



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.11.12.18-TDI

SENSORIAMENTO REMOTO POR VANT E ORBITAL NO ESTUDO DA CANA-DE-AÇÚCAR: VOLUMETRIA E ZONAS DE MANEJO

Gabriela Zoli Simões

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Hermann Johann
Heinrich Kux, e Fábio Marcelo
Breunig, aprovada em 10 de agosto
de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/458LTA2>>

INPE
São José dos Campos
2021

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.11.12.18-TDI

SENSORIAMENTO REMOTO POR VANT E ORBITAL NO ESTUDO DA CANA-DE-AÇÚCAR: VOLUMETRIA E ZONAS DE MANEJO

Gabriela Zoli Simões

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Hermann Johann
Heinrich Kux, e Fábio Marcelo
Breunig, aprovada em 10 de agosto
de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/458LTA2>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Simões, Gabriela Zoli.
Si51s Sensoriamento remoto por VANT e orbital no estudo da cana-de-açúcar: volumetria e zonas de manejo / Gabriela Zoli Simões.
– São José dos Campos : INPE, 2021.
xviii + 70 p. ; (sid.inpe.br/mtc-m21d/2021/08.11.12.18-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientadores : Drs. Hermann Johann Heinrich Kux, e Fábio Marcelo Breunig.

1. Agricultura de precisão. 2. VANTs. 3. Zonas de manejo.
4. Sensores orbitais. I.Título.

CDU 528.8:633.61



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**
Serviço de Pós-Graduação - SEPGR**DEFESA FINAL DE DISSERTAÇÃO DE GABRIELA ZOLI SIMÕES**
BANCA Nº 205/2021, REG 411886/2019

No dia 10 de agosto de 2021, às 09h00min, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestra em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

Título: “SENSORIAMENTO REMOTO POR VANT E ORBITAL NO ESTUDO DA CANA-DE-AÇÚCAR: VOLUMETRIA E ZONAS DE MANEJO”

Observações da banca: O aluno terá 60 (sessenta dias) para efetuar as correções sugeridas pelos membros da banca.

Membros da banca:

Dra. Cláudia Maria de Almeida - Presidente - INPE
Dr. Hermann Johann Heinrich Kux - Orientador - INPE
Dr. Fábio Marcelo Breunig - Orientador - UFSM
Dra. Ieda Del'Arco Sanches - Membro Interno - INPE
Dr. Luiz Henrique Pereira - Membro Externo - IDGeo



Documento assinado eletronicamente por **Ieda Del Arco Sanches, Chefe da Divisão de Pós-Graduação**, em 11/08/2021, às 07:45 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Cláudia Maria de Almeida, Pesquisador**, em 11/08/2021, às 09:51 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **LUIZ HENRIQUE PEREIRA (E), Usuário Externo**, em 13/08/2021, às 08:21 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Hermann Johann Heinrich Kux, Pesquisador**, em 17/08/2021, às 11:34 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Marcelo Breunig (E), Usuário Externo**, em 24/08/2021, às 10:36 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7971397** e o código CRC **4000446C**.

Referência: Processo nº 01340.005194/2021-84

SEI nº 7971397

AGRADECIMENTOS

Agradeço, inicialmente, a minha família, principalmente a meus pais, Silmar e Maria Hilda, por sempre me apoiar e incentivar em todos os momentos.

Aos meus orientadores, Dr. Hermann Kux e Dr. Fábio Breunig, pela confiança depositada em mim e por todo o conhecimento compartilhado e apoio durante essa jornada. Ao Luiz Henrique e a IDGeo pela parceria que tornou esse trabalho possível.

Aos demais membros da banca, Dra. Cláudia Maria de Almeida e Dra. Ieda Del'Arco Sanches, por terem aceitado e se disponibilizado a contribuir e acrescentar ideias e sugestões para o enriquecimento deste trabalho.

Ao Programa de Pós-Graduação do Instituto Nacional de Pesquisas Espaciais (INPE), e à todos os professores e demais servidores, que contribuíram para meu crescimento pessoal e profissional.

O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil, bem como da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes).

RESUMO

O objetivo deste trabalho foi investigar o potencial de sensores imageadores a bordo de um veículo aéreo não tripulado (VANT) e de sistemas sensores orbitais para o monitoramento de variáveis biofísicas e bioquímicas da cana-de-açúcar na região de Ribeirão Preto (SP). Para tanto, foram feitas estimativas de altura dos dosséis e da produtividade dos talhões, avaliando a sua relação com os índices de vegetação (NDVI e EVI) em diferentes resoluções espaciais (3 m, 10 m e 30 m) e temperatura/emissividade do dossel. Para estimar a altura do dossel, foram adquiridas imagens RGB de VANT ao longo do período de crescimento da cana-de-açúcar na safra de 2019/2020, as quais foram utilizadas para criar modelos de superfície e terreno por meio da técnica *SfM*. A altura estimada foi obtida pela subtração entre o MDS e MDT e, a partir dela, calculou-se a taxa de crescimento da cana nesse período. A produtividade e a produção total foram estimadas pelo método da volumetria, para o qual foi usada a altura estimada no último período imageado. O cálculo dos índices foi efetuado com imagens dos satélites PlanetScope, Sentinel-2 e Landsat 8, adquiridas o mais próximo possível da data do imageamento com o VANT. Para a análise de correlação espacial, o coeficiente de Pearson foi calculado entre as alturas estimadas, os Índices de Vegetação, e temperatura e emissividade, sendo um ponto selecionado para avaliar se há correlação temporal entre a altura e os IVs. Os dados de temperatura e emissividade foram obtidos do sensor ASTER. Por fim, foram construídos mapas de zonas de manejo pelo método de McQuitty e *k-means*, usando informações da taxa de crescimento e IVs. Os modelos de altura retrataram as fases de crescimento da cana, permitindo a identificação de falhas no plantio e regiões com menor crescimento, no entanto, o uso de GCP ou RTK poderiam minimizar os erros e melhorar a qualidade dos modelos. A altura estimada não apresentou correlação espacial com os IVs. Nem a temperatura ou a emissividade apresentaram correlação com a altura, todavia dados com maior resolução espacial poderiam trazer melhores resultados. Quanto às Zonas de Manejo, todos os sensores orbitais tiveram bons resultados. Tanto o método, quanto as variáveis de entrada influenciaram nos resultados, sendo recomendada o uso de duas ZMs, tendo como variáveis o NDVI e a taxa de crescimento e o método de *k-means*, que possibilitou criar zonas mais homogêneas, sendo a validação com dados de campo fundamental para uma avaliação mais precisa dos resultados. Concluímos que o desenvolvimento de metodologias, integrando o uso de dados obtidos por VANTs e sensores orbitais, permitem identificar características nas áreas agrícolas que podem ser aplicadas no gerenciamento de culturas.

Palavras-chave: Agricultura de precisão. VANTs. Zonas de manejo. Sensores orbitais.

REMOTE SENSING BY UAV AND ORBITAL IN THE STUDY OF SUGARCANE: VOLUMETRY AND MANAGEMENT ZONES

ABSTRACT

This work aimed to investigate the potential of imaging sensors on board unmanned aerial vehicles (UAVs) and orbital systems to monitor biophysical and biochemical variables of sugarcane in SE Brazil. For this purpose, estimates of the height of the canopies and the yield were made, evaluating their relationship with vegetation indices (NDVI and EVI) in different spatial resolutions (3 m, 10 m and 30 m) and temperature/emissivity of the canopy. To estimate canopy height, RGB images of UAV were acquired during the sugarcane growth period in the 2019/2020 harvest, which were used to create surface and ground models using the *SfM* technique. The estimated height was obtained by subtraction between the DSM and DTM. The estimated height in each period allowed to calculate the growth rate of the sugarcane in this period. Yield and the total production were estimated by the volumetric method, which used the height estimated in the last imaged period. In order to calculate the indices, images from the PlanetScope, Sentinel-2 and Landsat 8 satellites were used, acquired as close as possible to the date of the UAV flight. For spatial correlation analysis, Pearson's coefficient was calculated between the estimated heights, the VIs and temperature and emissivity. A point was selected in order to evaluate the existence of a temporal correlation between height and VIs. Temperature and emissivity data were obtained from the temperature and emissivity products of the ASTER sensor. Finally, maps of management zones were constructed using the McQuitty and k-means method, using information on growth rate and vegetation indices. The height models portrayed the growth phases of sugarcane, allowing the identification of failures in the plantation and regions with lower growth, however, the use of GCP or RTK could minimize errors and improve the quality of the models. The estimated height did not present a spatial correlation with the VIs. Neither temperature nor emissivity showed correlation with height, however data with higher spatial resolution could improve the results. As for the Management Zones, all spatial resolutions showed good results. Both methods, as well as the input variables influenced the results, recommending the use of two MZs, considering as variables the NDVI and growth rate and the k-means method, which created more homogeneous zones. However, the validation with field data is of fundamental importance for a more accurate evaluation of the results. Therefore, we conclude that it is possible to develop methodologies, integrating the use of data from UAVs and orbital sensors data, which are capable of identifying characteristics of agricultural areas that can be applied to crop management.

Keywords: Precision agriculture. UAVs. Management zones. Orbital sensors.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 Curva espectral de uma folha verde sadia.	9
Figura 2.2 - Esquema das aplicações dos VANTs na agricultura de precisão ao longo de uma estação de crescimento.	14
Figura 2.3 – Estágios de desenvolvimento da cana-de-açúcar.	19
Figura 3.1 – Localização da área de estudo.	21
Figura 3.2 - Pluviosidade mensal e temperatura média medida pela estação meteorológica localizada em Pradópolis-SP ao longo de out/2019 a set/2020.	22
Figura 3.3 – Área de estudo (em destaque) e região ao entorno.	23
Figura 3.4 – Fluxograma geral do estudo.	26
Figura 3.5 – Ortomosaicos da área de estudo em cada data analisada.	27
Figura 3.6 - Representação esquemática das etapas para obtenção da altura estimada.	28
Figura 3.7 – Figura esquemática para delineamento das zonas de manejo. ...	32
Figura 4.1 - Desempenho dos modelos para estimar a altura da cana-de-açúcar durante três estágios de desenvolvimento. Resultados obtidos a partir de 500 amostras aleatórias em cada data.	34
Figura 4.2 - Modelos de altura criados a partir da técnica SfM. DATUM: WGS 84 Projeção: UTM Zona 22 Sul.	35
Figura 4.3 - Mapa de taxa de variação da altura, considerando a resolução espacial de 0,10 m (Phantom 4).	36
Figura 4.4 - Valores dos índices de vegetação vs. altura estimada em cada data: (a) dezembro/2019, (b) junho/2020, (c) julho/2020 e (d) setembro/2020. 500 amostras obtidas do satélite PlanetScope.	38
Figura 4.5. Variação temporal dos valores dos índices de vegetação NDVI e EVI e altura estimada em um ponto central do talhão na resolução espacial de 3 m.	39
Figura 4.6 - Mapa de temperatura da cana-de-açúcar com 100 m de resolução espacial obtidos do sensor ASTER em 10 de set. 2020.	41

Figura 4.7 - Matrizes de dissimilaridade entre a) taxa de crescimento e NDVI e b) taxa de crescimento e EVI.	43
Figura 4.8 - Gráficos de dispersão entre taxa de crescimento e NDVI para o método de McQuitty.	45
Figura 4.9 - Gráficos de dispersão entre taxa de crescimento e NDVI para o método de <i>k-means</i>	46
Figura 4.10 - Mapa de zonas de manejo, com as variáveis NDVI e taxa de crescimento, geradas a partir do método de McQuitty.	48
Figura 4.11 - Mapa de Zonas de Manejo, com as variáveis NDVI e taxa de crescimento, geradas a partir do método <i>k-means</i>	49
Figura 4.12 - Gráficos de dispersão entre taxa de crescimento e EVI para o método de McQuitty.	51
Figura 4.13 - Gráficos de dispersão entre taxa de crescimento e EVI para o método <i>k-means</i>	52
Figura 4.14 - Mapa de zonas de manejo, com as variáveis EVI e taxa de crescimento, geradas a partir do método de McQuitty.	53
Figura 4.15 - Mapa de zonas de manejo, com as variáveis EVI e taxa de crescimento, geradas a partir do método <i>k-means</i>	54

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 – Características da área de estudo.	23
Tabela 3.2 - Especificações técnicas do Phantom 4.	24
Tabela 3.3 – Especificações técnicas de plataformas orbitais usadas.	25
Tabela 3.4 – Faixas espectrais bandas do produto de emissividade (AST_05 v003) do sensor ASTER.	25
Tabela 4.1 – Valores da correlação de Pearson entre a altura estimada e os índices de vegetação para cada data em três resoluções espaciais diferentes.....	37
Tabela 4.2 – Resultado da análise de correlação entre temperatura e emissividade em diferentes faixas espectrais com a altura estimada para 100 m de resolução espacial relativos a 10 set. 2020.	42
Tabela 4.3 – Resultados da avaliação dos métodos de <i>clustering</i> em diferentes resoluções espaciais na geração de 2, 3 e 4 zonas de manejo em termos da silhueta média (ASC) e ANOVA (teste Tukey) para o NDVI e taxa de crescimento como dados de entrada.	47
Tabela 4.4 - Resultados da avaliação dos métodos de <i>clustering</i> em diferentes resoluções espaciais na geração de 2, 3 e 4 zonas de manejo em termos da silhueta média (ASC) e ANOVA (teste Tukey) para o EVI e taxa de crescimento como dados de entrada.	52

LISTA DE SIGLAS E ABREVIATURAS

ASC	<i>Average Silhouette Coefficient</i> (Coeficiente de Silhueta Médio)
CS	Coeficiente de Silhueta
EVI	<i>Enhanced Vegetation Index</i> (Índice de Vegetação Melhorado)
GCP	<i>Ground Control Points</i> (Pontos de Controle em Solo)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
IPVI	<i>Infrared Percentage Vegetation Index</i> (Índice de Vegetação da Porcentagem do Infravermelho)
IV	Índice de Vegetação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
NDVI	<i>Normalized Difference Vegetation Index</i> (Índice da Diferença Normalizada)
NIR	<i>Near Infrared</i> (Infravermelho Próximo)
RTK	<i>Real Time Kinematic</i> (Cinemática em Tempo Real)
SfM	<i>Structure from Motion</i>
SIFT	<i>Scale-Invariant Feature Transform</i>
SURF	<i>Speeded-up Robust Features</i>
TVI	<i>Transformed Vegetation Index</i> (Índice de Vegetação Transformado)
VANT	Veículo Aéreo não Tripulado
ZM	Zonas de Manejo

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos	3
1.1.1 Objetivo geral.....	3
1.1.2 Objetivos específicos	3
2 REFERENCIAL TEÓRICO.....	5
2.1 Agricultura de precisão	5
2.2 Sensoriamento remoto óptico	6
2.2.1 Índices de Vegetação.....	8
2.3 Sensoriamento remoto termal.....	11
2.3.1 Princípios físicos básicos de sensoriamento remoto termal	12
2.4 Sensoriamento remoto na agricultura	13
2.4.1 Sensoriamento remoto termal na agricultura.....	15
2.4.2 Zonas de manejo	16
2.5 Cana-de-açúcar.....	18
3 MATERIAL E MÉTODOS.....	21
3.1 Área de estudo	21
3.2 Base de dados espectrais	24
3.3 Metodologia.....	25
3.3.1 Variação temporal da altura dos dosséis.....	26
3.3.1.1 Aquisição e processamento das imagens de VANT	26
3.3.1.2 Estimativa da altura do dossel	28
3.3.1.3 Análise de dados	29
3.3.2 Cálculo do volume produzido de cana-de-açúcar.....	29
3.3.3 Variação da temperatura no talhão	30
3.3.4 Índices de Vegetação.....	30
3.3.5 Zonas de manejo	31
4 RESULTADOS E DISCUSSÃO	33
4.1 Variação temporal da altura dos dosséis	33
4.2 Estimativa da produção	40
4.3 Análise de temperatura e emissividade da cana-de-açúcar.....	41

4.4 Zonas de manejo.....	42
4.4.1 Análise exploratória dos dados	42
4.4.1.1 Tendência à formação de <i>clusters</i>	42
4.4.1.2 Número ótimo de <i>clusters</i>	43
4.4.2 Criação de zonas de manejo.....	44
4.4.2.1 Taxa de crescimento e NDVI	44
4.4.2.2 Taxa de crescimento e EVI	50
4.4.2.3 Análise dos resultados.....	55
5 CONCLUSÃO	57
REFERÊNCIAS BIBLIOGRÁFICAS.....	59

1 INTRODUÇÃO

A agricultura de precisão vem ganhando cada vez mais espaço no modelo de gestão das lavouras por todo o mundo, tornando-se assim tema recorrente nas pesquisas científicas. Duas causas principais impulsionaram esta prática, a saber: I) o desenvolvimento tecnológico, que da mesma forma que em outros setores, como o industrial, por exemplo, permitiu a melhoria e criação de novas ferramentas, tornando-as mais precisas e inteligentes, o que possibilitou a automatização de diversos processos e aumento da eficiência (ZHANG; WANG; WANG, 2002); II) o aumento da população mundial, que exerce pressão sobre o setor agrícola devido à crescente necessidade de alimentos e outros recursos básicos provenientes do setor agroindustrial, como tecidos e energia (FAO, 2017). Estes fatos, juntamente com a redução das áreas disponíveis para plantio e com o enforque no meio ambiente, geram a necessidade da busca por meios para aumentar a eficiência dos processos agrícolas.

Um exemplo é a cultura da cana-de-açúcar, que representa um importante recurso para a economia brasileira e principalmente para o estado de São Paulo, o maior produtor dessa cultura no país. Além de ser matéria-prima do açúcar, a cana-de-açúcar é recurso fundamental para produção de biocombustíveis e energia no Brasil, devido isso, tem ganhado destaque com a crescente preocupação com as questões ambientais relacionadas ao uso de combustíveis fósseis.

É fato que combustíveis como a gasolina e o diesel são finitos, seja por escassez do petróleo ou por questões legais. Nesse sentido, há o Projeto de Lei nº 304 de 2017 aprovado este ano pela Comissão de Constituição de Justiça (CCJ), que propõe a substituição dos veículos movidos a combustíveis fósseis e dispõe sobre a vedação à sua comercialização e a circulação desses automóveis a partir de 2030 (BRASIL, 2017).

Medidas como esta estão sendo tomadas em várias partes do mundo, provocando o aumento da demanda por biocombustíveis. Contudo, a produção de biocombustíveis compete com a geração de alimentos e com áreas naturais,

devido a disputa por novas áreas para plantio. Assim, medidas que visam melhorar a eficiência das lavouras são imprescindíveis quando se busca a sustentabilidade e com a necessidade de se aumentar a produção mantendo e mesmo diminuindo as áreas plantadas. Por isso é imperativo o desenvolvimento de novas tecnologias visando a evolução da agricultura para novos patamares econômicos e socioambientais.

Segundo dados da CONAB (2020) a produção brasileira de cana-de-açúcar chegou a 642,7 milhões toneladas na safra de 2019/20 aumento de 3,6% em relação à safra anterior. Estando a maior parte desta produção concentrada no estado de São Paulo (342,6 milhões toneladas). Todavia, apesar do aumento de mais de 3% na produção do país, o total de área plantada apresentou decréscimo de 1,7%, prova de que práticas de manejo focadas no aumento da produtividade são fundamentais para o desenvolvimento de uma produção agrícola mais sustentável, capaz de suprir as demandas do mercado com a possibilidade de manutenção ou até redução da área plantada.

O sensoriamento remoto tem um papel de destaque nesta busca por eficiência, por prover informações espaciais e temporais fundamentais para o gerenciamento agrícola (WEISS; JACOB; DUVEILLER, 2020). No entanto, a aplicação de técnicas de sensoriamento remoto nos cultivos de cana-de-açúcar, ao longo dos anos, tem se focado em classificação da cultura e mapeamento das áreas plantadas, identificação do estágio de desenvolvimento por meio de dados termais, discriminação entre variedades, previsão da produção e monitoramento da saúde e estado nutricional da cultura (ABDEL-RAHMAN; AHMED, 2008). Essas análises geralmente são feitas por meio de dados de satélites e voltadas para grandes áreas.

Nos últimos anos as pesquisas nos canaviais têm se voltado para a AP com uso de VANTs e dados adquiridos com sensores orbitais. Dentre as aplicações do sensoriamento remoto na AP, uma de grande interesse ao gerenciamento de culturas agrícolas é o conhecimento sobre a biomassa e previsão da produtividade das lavouras. Historicamente, essas estimativas, em

sensoriamento remoto, têm sido realizadas por meio de índices de vegetação (KROSS et al. 2015; TODD, HOFFER; MILCHUNAS 1998; ZHOU et al. 2017).

Com a popularização dessas práticas, e do aumento de empresas fornecendo “soluções” aos produtores, principalmente devido à popularização dos VANTs, ou drones, se torna essencial conhecer o verdadeiro potencial e as limitações dos sensores remotos embarcados nessas plataformas. Para tanto, são ainda necessárias respostas para questões como: o que estas plataformas e os satélites ainda podem contribuir para a agricultura e quais suas reais vantagens, bem como as novas tecnologias de processamento de imagens junto com os avanços na inteligência artificial permitem avanços na agricultura de precisão e qual o papel do sensoriamento remoto nesse contexto? Tais questões já vêm sendo respondidas ao longo das últimas décadas, porém, há muito a avançar, principalmente, porque as inovações surgem a todo momento.

1.1 Objetivos

1.1.1 Objetivo geral

Dentro desse contexto, o presente trabalho tem por objetivo estudar o potencial do uso de um sensor RGB a bordo de um veículo aéreo não tripulado (VANT) Phantom 4 em conjunto com sistemas sensores orbitais para o monitoramento de variáveis biofísicas e bioquímicas da cana-de-açúcar na região de Ribeirão Preto-SP.

1.1.2 Objetivos específicos

- Estudar a variação temporal da altura dos dosséis da cana-de-açúcar com uso de imagens RGB obtidas pelo VANT Phantom 4.
- Avaliar a variação de temperatura da cana-de-açúcar dentro dos talhões, proveniente do sensor ASTER.
- Avaliar a relação da altura do dossel com os índices de vegetação NDVI e EVI, temperatura/emissividade do dossel.
- Obter estimativa da produção do talhão por meio do cálculo de volumetria.

- Identificar zonas de manejo dentro do talhão utilizando os sensores multiespectrais PlanetScope, Sentinel-2 e Landsat 8, e técnicas de *machine learning*.

2 REFERENCIAL TEÓRICO

2.1 Agricultura de precisão

O termo agricultura de precisão (AP) surgiu na década de 1980 e pode ser definido como um sistema agrícola no qual as práticas de manejo são direcionadas ao local certo, com a intensidade correta e no tempo certo, em vez de tratar as áreas de plantio homoganeamente. Este paradigma proporciona benefícios tanto para o produtor, com a redução dos gastos em insumos agrícolas e o aumento da produtividade, quanto para a sociedade, com a redução de impactos ambientais e a criação de empregos de alta tecnologia (MULLA, 2012).

Um conceito importante dentro da AP, é o conceito de unidades de gestão diferenciada (UGDs). As UGDs podem ser definidas como regiões dentro dos campos de produção que apresentam mínima variabilidade espacial e permanentes ao longo do tempo (MANN; SCHUMANN; OBREZA, 2010). As UGDs permitem reduzir os custos das operações de campo e otimizar a gestão do empreendimento. São, normalmente criadas a partir de mapas de fatores naturais, como parâmetros do solo (tipo, textura, condutividade elétrica), declividade ou informações sobre produtividade (MOLIN; AMARAL; COLAÇO, 2015). As UGDs também são conhecidas na literatura como zonas de manejo (ZMs), um capítulo a parte foi dedicado a este tema.

Portanto, na agricultura de precisão é imprescindível o conhecimento dos fatores que causam as variações espaço-temporais num cultivo. Este enfoque exige a necessidade de uma gama de dados e informações, além de grande capacidade de processamento e análise de dados para tornar os processos mais eficientes (HARMON et al., 2005). Segundo Zhang, Wang e Wang (2002) essas informações podem ser divididas em 6 grupos de variabilidade, que exercem grande influência na produção agrícola, a saber:

1. Produção – histórico do volume produzido
2. Terreno – mudanças da topografia e da declividade

3. Características do solo – fertilidade, condições físicas e químicas, umidade, etc.
4. Características da plantação – densidade de plantio, estresse hídrico e de nutrientes, propriedades biofísicas.
5. Anomalias – pragas e doenças diversas
6. Práticas de manejo – rotação de culturas, fertilizantes, plantio direto, etc.

O desenvolvimento tecnológico é o grande responsável pelo avanço da agricultura de precisão. Tecnologias como Sistemas de Navegação por Satélite (*Global Navigation Satellite System* – GNSS), controles automáticos, computadores portáteis, avanços no processamento das informações, contribuíram significativamente para a melhoria do gerenciamento das lavouras (ZHANG, WANG E WANG, 2002). Neste contexto, o sensoriamento remoto se tornou uma das principais fontes de informação para a agricultura de precisão, por prover dados sistemáticos e informações de forma não-destrutiva (WEISS; JACOB; DUVEILLER, 2020).

2.2 Sensoriamento remoto óptico

Sensoriamento remoto pode ser definido como uma técnica para a aquisição de informações sobre um determinado objeto na superfície terrestre, por meio de sensores e equipamentos de transmissão de dados a bordo de plataformas posicionados distantes do alvo que captam a Radiação Eletromagnética (REM) refletida, emitida ou retroespalhada dos alvos. Essa técnica parte do princípio que todos os materiais da superfície da terra com temperatura superior a 0°K emitem, refletem, transmitem ou absorvem a REM, sendo o Sol e a Terra as principais fontes de energia eletromagnética (EM) (LORENZZETTI, 2015).

O espectro eletromagnético é dividido em faixas de acordo com o comprimento de onda. Para o sensoriamento remoto óptico, as faixas analisadas são as faixas do visível e infravermelho de ondas curtas (ou infravermelho próximo) (0,4 μm a 2,5 μm). Nesse intervalo espectral a quantidade de energia proveniente da luz solar é muito intensa, interagindo com os átomos e moléculas que constituem a matéria, permitindo obter informações sobre seus

componentes físicos/químicos. Os sensores ópticos medem a intensidade do componente de radiância refletida dos objetos, partindo do princípio de que cada material da superfície terrestre reflete, absorve e transmite quantidades particulares de radiação de acordo com suas propriedades (pigmentação, conteúdo de umidade, estrutura celular da vegetação, conteúdo mineral e umidade do solo e quantidade de sedimentos na água) (REES, 2001; RICHARDS; JIA, 2006).

As plataformas de sensoriamento remoto geralmente são classificadas de acordo com suas características, como a altitude do imageamento, que pode ser de solo/campo, aéreo ou espacial, resolução espacial da imagem, tempo de revisita ou resolução temporal, resolução radiométrica e espectral do sensor (MULLA, 2012).

A resolução espacial está ligada ao tamanho do elemento de área imageada no terreno, ela determina o tamanho do menor objeto que pode ser identificado em uma imagem. Ela é determinada por um conjunto de fatores relacionados com o sensor (ex. detectores, distância focal e ângulo de visada) e a altitude da plataforma (MENESES; ALMEIDA, 2012).

A resolução temporal é definida pelo tempo que um mesmo ponto da superfície da Terra leva para ser revisitado. Esse tempo, no caso de sensores orbitais, depende da órbita que o satélite realiza em torno da Terra e da largura da faixa imageada no terreno (MENESES; ALMEIDA, 2012).

A resolução radiométrica pode ser definida como a intensidade de radiância da área de cada pixel medida pelos detectores. Quanto maior for a capacidade de um sensor em medir as diferenças de intensidade nos níveis de radiância, maior sua resolução radiométrica. A intensidade de radiância é convertida pelos detectores em um número digital discreto, o intervalo de número de valores digitais que um sensor é capaz de medir é denominado quantização, que é normalmente expressa em números de dígitos binários (*bits*) (MENESES; ALMEIDA, 2012).

A resolução espectral está relacionada com a quantidade de faixas (bandas) do espectro eletromagnético que um sensor é capaz de capturar. Diferentes

objetos da superfície terrestre apresentam comportamentos diferentes em relação a interação com a REM ao longo do espectro de radiação. Assim, a resolução espectral do sensor é determinada pelo número de bandas que o sensor possui, largura em relação ao comprimento de onda e a posição que essas bandas ocupam no espectro eletromagnético (MENESES; ALMEIDA, 2012).

Todavia, a escolha da plataforma deve levar em conta as necessidades de cada local e a aplicação desejada. Os sistemas orbitais tem a vantagem de cobrirem extensas áreas, proporcionarem cobertura frequente e repetitiva, porém, geralmente têm baixa resolução espacial, além de serem limitados pela cobertura de nuvens (KRISHNA, 2016), no entanto, já existem sensores orbitais comerciais capazes de adquirir imagens com resoluções melhores que 1 m. Sensores de campo não sofrem com interferências de nuvens, e a frequência de aquisição de dados fica a critério do usuário, porém, a aquisição de dados é mais laboriosa e ineficiente em áreas maiores (RUDD; ROBERSON; CLASSEN, 2017). Os VANTs proporcionam dados com alta resolução espacial e temporal e não sofrem tanto com a presença de aerossóis na atmosfera, porém, podem ter maior custo inicial e de processamento das imagens, aumentando o custo por unidade de área (KRISHNA, 2016). Contudo, uma forma de superar tais desafios é com o uso de múltiplas plataformas para adquirir informações do objeto de interesse, aprimorando, assim, a capacidade de observação (TOTH; JÓŰKÓW, 2016).


2.2.1 Índices de Vegetação

O sensoriamento remoto da vegetação se baseia, principalmente, na aquisição de informações das ondas do espectro eletromagnético refletidas pela vegetação (XUE; SU, 2017). A refletância da vegetação varia de acordo com o tipo de planta, conteúdo de água nos tecidos e outros fatores intrínsecos, como as características químicas e morfológicas dos tecidos e folhas. O comprimento de onda também tem influência na quantidade de luz absorvida, refletida e transmitida pelas folhas, devido à absorção seletiva dos pigmentos nela contidos (KUMAR et al., 2002).

Na região do visível do espectro eletromagnético, a vegetação apresenta baixa reflectância e transmitância, devido à forte absorção pelos pigmentos foliares, principalmente a clorofila, responsável pelo processo da fotossíntese. Exceção a isso é o comprimento de onda do verde, que apresenta a menor absorção na faixa do visível. Enquanto na região do infravermelho próximo, a reflectância e transmitância das plantas são altas, pois os níveis de energia nesse espectro não são tão fortes para as reações fotossintéticas, e assim, são menos absorvidos pelos pigmentos (KUMAR et al., 2002) (Figura 2.1).

Levando em consideração o comportamento espectral da vegetação, foram desenvolvidos os índices de vegetação (IVs). Os IVs são transformações espectrais de duas ou mais bandas com função de realçar as propriedades da vegetação numa imagem de satélite, permitindo o monitoramento espaço-temporal da cobertura de vegetação, atividade fotossintética, variações estruturais e fisiológicas, além de parâmetros biofísicos da vegetação (HUETE, et al. 2002; XUE; SU, 2017). Por serem simples transformações entre bandas espectrais, os IVs independem da cobertura e do tipo de solo ou das condições climáticas (HUETE, et al. 2002).

Figura 2.1 Curva espectral de uma folha verde sadia.



Fonte: Adaptado de Novo (2010).

Vários índices de vegetação foram desenvolvidos ao longo dos anos para diversas aplicações, sendo as mais comuns na agricultura, a estimativa de biomassa e produção e obtenção do índice de área foliar (WANG; LIU; LIU; FU; YU; XUE, 2018; ZHOU et al., 2017; RICHETTI et al., 2019; ZHANG; GE; SHEN; LI; LIU; CAO; ZHU; CAO; TIAN, 2019). Todavia, o Índice Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) , continua sendo o mais utilizado em aplicações agrícolas. Este índice corresponde à razão normalizada entre as bandas do vermelho e infravermelho próximo e apresenta boa correlação com parâmetros da vegetação, como biomassa, clorofila, índice de área foliar (TUCKER, 1979), produtividade (GOWARD; DYE, 1987), crescimento e densidade de distribuição espacial (PUREVDORJ; TATEISHI; ISHIYAMA; HONDA, 1998).

Os valores de NDVI variam de -1 a 1, em que -1 significa a ausência total de vegetação e 1 a cobertura total da superfície por vegetação. Isto porque a clorofila presente nas folhas, bem como em outros pigmentos absorvem, uma grande proporção da luz visível no espectro do vermelho, e as células mesofílicas das folhas verdes saudáveis refletem a radiação no infravermelho próximo (NIR) (TUCKER, 1979). A clorofila reflete cerca de 20% da luz no espectro do vermelho e cerca de 60% no (NIR), assim, o contraste entre as respostas dessas duas bandas permite quantificar a energia absorvida pela clorofila, o que por sua vez, permite identificar variações na vegetação da superfície (TUCKER; SELLERS, 1986). Todavia, o NDVI apresenta um sinal saturado quando há uma grande densidade de folhas, além de ser sensível ao efeito de fundo do solo em vegetações esparsas (JUSTICE et al., 1998).

Outro índice bastante conhecido em sensoriamento remoto é o Índice de Vegetação Melhorado (*Enhanced Vegetation Index* - EVI), que, assim como o NDVI, leva em consideração as bandas do vermelho e infravermelho próximo, mas também utiliza a banda do azul para descontar os efeitos de aerossóis da atmosfera. É, também, menos sensível à presença de vegetação densa e solo, além de apresentar alta resposta a parâmetros estruturais do dossel, como o Índice de Área Foliar (*Leaf Area Index* – LAI) (JUSTICE et al., 1998).

Esses índices, provenientes do sensoriamento remoto, além de auxiliarem no gerenciamento da produção agrícola, fornecem informações para estimativas de produtividade, fundamentais para o agronegócio, principalmente para a agricultura de precisão (MULLA, 2012). Devido a sua simplicidade e eficiência, eles vêm sendo amplamente utilizados em diversas plataformas orbitais, aeronaves e VANTs (XUE; SU, 2017).

2.3 Sensoriamento remoto termal

O sensoriamento remoto termal se baseia no fato de que todo objeto com temperatura acima de zero absoluto (0K ou -273°C) emite radiação eletromagnética (REM) (PRAKASH, 2000). Portanto, o sensoriamento remoto termal mede a radiação emitida por alvos na superfície, não a refletida, como ocorre no sensoriamento remoto óptico.

As informações são adquiridas primariamente nas regiões do infravermelho termal (TIR, na sigla inglesa) do espectro eletromagnético (EM), ou seja, na faixa espectral de 3 a 1.000 μm . No entanto, devido à interferência atmosférica, somente é possível obter informações em duas faixas do espectro eletromagnético, de 3 a 5 μm e 8 a 14 μm , contudo, devido à sobreposição com a energia solar refletida, a faixa de 3 a 5 μm não é muito utilizada (PRAKASH, 2000).

A radiação emitida na faixa do termal é utilizada para estimar a temperatura dos objetos, que recebe o nome de temperatura radiante e depende da energia cinética e da emissividade do objeto (PRAKASH, 2000). A energia cinética provém dos movimentos de vibração das moléculas, que são transformadas na energia radiante a ser captada pelo sensor. A emissividade está relacionada à eficiência de cada corpo em emitir radiação, que depende de suas características físico-químicas (ABRAMS; HOOK; ABRAMS, 2002).

Os sensores termais, ao contrário dos sensores ópticos, podem atuar em condições de baixa iluminação ou até mesmo à noite (PAJARES, 2015) e têm uma série de aplicações, como estudos do solo, hidrologia, zonas costeiras, estudos de vulcões, detecção de queimadas, agricultura, modelagem ambiental e meteorologia (KUENZER; DECH, 2013).

2.3.1 Princípios físicos básicos de sensoriamento remoto termal

Um corpo negro é um corpo hipotético, que possui emitância igual a 1, ou seja, toda a radiação absorvida pelo corpo é emitida em forma de energia radiante, sendo a sua emitância em um determinado comprimento de onda e de temperatura ($M_{CN}(\lambda, T)$) descrita pela lei de Plank (Equação 2.1) (LORENZZETTI, 2015):

$$M_{CN}(\lambda, T) = \frac{2\pi hc^2}{\lambda^5 [exp(\frac{hc}{\lambda kT}) - 1]} [Wm^{-2}sr^{-1}\mu m^{-1}], \quad (2.1)$$

em que k é a constante de Boltzmann ($1,38 \cdot 10^{-23} [J K^{-1}]$), h , a constante de Plank ($6,626 \cdot 10^{-34} [J s]$), c , a velocidade da luz no vácuo [ms^{-1}], T , a temperatura absoluta [K] e λ , o comprimento de onda [μm].

O total de energia irradiada por um corpo negro depende de sua temperatura, sendo que essa relação é descrita pela lei de Stefan-Boltzmann (Equação 2.2) (KUENZER; DECH, 2013).

$$M = \sigma T^4 [Wm^{-2}], \quad (2.2)$$

em que σ é a constante de Stefan-Boltzmann ($5,67 \cdot 10^{-8} [Wm^{-2}K^{-4}]$) e T , a temperatura em graus Kelvin. Por essa relação, percebe-se que pequenas variações na temperatura causam grandes variações na emitância do corpo negro, o que permite sensores termais discriminarem alvos com poucos graus de diferença de temperatura (LORENZZETTI, 2015).

No entanto, a Lei de Plank não se aplica a corpos terrestres reais, pois não existem emissores perfeitos na natureza. Assim, cada objeto irá emitir radiação eletromagnética de acordo com sua emissividade (ϵ_λ), que é a razão entre o fluxo radiante de um objeto com uma dada temperatura e o fluxo radiante de um corpo negro com a mesma temperatura, sendo que a emissividade depende do tipo de superfície e comprimento de onda, mas independe da temperatura (KUENZER; DECH, 2013).

Com base na definição de emissividade (ϵ) e na lei de Stefan-Boltzmann, é possível converter a temperatura radiante (T_{rad}), medida por um sensor termal, em temperatura cinética (T_{cin}), conforme a Equação 2.3:

$$T_{rad} = \varepsilon^{(1/4)} T_{cin} [K] . \quad (2.3)$$

Como a emissividade de corpos reais é sempre menor que 1, a temperatura radiante será sempre menor do que a temperatura cinética real do objeto. Assim, objetos com a mesma temperatura cinética podem apresentar temperaturas radiantes diferentes, devido às condições de imageamento (KUENZER; DECH, 2013).

2.4 Sensoriamento remoto na agricultura

O comportamento fenológico das culturas agrícolas favorece o uso de dados de sensoriamento remoto. É a sucessão de diferentes coberturas e quantidade de biomassa verde sobre o solo que promove a formação de diferentes comportamentos espectrais ao longo do tempo que definem os diferentes tipos de cultivos e estágios de crescimento, por exemplo, que são registadas nas imagens capturadas pelos sensores. O sensoriamento remoto começou a ser utilizado para estudos em agricultura na década de 1970, com o lançamento do satélite Landsat 1 para estimativa da área de trigo cultivada globalmente. (FORMAGGIO; SANCHES, 2017).

Historicamente, imagens provenientes de satélites tem sido utilizadas para mapeamento de diferentes tipos de cultivos, estimativas de área e análises das condições gerais da vegetação, normalmente considerando grandes áreas devido a limitação de resolução espacial dos sensores. Todavia, o surgimento de sensores com resoluções espaciais mais altas, tem permitido outros tipos de análises dentro de talhões, como, por exemplo, análises de estresse hídrico, danos por inundação e granizo (WÓJTOWICZ; WÓJTOWICZ; PIEKARCZYK, 2015), estimativas de biomassa e produtividade (CAMPOS; GONZÁLEZ-GÓMEZ; VILLODRE; GONZÁLEZ-PIQUERAS; SUYKER; CALERA, 2018; DONG; LIU; QIAN; HE; LIU; WANG; JING; CHAMPAGNE; MCNAIRN; POWERS, 2020; AWAD, 2019), e caracterização da salinidade do solo em culturas irrigadas (ABBAS; KHAN; HUSSAIN; HANJRA; AKBAR, 2013).

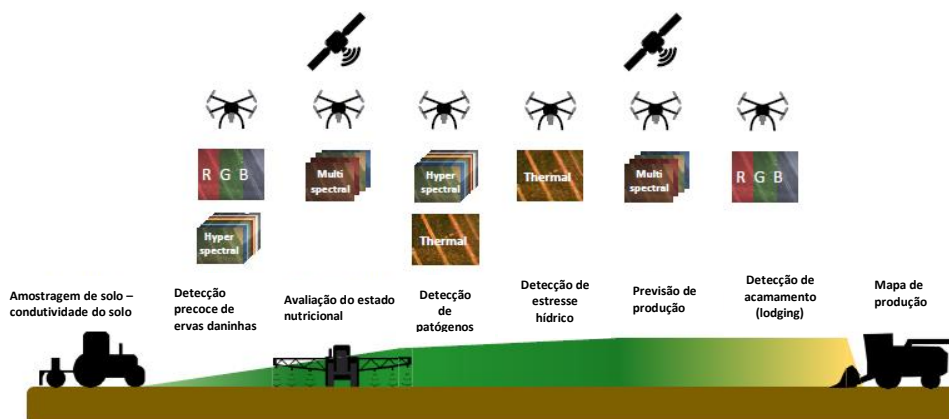
Segarra, Buchailot, Araus e Kefauver (2020) visando aplicações para a agricultura de precisão, realizaram uma revisão comparando o uso de dados da constelação de satélites Sentinel-2 A e B em relação à outras plataformas

orbitais. Os autores concluíram que a melhor resolução espacial, menor tempo de revisita, a presença da banda na faixa do *red-edge*, além da disponibilidade gratuita de seus dados, garantem melhor desempenho no monitoramento e gerenciamento de culturas, principalmente no que diz respeito ao monitoramento de estresses abióticos e bióticos, contudo, também evidenciam que ainda existem limitações para esta plataforma.

Os VANTs também têm sido amplamente utilizados, principalmente, na agricultura de precisão, pelo seu custo-benefício vantajoso e pela diversidade de aplicações, do plantio à colheita (Figura 2.2). Hunt e Daughtry (2017) classificaram as aplicações de VANTs na agricultura de precisão em três diferentes nichos, a saber: 1) exploração de possíveis problemas, 2) monitoramento para prevenir a perda de produção e 3) planejamento de operações de gerenciamento da plantação.

O nicho de exploração não demanda muitos custos ou análises complexas. Vídeos em tempo real podem ser utilizados para encontrar áreas problemáticas, a serem posteriormente verificadas no solo. O monitoramento fornece informações antecipadas, possibilitando o direcionamento das ações e prevenindo perdas na produção. O planejamento antecipado das ações é o nicho com maior retorno econômico, mas também o que mais demanda em relação à aquisição e análise de dados, e em consequência, o que apresenta maior custo (HUNT; DAUGHTRY, 2017).

Figura 2.2 - Esquema das aplicações dos VANTs na agricultura de precisão ao longo de uma estação de crescimento.



Fonte: Adaptado de Maes e Steppe (2019).

O monitoramento ainda é o nicho mais explorado na agricultura de precisão, abarcando a maior parte dos estudos realizados nos últimos anos, como por exemplo, a detecção de estresse hídrico em plantações usando diferentes índices, como o Índice de Estresse Hídrico da Plantação (*Crop Water Stress Index – CWSI*) e o Índice de Déficit de Água (*Water Deficit Index – WDI*) (SANTESTEBAN et al., 2017; HOFFMAN et al., 2016; QUEBRAJO; PEREZ-RUIZ; PÉREZ-URRESTARAZU; MARTÍNEZ; EGEA, 2018; BIAN et al., 2019); estimativa da salinidade do solo, com o uso de diferentes sensores (termal, hiperespectral e LiDAR) (IVUSHKIN et al., 2019); estimativa da concentração de clorofila (ELARAB; TICLAVILCA; TORRES-RUA; MASLOVA; MCKEE, 2015); acamamento (lodging) (CHU; STAREK; BREWER; MURRAY; PRUTER, 2017; LIU et al., 2018); monitoramento da biomassa e produção (BENDIG et al., 2015, SANCHES et al., 2018; GRÜNER; ASTOR; WACHENDORF, 2019); detecção de falhas na lavoura (LUNA; LOBO, 2016; SOUZA et al., 2017a) e avaliação do crescimento da cultura (BENDIG; BOLTEN; BARETH, 2013; SOUZA et al., 2017b).

2.4.1 Sensoriamento remoto termal na agricultura

Além dos sensores ópticos, os sensores termais podem fornecer dados fundamentais para estudos da vegetação, pois, por meio da temperatura, é possível inferir sobre a condição fisiológica das plantas. A temperatura da folha é dependente da taxa de transpiração, sendo esta função da demanda evaporativa atmosférica e da disponibilidade de água no solo (SMIGAJ; GAULTON; BARR; SUÁREZ, 2015; KHANAL; FULTON; SHEARER, 2017). Assim, se as plantas estão em condições de estresse, seja hídrico, por nutrientes ou pragas, isso irá influenciar a temperatura do dossel, que pode ser medido durante estágios fenológicos críticos da planta para auxiliar no manejo das culturas (KHANAL; FULTON; SHEARER, 2017).

Medidas de temperatura do solo e da superfície dos dosséis têm utilidade em diversas aplicações, como, por exemplo, no monitoramento de estresses, de viveiros, planejamento da irrigação, detecção de salinidade e disponibilidade de água no solo, detecção de doenças e patógenos, estimativas de produtividade

e avaliação da maturidade de frutos (ISHIMWE; ABUTALEB; AHMED, 2014; KHANAL; FULTON; SHEARER, 2017). A vegetação verde pode ser considerada como um corpo negro no TIR quando se utilizam amplas bandas, devido a sua baixa emissividade (ELVIDGE, 1988). Dessa forma, a emissividade nessa faixa espectral vem sendo utilizada para calcular a temperatura radiante dos dosséis e estimativas de evapotranspiração e biomassa (ELVIDGE, 1988). A emissividade de uma planta verde em condições normais varia geralmente de 0,96 a 0,99, estando mais frequentemente entre 0,97 e 0,98, enquanto para plantas secas a emissividade apresenta maior variação, entre 0,88 a 0,94 (HATFIELD; BAKER; ARKEBAUER, 2005).

Vários estudos já demonstraram o potencial do sensoriamento remoto termal na agricultura. Conrad, Rucker, Schweitzer, Dech e Hafeez (2004) conseguiram boa precisão ao modelar a evapotranspiração sazonal em uma região semiárida do Uzbequistão utilizando dados do MODIS. Alzaben, Fraser e Swanton (2019), ao estudarem a deficiência por nitrogênio no milho, observaram uma relação inversa entre a temperatura do dossel e a taxa de nitrogênio. Palombo et al. (2019) criaram mapas de umidade do solo para uma região agrícola, correlacionando dados de campo, do satélite *WorldView-2* e de sensoriamento remoto termal obtidos por uma aeronave. Sepulcre-Cantó et al. (2006) mapearam a variação espaço-temporal da temperatura de pomares de oliveiras em função da variação diurna do estresse hídrico, utilizando um sensor a bordo de uma aeronave. Esses estudos indicam que a temperatura pode ser utilizada como parâmetro para analisar a variabilidade dentro dos talhões causada por diversos fatores.

2.4.2 Zonas de manejo

Dentro das aplicações de sensoriamento remoto na agricultura, a criação de Zonas de manejo (ZMs) está em crescente estudo. ZMs correspondem a regiões dentro de uma área agrícola que são homogêneas em relação a certos atributos ou variáveis. O delineamento das zonas de manejo é importante, na medida em que oferece meios para gerir os insumos e recursos de uma área

específica, de acordo com suas características próprias, evitando assim o desperdício de materiais/mão de obra e, por consequência, consolidando o aumento da sua produtividade (GAVIOLI et al. 2019)

Zonas de manejo geralmente são determinadas através da análise de *clusters*. Algoritmos de *clustering* são métodos de *machine learning* (aprendizado de máquinas) não supervisionados, cujo objetivo é identificar padrões ou grupos similares em um conjunto de dados. Trata-se de uma técnica matemática que tem como finalidade revelar estruturas de classificação nos dados do mundo real (KAUFMAN; ROUSSEEUW, 1990).

Esses algoritmos podem ser classificados em duas categorias: algoritmos de particionamento ou não hierárquicos e algoritmos hierárquicos. Os primeiros fazem a divisão do conjunto de elementos em k grupos, baseando-se no princípio da existência de similaridade entre indivíduos do mesmo grupo, dividindo os dados na tentativa de identificar grupos naturalmente existentes neles, onde cada elemento pertence a um único grupo. Posto que, os algoritmos hierárquicos agrupam os dados definindo uma série de divisões conectadas, podendo começar com um único grupo de n elementos, resultando em n grupos com um elemento cada, ou vice-versa (KAUFMAN; ROUSSEEUW, 1990).

Os métodos de particionamento, como aqueles baseados em algoritmos *fuzzy*, são mais frequentemente usados para definir as ZMs. Boydell e Mcbratney (2002), por exemplo, utilizando o método de classificação *fuzzy k-means* modificado, estabeleceram zonas de produção em um cultivo de algodão com base em estimativas de produção derivados de 11 anos consecutivos de imagens Landsat TM. Tagarakis et al. (2012), usando técnicas de *fuzzy clustering*, delimitaram zonas de manejo para vinhedos com base em propriedades do solo e do dossel. Breunig et al. (2020a) propuseram um método para delimitar zonas de manejo usando classificação *fuzzy* não supervisionada e biomassa de três diferentes culturas de cobertura, estimadas por meio de dados de um sensor espacial com alta resolução espacial e temporal.

Por outro lado, Gavioli et al. (2019) compararam 20 algoritmos para definir as ZMs, sendo que 17 deles permitiram delinear as ZMs segundo os seus critérios de avaliação. Dentre eles, o método hierárquico de McQuitty (1966) e o de particionamento Fanny alcançaram os melhores desempenhos, pois promoveram uma maior redução da variância nas áreas analisadas e geraram classes com alta homogeneidade interna, além de delimitarem as ZMs sem fragmentação espacial.


Ortega e Santibáñez (2007), ao avaliarem três métodos de zoneamento baseados em propriedades do solo, o primeiro utilizando o algoritmo *k-means* e os outros dois por meio de estimativas de índices de solo por componentes principais (PCA, do inglês *principal component analysis*) e por coeficiente de variação, concluíram que a escolha das variáveis que melhor representam as variabilidades na produção é mais importante para a boa divisão das zonas de manejo do que o método em si. Gili, Álvarez, Bagnato e Noellemeyer (2017) avaliaram três abordagens para a definição de zonas homogêneas, sendo duas delas utilizando o algoritmo *fuzzy k-means*, e concluíram que a escolha do método depende dos objetivos para a determinação das zonas de manejo, já que os resultados obtidos foram diferentes para cada abordagem.

2.5 Cana-de-açúcar

A cana-de-açúcar é uma cultura sem-perene que pode ter um ciclo de 12 ou 18 meses dependendo da variedade. O desenvolvimento da cana-de-açúcar é dividido em quatro estágios: brotação, perfilhamento, crescimento dos colmos e maturação. O primeiro estágio se caracteriza pela formação e desenvolvimento das folhas, levando de 20 a 30 dias para a ocorrência da brotação. O perfilhamento é o processo de emissão de brotos, colmos ou hastes laterais pelas plantas, e ocorre em torno de 40 dias após o plantio, com duração de até 120 dias. O crescimento dos colmos começa após os 120 dias e pode durar até 270 dias em um cultivo de 12 meses, sendo que é nesse estágio que ocorre o acúmulo de 75% da matéria seca total, portanto, este o estágio de maior importância, onde há o predomínio de vegetação verde e fechamento do dossel. Na maturação, ocorre redução nas taxas de crescimento das plantas e

aumento no acúmulo de sacarose, essa fase tem início de 270 a 360 dias após o plantio, podendo se prolongar por até 6 meses (MARAFON, 2012)(Figura 2.3).

Figura 2.3 – Estágios de desenvolvimento da cana-de-açúcar.



Fonte: Adaptado de Marafon (2012).

As características morfológicas da cana-de-açúcar exercem grande influência no seu comportamento espectral, essas características variam de acordo com o estágio fenológico que a cultura de encontra (JOAQUIM, 1998). Além disso, a variação no dossel deixa exposta as camadas inferiores, expondo maior quantidade de folhas senescentes, solo/palhada e colmos da cana. Portanto, a arquitetura do dossel, que é formada pela distribuição espacial de seus elementos, densidade e orientação, também exerce influência nos valores de reflectância (BENVENUTI, 2005)

Simões (2004) estudou a relação entre indicadores de crescimento e produção da cana-de-açúcar e dados espectrais obtidos de imagens dos satélites Landsat 5 e 7. A banda B3 (vermelho) e os índices de vegetação NDVI e RVI obtiveram as maiores correlações com as variáveis agrônomicas e de

crescimento da cana estudadas. A B3 apresentou dois picos de reflexão e dois picos de absorção. Segundo o autor os picos de reflexão estão relacionados com a alta reflexão da palha devido a colheita mecanizada no início do ciclo da cultura. Já a absorção pode ser explicada pelo desenvolvimento do dossel, que cobriu totalmente a palha e expressa o comportamento espectral da fase de desenvolvimento da cultura.

Segundo o mesmo autor, o comportamento temporal da banda B4 (infravermelho próximo) não correspondeu com o aumento da biomassa nas fases iniciais de desenvolvimento da cultura, segundo ele, a queda nos valores de reflectância pode ter ocorrido pelo tombamento da cultura, que altera o seu comportamento espectral característico, devido a reflectância do colmo e da palhada. Ainda, os valores de reflectância aumentaram nos meses anteriores à colheita, nas duas safras avaliadas, todavia, o esperado era que ocorresse uma queda nos valores de reflectância nessa faixa, pois nessa fase há um aumento da translocação de fotossintetizados para os colmos, diminuindo a área fotossinteticamente ativa da cultura.

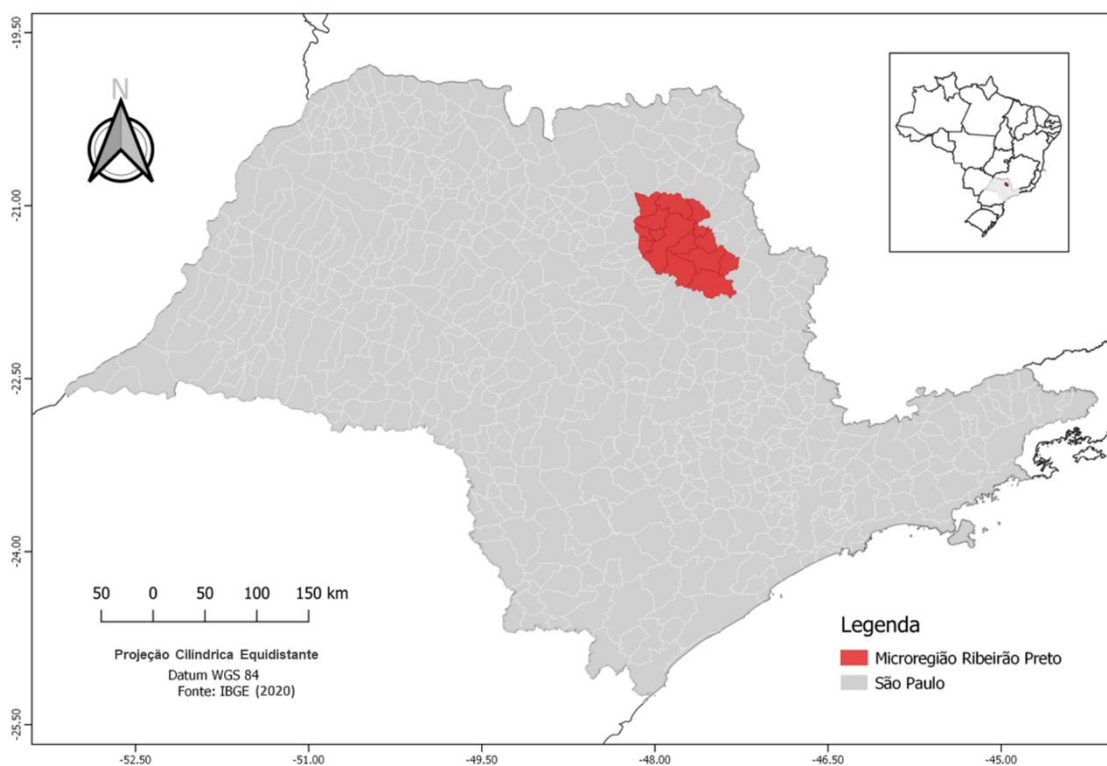
Benvenuti (2005) também observou um comportamento decrescente da resposta espectral de um dossel de cana-de-açúcar no período de máximo crescimento da cana. O autor também atribuiu esse comportamento ao aumento da quantidade de folhas senescentes no interior do talhão e à diminuição da quantidade de plantas por metro. Já, no período de maturação, quando o canavial se encontrava com 9 meses, a redução dos valores de reflectância foi atribuída ao avanço da idade da cultura com diminuição da atividade vegetativa, à seca e temperaturas mais baixas. Assim, o autor conclui que a resposta espectral da cana-de-açúcar é influenciada por mudanças no dossel e condições climáticas, mesmo em um curto período de tempo.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

A área de estudo está localizada na microrregião do município de Ribeirão Preto (Figura 3.1), no nordeste do Estado de São Paulo (21,18° S e 47,82° O). Devido a um acordo de sigilo com a empresa onde foi realizado este estudo, a localização exata da área não pôde ser identificada. Esta região caracteriza-se como um forte polo agrícola e agroindustrial, com culturas de café, seringueira, amendoim, soja, milho, citrus, cana-de-açúcar, entre outras (IEA, 2018). O setor sucroalcooleiro é sua principal atividade econômica, que concentra a maior parte da produção brasileira de cana-de-açúcar, tornando-a a maior produtora mundial de açúcar e álcool (EMPLASA, 2016).

Figura 3.1 – Localização da área de estudo.




O clima da região, segundo a classificação de Köppen, é do tipo Aw (DUBREUIL; FANTE; PLANCHON; SANTANNA NETO, 2018), tropical com verão chuvoso e inverno seco, temperaturas médias superiores a 18°C e índices pluviométricos de aproximadamente 1.500 mm/ano (AYOADE, 1996). O tipo de solo predominante é o Latossolo Vermelho, conhecido como “terra

roxa”, devido a sua grande fertilidade (ROSSI, 2017). O terreno tem amplitude de 600 m de altitude, onde as áreas mais altas se localizam na extremidade leste, com altitudes acima de 1.000 m. Na porção oeste, se encontram as terras mais baixas, com mínimas de 400 m, caracterizadas por terrenos mais planos com predomínio de planícies. Nessas regiões, há o predomínio da cultura canaveira, enquanto nas partes mais elevadas há maior diversidade de cultivo e áreas de vegetação natural(EMPLASA, 2016).

Na figura 3.2 estão apresentados os índices pluviométricos obtidos na região ao longo da safra 2019/2020, bem como a temperatura média para cada mês. Como pode ser observado, este foi um ano típico com verão chuvoso, chegando a 243 mm em janeiro/2020, e inverno seco. A pluviosidade total para o período foi de 1.060,8 mm, abaixo do que se é esperado para a região. Não houve muita variação da temperatura, com excessão dos meses de inverno (maio, junho e julho), nos quais a temperatura média chegou a 18.2 °C (INMET, 2021).

Figura 3.2 - Pluviosidade mensal e temperatura média medida pela estação meteorológica localizada em Pradópolis-SP ao longo de out/2019 a set/2020.



Fonte: Adaptado de INMET (2021).


As análises foram realizadas em uma parte de um talhão (Figura 3.3), escolhido pela disponibilidade de dados auxiliares para a pesquisa e porque a cana-de-açúcar estava em um estágio inicial de desenvolvimento, tornando possível, assim, o acompanhamento de todo o seu ciclo de vida. Algumas informações relevantes sobre a área estão especificadas na Tabela 3.1. A área analisada não correspondeu a área total do talhão em primeiro lugar, pois, devido ao tamanho do mesmo, seria preciso mais de um voo com o VANT, em segundo lugar, porque houveram discrepâncias entre a área imageada no primeiro voo realizado e os demais. Assim, a área analisada correspondeu à área comum entre os voos.

Tabela 3.1 – Características da área de estudo.

Área total do talhão (ha)	Área analisada (ha)	Tipo de Solo	Data do primeiro plantio	Variedade	Estágio do corte	Data da última colheita	TCH ¹ 19/20
30,33	13,73	LVe (Latossolo vermelho eutrófico)	03/12/2014	SP80-3280	4º Corte (12 meses)	10/2019	76,95

Nota: ¹Toneladas de colmos por hectare para a safra 2019/2020

Figura 3.3 – Área de estudo (em destaque) e região ao entorno.



3.2 Base de dados espectrais

Para este estudo, foram obtidos dados de cinco plataformas diferentes. Um veículo aéreo não tripulado (VANT) Phantom 4 da fabricante DJI e quatro plataformas orbitais: PlanetScope, Sentinel-2, Landsat 8 e o sensor ASTER do satélite TERRA. As imagens foram obtidas em suas respectivas base de dados: Planet Explorer (<https://www.planet.com/explorer/>), Open Hub (<https://scihub.copernicus.eu/dhus/>) e EarthExplorer (<https://earthexplorer.usgs.gov/>), sendo a data de aquisição a mais próxima possível à do imageamento com VANT (Tabela 3.3). As imagens multiespectrais foram adquiridas em reflectância de superfície, assim, o pré-processamento consistiu somente no recorte das bandas. No caso do Landsat 8, foi feita, também, a correção da projeção. Diferentes resoluções espaciais foram empregadas para verificar a sua influência sobre os dados. Um resumo das especificações técnicas do Phantom 4 e das plataformas orbitais constam nas Tabelas 3.2 e 3.3, respectivamente.

Tabela 3.2 - Especificações técnicas do Phantom 4.

	Peso	Sensor	Resolução	Lente	Tamanho da imagem	Sist. de pos. por satélite ¹	Auto. Máx. ²	Vel. Máx. ³
Phantom 4	1.380g	CMOS 1/2.3"	12,4 Mega Pixels	FOV 94° 20 mm	3.000x4.000	GPS/GLONASS	28 min	20 m/s

Nota:¹Sistema de posicionamento por satélite; ²Autonomia máxima; ³Velocidade máxima.

Fonte: Adaptado de DJI (2020).

Tabela 3.3 – Especificações técnicas de plataformas orbitais usadas.

	PlanetScope	Sentinel-2	Landsat 8		ASTER
Resolução espectral	4VNIR	10 VNIR/ 3 SWIR	4 VNIR/ 2 SWIR/ 2 TIR/ 1 PAN/ 1 Cirrus		3 VNIR/ 6 SWIR/ 5 TIR
Resolução temporal	1 dia	5 dias	16 dias		16 dias
Horário de passagem		-	10:30 am	10:00 am	10:30 am
Resolução espacial		3 m (VNIR)	10m (VNIR)	30m (VNIR)	90m (TIR)
Datas de aquisição das imagens		17/12/2019	26/12/2019	30/12/2019	
		02/06/2020	13/06/2020	22/05/2020	09/10/2020
		30/07/2020	28/07/2020	25/07/2020	
		27/09/2020	26/09/2020	27/09/2020	

Fonte: Adaptado de Planet (2021); ESA (2020); USGS (2020); Embrapa (2013).

Foram utilizadas as bandas correspondentes às faixas espectrais do visível e infravermelho próximo dos satélites PlanetScope, Sentinel-2 e Landsat 8. Do satélite ASTER, foram utilizadas os produtos de temperatura cinética da superfície (AST_08 v003) e emissividade (AST_05 v003) (Tabela 3.4) (LP DAAC, 2021).

Tabela 3.4 – Faixas espectrais bandas do produto de emissividade (AST_05 v003) do sensor ASTER.

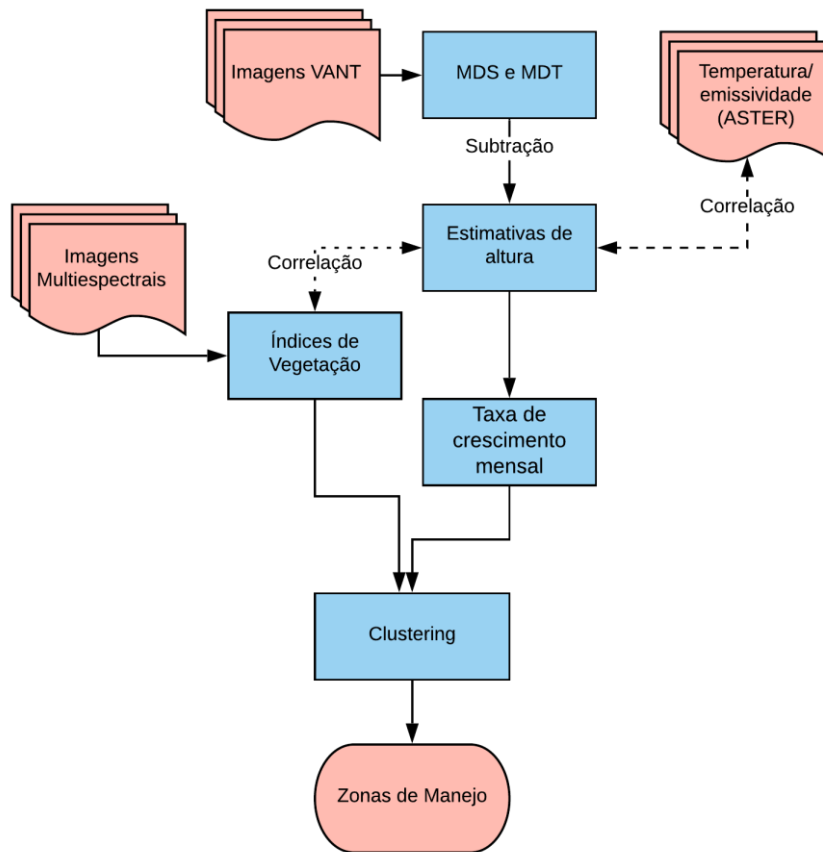
Bandas	Faixa Espectral	Resolução Espacial
10	8,125 – 8,475	90 m
11	8,475 – 8,825	90 m
12	8,925 – 9,275	90 m
13	10,25 – 10,95	90 m
14	10,95 – 11,65	90 m

Fonte: Adaptado de LP DAAC (2021).

3.3 Metodologia

Na figura 3.4 está apresentado o fluxograma geral das etapas realizadas nesse estudo, que serão detalhadas nos subcapítulos posteriores.

Figura 3.4 – Fluxograma geral do estudo.




3.3.1 Variação temporal da altura dos dosséis

3.3.1.1 Aquisição e processamento das imagens de VANT

Foram realizados quatro voos ao longo de um período de 12 meses, em 19/12/2019, 06/06/2020, 28/07/2020 e 24/09/2020, buscando abranger todos os estágios de crescimento da cana-de-açúcar (Figura 3.5). Foram efetuados voos a 100 m de altura em relação ao solo, seguindo a orientação de plantio e com sobreposições, longitudinais e laterais, de 80%, devido ao tamanho do talhão, um único voo foi necessário para cobrir toda a área. Os voos foram realizados por um profissional habilitado da própria usina responsável pela área. Devido a pandemia, não foi possível acompanhar as missões de voo, assim, não tivemos controle das informações obtidas em campo (como condições do tempo, por exemplo) ou do horário em que os voos foram realizados.

Figura 3.5 – Ortomosaicos da área de estudo em cada data analisada.



Para o pré-processamento das imagens, foi utilizado o *software* de fotogrametria *Agisoft Photoscan Professional v. 1.4.5*, que possibilita a geração de modelos de elevação e ortomosaicos pelo método *Structure from Motion (SfM)*.

A primeira etapa consiste no alinhamento das fotos, resultando em uma nuvem de pontos esparsos e a localização inicial da câmera. Nessa etapa, é possível definir o nível de detalhamento desejado para a busca por pixels de pontos homólogos, que varia de *lowest* (mais baixo) a *highest* (mais alto), sendo que quanto maior o nível de detalhamento, maior o custo de processamento (AGISOFT, 2019). A fim de se obter a melhor precisão e qualidade possíveis para os modelos, foi utilizado o parâmetro mais alto (*highest*) para o alinhamento.

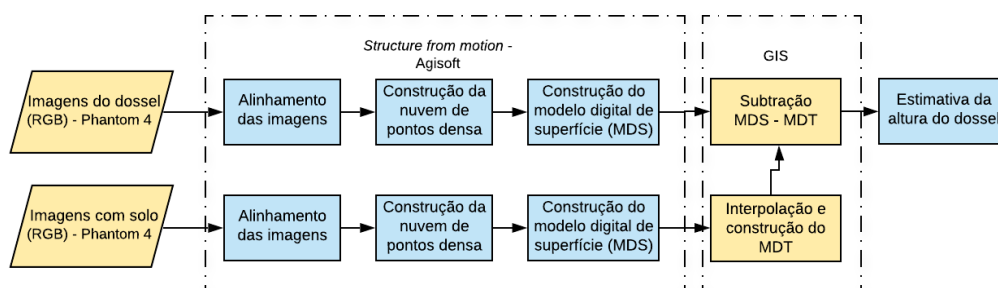
A etapa seguinte do processamento é a construção de uma nuvem de pontos densa, criada a partir da localização da câmera e da nuvem de pontos esparsos. Nessa etapa, também é possível selecionar a qualidade desejada, que varia de *low* (baixa) a *ultrahigh* (muito alta), bem como a robustez do filtro

de profundidade, que faz a remoção dos *outliers*, podendo ser mais agressivo ou suave, dependendo do nível de detalhamento desejado (AGISOFT, 2019). O parâmetro *ultrahigh* utiliza as fotos em seu tamanho original para criar a nuvem de pontos, no entanto, demanda uma capacidade de processamento muito alta. Assim, foi preferível utilizar o parâmetro *High* (Alto) para o processamento da nuvem de pontos. O filtro de profundidade usado foi o *mild* (suave), a fim de preservar os detalhes do modelo. Após, seguem-se as etapas de construção dos modelos de elevação e ortomosaico, nas quais foram utilizadas as configurações *default* do *software*.

3.3.1.2 Estimativa da altura do dossel

O Modelo Digital de Terreno (MDT) foi construído pela interpolação de pontos com informações de altitude do solo entre as linhas de plantio. Esses dados foram obtidos de um voo realizado em uma data onde a cana-de-açúcar estava pequena o suficiente para ser possível visualizar o solo, ou seja, em dezembro de 2019. A estimativa da altura foi feita pela subtração entre o MDS, construído a partir das imagens do VANT, e o MDT interpolado (Figura 3.6). Os valores negativos foram padronizados com valor zero, por meio da ferramenta de álgebra de mapas (*Raster Calculator* do *software* ArcGis).

Figura 3.6 - Representação esquemática das etapas para obtenção da altura estimada.



Foram solicitadas informações de altura da cana nas datas em que foram realizados os voos com o VANT, todavia, esses dados não foram coletados pelo responsável da usina. Assim, as alturas médias estimadas em cada data foram comparadas com as alturas médias medidas em campo durante a safra anterior (2018/2019), fornecidas pela empresa IDGeo. Nesse período, para o

cálculo da média, cada ponto de coleta em campo foi composto por quatro amostras, distribuídas em vértices em uma geometria quadrangular, e para cada vértice foi medida a altura, a fim de obter valores mais representativos da área observada. O resultado final representa a média entre as alturas das 4 amostras (IDGEO, 2019).

3.3.1.3 Análise de dados

Uma análise de correlação de *Pearson* foi realizada entre os dados estimados de altura do dossel, índices de vegetação (NDVI e EVI) obtidos por imagens dos satélites *PlanetScope*, *Sentinel-2* e *Landsat 8*, temperatura do dossel e emissividade. O objetivo foi avaliar se essas variáveis apresentam uma relação com a altura.

Para os índices de vegetação, foram feitas análises de correlação espacial de cada período, além de uma análise temporal, pela análise de um ponto representativo ao longo de todo o período. Os métodos de obtenção das variáveis estão descritos nas seções a seguir.

3.3.2 Cálculo do volume produzido de cana-de-açúcar

A estimativa do volume produzido no talhão foi feita pelo método da volumetria, sendo para isso foram utilizados os dados de altura estimada do estágio mais avançado de crescimento, conforme a Equação 3.1:

$$V = h * (D^2 / 2) * \pi * C / D * (L / Esp + 1) \text{ [m}^3\text{]}, \quad (3.1)$$

Em que V é o volume total de cana-de-açúcar; h , a altura média do talhão; D , o diâmetro médio do caule; C , o comprimento do talhão, seguindo a linha de plantio; L , a largura do talhão, perpendicular à linha de plantio e Esp , o espaçamento entre as linhas de plantio (considerado o espaçamento padrão de 1,5 m). Para obter o resultado em toneladas, multiplicou-se o volume calculado pela densidade da cana-de-açúcar. Como não foi possível realizar medidas em campo, o diâmetro (LOPES, 2011) e densidade da cana (AZZINI et al., 1986) tiveram que ser obtidos empiricamente. Sabendo-se que a produtividade da cana-de-açúcar decai após sucessivos cortes, uma equação de decaimento foi aplicada a produtividade calculada (Equação 3.2) (BERNARDES et al., 2008).

O volume e produtividade estimadas foram comparado com o volume e produtividade real obtidas em outubro de 2020.

$$TCH_n = TCH_1 * n^{cd}, \quad (3.2)$$

em que TCH_n é a produtividade do canavial, em ton/ha, no corte número n , TCH_1 , a produtividade no primeiro ano de corte e cd o coeficiente de decaimento cujo valor é inversamente proporcional a intensidade de manejo.

3.3.3 Variação da temperatura no talhão

Para avaliar as variações de temperatura no talhão de cana-de-açúcar, foram utilizados dados de temperatura cinética de superfície provenientes do sensor ASTER, assim, foi possível obter os valores mínimos, máximos e a média de temperatura dentro do talhão. Devido à baixa resolução espacial desse sensor, foi analisada apenas a imagem correspondente ao período de máxima cobertura do dossel, para que a influência da temperatura do solo fosse a menor possível.

3.3.4 Índices de Vegetação

Foram utilizados para correlação com a altura estimada e para a identificação das zonas de manejo os índices NDVI (ROUSE et al., 1973) e EVI (HUETE et al., 1997). Esses índices são calculados conforme as Equações 3.3 e 3.4, respectivamente.

$$NDVI = \frac{\rho_{ivp} - \rho_{red}}{\rho_{ivp} + \rho_{red}}, \quad (3.3)$$

em que ρ_{ivp} é a reflectância na região do infravermelho próximo e ρ_{red} é a reflectância na região do vermelho.

$$EVI = \frac{2,5(\rho_{ivp} - \rho_{red})}{(1 + \rho_{ivp} + 6\rho_{red} - 7,5\rho_{blu})}, \quad (3.4)$$

em que ρ_{ivp} é a reflectância na região do infravermelho próximo, ρ_{red} é a reflectância na região do Vermelho e ρ_{blu} é a região do azul do espectro eletromagnético. Assim, os índices foram calculados para cada área em três resoluções espaciais diferentes, 3, 10 e 30 m.

3.3.5 Zonas de manejo

Foram criadas Zonas de Manejo (ZMs) utilizando duas diferentes abordagens, variando o algoritmo de *clustering*. Para a primeira abordagem o método escolhido foi o método hierárquico de McQuitty (MCQUITTY, 1966), já na segunda, foi utilizado o método de particionamento *k-means* (MACQUEEN, 1967). Em cada abordagem variou-se as variáveis de entrada, inicialmente, foram utilizados o NDVI e a taxa de crescimento como dado de entrada, posteriormente o NDVI foi substituído pelo EVI. Foram criados Mapas de Zonas de Manejo com duas, três e quatro zonas.

Essas abordagens foram aplicadas a cada um dos satélites (PlanetScope, Sentinel-2 e Landsat 8), a fim de verificar se a resolução espacial é um fator limitante para a construção de ZMs. Os dados foram normalizados para evitar erros devido às diferenças nas unidades de medida, e a taxa de crescimento foi reamostrada de acordo com a resolução espacial de cada satélite. O fluxograma com os passos gerais para o delineamento das zonas de manejo está apresentado na figura 3.7.

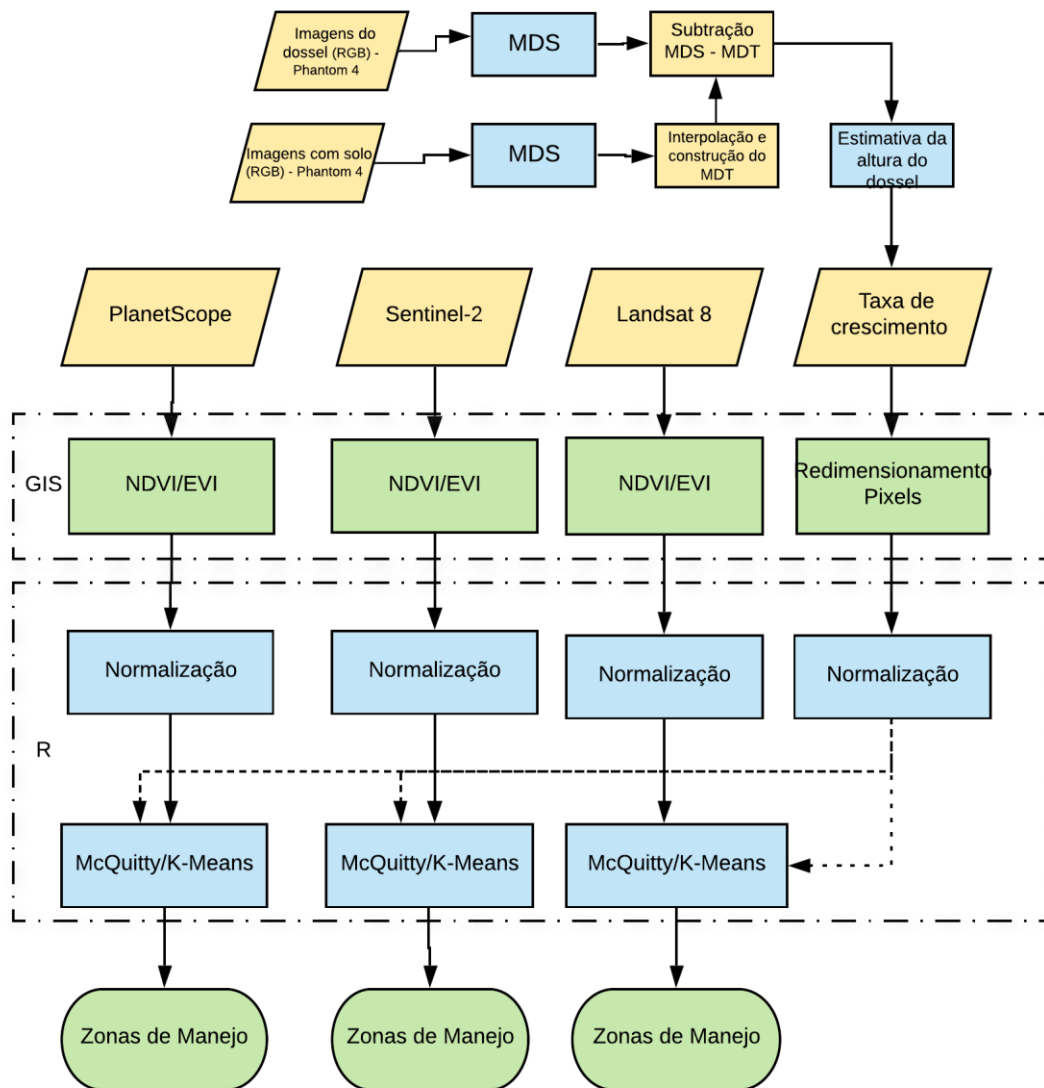
O método da silhueta média (*average silhouette coefficient* - ASC), obtido a partir do coeficiente de silhueta (CS) (ROUSSEEUW, 1987), foi utilizado para avaliar a qualidade dos mapas de ZMs criados. O CS mede a qualidade do *cluster* e estima a distância média entre *clusters*, nos quais o número ótimo de *clusters* é aquele que maximiza o valor do coeficiente de silhueta (ROUSSEEUW, 1987). O valor de CS para cada ponto (ou *pixel*) (CS_i) é calculado usando a média das distâncias intragrupo e médias das distâncias intergrupos, conforme a Equação 3.5:

$$CS_i = \frac{(b_i - a_i)}{\max(a_i, b_i)}, \quad (3.5)$$

em que a_i é a média das distâncias entre o ponto i e todos os outros pontos pertencentes ao mesmo grupo e b_i é a média das distâncias entre o ponto i e todos os pontos no grupo mais próximo ao grupo que contém o ponto i . O ASC de k grupos é obtido calculando a média entre os valores médios de CSs para cada grupo k . Os valores de ASC variam de -1 a 1, em que -1 indica um

agrupamento incorreto, enquanto 1 indica a melhor formação de *clusters* (ROUSSEUW, 1987).

Figura 3.7 – Figura esquemática para delineamento das zonas de manejo.



Uma ANOVA foi realizada para comparar os valores médios entre os clusters formados, sendo o teste *Tukey* aplicado para identificar se os *clusters* apresentam diferenças significantes entre si. Tanto o delineamento das zonas de manejo, quanto os métodos de validação foram realizados através do *software* estatístico R v. 3.6.1 (*R Core Team*, 2019).

4 RESULTADOS E DISCUSSÃO

4.1 Variação temporal da altura dos dosséis

As alturas médias obtidas em 19/12/2019, 06/06/2020, 28/07/2020 e 24/09/2020 foram, respectivamente, 0,20 m ($\pm 0,20$ m), 2,77 m ($\pm 0,62$ m), 3,01 m ($\pm 0,52$ m) e 2,98 m ($\pm 0,67$ m), considerando somente os valores acima de 0,05 m. As médias observadas em campo referentes ao mesmo estágio vegetativo foram de 0,33 m, 3,03 m, 2,61 m e 3,18 m, respectivamente. Apesar dos valores médios estimados e de campo estarem relativamente próximos, eles não são estatisticamente iguais ($p < 0,05$), sendo as médias estimadas menores que as de campo, com exceção de julho/2020 (Figura 4.1).

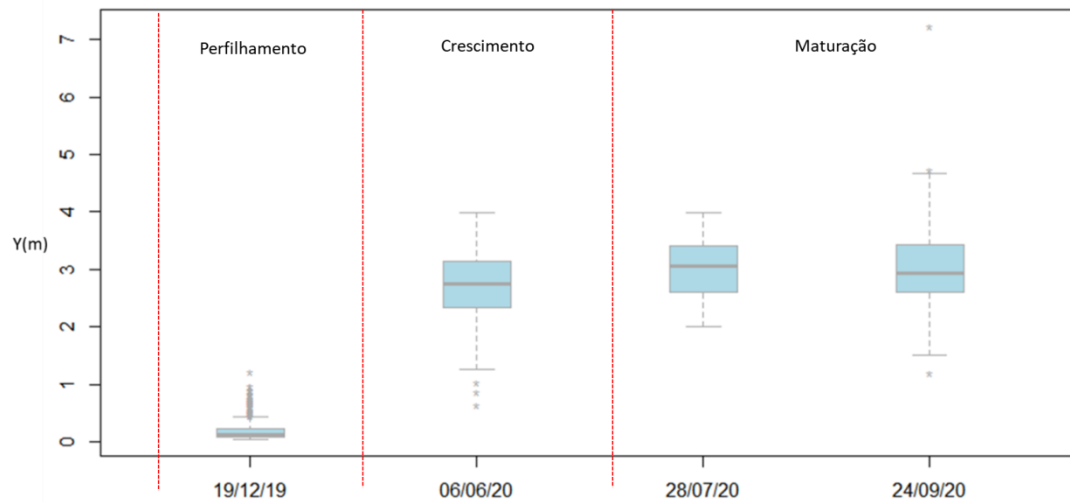
Vários autores também verificaram que os modelos criados a partir do SfM tendem a subestimar os valores de altura (WILLKOMM; BOLTEN; BARETH, 2016; AASEN et al., 2015). Além disso, as médias obtidas com o SfM são contínuas e englobam toda a microvariabilidade interna do dossel, enquanto, para as medidas em campo, foi selecionada uma área homogênea do talhão, buscando ser a mais representativa possível, mas que, no entanto, não engloba toda a variabilidade do talhão. Assim, para a comparação direta de médias, é esperada uma média menor para os dados derivados de VANTs.

Outro ponto importante consiste na dificuldade de obter pontos relativos a folhas erectófilas do topo do dossel da cana-de-açúcar devido a sua pequena representatividade e área projetada no zênite, dificultando a reconstrução na nuvem densa de pontos e medição da altura. Algo semelhante ocorre com medidas de altura de árvores caducifólias, quando da ausência de folhas (SESTARI et al., 2019). Todavia, a diferença significativa entre as médias não desqualifica nenhum dos produtos obtidos.

Pela análise do bloxplot (Figura 4.1) percebe-se que o estágio de perfilhamento apresentou a menor variabilidade na altura, enquanto os outros estágios apresentaram variabilidades semelhantes. É possível observar que o pico de crescimento ocorreu entre dezembro de 2019 e junho de 2020, e, após esse período, o crescimento se manteve estável. Esse padrão era esperado, pois

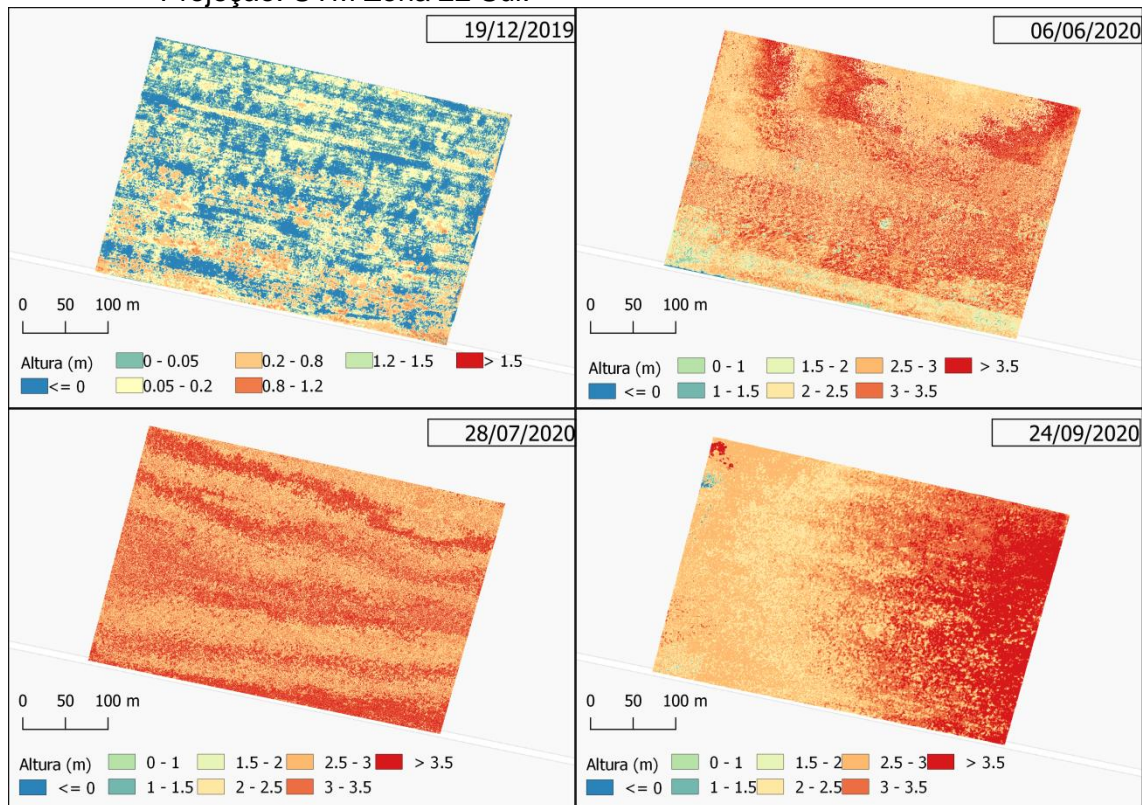
esse período corresponde à fase mais ativa de crescimento dos colmos. Segundo Marafon (2012), essa fase ocorre entre 120 e 270 dias após o plantio, e, após esse período, na fase de maturação, ocorre a redução da taxa de crescimento.

Figura 4.1 - Desempenho dos modelos para estimar a altura da cana-de-açúcar durante três estágios de desenvolvimento. Resultados obtidos a partir de 500 amostras aleatórias em cada data.



Por meio dos modelos de altura estimados para cada data (Figura 4.2), foi possível observar o crescimento da cana-de-açúcar no talhão de forma contínua no espaço. Em relação à capacidade dos modelos para detectar a distribuição das plantas no talhão, em dezembro de 2019 identificaram-se as falhas nas linhas de plantio, o que, nos modelos posteriores, já não foi mais tão evidente. Vale ressaltar que não é possível identificar um padrão claro de crescimento no talhão, principalmente no imageamento de setembro de 2020 em relação aos demais. Isso pode ser atribuído a falta de pontos de controle em campo (GCPs) ou algum outro sistema de referência, como RTK. Além disso, a homogeneidade interna do talhão dificultou o alinhamento entre os modelos e o MDT criado a partir do voo de dezembro de 2019, provocando um aumento nos erros de posicionamento, e em consequência, uma distribuição não tão regular da altura.

Figura 4.2 - Modelos de altura criados a partir da técnica SfM. DATUM: WGS 84
 Projeção: UTM Zona 22 Sul.

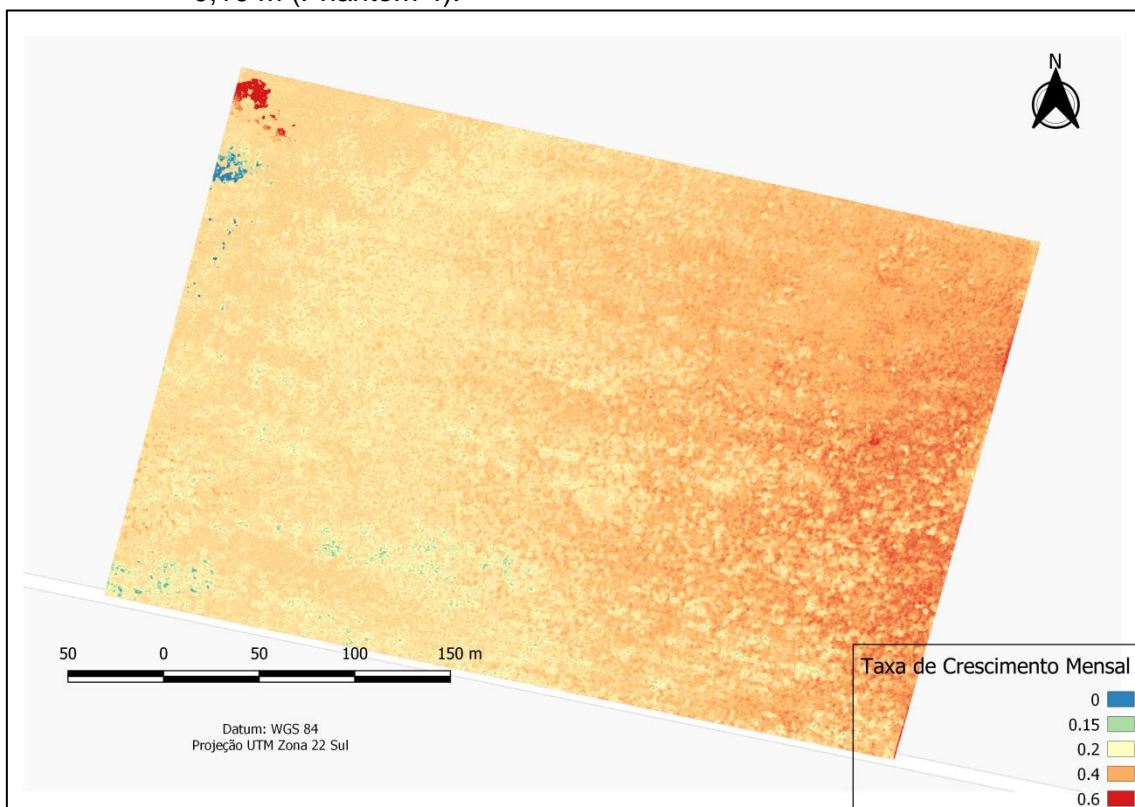


Assim, o uso de pontos de controle no solo poderia melhorar significativamente a acurácia dos modelos, como evidenciado por Ruiz et al. (2013) e Turner, Lucieer, e Watson (2012), que em seus trabalhos concluíram que o georreferenciamento feito somente com os dados do GPS a bordo dos VANTS aumentamos erros nos algoritmos de SfM. Todavia, outro fator que exerceu influência na acurácia do resultado foi o efeito da sombra. Vários autores já atestaram como o efeito de sombra afeta a qualidade dos modelos. Assim, Souza et al. (2017b), ao estimarem a altura da cana-de-açúcar usando imagens de alta resolução e diferentes geometrias de aquisição (Norte/Sul (N/S) e Leste/Oeste (L/O)), verificaram que o efeito de sombra afeta a qualidade do modelo obtido, e que uma abordagem combinando os dois planos de voo gerou modelos com menores erros, justamente por amenizar o efeito da sombra nas imagens. Bendig, Bolten e Bareth (2013) concluíram que o uso de diferentes perspectivas na aquisição das imagens fornece um melhor resultado,

principalmente quando existem grandes diferenças de altura. No entanto, esse procedimento requer um maior tempo de aquisição. Assim, a aquisição de imagens ao nadir próximo ao meio dia poderia amenizar esse efeito sem a necessidade de um voo extra.

Em relação à taxa de crescimento (Figura 4.3), percebe-se que o crescimento ocorreu de forma mais acentuada na porção leste do talhão, com taxas superiores a 0,35 m por mês, enquanto a porção oeste teve taxas menores. No entanto, observando os modelos de altura estimadas, fica evidente a influência do último período imageado, que também foi o que apresentou maior discrepância dos demais em relação à estimativa da altura. Vale ressaltar que o crescimento da cana-de-açúcar ocorre, principalmente, entre 120 e 270 dias após o plantio, portanto, o crescimento não é regular em todo o período de safra. Ainda assim, por meio dos modelos criados, foi possível identificar falhas nas linhas plantio logo no primeiro estágio de desenvolvimento da cana-de-açúcar, regiões de menor crescimento dentro do talhão e, ainda, acompanhar o desenvolvimento da cana-de-açúcar.

Figura 4.3 - Mapa de taxa de variação da altura, considerando a resolução espacial de 0,10 m (Phantom 4).



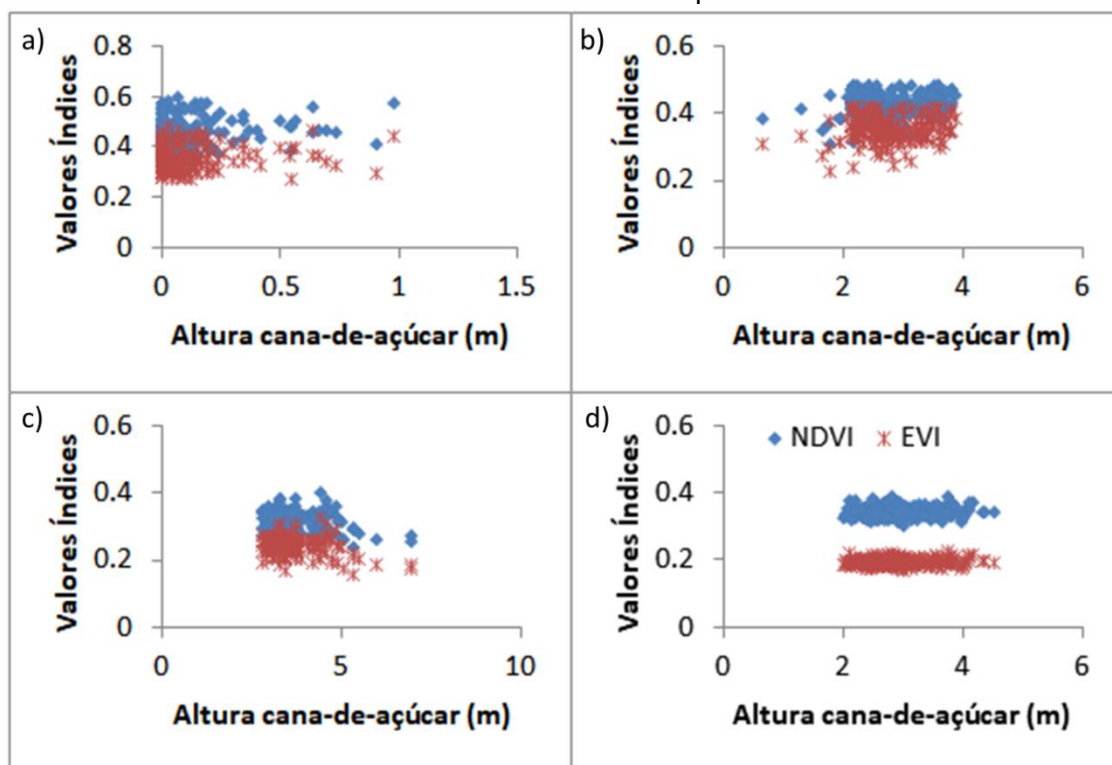
Os resultados das análises de correlação espacial não indicaram relação direta entre a altura e os índices de vegetação (Tabela 4.1). A falta de correlação é comprovada ao analisar a Figura 4.4, em que é possível observar que os valores dos índices independem das alturas observadas. Todavia, o NDVI apresentou maiores valores de correlação com a altura do que o EVI, com exceção de julho/2020 e setembro/2020 a 3 m e 10 m. Vale ressaltar que, por representarem um único período no tempo e pouca variação de altura, sendo assim, a variabilidade dos dados é muito pequena para que se obtenham correlações mais significativas entre os IVs e os dados de altura. Além disso, a falta de correlação também ocorre devido às propriedades da cana-de-açúcar, principalmente relacionadas ao crescimento.

Tabela 4.1 – Valores da correlação de Pearson entre a altura estimada e os índices de vegetação para cada data em três resoluções espaciais diferentes.

		3 m	10 m	30 m
Dez/2019	NDVI	0,3850	0,3785	-0,0509
	EVI	0,3566	0,3537	-0,0546
Jun/2020	NDVI	0,1533	0,1026	0,6387
	EVI	0,1492	0,0873	0,6204
Jul/2020	NDVI	-0,1626	-0,1800	-0,2940
	EVI	-0,1706	-0,2303	-0,3217
Set/2020	NDVI	0,0012	-0,0052	-0,0999
	EVI	0,0466	0,0367	-0,0059

Analisando temporalmente um único ponto do talhão (Figura 4.5), nota-se o mesmo padrão de comportamento dos valores médios de altura e índices, com crescimento até julho e queda da altura em setembro, e redução dos valores dos IVs ao longo do período, com o NDVI apresentando um pequeno acréscimo em setembro. A análise de correlação temporal indicou uma forte correlação negativa entre a altura e o NDVI ($\rho = - 0,83$) e menor correlação entre altura e EVI ($\rho = - 0,53$).

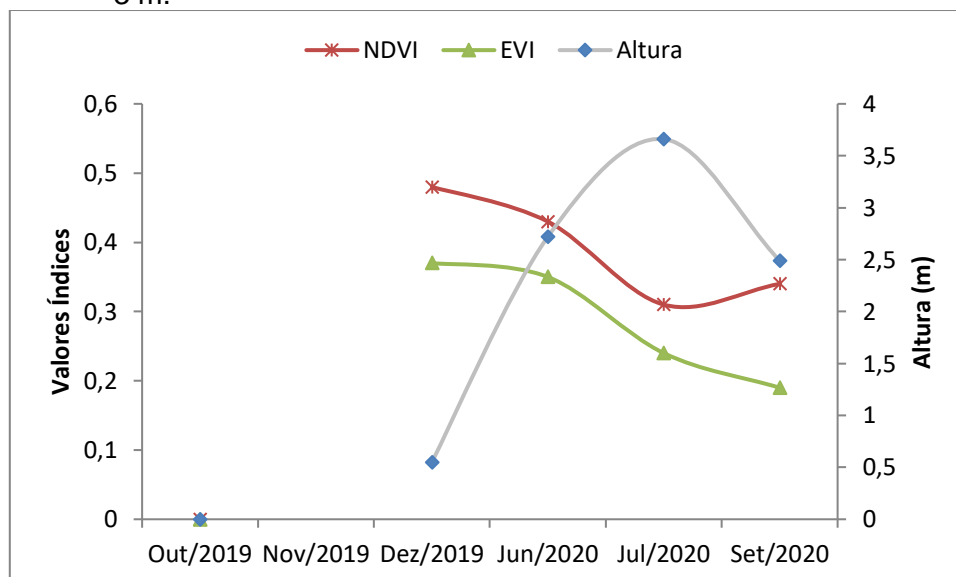
Figura 4.4 - Valores dos índices de vegetação vs. altura estimada em cada data: (a) dezembro/2019, (b) junho/2020, (c) julho/2020 e (d) setembro/2020. 500 amostras obtidas do satélite PlanetScope.



A correlação negativa pode ser explicada devido ao comportamento oposto apresentados por esses parâmetros, pois, enquanto havia um aumento da altura, os valores dos índices decresceram, e quando houve queda da altura, o valor do NDVI aumentou. Todavia, vale ressaltar que a quantidade de dados analisados foi muito pequena para poder confirmar esses resultados, sendo necessário uma avaliação por um período de tempo mais longo.

Comparando os resultados entre as resoluções espaciais, não foram observadas diferenças relevantes, indicando que a resolução não foi um fator limitante nesse caso, resultado igual ao encontrado por Breunig et al. (2020b). Cabe destacar que os IVs analisados têm princípios distintos na formulação. O NDVI é um índice relacionado especialmente a pigmentos (clorofilas), e o EVI está fortemente relacionado a parâmetros estruturais do dossel e apresenta forte correlação com a banda do infravermelho próximo, assim como o NDVI (LEBLON; GRANBERG; CHARLAND, 1996; HUETE et al., 2002; GALVÃO et al., 2018).

Figura 4.5. Variação temporal dos valores dos índices de vegetação NDVI e EVI e altura estimada em um ponto central do talhão na resolução espacial de 3 m.



Payero, Neale e Wright (2004) compararam a habilidade de 11 índices de vegetação em estimar a altura de plantações de alfafa e capim. Eles encontraram uma boa relação logística entre os índices e a altura para a alfafa ($R^2 > 0,90$), contudo, os índices NDVI, Índice de Vegetação da Porcentagem do Infravermelho (*Infrared Percentage Vegetation Index* - IPVI) e Índice de Vegetação Transformado (*Transformed Vegetation Index* - TVI) se tornaram insensíveis ao crescimento das plantas quando elas ultrapassavam 0,40 m de altura. Para o capim, os índices apresentaram desempenho inferior na estimativa de altura, sendo que somente os índices de Proporção de Banda (*Band Ratio* - RATIO), TVI, NDVI e IPVI apresentaram boa relação linear ($R^2 \approx 0,76$). Assim, as respostas dos índices variam de acordo com as características da vegetação e com o estágio fenológico em que ela se encontra.

Não obstante, tanto a altura, como os índices de vegetação podem ser relacionados com a produtividade e a biomassa. Bendig et al. (2015) verificaram que a combinação dos índices de vegetação com informações sobre a altura permitiu gerar um modelo melhor para a estimativa da biomassa do que quando utilizaram uma variável somente. Yu et al. (2020), ao incorporarem medidas de altura em um modelo de estimativa de produção para cana-de-açúcar, observaram uma melhora nos resultados obtidos, concluindo

que as medidas realizadas no último estágio de desenvolvimento produziram resultados mais significativos, não sendo por isso necessário amostrar todo o período de desenvolvimento. Portanto, mesmo não apresentando relação direta, essas variáveis podem se complementar em análises de outras propriedades da vegetação.

4.2 Estimativa da produção

A altura média estimada para o mês de setembro foi de 2,98 m para a área de 13,73 ha, e considerando o diâmetro médio de 2,75 cm (LOPES, 2011), o volume produzido conforme a Equação 3.1 foi de 5188,22 m³. Considerando a densidade da cana-de-açúcar como sendo 0,299 g/cm³ (AZZINI et al., 1986), então o volume produzido estimado em toneladas, foi de 1551,28 ton ao todo, e portanto, a produtividade estimada para a safra 2019/2020 foi de 112,98 ton/ha. Os valores de comprimento (425 m) e largura (283 m) utilizados foram medidos no próprio modelo de altura gerado, já para o espaçamento foi utilizado o padrão de 1,5 m.

$$V = 2,98m * (0,0275m/2)^2 * \pi * [(425m/0,0275) * (283m/1,50m + 1)] = 5188,22 \text{ [m}^3\text{]},$$

O coeficiente de decaimento para a cana-de-açúcar considerado foi de 0,3, levando em consideração uma intensidade de manejo mediana (BERNARDES et al., 2008). Assim, a produtividade para o quarto ano de corte foi de 74,5 ton/ha.

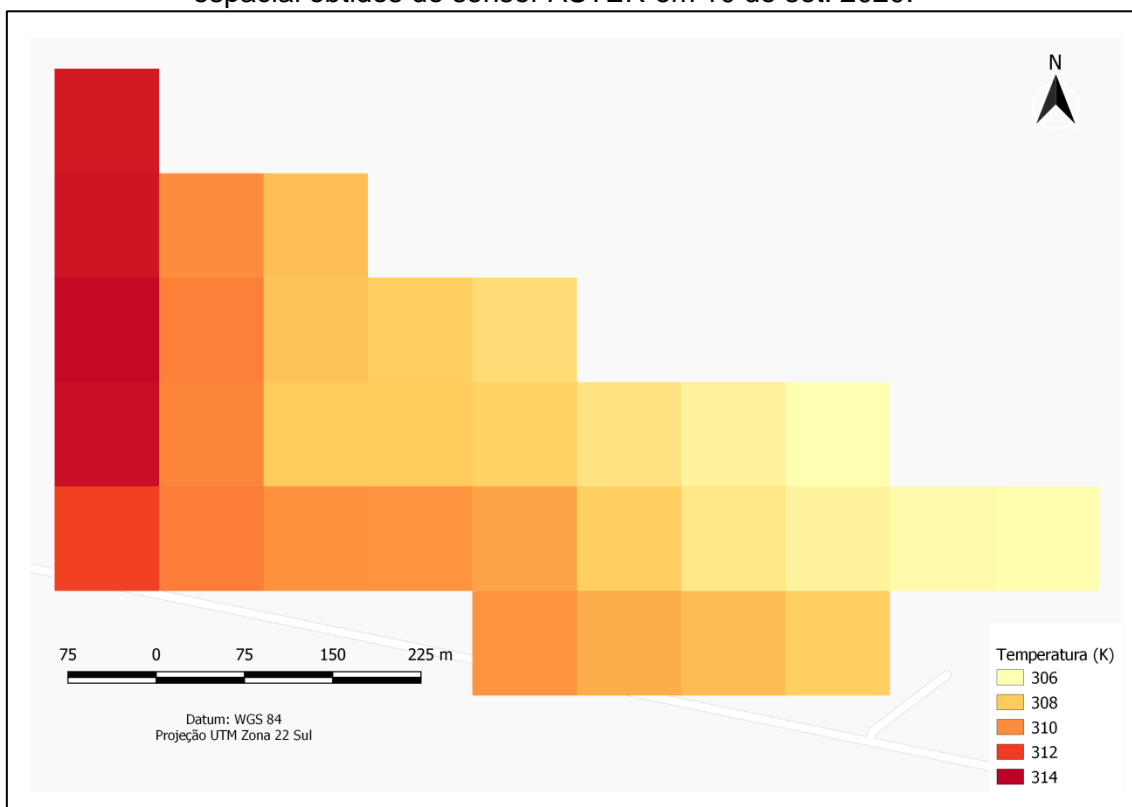
$$TCH_4 = 112,98 * 4^{(-0,3)} = 74,5 \text{ [ton/ha]}$$

O volume real colhido para a safra de 2019/2020 foi de 1056,52 ton, o que proporcionou uma produtividade real de 76,95 ton/ha (dados foram fornecidos pela empresa após o corte). Assim, a produtividade estimada após a correção com o coeficiente de decaimento ficou próxima da produtividade real, evidenciando a efetividade do modelo. Todavia, para melhor validação do modelo, é indicado a utilização de dados de campo na equação (ex. densidade, diâmetro), na falta desses, foram utilizados os dados empíricos.

4.3 Análise de temperatura e emissividade da cana-de-açúcar

Para avaliar possíveis relações entre as métricas extraídas do VANT e imagens ópticas, foram estudados dados adquiridos pelo sensor ASTER na faixa espectral do infravermelho termal em 10 de setembro de 2020. Devido a baixa resolução espacial deste sensor, foi considerada para análise a área total do talhão (30,33 ha). Apesar de sua baixa resolução espacial, foi possível observar diferenças na temperatura interna do talhão de cana-de-açúcar (Figura 4.6). A temperatura teve amplitude de 306 K a 313,7 K (33 a 40,7 °C), uma variação de quase 8°, sendo os valores mais altos localizados na porção oeste do talhão, sendo a média de temperatura de 309,85 K. À oeste e ao sul do talhão (onde as temperaturas foram maiores), estão localizados dois carregadores, além disso, à oeste, também está localizada uma linha de alta tensão. Ao norte, fica uma área de várzea com APP preservada. Assim, as características do entorno do talhão influenciaram nas variações de temperatura do mesmo.

Figura 4.6 - Mapa de temperatura da cana-de-açúcar com 100 m de resolução espacial obtidos do sensor ASTER em 10 de set. 2020.



As análises de correlações (Tabela 4.2) não indicaram nenhuma correlação entre a temperatura do dossel e a altura. Os maiores valores de correlação foram entre a altura e a emissividade, principalmente para as bandas 11, 13 e 14 (Tabela 3.4), no entanto, os valores ainda ficaram abaixo de 0.5. Todavia, a temperatura não apresentou correlação com a taxa de crescimento, indicando que a emissividade, particularmente nas faixas correspondentes as bandas B11, B13 e B14, seriam as melhores faixas espectrais para análises termais da cana-de-açúcar, principalmente quando relacionadas com dados de altura e/ou taxa de crescimento. Todavia, vale ressaltar, que a baixa resolução espacial dos dados causa grande homogeneização do talhão, tornando-se, assim, necessária uma avaliação com uso de resoluções mais refinadas, a fim de se abranger toda a variabilidade interna da área de estudo.

Tabela 4.2 – Resultado da análise de correlação entre temperatura e emissividade em diferentes faixas espectrais com a altura estimada para 100 m de resolução espacial relativos a 10 set. 2020.

Coefficiente de Pearson (ρ)	
B10	0,1986
B11	0,4975
B12	0,1767
B13	0,4173
B14	0,4275
Temperatura	-0,0726

4.4 Zonas de manejo

4.4.1 Análise exploratória dos dados


4.4.1.1 Tendência à formação de *clusters*

O valor da estatística Hopkins entre a taxa de crescimento e NDVI foi de 0,076, e entre a taxa de crescimento e o EVI foi de 0,079. Isso significa que, como os valores estatísticos estão próximos de zero, os dados apresentam tendência à formação de *clusters*.

Pela abordagem de análise visual da tendência de formação de *clusters* (VAT – *visual assessment of cluster tendency*) (BEZDEK; HATHAWAY, 2002) (Figura 4.7), é possível verificar que há uma estrutura de *clustering* nas bases de dados pela presença de blocos vermelhos ao longo da diagonal principal.

Todavia, a coloração clara indica que os valores de dissimilaridades não são tão evidentes.

Figura 4.7 - Matrizes de dissimilaridade entre a) taxa de crescimento e NDVI e b) taxa de crescimento e EVI.



4.4.1.2 Número ótimo de *clusters*

Para definir o número ótimo de *clusters* em cada resolução espacial, 23 índices foram aplicados por meio de uma função no *software* R, sendo o melhor agrupamento escolhido de acordo com a regra da maioria, ou seja, o aquele que foi apontado pela maioria dos índices.

Sendo assim, entre as variáveis NDVI e taxa de crescimento, os números ótimos de *clusters* segundo a maioria dos índices foi 2 e 3. Enquanto que, para o EVI e taxa de crescimento os números ótimos de *clusters* foram de 5 e 2. Em geral, os trabalhos publicados operam com duas ou três zonas de manejo (BREUNIG et al., 2020b; TAGARAKIS et al., 2012; SONG et al., 2009).

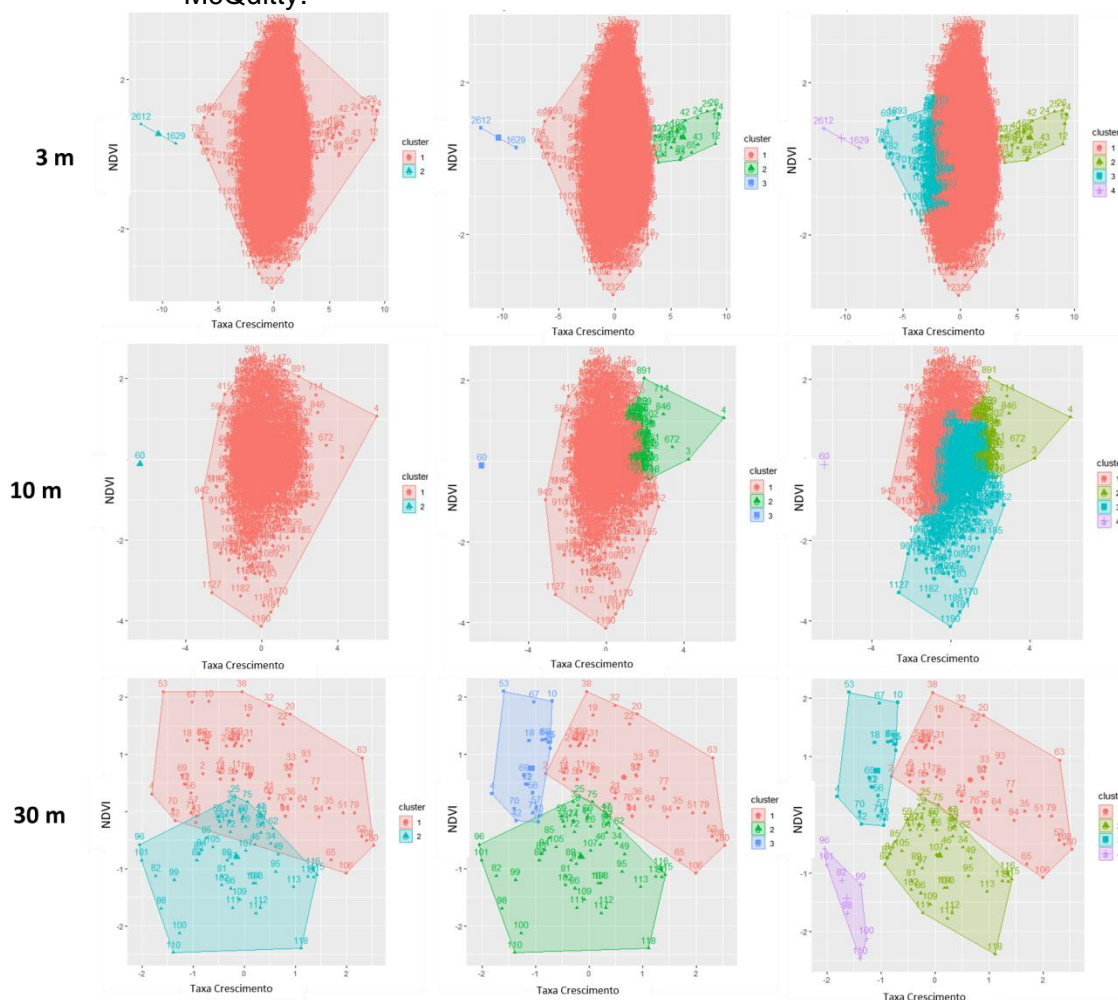
No entanto, apesar de definido qual o melhor agrupamento, foram geradas duas, três e quatro zonas de manejo para cada base de dados, resolução e método, a fim de verificar a influencia de cada uma dessas variáveis na formação dos grupos.

4.4.2 Criação de zonas de manejo

4.4.2.1 Taxa de crescimento e NDVI

Nas Figuras 4.8 e 4.9, são apresentados os gráficos de dispersão entre a taxa de crescimento e NDVI para cada número de zonas formadas em cada resolução espacial (3, 10 e 30 m), para o método de McQuitty e *k-means*, respectivamente. Pela comparação entre os gráficos, é possível perceber que método de *clustering* possui grande influência no delineamento das zonas de manejo, pelas diferenças nas escolhas para a formação dos grupos. O método de particionamento *k-means* criou zonas de manejo (ZMs) mais homogêneas quanto a sua distribuição espacial, com número de células parecido em cada zona. Isto não ocorreu com o método hierárquico de McQuitty, em que as ZMs ficaram mais dispersas e com o maior número de células concentradas em um grupo. Nesse caso, quanto maior a resolução espacial maior é a dominância de um único grupo. Essa diferença fica clara quando se observam os mapas de zonas de manejo (Figuras 4.10 e 4.11).

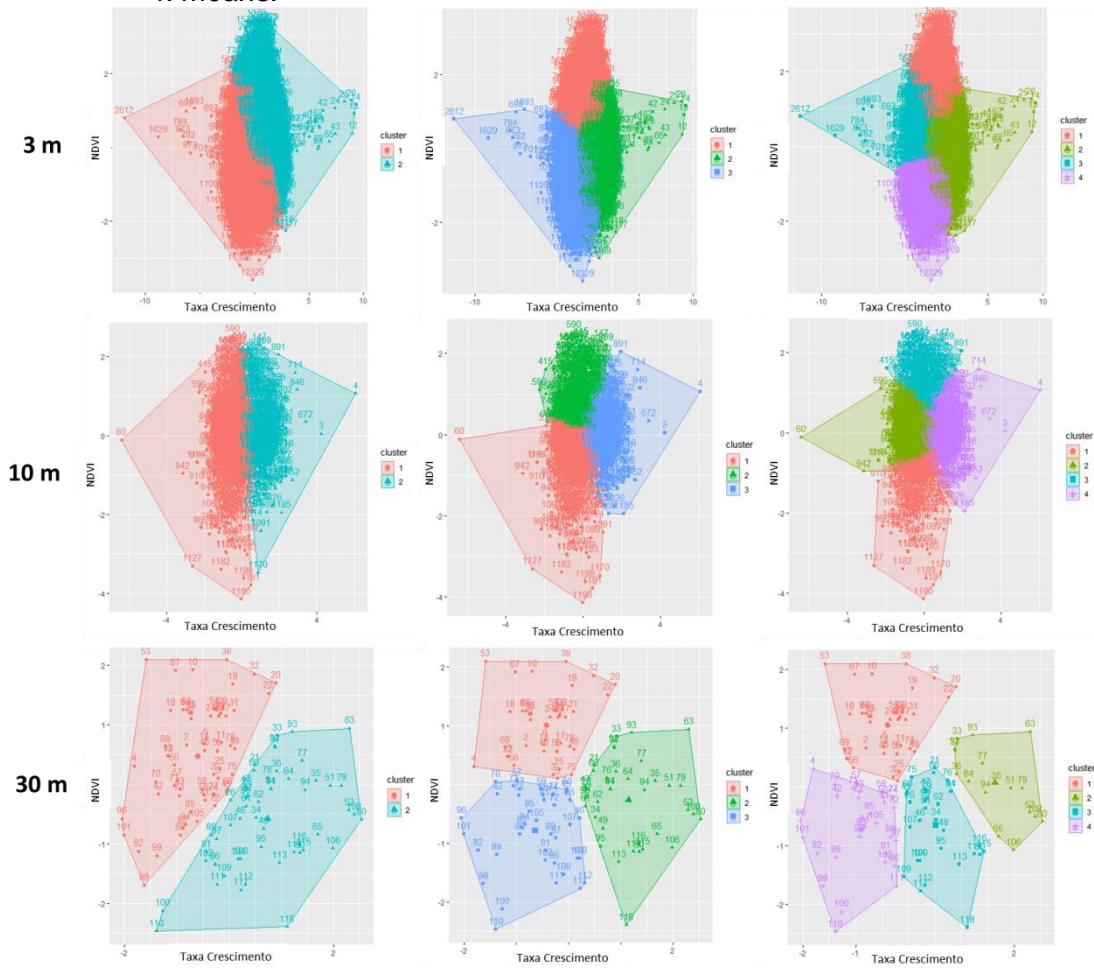
Figura 4.8 - Gráficos de dispersão entre taxa de crescimento e NDVI para o método de McQuitty.



Em relação à resolução espacial, com 30 m observa-se uma separação mais clara entre as zonas, para ambos os métodos mencionados (Figuras 4.8 e 4.9), provavelmente devido à menor quantidade de dados. Além disso, a presença de *outliers* pode ter influenciado na formação das zonas de manejo, principalmente para o método de McQuitty nas resoluções de 3 e 10 m, pois alguns grupos foram formados por poucas células que se destacaram das demais, e esses agrupamentos foram também os que tiveram os maiores valores de silhueta média (ASC) (Tabela 4.3), principalmente com duas e três zonas. Assim, é recomendada a identificação e remoção de *outliers* para evitar erros no delineamento das ZMs, principalmente quando se utilizam métodos hierárquicos, que se mostraram mais sensíveis a tais delineamentos. No entanto, de acordo com a ANOVA (teste Tukey), as quatro ZMs formadas

apresentaram médias estatisticamente diferentes, com exceção da resolução espacial de 30 m, em que as zonas 3 e 4 não apresentaram diferenças significativas (Tabela 4.3).

Figura 4.9 - Gráficos de dispersão entre taxa de crescimento e NDVI para o método de *k-means*.



O método de *k-means* não apresentou diferenças relevantes nos valores do coeficiente de silhueta, indicando que nem o número de grupos nem a resolução espacial tiveram influência na qualidade na definição das ZMs. Todavia, os valores de ASC para esse método foram menores que 0,4, indicando que o agrupamento apresentou alguma confusão, sugerindo uma divisão não tão apropriada das ZMs. Contudo, os resultados da ANOVA (Teste Tukey), com significância de 0,05, indicaram diferenças significativas entre as médias das ZMs, em todas as resoluções espaciais e para todos os agrupamentos formados (2, 3 e 4 zonas) (Tabela 4.4). Além disso, a taxa de crescimento aparentemente teve grande influência no agrupamento para esse

método, pois, por meio de análise visual, é possível perceber que houve uma divisão entre as regiões de maior e menor crescimento, principalmente na divisão entre duas ZMs.

Tabela 4.3 – Resultados da avaliação dos métodos de *clustering* em diferentes resoluções espaciais na geração de 2, 3 e 4 zonas de manejo em termos da silhueta média (ASC) e ANOVA (teste Tukey) para o NDVI e taxa de crescimento como dados de entrada.

	Resolução espacial (m)	2 zonas			3 zonas			4 zonas					
		ASC	Z ₁	Z ₂	CS	Z ₁	Z ₂	Z ₃	CS	Z ₁	Z ₂	Z ₃	Z ₄
McQuitty	3	0,83			0,71				0,19	d	a	b	c
	10	0,73			0,28				0,20	d	a	b	c
	30	0,26			0,23				0,24	c	a	b	b
Kmeans	3	0,33	a	b	0,38	c	a	b	0,35	d	a	b	c
	10	0,34	a	b	0,36	c	a	b	0,37	d	a	b	c
	30	0,34	a	b	0,38	b	a	b	0,34	d	a	b	c

Figura 4.10 - Mapa de zonas de manejo, com as variáveis NDVI e taxa de crescimento, geradas a partir do método de McQuitty.

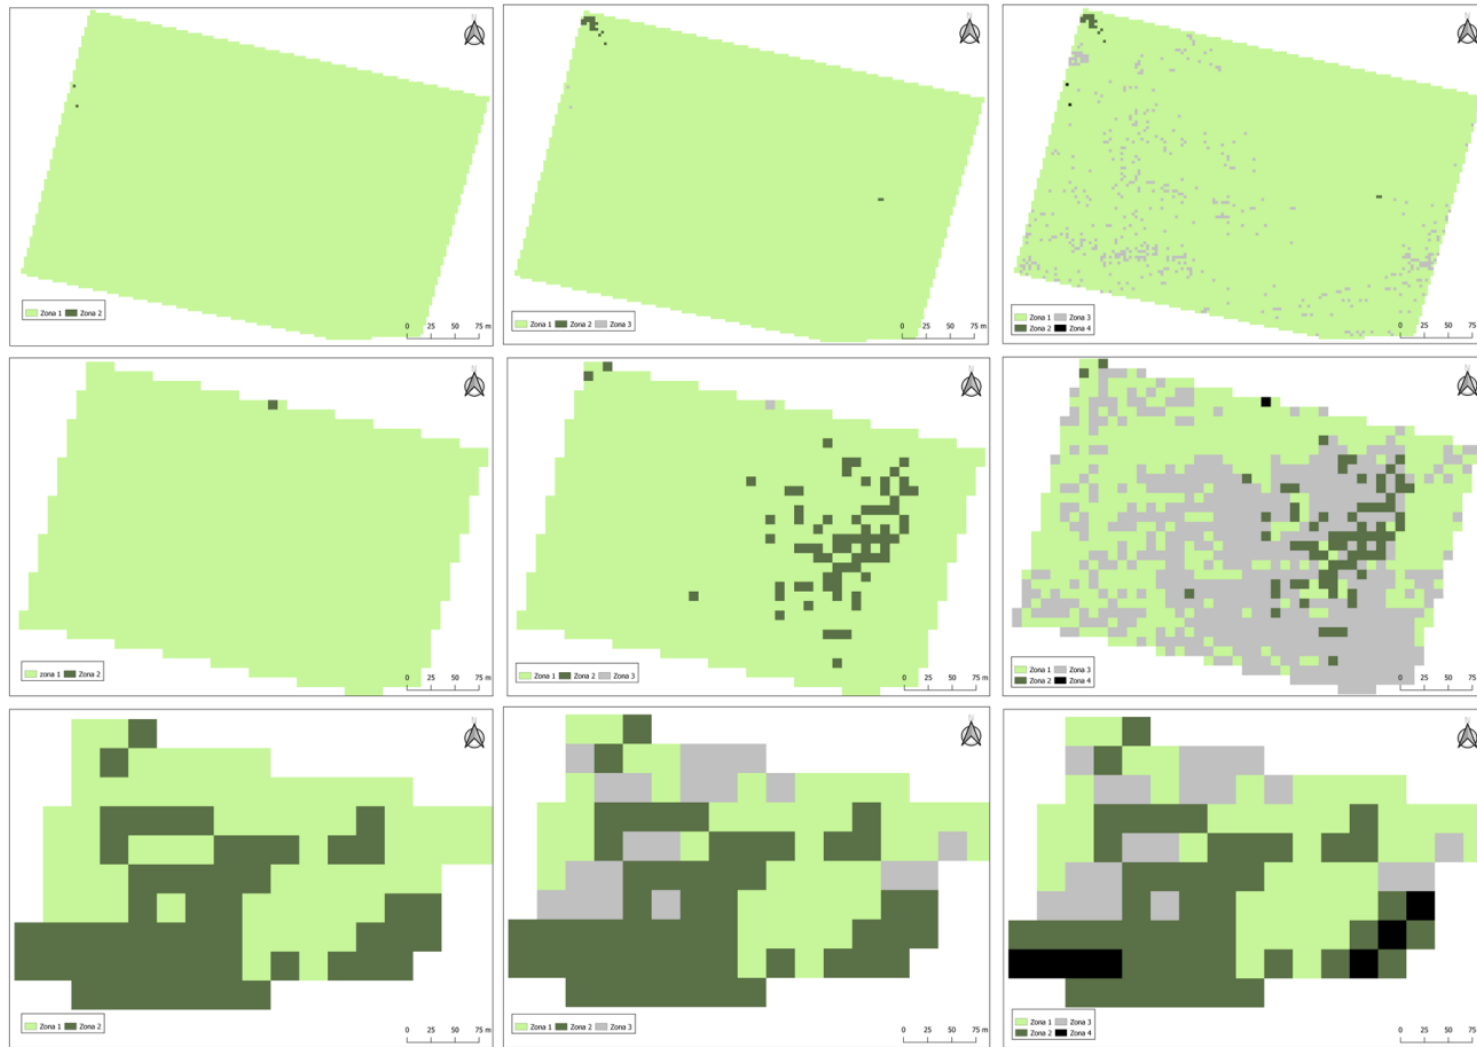
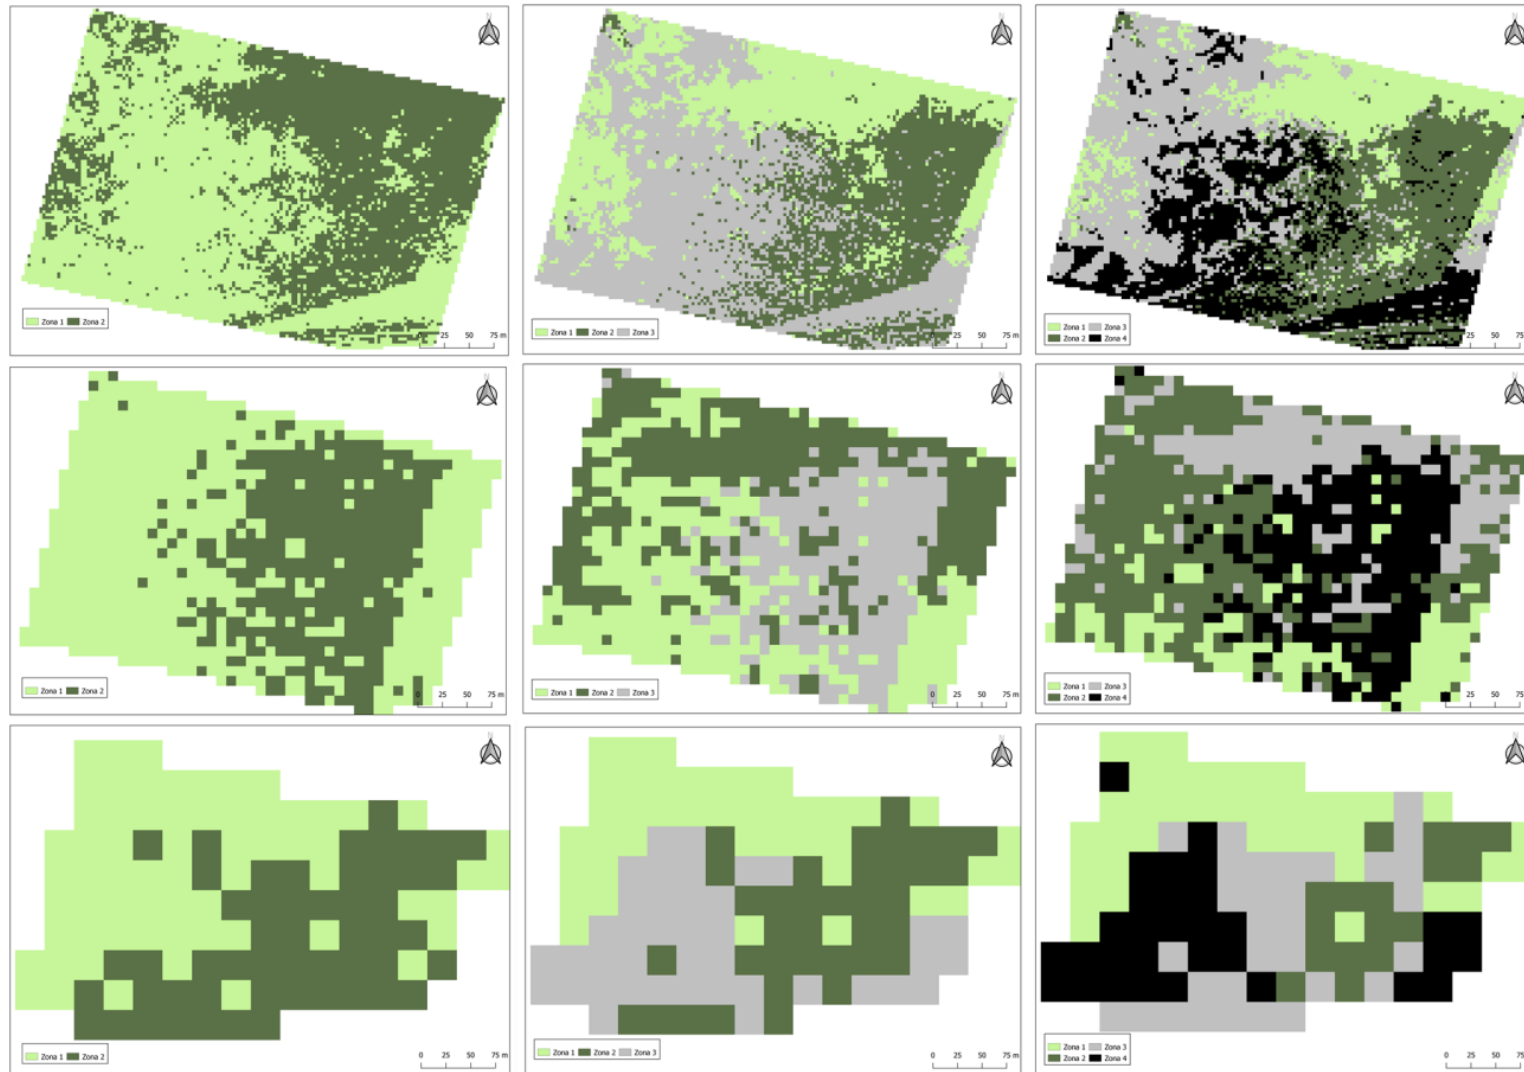


Figura 4.11 - Mapa de Zonas de Manejo, com as variáveis NDVI e taxa de crescimento, geradas a partir do método *k-means*.



4.4.2.2 Taxa de crescimento e EVI

Nas Figuras 4.12 e 4.13, estão representados os gráficos de dispersão entre a taxa de Crescimento e o EVI para cada número de zonas formadas em cada resolução espacial (3, 10 e 30 m), pelo Método de McQuitty e *k-means*, respectivamente. Assim como o NDVI, tendo o EVI como variável de entrada, no Método de McQuitty houve a dominância de um grupo sobre os demais. Ela, contudo, foi um pouco menos pronunciada, indicando que com o EVI o método se torna um pouco menos sensível aos *outliers*. O método de *k-means* continuou apresentando grupos mais homogêneos, com divisões bem parecidas às que ocorreram com o NDVI, com exceção daquela com 30 m de resolução espacial, que apresentou distribuição bem diferente em ambos os métodos, o que também pode ser observado na Figura 4.15.

Na Tabela 4.4, estão apresentados os valores de silhueta média (ASC) obtidos para cada método bem como os resultados do teste Tukey a 0,05 de significância. Diferentemente do NDVI, os maiores valores, para ambos os métodos, foram obtidos pelas zonas formadas com 30 m de resolução espacial, sendo o maior valor obtido pelo método de McQuitty com duas zonas. Analisando o gráfico de dispersão, é possível observar a clara distinção entre os grupos, no entanto, como se pode observar nos mapas de zonas de manejo para o método de McQuitty (Figura 4.14), da mesma forma como ocorreu com o NDVI, há a predominância de uma ZM, com a diferença de que, nesse caso, há uma maior prevalência de uma segunda ZM. Os valores de ASC para o método de *k-means* não se diferenciaram muito dos valores obtidos com o NDVI, com exceção daqueles na resolução espacial de 30 m, em que os valores de ASC foram um pouco maiores. Os resultados da ANOVA, com significância de 0,05, também indicaram diferenças significativas entre as médias das ZMs.

Figura 4.12 - Gráficos de dispersão entre taxa de crescimento e EVI para o método de McQuitty.

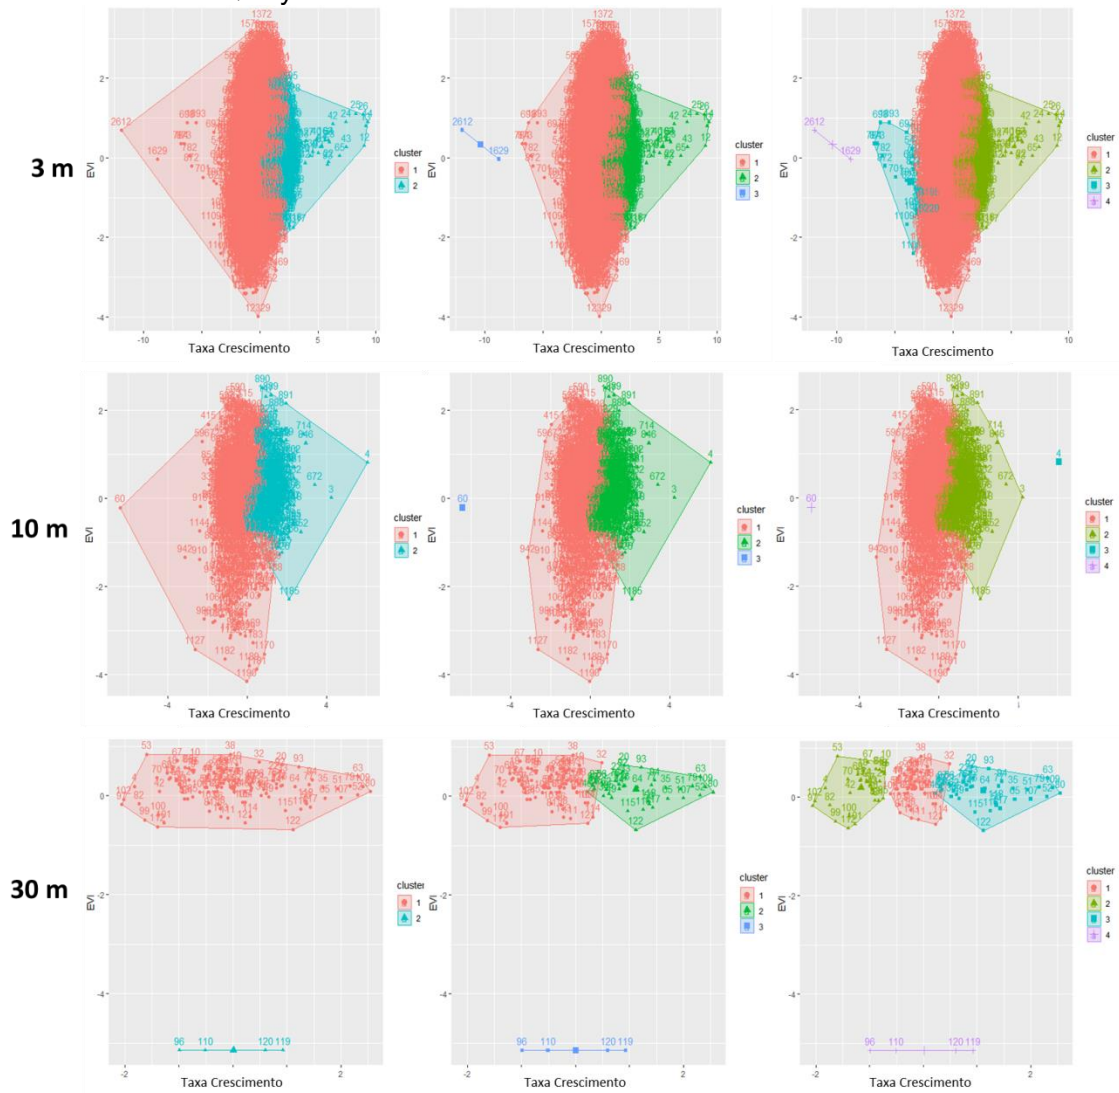


Figura 4.13 - Gráficos de dispersão entre taxa de crescimento e EVI para o método *k-means*.

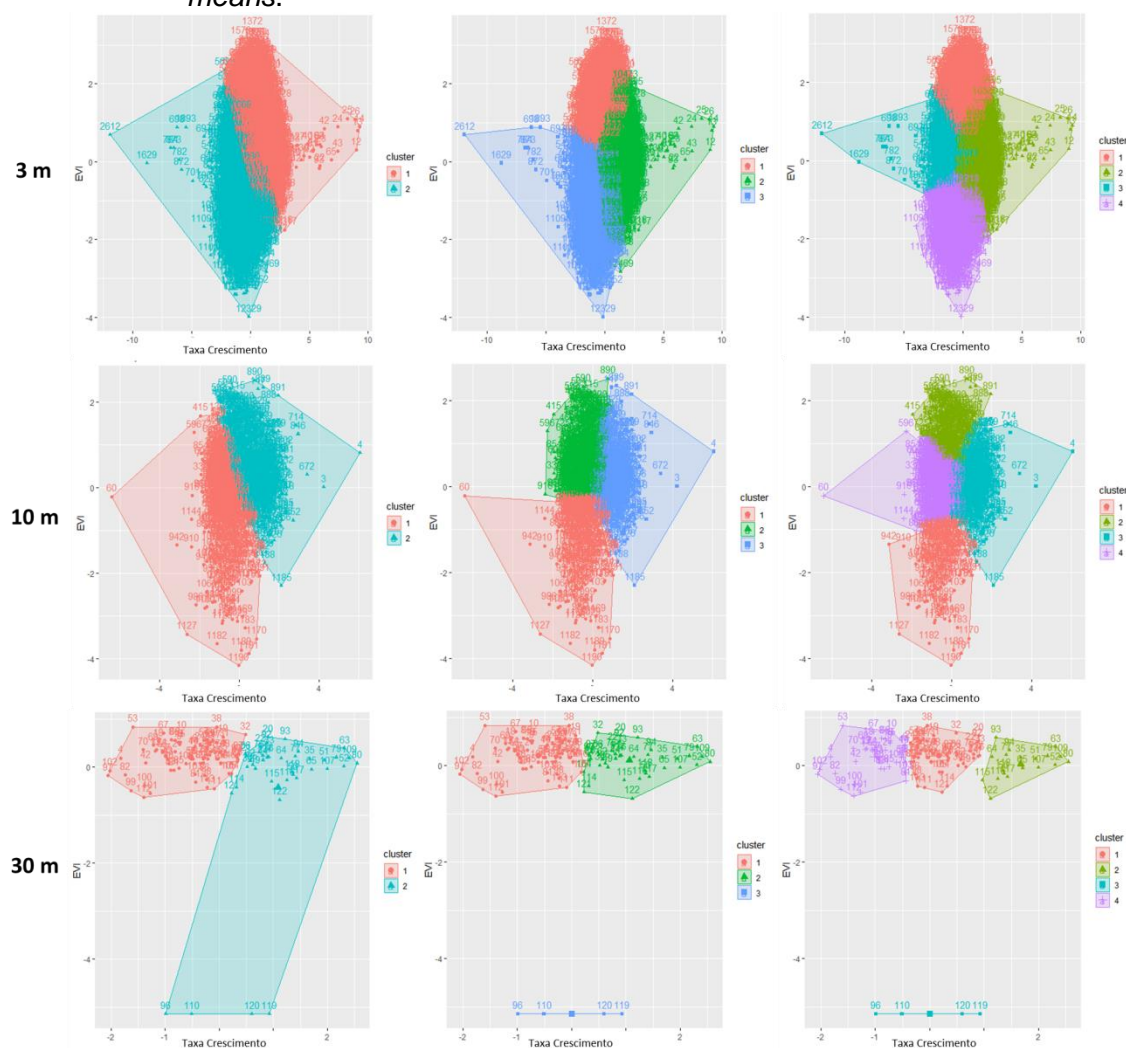


Tabela 4.4 - Resultados da avaliação dos métodos de *clustering* em diferentes resoluções espaciais na geração de 2, 3 e 4 zonas de manejo em termos da silhueta média (ASC) e ANOVA (teste Tukey) para o EVI e taxa de crescimento como dados de entrada.

	Resolução espacial (m)	2 zonas		3 zonas			4 zonas						
		ASC	Z ₁	Z ₂	CS	Z ₁	Z ₂	Z ₃	CS	Z ₁	Z ₂	Z ₃	Z ₄
McQuitty	3	0,29			0,29				0,28	d	a	b	c
	10	0,32			0,32				0,32	d	a	b	c
	30	0,77			0,50				0,41	c	a	b	b
Kmeans	3	0,33	a	b	0,37	c	a	b	0,36	d	a	b	c
	10	0,33	a	b	0,37	c	a	b	0,38	d	a	b	c
	30	0,47	a	b	0,51	b	a	b	0,44	d	a	b	c

Figura 4.14 - Mapa de zonas de manejo, com as variáveis EVI e taxa de crescimento, geradas a partir do método de McQuitty.


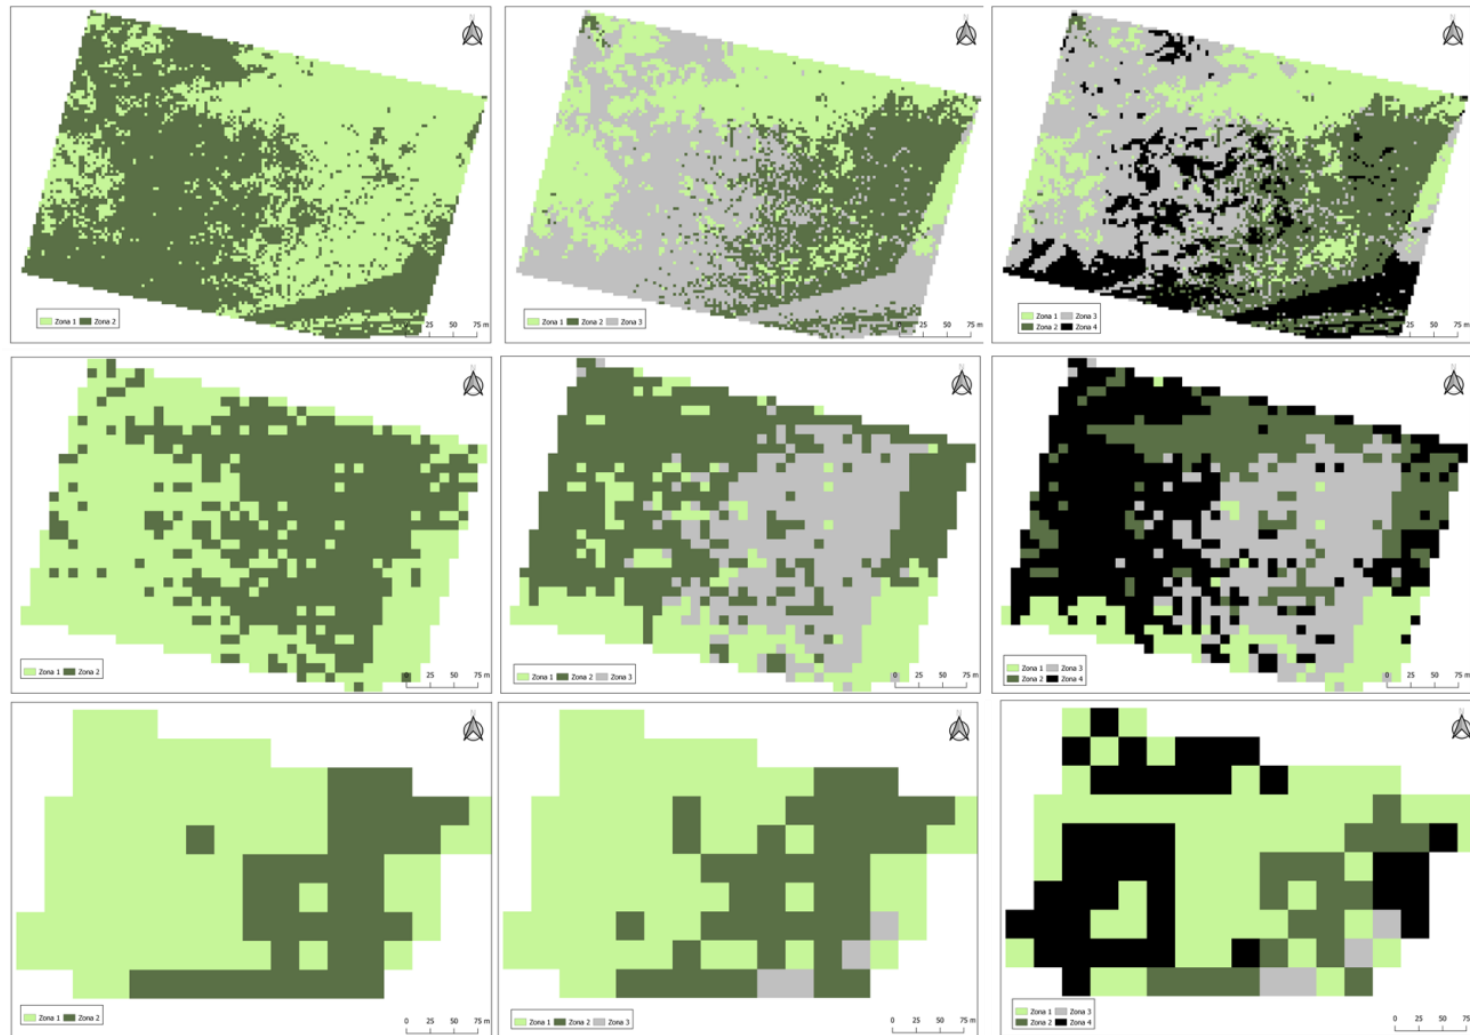


Figura 4.15 - Mapa de zonas de manejo, com as variáveis EVI e taxa de crescimento, geradas a partir do método *k-means*.



4.4.2.3 Análise dos resultados

Para ambas as variáveis de entrada, houve diferenças nos resultados obtidos com cada método de agrupamento. Isso ocorre devido à forma como cada método realiza os agrupamentos. Métodos hierárquicos, como o método de McQuitty, dividem os elementos de um conjunto de dados em números específicos de grupos em um ou mais passos. Nesse método, o agrupamento é realizado definindo uma série de divisões conectadas. No caso do método de McQuitty, cada grupo começa com um único elemento, e se agrupam até a formação de um único grupo que contém todos os elementos, ou seja, é uma técnica aglomerativa. Assim, mais de um tipo de agrupamento é possível (EVERITTY, 2011).

Em cada etapa, o método de McQuitty, também conhecido como método da ligação média ponderada (do inglês, *weighted pair group method with averaging* - WPGMA), realiza o agrupamento entre dois grupos com a maior similaridade, e assim, na próxima iteração, a distância deste grupo para o restante é simplesmente a média aritmética das distâncias médias entre os membros do grupo formado (MCQUITTY, 1966). Nesse método, os membros em grupos menores recebem peso maior do que os membros de grupos maiores, o que é útil quando os tamanhos dos grupos são desiguais (EVERITTY, 2011).

O algoritmo *k-means* realiza uma divisão dos n elementos em um número de grupos predefinido, pela escolha de um centroide de referência (centro geométrico artificial do grupo) e uma função de distância (euclidiana, no caso), buscando maximizar a similaridade entre os elementos do grupo e minimizar as semelhanças entre os diferentes grupos. Portanto, cada elemento pertence a um único grupo. Para tanto, esse método busca minimizar a soma dos quadrados das distâncias entre os elementos e centroides de cada grupo (GAVIOLLI et al., 2019). Conforme a iteração ocorre, o valor de cada centroide é refinado pela média dos valores de cada elemento pertencente ao centroide. Esse método tem a vantagem de ser simples e rápido. Todavia, os resultados

obtidos podem não ser os mesmos a cada vez que se roda o algoritmo, pois o ponto de partida é escolhido aleatoriamente todo vez que se inicia o programa.

Com relação à avaliação dos métodos, praticamente todas as análises não obtiveram valores muito altos de silhueta média (ASC), indicando alguma confusão entre os grupos, enquanto a ANOVA demonstrou diferenças entre os valores médios dos grupos. Vale ressaltar que, apesar de não terem sido tão próximos a 1, todos os valores de ASC foram positivos, assim, pode-se afirmar que, mesmo não havendo confusão entre os indivíduos de cada ZM, o resultado obtido teve uma qualidade satisfatória, já que os valores de ASC variam de -1 a 1.

Convém informar, ainda, que o ASC foi calculado levando em consideração a taxa de crescimento e os índices de vegetação, enquanto a ANOVA considerou somente as diferenças entre as taxas de crescimento dos grupos, não levando em conta os valores dos índices. Isto pode ter influenciado nos melhores resultados apresentados pela ANOVA em relação ao ASC. Um teste ANOVA foi realizado, a fim de verificar o comportamento das ZMs com ambas as variáveis, e os resultados desse teste também indicaram diferenças significantes entre os grupos ($p < 0,05$).

Por fim, é importante ter cautela ao utiliza essas áreas como zonas de manejo, porque não foram comparadas a resultados gerados com métodos tradicionais, que utilizam dados de solo e produtividade. Em trabalhos futuros, outros métodos poderão ser utilizados como o *Management Zone Analyst* (MZA) e outros (GAVIOLI et al., 2019).

5 CONCLUSÃO

Os modelos de altura criados possibilitaram retratar as fases de crescimento da cana-de-açúcar, permitindo o acompanhamento do desenvolvimento da plantação. Ademais, as análises feitas com imagens de VANT possibilitam uma continuidade espacial e capturam a microvariabilidade existente no talhão, permitindo uma avaliação mais precisa e detalhada do mesmo, o que não é possível com análises feitas somente em campo, que caracterizam os talhões por meio de amostras. Estas informações são essenciais para a tomada de decisão e aumento da eficiência da produção, justamente por reduzirem os erros devido à possível má representatividade das amostras em campo. Todavia, recomenda-se o uso de pontos de controle ou RTK para evitar erros e melhorar a qualidade dos modelos. Além disso, voos realizados em horários diferentes, principalmente, nos períodos de maior sombra, agregam erros nas estimativas e devem ser evitados.

Foi possível o cálculo do volume produzido e produtividade com boa precisão, pelo método de volumetria, utilizando a altura estimada. No entanto, a utilização de dados empíricos e não-amostrados em campo pode agregar erros ao método. Assim, para um resultado mais preciso e fidedigno recomenda-se a utilização de dados de campo para o cálculo do volume.

Os índices de vegetação, NDVI e EVI, não apresentaram correlação espacial com a altura estimada, o que já era esperado pelas características da cultura. A temperatura e a emissividade também não apresentaram uma correlação com a altura estimada, no entanto, foi possível identificar faixas espectrais de emissividade mais propícias para análises juntamente com a altura. Contudo, dados de temperatura/emissividade com melhor resolução espacial poderiam fornecer melhores resultados.

Foi possível a criação mapas de zonas de manejo com boa qualidade, para as três resoluções espaciais, principalmente pelo método *k-means*. Entretanto, diferentes métodos de *clustering* bem como diferentes variáveis de entrada produziram resultados diferentes, inviabilizando alguns resultados. O método hierárquico de McQuitty produziu ZMs mais dispersas e com predominância de

um ou dois grupos, enquanto o método de particionamento *k-means* produziu ZMs mais homogêneas, se mostrando menos sensível a mudança de uma das variáveis de entrada. Pode-se concluir que duas ZMs são o resultado mais indicado, utilizando como variáveis o NDVI e a taxa de crescimento. No entanto, é fundamental identificar a melhor combinação entre o método e as variáveis de acordo com o objetivo. Além disso, apesar de as ZMs apresentarem diferenças significativas de acordo com os testes estatísticos, recomenda-se a validação com dados de campo para uma avaliação mais precisa dos métodos e das ZMs criadas.

Conclui-se, portanto, que é possível o desenvolvimento de metodologias com o uso de imagens de VANTs e de sensores orbitais, que permitam de identificar características nas áreas agrícolas que possam ser aplicadas no gerenciamento de culturas, especialmente no setor sucroalcooleiro. Contudo, para obter resultados mais precisos é fundamental a coleta de dados em campo das áreas analisadas, importantes tanto como referência, quanto para validação dos resultados. Vale destacar, que mapeamentos com o uso de VANTs já são realizados de forma regular pela usina, que, no entanto, são subutilizados, já que na maior parte dos casos, são realizadas somente análises visuais.

REFERÊNCIAS BIBLIOGRÁFICAS

AASEN, H.; BURKART, A.; BOLTEN, A.; BARETH, G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: from camera calibration to quality assurance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 245-259, 2015.

ABBAS, A.; KHAN, S.; HUSSAIN, N.; HANJRA, M. A.; AKBAR, S.. Characterizing soil salinity in irrigated agriculture using a remote sensing approach. **Physics And Chemistry of The Earth, Parts A/B/C**, v. 55-57, p. 43-52, 2013.

ABDEL-RAHMAN, E. M.; AHMED, F. B. The application of remote sensing techniques to sugarcane (*Saccharum spp. hybrid*) production: a review of the literature. **International Journal of Remote Sensing**, v. 29, n. 13, p. 3753-3767, 2008.

ABRAMS, M. J.; HOOK, S.; ABRAMS, M. C. Imaging spectrometry in the thermal infrared. In: MEER, F. D. van Der; JONG, S. M.(Ed.). **Imaging spectrometry: basic principles and prospective applications**. Dordrecht: Kluwer Academic Publishers, 2002. p. 283-306. (Remote Sensing and Digital Image Processing).

AGISOFT. **Agisoft metashape user manual**: professional edition, version 1.5. 2019. Disponível em: https://www.agisoft.com/pdf/metashape-pro_1_5_en.pdf. Acesso em: 26 jan. 2020.

ALZABEN, H.; FRASER, R.; SWANTON, C.. An inverse correlation between corn temperature and nitrogen stress: a field case study. **Agronomy Journal**, v. 111, n. 6, p.3207-3219, 2019.

AWAD, M. Toward precision in crop yield estimation using remote sensing and optimization techniques. **Agriculture**, v. 9, n. 3, p. 54, 2019. MDPI AG.

AYOADE, J. O. **Introdução à climatologia para os trópicos**. 4. ed. Rio de Janeiro: Bertrand Brasil, 1996. 332 p.

AZZINI, A.; ZULLO, M. A.T; ARRUDA, M. C. Q.; BASTOS, C. R.; COSTA, A. A. Densidade básica do colmo e sua correlação com os valores de brix e pol em cana-de-açúcar. **Bragantia**, v. 45, n. 1, p. 155-160, 1986.

BENDIG, J.; BOLTEN, A.; BARETH, G.. UAV-based imaging for multi-temporal, very high resolution crop surface models to monitor crop growth variability. **Photogrammetrie - Fernerkundung - Geoinformation**, v. 2013, n. 6, p.551-562, 2013.

BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. 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.

BENVENUTI, F. A. **Relação de índices espectrais de vegetação com a produtividade da cana-de-açúcar e atributos edáficos**. 2005. 120 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, SP, 2005.

BERNARDES, M.S.; PRELLWITZ, W.P.V.; BRAGA JUNIOR, R. L. C.; SUGUITANI, C.; BEAUCLAIR, E.G.F.; CÂMARA, G.M. S. Equação para estimativa de produtividade dos sucessivos cortes associada ao ambiente de produção e manejo da cultura de cana-de-açúcar (*Saccharum spp*). In: CONGRESSO NACIONAL DA STAB, 9., 2008. **Anais...** 2008. p.628-631.

BEZDEK, J.C.; HATHAWAY, R.J. VAT: a tool for visual assessment of (cluster) tendency. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 12., 2002, Madri. **Proceedings...** IEEE, 2002. p. 2225-2230.

BIAN, J.; ZHANG, Z.; CHEN, J.; CHEN, H.; CUI, C.; LI, X.; CHEN, S.; FU, Q. Simplified evaluation of cotton water stress using high resolution unmanned aerial vehicle thermal imagery. **Remote Sensing**, v. 11, n. 3, p.267-284, 2019.

BOYDELL, B.; MCBRATNEY, A. B. Identifying potential within-field management zones from cotton-yield estimates. **Precision Agriculture**, v. 3, p.9-23, 2002.

BRASIL. SENADO. **Projeto de Lei do Senado nº 304, de 2017**: institui a política de substituição dos automóveis movidos a combustíveis fósseis e altera a Lei nº 9.503, de 23 de setembro de 1997 (Código de Trânsito Brasileiro) para dispor sobre a vedação a comercialização e a circulação de automóveis movidos a combustíveis fósseis. Disponível em:

<https://legis.senado.leg.br/sdleg-getter/documento?dm=7152126&ts=1582815993352&disposition=inline>.

Acesso em: 26 fev. 2020.

BREUNIG, F. M.; GALVÃO, L. S.; DALAGNOL, R.; DAUVE, C. E.; PARRAGA, A.; SANTI, A. L.; DELLA FLORA, D. P.; CHEN, S. Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p.102004-102019, 2020a.

BREUNIG, F. M.; GALVÃO, L. S.; DALAGNOL, R.; SANTI, A. L.; DELLA FLORA, D. P.; CHEN, S. Assessing the effect of spatial resolution on the delineation of management zones for smallholder farming in southern Brazil. **Remote Sensing Applications: Society and Environment**, v. 19, p. 100325, 2020b

CAMPOS, I.; GONZÁLEZ-GÓMEZ, L.; VILLODRE, J.; GONZÁLEZ-PIQUERAS, J.; SUYKER, A. E.; CALERA, A.. Remote sensing-based crop biomass with water or light-driven crop growth models in wheat commercial fields. **Field Crops Research**, v. 216, p. 175-188, 2018.

CHU, T.; STAREK, M.; BREWER, M.; MURRAY, S.; PRUTER, L. Assessing lodging severity over an experimental maize (*Zea mays* L.) field using UAS images. **Remote Sensing**, v. 9, n. 9, p.923-947, 2017.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Acompanhamento da safra brasileira de cana-de-açúcar- Safra 2019/20**. 4. ed. Brasília: Estúdio Nous, 2020. 58 p. Disponível em: <https://www.conab.gov.br/>. Acesso em: 17 out. 2020.

CONRAD, C.; RUCKER, G. R.; SCHWEITZER, C.; DECH, S.; HAFEEZ, M. M. Modeling seasonal actual evapotranspiration with remote sensing and GIS in Khorezm region, Uzbekistan. **Remote Sensing for Agriculture, Ecosystems, and Hydrology Vi**, p.214-224, 2004.

DJI. **Phantom 4 especificações**. Disponível em: <https://www.dji.com/br/phantom-4>. Acesso em: 02 fev. 2020.

DONG, T.; LIU, J.; QIAN, B.; HE, L.; LIU, J.; WANG, R.; JING, Q.; CHAMPAGNE, C.; MCNAIRN, H.r; POWERS, J.. Estimating crop biomass using leaf area index derived from Landsat 8 and Sentinel-2 data. **Isprs Journal Of Photogrammetry And Remote Sensing**, v. 168, p. 236-250, 2020.

DUBREUIL, V.; FANTE, K. P.; PLANCHON, O.; SANT'ANNA NETO, J. L. Os tipos de climas anuais no Brasil: uma aplicação da classificação de Köppen de 1961 a 2015. **Confins**, n. 37, p.1-20, 2018.

ELARAB, M.; TICLAVILCA, A. M; TORRES-RUA, A. F.; MASLOVA, I.; MCKEE, M.. Estimating chlorophyll with thermal and broadband multispectral high resolution imagery from an unmanned aerial system using relevance vector machines for precision agriculture. **International Journal of Applied Earth Observation and Geoinformation**, v. 43, p.32-42, 2015.

ELVIDGE, C. D. Thermal infrared reflectance of dry plant materials: 2.5–20.0 μm . **Remote Sensing of Environment**, v. 26, n. 3, p.265-285, 1988.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **TERRA – Earth Observing System (EOS)**. 2013. Disponível em: https://www.cnpm.embrapa.br/projetos/sat/conteudo/missao_terra.html. Acesso em: 02 fev. 2020.

EMPRESA PAULISTA DE PLANEJAMENTO METROPOLITANO (EMPLASA). **Região metropolitana de Ribeirão Preto: estudos técnicos**. 2016. Disponível em:

emplasa.sp.gov.br/Cms_Data/Contents/Emplasa/Media/publicacoes/RMRP_estudos_tecnicos.pdf. Acesso em: 23 jan. 2020.

EUROPEAN SPACE AGENCY (ESA). **Sentinel-2**. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. Acesso em: 02 fev. 2020.

EVERITT, B. S.; LANDAU, S.; LEESE, M.; STAHL, D.I. **Cluster analysis**. 5. ed. London: John Wiley & Sons, 2011. 330 p.

FOOD AND AGRICULTURE ORGANIZATION (FAO). **The future of food and agriculture: trends and challenges**. Roma: FAO, 2017. 163 p.

FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del'arco. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017. 288 p.

GALVÃO, L. S.; EPIPHANIO, J. C. N.; BREUNIG, F. M.; FORMAGGIO, A. R. Crop type discrimination using hyperspectral data: advances and perspectives. In: PRASAD, A. H. THENKABAIL, S.; LYON, J. G. (Ed.). **Biophysical and biochemical characterization and plant species studies**. 2.ed. Boca Raton, FL: CRC Press, 2018. p. 183–211.

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; BETZEK, N. M. Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. **Biosystems Engineering**, v. 181, p.86-102, 2019.

GILI, A.; ÁLVAREZ, C.; BAGNATO, R.; NOELLEMEYER, E. Comparison of three methods for delineating management zones for site-specific crop management. **Computers and Electronics in Agriculture**, v. 139, p.213-223, 2017.

GOWARD, S. N.; DYE, D. G. Evaluating North American net primary productivity with satellite observations. **Advances in Space Research**, v. 7, n. 11, p. 165-174, 1987.

GRÜNER, E.; ASTOR, T.; WACHENDORF, M. Biomass prediction of heterogeneous temperate grasslands using an SfM approach based on UAV imaging. **Agronomy**, v. 9, n. 2, p.54-70, 2019.

HARMON, T.; KVIEN, C.; MULLA, D.; HOGGENBOOM, G.; JUDY, J.; HOOK, J.; WEINREICH, D. Precision agriculture scenario. In: LAGASSE, P.; MORRISON, R. (Ed.). **Sensors for environmental observatories: report of the NSF-sponsored Workshop December 2004**. [S.l.]: Wtec, 2005. p. 18-22.

HATFIELD, J.; BAKER, J.M.; ARKEBAUER, T.J. Leaf radiative properties and the leaf energy budget. **Agronomy Monographs**, p.93-103, 2005.

HOFFMANN, H.; NIETO, H.; JENSEN, R.; GUZINSKI, R.; ZARCO-TEJADA, P.; FRIBORG, T. Crop water stress maps for an entire growing season from visible and thermal UAV imagery. **Biogeosciences**, v. 13, n. 24, p.6545-6563, 2016.

HUETE, A et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440-451, 1997.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p.195-213, 2002.

HUNT, E. R.; DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing**, v. 39, n. 15-16, p.5345-5376, 2017.

IDGEO. Dados de biometria da cana-de-açúcar para safra 2018/2019. 2019. No prelo.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE).. **Organização doterritório**: malhas territoriais. 2020. Disponível em: <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>. Acesso em: 18 jan. 2020.

INSTITUTO DE ECONOMIA AGRÍCOLA (IEA). **Estatísticas da produção agrícola**: período de 2017 à 2018. Disponível em: http://ciagri.iea.sp.gov.br/nia1/subjetiva.aspx?cod_sis=1&idioma=1 Acesso em: 23 jan. 2020.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Dados históricos anuais**. Disponível em: <https://portal.inmet.gov.br/dadoshistoricos>. Acesso em: 18 abr. 2021.

ISHIMWE, R.; ABUTALEB, K.; AHMED, F. Applications of thermal imaging in agriculture: a review. **Advances in Remote Sensing**, v. 3, n. 3, p.128-140, 2014.

IVUSHKIN, K.; BARTHOLOMEUS, H.; BREGT, A. K.; PULATOV, A.; FRANCESCHINI, M. H.D.; KRAMER, H.; VAN LOO, E. N.; ROMAN, V. J.; FINKERS, R. UAV based soil salinity assessment of cropland. **Geoderma**, v. 338, p.502-512, 2019.

JOAQUIM, A. C. **Identificação de variedades de cana-de-açúcar em três classes texturais de solos, na região de Araraquara - SP, através de análise de nível de cinza em imagens Landsat/TM**. 96p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 1998.

JUSTICE, C. O.; VERMOTE, E; TOWSHEND, J. R. G.; DEFRIES, R.; ROY, D. P.; HALL, D. K.; SALOMONSON, V. V.; PRIVETTE, J. L.; RIGGS, J.; STRAHLER, A.; LUCHT, W.; MYNENI, R. B.; KNYAZIKHIN, Y.; RUNNING, S. W.; NEMANI, R. R.; WAN, Z.; HUETE, A. R.; LEEUWEN, W. van; WOLFE, R. E.; GIGLIO, L.; MULLER, J. P.; LEWIS, P.; BARNESLEY, M. J. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228-1249, 1998.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p.22-32, 2017.

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding groups in data: an introduction to cluster analysis**. Hoboken, New Jersey: John Wiley & Sons, 1990. 342p.

KRISHNA, K. R. **Push button agriculture: robotics, drones, satellite-guided soil and crop management**. Oakville, Ca: Apple Academic Press, 2016. 437p.

KROSS, A.; MCNAIRN, H.; LAPEN, D.; SUNOHARA, M.; CHAMPAGNE, C. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, n. 1, p. 235-248, 2015.

KUENZER, C.; DECH, S. (Ed.). **Thermal infrared remote sensing: sensors, methods, applications**. Dordrecht: Springer, 2013. 537p. (Remote Sensing and Digital Image Processing).

KUMAR, L.; SCHMIDT, K.; DURY, S.; SKIDMORE, A. Imaging spectrometry and vegetation science. In: MEER, F. D. van Der; JONG, S. M. (Ed.). **Imaging spectrometry: basic principles and prospective applications**. Dordrecht: Kluwer Academic Publishers, 2002. p. 111-155. (Remote Sensing and Digital Image Processing).

LEBLON, B.; GRANBERG, H.; CHARLAND, S.D. Shadowing effects on SPOT-HRV and high spectral resolution reflectances in Christmas tree plantations. **International Journal of Remote Sensing**, v. 17, n. 2, p. 277-289, 1996.

LIU, T.; LI, R.; ZHONG, X.; JIANG, M.; JIN, X.; ZHOU, P.; LIU, S.; SUN, C.; GUO, W. Estimates of rice lodging using indices derived from UAV visible and thermal infrared images. **Agricultural and Forest Meteorology**, v. 252, p.144-154, 2018.

LOPES, F. C. C. **Mapeamento genético da cana-de-açúcar (*Saccharum spp.*) por associação empregando marcadores SSR e AFLP**. 2011. 140 f. Tese (Doutorado em Agronomia) - Universidade de São Paulo, Piracicaba, 2011. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11137/tde->

[29062011-152130/publico/Francisco Claudio da Conceicao Lopes.pdf](https://29062011-152130/publico/Francisco%20Claudio%20da%20Conceicao%20Lopes.pdf).

Acesso em: 20 mar. 2021.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. São Paulo, SP: Blucher, 2015. 292 p.

LP_DAAC. **Data**. 2021. Disponível em: <https://lpdaac.usgs.gov/data/>. Acesso em: 17 mar. 2021.

LUNA, I.; LOBO, A. Mapping crop planting quality in sugarcane from UAV imagery: a pilot study in Nicaragua. **Remote Sensing**, v. 8, n. 6, p.500-519, 2016.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., 1967, Berkeley. **Proceedings...** Los Angeles: Universidade da Califórnia, 1967. p. 281-297.

MAES, W. H.; STEPPE, K. Perspectives for remote sensing with Unmanned Aerial Vehicles in precision agriculture. **Trends in Plant Science**, v. 24, n. 2, p.152-164, 2019.

MARAFON, A. C. **Análise quantitativa de crescimento em cana-de- açúcar**: uma introdução ao procedimento prático. Aracaju: Embrapa Tabuleiros Costeiros, 29 p. 2012.(Documentos / Embrapa Tabuleiros Costeiros, ISSN 1678-1953; 168). Disponível em: http://www.cpatc.embrapa.br/publicacoes_2012/doc_168.pdf. Acesso em: 05 mar. 2021.

MCQUITTY, L. L. Similarity analysis by reciprocal pairs for discrete and continuous data. **Educational and Psychological Measurement**, v. 26, n. 4, p.825-831, 1966.

MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: Unb, 2012. 266 p.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F.. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015. 223 p

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p.358-371, 2012.

NOVO, E. M. M. **Sensoriamento remoto**: princípios e aplicações. São Paulo. Edgard Blucher, 2010. 308p.

ORTEGA, R. A.; SANTIBÁÑEZ, O. A. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. **Computers and Electronics in Agriculture**, v. 58, n. 1, p.49-59, 2007.

PAJARES, G. Overview and current status of remote sensing applications based on Unmanned Aerial Vehicles (UAVs). **Photogrammetric Engineering & Remote Sensing**, v. 81, n. 4, p.281-330, 2015.

PALOMBO, A.; PASCUCCI, S.; LOPERTE, A.; LETTINO, A.; CASTALDI, F.; MUOLO, M. R.; SANTINI, F. Soil moisture retrieval by integrating TASI-600 airborne thermal data, WorldView 2 satellite data and field measurements: Petacciato case study. **Sensors**, v. 19, n. 7, p.1515-1535, 2019.

PAYERO, J. O.; NEALE, C. M. U.; WRIGHT, J. L.. Comparison of eleven vegetation indices for estimating plant height of alfalfa and grass. **Applied Engineering In Agriculture**, v. 20, n. 3, p. 385-393, 2004.

PLANET. **Planet imagery product specification**. Papua Province, Indonesia: Planet Labs, 2021. Disponível em: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. Acesso em: 25 fev. 2021.

PRAKASH, A. Thermal remote sensing: concepts, issues and applications. **International Archives of Photogrammetry and Remote Sensing**, v. 33, p.239-243, 2000.

PUREVDORJ, T.; TATEISHI, R.; ISHIYAMA, T.; HONDA, Y. Relationships between percent vegetation cover and vegetation indices. **International Journal of Remote Sensing**, v. 19, n. 18, p. 3519-3535, 1998.

QUEBRAJO, L.; PEREZ-RUIZ, M.; PÉREZ-URRESTARAZU, L.; MARTÍNEZ, G.; EGEA, G. Linking thermal imaging and soil remote sensing to enhance irrigation management of sugar beet. **Biosystems Engineering**, v. 165, p.77-87, 2018.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2019. Disponível em: <https://www.r-project.org/index.html>. Acesso em: 15 fev. 2020.

REES, W. G. **Physical principles of remote sensing**. 2.ed. Cambridge, Reino Unido: Cambridge University Press, 2001. 343 p.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis**. 4.ed. Berlim: Springer, 2006. 439 p.

RICHETTI, J.; BOOTE, K. J.; HOOGENBOOM, G.; JUDGE, J.; JOHANN, J. A.; URIBE-OPAZO, M. A. Remotely sensed vegetation index and LAI for parameter determination of the CSM-CROPGRO-Soybean model when in situ data are not available. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, p.110-115, 2019.

ROSSI, M. **Mapa pedológico do Estado de São Paulo**: revisado e ampliado. São Paulo: Instituto Florestal, 2017. v.1. 118p. 2017. (inclui Mapas)

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Washington: NASA, 1973. v. 1, p. 309-317.

ROUSSEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of Computational and Applied Mathematics**, v. 20, p.53-65, 1987.

RUDD, J. D.; ROBERSON, G. T.; CLASSEN, J. J. Application of satellite, unmanned aircraft system, and ground-based sensor data for precision agriculture: a review. In: ASABE ANNUAL INTERNATIONAL MEETING, 2017, Spokane, Washington. **Proceedings...** American Society of Agricultural and Biological Engineers, 2017. p.1700272-1700280.

RUIZ, J.J.; DIAZ-MAS, L.; PEREZ, F.; VIGURIA, A. Evaluating the accuracy of DEM generation algorithms from UAV imagery. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, p.333–337, 2013.

SANCHES, G. M.; DUFT, D. G.; KÖLLN, O. T.; LUCIANO, A. C. S.; CASTRO, S. G. Q.; OKUNO, F. M.; FRANCO, H. C.J. 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.

SANTESTEBAN, L. G.; GENNARO, S.F.; HERRERO-LANGREO, A.; MIRANDA, C.; ROYO, J.B.; MATESE, A. High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. **Agricultural Water Management**, v. 183, p.49-59, 2017.

SEGARRA, J.; BUCHAILLOT, M. L.; ARAUS, J. L.; KEFAUVER, S. C.. Remote Sensing for Precision Agriculture: sentinel-2 improved features and applications. **Agronomy**, v. 10, n. 5, p. 641, 2020.

SEPULCRE-CANTÓ, G.; ZARCO-TEJADA, P. J.; SOBRINO, J. A.; JIMÉNEZ-UMÑOZ, J. C.; VILLALOBOS, F. J. Spatial variability of crop water stress in an olive grove with high-spatial thermal remote sensing imagery. **Precision Agriculture: An International Journal on Advances in Precision Agriculture**, v. 7, p.267-272, 2006.

SESTARI, G.; HOLZ, E.; SPOHR, R. B.; BREUNIG, F. M. Mensuração da altura total de árvores com vant. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** São José dos Campos, INPE, 2019. Disponível em: <https://proceedings.science/sbsr-2019/papers/mensuracao-da-altura-total-de-arvores-com-vant>. Acesso em: 08 jun. 2021.

SIMÕES, M. S. **Relação entre indicadores de crescimento e de produção da cana-de-açúcar e dados espectrais terrestres e orbitais**. 2004. 117 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, SP, 2004.

SMIGAJ, M.; GAULTON, R.; BARR, S. L.; SUÁREZ, J. C. UAV-borne thermal imaging for forest health monitoring: detection of disease-induced canopy temperature increase. **ISPRS - International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 3, n.3, p.349-354, 2015.

SONG, X.; WANG, J.; HUANG, W.; LIU, L.; YAN, G.; PU, R. The delineation of agricultural management zones with high resolution remotely sensed data. **Precision Agriculture**, v. 10, n. 6, p. 471-487, 2009.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture**, v. 143, p.49-56, 2017a.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Height estimation of sugarcane using an Unmanned Aerial System (UAS) based on Structure from Motion (SfM) point clouds. **International Journal of Remote Sensing**, v. 38, n. 8-10, p.2218-2230, 2017b.

TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. A..Management zones delineation using fuzzy clustering techniques in grapevines. **Precision Agriculture**, v. 14, n. 1, p.18-39, 2012.

TODD, S. W.; HOFFER R. M.; MILCHUNAS D. G. Biomass estimation on grazed and ungrazed rangelands using spectral indices, **International Journal of Remote Sensing**, p. 427-438, 1998.

TOTH, C.; JÓÚKÓW, G.. Remote sensing platforms and sensors: a survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p.22-36, 2016.

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

TUCKER, C. J.; SELLERS, P. J. Satellite remote sensing of primary production. **International Journal of Remote Sensing**, v. 7, n. 11, p. 1395-1416, 1986.

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from Ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SfM) point clouds. **Remote Sensing**, v. 4, 1392–1410, 2012.

UNITES STATES GEOLOGICAL SURVEY (USGS). **Landsat missions:** Landsat 8. Disponível em: https://www.usgs.gov/land-resources/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con. Acesso em: 02 fev. 2020.

WANG, G.; LIU, S.; LIU, T.; FU, Z.; YU, J.; XUE, B. Modelling above-ground biomass based on vegetation indexes: a modified approach for biomass estimation in semi-arid grasslands. **International Journal of Remote Sensing**, v. 40, n. 10, p.3835-3854, 2018.

WEISS, M.; JACOB, F.; DUVEILLER, G.. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, v. 236, p.111402-111411, 2020.

WILLKOMM, M.; BOLTEN, A.; BARETH, G. Non-destructive monitoring of rice by hyperspectral in-field spectrometry and UAV-based remote sensing: case study of field-grown rice in north Rhine-Westphalia, Germany, **ISPRS International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.41, p. 1071–1077, 2016.

WÓJTOWICZ, M.; WÓJTOWICZ, A.; PIEKARCZYK, J.. Application of remote sensing methods in agriculture. **Communications In Biometry And Crop Science**, v. 11, n. 1, p. 31-50, 2015.

XUE, J.; SU, B.. Significant remote sensing vegetation indices: a review of developments and applications. **Journal of Sensors**, v. 2017, p.1-17, 2017.

YU, D.; ZHA, Y.; SHI, L.; JIN, X.; HU, S.; YANG, Q.; HUANG, K.; ZENG, W.. Improvement of sugarcane yield estimation by assimilating UAV-derived plant height observations. **European Journal Of Agronomy**, v. 121, p. 126159, 2020.

ZHANG, K.; GE, X.; SHEN, P.; LI, W.; LIU, X.; CAO, Q.; ZHU, Y.; CAO, W.; TIAN, Y. Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages. **Remote Sensing**, v. 11, n. 4, p.387-411, 2019.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture: a worldwide overview. **Computers and Electronics in Agriculture**, v. 36, n. 2-3, p.113-132, 2002.

ZHOU, X.; ZHENG, H.B.; XU, X.Q.; HE, J.y.; GE, X.K.; YAO, X.; CHENG, T.; ZHU, Y.; CAO, W.X.; TIAN, Y.C. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p.246-255, 2017.

ZHU, W.; SUN, Z.; PENG, J.; HUANG, Y.; LI, J.; ZHANG, J.; YANG, B.; LIAO, X.. Estimating maize above-ground biomass using 3D point clouds of multi-

source Unmanned Aerial Vehicle data at multi-spatial scales. **Remote Sensing**, v. 11, n. 22, p.2678-2700, 2019.