2021.

HERREROS, J.L.E. Los drones y sus aplicaciones a la ingeniería civil. **Madrid: Fundación de la Energía de la Comunidad de Madrid**, p.237, 2015.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p.205-309, ago. 1988.

HUNT, E. R. *et al.* Remote sensing leaf chlorophyll content using a visible band index. **Agronomy journal**, v. 103, n. 4, p. 1090-1099, 2011.

HYSLOP, K. *et al.* Avaliação de diferentes Modelos Digitais de Superfície (MDS) na delimitação da bacia hidrográfica do Rio Piririm-AP utilizando o software Invest. In: Embrapa Territorial-Artigo em anais de congresso (ALICE). In: **Congresso interinstitucional de iniciação científica**, Campinas: Embrapa Informática Agropecuária, 2020.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Sistema IBGE de Recuperação Automática (SIDRA): Produção agrícola municipal**, 2018. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>. Acesso em: 24 nov. 2021.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Sistema IBGE de Recuperação Automática (SIDRA): Levantamento sistemático da produção**

agrícola, 2020. Disponível em: <https://sidra.ibge.gov.br/tabela/6588>. Acesso em: 24 nov. 2021.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective**. 2º ed. Bergen: Pearson Prentice Hall, 2014.

KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.

KONECNY, G. **Geoinformation: remote sensing, photogrammetry and geographic information systems**. Boca Raton: CRC Press, 2014.

LADWING, N. I. *et al.* Sistemas de Informação Geográfica. **Editora Unisul Virtual**, 2011.

LAMPARELLI, R. A. C.; ROCHA, J. V.; BORGHI, E. Geoprocessamento. Agricultura de precisão. **Brasília: Agência Embrapa de Informação Tecnológica**, 2016.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and image interpretation**. 3º ed. Nova Jersey: John Wiley & Sons, 1994.

LOPES, A. S. **Emissões de gases de efeito estufa em cana-de-açúcar fertirrigada por gotejamento subsuperficial**. 2017. 78 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal do Vale do São Francisco, 2017.

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, n. 1, p. 65-70, 2001.

MAINARDI, L.C. **Viabilidade de utilização de técnicas de agricultura de precisão na lavoura orizícola**. 2015. 75 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Agricultura de Precisão, Universidade Federal de Santa Maria, 2015.

MANFREDA, S. *et al.* On the Use of Unmanned Aerial Systems for Environmental Monitoring. **Remote Sensing**, v. 10, n. 4, p. 641, abr. 2018.

McFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International journal of remote sensing**, v. 17, n. 7, p. 1425-1432, 1996.

MELLO, L. M. R. Panorama da produção de uvas no Brasil. Nota Técnica: Embrapa Uva e Vinho. **Campo & Negócio**, p. 75-78, 2018.

MELO, D. H. *et al.* Evolução da observação da terra por Sensoriamento Remoto. **Revista Brasileira de Sensoriamento Remoto**, v. 2, n. 2, 2021.
MENDONÇA, F. N. **Deteccção de linhas de plantio da cana de açúcar por meio de veículo aéreo não tripulado**. 2019. 63 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Agronomia, Universidade Estadual Paulista, 2019.

MENEZES, L. DE S.; SANTOS, M. R. R.; SENRA, A. S. Fotointerpretação obtida por aeronave remotamente pilotada (RPA) aplicada em mapeamento litoestrutural de escala 1:800, afloramento do domínio Macururé, município de Capela-SE.

Geosciences = Geociências, v. 38, n. 2, p. 483–493, 20 ago. 2019.

MEYER, G. E.; HINDMAN, T. W.; LAKSMI, K. Machine vision detection parameters for plant species identification. In: **Precision agriculture and biological quality**. SPIE, 1998. p. 327-335.

MIRANDA, R.Q. **Avaliação integrada da variação espacial e temporal do balanço hídrico na Caatinga**. 2017. 123 f. Tese (Doutorado) – Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente, Universidade Federal de Pernambuco, 2017.

MOLIN, J. P. Desafios da agricultura brasileira a partir da agricultura de precisão. **Piracicaba: Simpósio sobre rotação soja/milho no plantio direto**, 2002.

NASA - NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **Tour of the electromagnetic spectrum**. 3ª ed. Washington: NASA, 2016.

NETO, M. S. **Planejamento de voo: tudo o que você precisa saber**. Droneng, 2015. Disponível em: <http://droneng.com.br/planejamento-de-voo>. Acesso em: 12 nov. 2021.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. 2º ed. São Paulo: Edgard Blucher, v. 308, 2010.

OLIVEIRA, A. J. *et al.* Potencialidades da utilização de drones na agricultura de precisão. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140-64149, 2020.

OLIVEIRA, P. D. D. DE. Situação econômica da fruticultura irrigada no submédio do São Francisco: avaliação dos últimos anos. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 7, n. 6, p. 823–842, 30 jun. 2021.

ONU - ORGANIZAÇÃO DAS NAÇÕES UNIDAS. Adopts the Principles Relating to Remote Sensing of the Earth from Space set forth in the annex to the resolution. **Resolutions and Decisions**, 95th plenary. New York: ONU, 1986. Disponível em: <https://digitallibrary.un.org/record/126423>. Acesso em: 8 de agosto de 2021.

PINTO, L. de M. **Altimetria com topografia convencional e sensoriamento remoto**. 2012. 96 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Geomática, Universidade Federal de Santa Maria, 2012.

PONTES, L. B.; CAVICHIOLI, F. A. Agricultura de precisão: uma ferramenta eficaz para o produtor rural. **Taquaritinga: V SIMTEC – Simpósio de Tecnologia**, 2018.

PONTI, M. P. Segmentation of low-cost remote sensing images combining vegetation indices and mean shift. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 1, p. 67-70, 2012.

QGIS Development Team. QGIS Geographic Information System. **Open-Source Geospatial Foundation Project**, 2019. Disponível em: <http://www.qgis.org>. Acesso em: 25 nov. 2021.

RABELLO, L. M.; BERNARDI, A. C. C.; INAMASU, R. Y. Condutividade elétrica aparente do solo. In: Bernardi, A.C.C.; Naime, J.M.; Resende, A.V.; Bassoi, L.H.; Inamasu, R.Y. **Agricultura de precisão: resultados de um novo olhar**. Brasília: Embrapa, 2014.

REICHHARDT, T. The first photo from space. **Air and Space Magazine**, v. 24, 2006.

RISSINI, A. L. L.; KAWAKAMI, J.; GENÚ, A. M. Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, v. 39, n. 6, p. 1703-1713, 2015.

RODRIGUES, M. T.; RODRIGUES, B. T. Aplicação do índice da vegetação por diferença normalizada (NDVI) em imagens CBERS 2B no município de Botucatu-SP. **Revista Brasileira de Engenharia de Biosistemas**, v. 6, n. 3, p. 139-147, 2012.

ROUSE, J. W. *et al.* **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Texas: A&M University, 1974.

RUY, R. da S. **Desenvolvimento e validação geométrica de um sistema para mapeamento com câmeras digitais de médio formato**. 2008. 246 f. Tese (Doutorado) – Programa de Pós-Graduação em Ciências Cartográficas, Universidade Estadual Paulista, 2008.

SABINS, F. F. **Remote Spensing: Principles and Interpretations**. 3º ed. New York: W. H. Freeman, 1996.

SANTOS, A. DA S. *et al.* Previsão e construção de indicadores operacionais da produção de cana-de-açúcar por meio de séries temporais. In: **Anais do XII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. SBC, p. 117-126, 2021.

SANTOS, O. L. DOS; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v. 14, n. 1, p. 145-165, 2018.

SILVA, F. B.; DE ALMEIDA, L. T.; VIEIRA, E. DE O. Impacto da agricultura irrigada na potência hidrelétrica instalada na bacia do rio São Francisco. **Revista Augustus**, v. 24, n. 49, p. 305-319, 2019.

SILVA JÚNIOR, E. E. de A. **Geotecnologias e planejamento urbano: proposta metodológica e avaliação de dados obtidos por Aeronaves Remotamente Pilotadas (RPA) como contribuição à cartografia geotécnica**. 2019. Tese (Doutorado) – Programa de Pós-Graduação em Geotecnia, Universidade de Brasília, 2019.

SILVA, G. C. **Detecção e contagem de plantas utilizando técnicas de inteligência artificial e machine learning**. 2018. Monografia – Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, 2018.

SILVA, J. F. A. A. **Classificação Automática de Imagens Aéreas Multiespectrais para Agricultura de Precisão**. 2021. 100 f. Dissertação (Mestrado) – Mestrado em Engenharia Eletrotécnica e Computadores, Universidade Nova Lisboa, 2021.

SILVA, J. F. *et al.* Remote sensing vegetation index for processing images in the visible band (RGB). **Journal of Hyperspectral Remote Sensing**, v.9, n.4, 228-239, dez. 2019.

SANTOS DA SILVA, L. **Fotogrametria com imagens adquiridas com Drones: do Plano de Voo ao Modelo 3D**. Ebook. p.59, 2018.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

WOLF, P. R. **Elements of photogrammetry**. New York: Mc Graw-Hill, 1995.

WOLF, P. R.; DEWITT B. A.; WILKINSON, B. E. **Elements of Photogrammetry with Applications in Gis**. 4^o ed. Nova York: Mc Graw Hill, 2014.

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International journal of remote sensing**, v. 27, n. 14, p. 3025-3033, 2006.