UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ

CAMPUS DE CASCAVEL

CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS

DELINEAMENTO DE ZONAS DE MANEJO POR IMAGENS SUBORBITAIS, ORBITAIS E VARIÁVEIS DE SOLO

LAÍZA CAVALCANTE DE ALBUQUERQUE SILVA

Cascavel – Paraná – Brasil

Maio - 2020

LAÍZA CAVALCANTE DE ALBUQUERQUE SILVA

DELINEAMENTO DE ZONAS DE MANEJO POR IMAGENS SUBORBITAIS, ORBITAIS E VARIÁVEIS DE SOLO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola para obtenção do título de mestre em Engenharia Agrícola, área de concentração Sistemas Biológicas e Agroindustriais, com a temática Geoprocessamento, Estatística Espacial e Agricultura de Precisão.

Orientador: Dr. Jerry Adriani Johann

Cascavel – Paraná – Brasil

Maio - 2020

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Silva, Laíza Cavalcante de Albuquerque DELINEAMENTO DE ZONAS DE MANEJO POR IMAGENS SUBORBITAIS, ORBITAIS E VARIÁVEIS DE SOLO / Laíza Cavalcante de Albuquerque Silva; orientador(a), Jerry Adriani Johann, 2020. 117 f. Dissertação (mestrado), Universidade Estadual do Oeste do Paraná, Campus de Cascavel, Centro de Ciências Exatas e Tecnológicas, Graduação em Engenharia AgrícolaPrograma de Pós-Graduação em Engenharia Agrícola, 2020. 1. monitoramento agrícola. 2. índice de vegetação. 3. agrupamento hierárquico. I. Johann, Jerry Adriani. II.

Título.

Revisor de português, inglês e normas do PGEAGRI: José Carlos da Costa, Julho de 2020.

LAÍZA CAVALCANTE DE ALBUQUERQUE SILVA

DELINEAMENTO DE ZONAS DE MANEJO POR IMAGENS SUBORBITAIS. ORBITAIS E VARIÁVEIS DE SOLO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Mestra em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADA pela seguinte banca examinadora:

Orientador(a) - Jerry Adriani Johann

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Jonathan Richetti

Commonwealth Scientific and Industrial Research Organization (CSIRO)

Marco F. Magj

Marcio Furlan Maggi Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 29 de maio de 2020.

BIOGRAFIA RESUMIDA

Laíza Cavalcante de Albuquerque Silva, brasileira, nasceu no Rio de Janeiro – RJ, no ano de 1994. Graduou-se em Engenharia Agrícola pela Universidade Estadual do Oeste do Paraná – UNIOESTE/Cascavel em 2017. Desenvolveu pesquisas na área de geoprocessamento e sensoriamento remoto voltadas para o mapeamento e estimativa de culturas agrícolas ao longo de 4 projetos de iniciação científica. Atualmente é aluna do Programa de Pós-Graduação em Engenharia Agrícola – Nível Mestrado (2018-atual) e realiza pesquisas na área de sensoriamento remoto aplicado à agricultura, principalmente nos temas: técnicas de mineração de dados para mapeamento de áreas agrícolas, estimativas de área e produtividade, distribuição de unidades armazenadoras e aplicação de VANTs na Agricultura de Precisão para monitoramento de lavouras. Integra o grupo de Pesquisa em Geoestatística Aplicada (GGEA), o Núcleo de Geoprocessamento e Ciência de Dados (GeoScience) e o Laboratório de Estatística Aplicada (LEA) na UNIOESTE.

AGRADECIMENTOS

A minha família, pelo imenso apoio ao longo da graduação, especialmente aos meus pais, minha irmã, meus avós e meu companheiro, pois eles são a razão da minha resiliência;

Ao meu orientador Prof. Dr. Jerry Adriani Johann pela orientação, confiança no meu trabalho e compreensão ao longo desse período. Inúmeras foram as reviravoltas, mas em todas pude contar com sua supervisão;

Aos meus amigos do GeoScience pelo esforço, motivação e muitas vezes sacrifícios realizados para as coletas de campo e processamento dos dados. Vocês são incríveis e tudo isso só foi possível por suas participações. Obrigada digníssimos Willyan Becker, Eduardo Rambo, Valdir Moura, Alex Paludo, Thiago Ló, Eduarda Rodrigues, Humberto Comineti e João Siqueira. Vocês moram no meu coração;

Ao Léo Zardo, por ter aceitado esta parceria e se disposto a me auxiliar no que fosse necessário ao longo desse período. Sou imensamente grata por seu companheirismo, paciência, disposição em ajudar, bom humor afiado e por sua amizade;

Ao professor Armin Feiden, da Pós-Graduação em Desenvolvimento Rural Sustentável, pela imensa generosidade e participação nas coletas de pontos, tornando-se um dos espelhos de como desejo ser;

A todos os membros do LAMAP e do Geolab, pelos empréstimos de equipamentos (mesmo quando inesperados) e prontidão na ajuda;

Aos colegas e amigos adquiridos ao longo dessa jornada, responsáveis por amenizar os danos e engrandecer a felicidade;

À Universidade Estadual do Oeste do Paraná – UNIOESTE e ao Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, pela oportunidade oferecida em cursar o mestrado;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo apoio financeiro;

Meu sincero obrigada a todos que de certa forma contribuíram na execução desta pesquisa.

iv

DELINEAMENTO DE ZONAS DE MANEJO POR IMAGENS SUBORBITAIS, ORBITAIS E VARIÁVEIS DE SOLO

RESUMO

A Agricultura de Precisão possui contínua preocupação com o uso coerente dos recursos naturais, tornando-se uma peça-chave na otimização do manejo, por considerar a variabilidade espacial da área e segmentá-la em sub-regiões (Zonas de Manejo, ZM). Uma das formas de avaliar esta variabilidade é por dados espectrais, ou seja, por sensores orbitais, suborbitais e terrestres. Dentre os sensores suborbitais, os acoplados aos Veículos Aéreos Não-Tripulados (VANTs) possibilitam o acompanhamento da área de forma não intrusiva, com elevado nível de detalhamento e sob menor custo. Nesse sentido, este trabalho tem como objetivo criar ZM focadas na análise temporal sob curto período (uma safra), por índices de vegetação derivados de imagens de VANT e do sensor Sentinel-2, e por variáveis de solo. Após isso, compará-las com a produtividade. No estudo, monitorou-se uma propriedade agrícola ao longo de dois ciclos produtivos (soja, safra 2018/2019 e trigo, safra 2019), coletando-se dados espectrais na faixa do visível e dados de campo (amostragem de solo e produtividade). Construíram-se ZMs para o subconjunto de dados espectrais (VANT e Sentinel-2) e amostragem do solo pelo método de agrupamento hierárquico com restrição espacial, e foram avaliadas diferentes matrizes de contiguidade (Rainha, Torre e KNN). Dentre os índices de vegetação ExG, GLI, GRVI, RGBVI e VARI, os de melhor desempenho foram o GRVI e VARI. A quantidade ideal de ZMs para os subconjuntos de dados espectrais foi duas para ambas as culturas e quatro para as variáveis do solo. Nenhuma das ZMs se assemelharam à produtividade das culturas. Constatou-se que índices derivados do visível não apresentaram bons resultados para o delineamento das Zonas de Manejo, independente do sensor utilizado (VANT ou Sentinel-2).

Palavras-Chave: monitoramento agrícola, índice de vegetação, agrupamento hierárquico.

DESIGNING OF MANAGEMENT ZONES USING SOIL VARIABLES, ORBITAL AND SUB-ORBITAL IMAGES

ABSTRACT

Precision Agriculture is constantly concerned with coherent use of natural resources, which makes it key in optimizing management, as it considers the spatial variability of an area and allows its segmentation into subregions (Management Zones - MZ). One of the possible ways to evaluate such variability is by using spectral data, i.e., via orbital, sub-orbital, and terrestrial sensors. Among the suborbital sensors, Unmanned Aerial Vehicles (UAVs) enable non-intrusive surveys with high level of detail and at lower cost. Thus, this work proposes to create MZ focused on temporal analysis on a short period (one harvest) from three datasets: visible vegetation indexes from UAVs and Sentinel-2, and soil data; comparing the MZs with vield maps. In this study, one area was monitored throughout two harvest cycles (soybean, during the 2018/2019 crop, and maize, crop of 2019), collecting UAV images, field data (soil sampling and yield). MZs were designed for the subsets through spectral data (VANT and Sentinel-2) and soil sampling using hierarchical clustering with spatial constraints weights, evaluating different spatial contiguity matrices (Queen, Rook, and KNN). Among the visible vegetation indexes ExG, GLI, GRVI, RGBVI, and VARI, GRVI and VARI achieved higher results. MZs created by UAV or Sentinel-2 for both crops achieved higher performance with two groups; and for soil data, by four groups. None of the MZs shared any similarities regarding their cultures' productivity. Visible vegetation index achieved poor results for MZ creation, regardless of the sensor employed (VANT or Sentinel-2).

KEYWORDS: agricultural monitoring, hierarchical clustering, vegetation index.

SUMÁRIO

LISTA DE TABELASIX			
LISTA	DE FIGURAS	Х	
1	INTRODUÇÃO	1	
2	OBJETIVOS	2	
2.1	Objetivo geral	2	
2.2	Objetivos específicos	2	
3	REVISÃO BIBLIOGRÁFICA	3	
3.1	Sensoriamento remoto	3	
3.1.1	Sensores terrestres, embarcados e orbitais	4	
3.1.1.1	Sentinel-2	5	
3.1.2	Índices de vegetação	6	
3.1.2.1	Índices de vegetação na faixa do visível	7	
3.2	Veículos aéreos não tripulados	. 10	
3.3	Agricultura de precisão	. 14	
3.3.1	Atributos químicos e físicos do solo e produtividade agrícola	. 15	
3.3.2	Zona de manejo	. 17	
3.3.2.1	Aquisição e análise de dados	. 19	
3.3.2.2	Interpoladores	. 20	
3.3.2.3	Técnicas de agrupamentos dados	. 24	
3.3.2.4	Avaliação da zona de manejo	. 28	
4	MATERIAL E MÉTODOS	. 29	
4.1	Área de estudo	. 30	
4.2	Coleta de dados	. 31	
4.2.1	Aquisição de imagens por VANT	. 32	
4.2.1.1	Planejamento e realização dos voos	. 33	
4.2.2	Dados de altura e estádio fenológico das culturas	. 35	
4.2.3	Grade amostral de solo	. 37	
4.2.4	Dados de produtividade das culturas	. 38	
4.2.5	Aquisição de imagens Sentinel-2	. 39	
4.3	Processamento de dados	. 40	
4.3.1	Geração de ortomosaicos	. 40	
4.3.2	Normalização das imagens	. 42	

4.3.3	Índices de vegetação	. 43	
4.3.4	Seleção do índice de vegetação	. 43	
4.4	Análise estatística dos dados	. 44	
4.5	Delineamento de zonas de manejo	. 46	
4.5.1	Análise das zonas de manejo	. 46	
5	RESULTADOS E DISCUSSÕES	. 48	
5.1	Análise exploratória espacial e temporal das culturas e do solo	. 48	
5.1.1	Monitoramento fenológico da soja	. 48	
5.1.2	Interpolação dos dados de produtividade	. 49	
5.1.3	Interpolação das variáveis do solo	. 50	
5.2	Análise de dados derivados de sensores orbitais e suborbitais	. 53	
5.3	Análise das zonas de manejo	. 61	
5.3.1	Zonas de manejo para o solo	. 62	
5.3.2	Zonas de manejo por imagens de VANT para a soja	. 64	
5.3.3	Zonas de manejo por imagens de VANT para o trigo	. 68	
5.3.4	Zonas de manejo pelo Sentinel-2 para a soja	. 70	
5.3.5	Zonas de manejo pelo Sentinel-2 para o trigo	. 74	
5.3.6	Zonas de manejo e produtividade	. 76	
6	CONCLUSÕES	. 79	
7	TRABALHOS FUTUROS	. 80	
REFE	RÊNCIAS	. 81	
APÊN	DICES	. 94	
APÊN	DICE A	. 95	
APÊNDICE B			
APÊNDICE C			
APÊNDICE D			
APÊNDICE E			
APÊNDICE F			
APÊNDICE G 101			
APÊNDICE H 102			
APÊNDICE I 103			
APÊN	DICE I	103	

LISTA DE TABELAS

Tabela 1	Características dos sensores multiespectrais dos satélites S2A e S2B6
Tabela 2	Janela para a previsão das coletas de campo, monitoramento efetuado e
	condição climática 32
Tabela 3	Índices de ajuste das ZMs para o subconjunto variáveis do solo 64
Tabela 4	Índices de ajuste das ZMs para o subconjunto índices GRVI e VARI do VANT
	pelos métodos Rainha, Torre e KNN para os cultivares NA5909RG e
	BRS1003IPRO da soja 66
Tabela 5	índices de vegetação GRVI e VARI do VANT para os cultivares NA5909RG e
	BRS1003IPRO da soja67
Tabela 6	Índices de ajuste das ZMs para o subconjunto índices de vegetação GRVI e
	VARI do VANT para o trigo 69
Tabela 7	VARI do VANT para o trigo
Tabela 7 Tabela 8	VARI do VANT para o trigo
Tabela 7 Tabela 8	VARI do VANT para o trigo
Tabela 7 Tabela 8	VARI do VANT para o trigo
Tabela 7 Tabela 8 Tabela 9	VARI do VANT para o trigo
Tabela 7 Tabela 8 Tabela 9	VARI do VANT para o trigo
Tabela 7 Tabela 8 Tabela 9 Tabela 10	VARI do VANT para o trigo
Tabela 7 Tabela 8 Tabela 9 Tabela 10	VARI do VANT para o trigo

LISTA DE FIGURAS

Figura 1	Assinatura espectral da folha verde sadia4
Figura 2	Relação entre os sistemas de coordenadas da imagem e objeto: a) Ilustração
	das coordenadas da imagem e terreno (X ₀ , Y ₀ , Z ₀ e X, Y, Z); b) Posicionamento
	dos ângulos de rotação de Euler ($\omega, \phi \in \kappa$)
Figura 3	Ciclo da agricultura de precisão com sistemas aplicados
Figura 4	Diagrama com as etapas para construção de zona de manejo 18
Figura 5	Semivariograma teórico
Figura 6	Dendograma ilustrando o procedimento do método hierárquico aglomerativo (à
	esquerda) e do método hierárquico divisivo (à direita)
Figura 7	Representação das funções de distância single linkage, complete linkage,
	average linkage e centroid linkage, pelo método aglomerativo
Figura 8	Ilustração dos tipos de contiguidade: torre (rook), bispo (bishop) e rainha
	(queen)
Figura 9	Fluxograma geral da dissertação com as etapas de coletas de dados a campo
	(A), processamento dos dados (B) e análise exploratória (C) 29
Figura 10	Área sob estudo localizada no município de Cascavel - Paraná, com enfoque na
	divisão dos cultivares de soja NA5909RG e BRS1003IPRO, pontos de
	monitoramento, controle, elevação e ortomosaico
Figura 11	Veículo aéreo não tripulado Mavic PRO
Figura 12	Veículo aéreo não tripulado Phantom 4 PRO
Figura 13	Plano de voo para a soja (A) e trigo (B)
Figura 14	Materialização do Ground control point (PC): A) demarcação piquete; B) PC a
	campo; C) demarcação e posicionamento do PC
Figura 15	Receptores geodésicos da TechGeo GTR/G2 na área sob estudo
Figura 16	Monitoramento da soja no ponto 12 em 21/11/2018. A) Fotografia vertical
	ilustrando a condição da soja; B) Fotografia ilustrando o estádio vegetativo 36
Figura 17	Monitoramento do trigo em 04/09/2019: A) Fotografia vertical do trigo;
	B) Fotografia ilustrando o estádio vegetativo
Figura 18	Grade amostral de solo, com grid utilizado e centroides
Figura 19	Pontos amostrais de produtividade: A) soja; B) trigo
Figura 20	Etapas de processamento no software Photoscan para o voo 18/07/19 (trigo): A)
	Tie points; B) Nuvem densa de pontos; C) Modelo digital de elevação;
	D) Ortomosaico

Figura 21	Esquema do grid de <i>pixels</i> de imagens de satélite <i>si, j</i> e <i>Gi, j</i> numa dada latitude
	$\alpha si, j$ e longitude $\beta si, j$, sendo o grid Gi, j do sensor Sentinel-2 (B) utilizado para
	construção do upscaling da imagem de VANT (A) 44
Figura 22	Altura da soja ao longo do período monitorado (06/12/18 a 09/02/19) para os
	cultivares BRS1003IPRO e NA5909RG 48
Figura 23	Evolução do desenvolvimento da soja ao longo do monitoramento para os
	cultivares BRS1003IPRO e NA5909RG 49
Figura 24	Mapa de produtividade da soja, trigo e média das produtividades50
Figura 25	Mapas das variáveis alumínio, ferro, potássio e V%, com a presença e ausência
	de <i>outliers</i> 51
Figura 26	Mapas das variáveis químicas e físicas do solo53
Figura 27	Ortomosaicos para a soja e trigo54
Figura 28	Histograma dos índices de vegetação ExG, GLI, GRVI, RGBVI e VARI para a
	soja pelo VANT55
Figura 29	Histograma dos índices de vegetação ExG, GLI, GRVI, RGBVI e VARI para o
	trigo pelo VANT
Figura 30	Histograma dos índices de vegetação ExG, GLI, GRVI, NDVI, RGBVI e VARI
	para a soja pelo sensor Sentinel-257
Figura 31	Histograma dos índices de vegetação ExG, GLI, GRVI, NDVI, RGBVI e VARI
	para o trigo pelo sensor Sentinel-258
Figura 32	Correlação de Spearman entre os IVs extraídos do VANT e Sentinel-2 para soja
	e trigo; sendo A1 a correlação entre IVs (VANT e Sentinel-2) para soja; A2 a
	correlação entre IVs (VANT e Sentinel-2) para trigo; B1 a correlação entre IVs
	VANT com NDVI do Sentinel-2 para soja; B2 a correlação entre IVs VANT com
	NDVI do Sentinel-2 para trigo
Figura 33	Correlação de Spearman entre os IVs calculados pelo VANT e produtividade da
	soja e trigo60
Figura 34	Comparação entre o índice de vegetação VARI ao longo do período monitorado
	para a soja com a produtividade60
Figura 35	Correlação de Spearman entre os IVs VANT e produtividade da soja para os
	cultivares NA5909RG (esquerda) e BRS1003IPRO (direita)61
Figura 36	Correlação de Spearman entre os IVs calculados pelo Sentinel-2 para soja
	(esquerda) e trigo (direita) com produtividade61
Figura 37	Mapas de 2 a 5 zonas de manejo, considerando as variáveis químicas e físicas
	do solo pelos métodos Rainha, Torre e KNN63
Figura 38	Mapas de 2 a 5 zonas de manejo pelos índices GRVI e VARI do VANT pelos
	métodos Rainha, Torre e KNN para os cultivares de soja NA5909RG (A) e
	BRS1003IPRO (B)

- Figura 47 Índices de vegetação ExG, GLI, GRVI, RGBVI e VARI do Sentinel-2 ao longo do ciclo do trigo (10/06/2019 a 24/08/2019), com resolução espacial de 10 m. 99
- Figura 48Boxplot dos índices de vegetação com *outlier* ExG, GLI, GRVI RGBVI e VARI do
VANT para a soja.100
- Figura 49
 Boxplot dos índices de vegetação com *outlier* ExG, GLI, GRVI RGBVI e VARI do

 VANT para o trigo.
 101
- - Sentinel-2 para o trigo. 103

1 INTRODUÇÃO

A Agricultura de Precisão (AP) preza pela otimização de recursos e pelo manejo adequado de áreas agrícolas (WHELAN; TAYLOR, 2013). Isso se torna possível pela criação de Zonas de Manejo (ZM), que segmentam uma área em unidades de gerenciamento com características internamente semelhantes e distintas entre si, que expressem a variabilidade espacial e temporal dos fatores físicos, químicos e biológicos do solo. Uma das formas de delinear ZMs é pela amostragem de solo (MZUKU et al., 2005), entretanto, a representação da variabilidade da área demanda uma elevada densidade amostral, ocasionando, assim, um alto custo de aquisição (BAIO et al., 2017; NANNI et al., 2011).

Alguns pesquisadores propõem a criação de ZMs a partir de imagens de satélite por proporcionarem o acompanhamento da lavoura em diferentes comprimentos de onda (YUZUGULLU et al., 2020; SAIFUZZAMAN et al., 2019; CICORE, et al., 2016). Entretanto, a utilização de sensores orbitais gratuitos (Landsat-8), deixa essa técnica sujeita a resoluções espaciais e temporais com menor detalhamento que não expressam a heterogeneidade do solo ou das plantas (TSOUROS; BIBI; SARIGIANNIDIS, 2019; MULLA, 2013). Uma hipótese para contornar esse problema, é o emprego de Veículos Aéreos Não-Tripulados (VANTs). Essas aeronaves de pequeno porte ganham destaque por sua facilidade de utilização, aquisição de imagens com maior resolução espacial e temporal que os sensores orbitais gratuitos, mobilidade do equipamento e seu baixo custo de obtenção (TSOUROS; BIBI; SARIGIANNIDIS, 2012).

Nesse sentido, o emprego de VANTs no delineamento de ZMs torna-se vantajoso pela disponibilidade temporal e flexibilidade de resolução espacial quando comparado a imagens de satélite. Por essa razão, neste trabalho, propõe-se a investigação das vantagens e desvantagens no delineamento de ZMs por imagens de VANT, do sensor Sentinel-2 e por variáveis químicas e físicas do solo.

2.1 Objetivo geral

Delinear Zonas de Manejo por meio da análise temporal de imagens de VANT, satélite e variáveis químicas e físicas do solo de uma propriedade agrícola em Cascavel - Paraná.

2.2 Objetivos específicos

- Calcular índices de vegetação utilizando bandas da faixa do visível por imagens de VANT e Sentinel-2;
- Comparar os índices de vegetação entre os sensores (VANT e Sentinel-2) e selecionar o índice com melhor desempenho;
- Delinear e comparar as ZMs tanto pelo método tradicional baseado na amostragem de solo, como a partir de imagens de VANTs e Sentinel-2;
- Avaliar o desempenho do agrupamento hierárquico com restrição espacial no delineamento de ZMs.

3 REVISÃO BIBLIOGRÁFICA

3.1 Sensoriamento remoto

Sensoriamento remoto é a ciência de obtenção de informações sobre um determinado objeto, área ou fenômeno, pela análise de dados adquiridos por um instrumento sem o contato com o alvo sob investigação (MA et al., 2015; CORTI et al., 2018; YAN et al., 2018). A utilização do sensoriamento remoto apresenta várias vantagens exclusivas (JENSEN, 2009), como: (i) coleta de dados não destrutiva; (ii) cobertura de vastas áreas geográficas, contrastando com observações isoladas pontuais; (iii) disponibilidade em locais acidentados, de difícil acesso ou virgens; (iv) ajuste de erros por meio da avaliação de séries históricas de imagens; (v) caráter multidisciplinar da informação produzida. Imagens hiperespectrais e multiespectrais têm sido utilizadas como forma de apoio a operações a tarefas de mapeamento, monitoramento de estresse vegetal, aplicação de fertilizantes e pesticidas e manejo de irrigação.

A coleta de dados entre o sensor e o alvo sob estudo pode acontecer de diferentes formas, variando o nível de aquisição (plataforma orbital, suborbital e terrestre), o tipo de iteração entre a Radiação Eletromagnética (REM) com o alvo (passivo ou ativo) e o produto obtido (imageador ou não imageador). O nível de aquisição a ser utilizado depende principalmente das características da área sob estudo e do recurso disponível, que limitarão a frequência desejada de dados e o tamanho da área (FORMAGGIO; SANCHES, 2017). Sensores passivos e ativos variam em função da REM, em que sensores passivos registram a interação da REM proveniente de uma fonte externa com um alvo, enquanto sensores ativos possuem fonte própria de energia e capturam sua interação com o alvo. O produto resultante da captura pode ser uma imagem ou um produto numérico (assinatura espectral).

As capacidades técnicas dos sensores dependem de quatro resoluções: (a) resolução espacial, que se refere ao tamanho do *pixel* da imagem gerada; (b) resolução radiométrica, que se refere à intensidade de radiância de cada *pixel* que o sensor é capaz de mensurar, representado por valores numéricos ou nível de cinza; (c) resolução espectral, que se refere ao número de faixas espectrais do sensor; (d) resolução temporal, que corresponde ao tempo de revisita do satélite na mesma área (BELWARD; SKØIEN, 2015; FORMAGGIO; SANCHES, 2017).

A resolução espectral possibilita a diferenciação de alvos em função de sua interação com a REM. Para tanto, para facilitar essa distinção é necessário que os sensores registrem a interação em diferentes frequências do espectro-eletromagnético pela diferente absorção de energia num determinado comprimento de onda (FORMAGGIO; SANCHES, 2017).

Segundo Meneses e Almeida (2012), a resolução espectral envolve pelo menos três parâmetros de medida: o número de bandas do sensor, a largura e o comprimento de onda das bandas e sua posição no espectro-eletromagnético. Desta forma, os sensores podem se subdividir em pancromático (apenas uma banda de maior largura), multiespectral (múltiplas bandas com largura inferior), hiperespectral (centenas de bandas de largura estreita).

As plantas possuem uma assinatura espectral característica, com baixa refletância na região espectral visível pela forte absorção pela clorofila; maior refletância no infravermelho próximo (NIR), por causa da dispersão interna das folhas da absorção pela clorofila; refletância mais baixa no infravermelho pela forte absorção por água (Figura 1). A refletância de um dossel vegetal é semelhante, mas é modificada pela não uniformidade da radiação solar incidente, estruturas de plantas, áreas foliares, sombras e reflexividades de fundo (KNIPLING, 1970).



Figura 1 Assinatura espectral da folha verde sadia. Fonte: Jensen (2009).

3.1.1 Sensores terrestres, embarcados e orbitais

A assinatura espectral de objetos pode ser adquirida de diferentes formas, conforme o grau de especificidade e escala desejados, por meio de sensores terrestres ou embarcados em aeronaves e em satélites. O sensoriamento remoto terrestre consiste na utilização de sensores para coletas *in situ* ou em laboratório, empregando sensores hiperespectrais e multiespectrais (SAIFUZZAMAN et al., 2019), como por exemplo, os espectroradiômetros. O sensoriamento remoto aéreo e terrestre apresenta vantagens em relação a aplicações individuais. Ge, Thomasson e Sui (2011) consideram essas técnicas complementares, pois o sensoriamento remoto convencional cobre extensas áreas com baixa resolução espectral e a espectrorradiometria envolve informação espectral detalhada, utilizando, em geral, uma malha regular e incluindo erros como consequência do processo de interpolação.

Nesse sentido, para suprir o acompanhamento de regiões em diferentes escalas podem ser adotados sensores multiespectrais ou hiperespectrais embarcados em aeronaves ou em satélites. Sensores embarcados em aeronaves despontam como uma alternativa de monitoramento por oferecerem maior detalhamento da área sob estudo e maior frequência de revisita. Entretanto, mesmo com as vantagens expostas, seu emprego esbarra na dificuldade de aquisição e processamento de imagens, necessitando de treinamento especializado e computadores com elevada capacidade de processamento para reduzir o tempo associado a essa tarefa. Os sensores orbitais também oferecem distintos níveis de detalhamento espacial, radiométrico e temporal, com opções de imagens gratuitas e pagas. As vantagens de se empregar sensores orbitais estão na diversidade de satélites multi e hiperespectrais, sua facilidade de aquisição de imagens gratuitas e imagens já pré-processadas e corrigidas geometricamente.

Três missões destacam-se no monitoramento terrestre: a *Earth Observing System* (Sistema de observação terrestre) responsável pelo sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) com 36 bandas que operam no espectro de 0,4 a 14,4 µm, a bordo dos satélites TERRA (EOS-AM) e AQUA (EOS-PM) de baixa resolução espacial (250 m a 1 km) (NASA, 2020a); Landsat, com seis missões, representando a maior coleção de dados de sensoriamento terrestre de resolução média de 30 m (USGS, 2020); e a missão Sentinel, iniciativa da Agência Espacial Europeia (ESA), composta pelos sensores Sentinel 1 a 5, que monitoram a superfície terrestre, a vida marinha e a qualidade do ar (ESA, 2020a).

3.1.1.1 Sentinel-2

A missão Sentinel está inserida no programa Copernicus, uma iniciativa da ESA de monitorar o planeta e disponibilizar aos usuários acesso autônomo e confiável de dados (ESA, 2020a). A missão Sentinel-2 foi projetada para o imageamento da superfície terrestre, oferecendo dados multiespectrais de média/alta resolução espacial e temporal em larga escala (ESA, 2020b). Esta possui uma constelação de dois satélites gêmeos colocados na mesma órbita polar, divididos em 180° entre si, com altitude orbital média de 786 km e inclinação da órbita de 98,62°. Ambos monitoram a variabilidade das condições da superfície terrestre, com resolução temporal de 10 dias no Equador com 1 satélite e 5 dias com ambos os satélites (ESA, 2020b). Os instrumentos multiespectrais embarcados utilizam o sistema de varredura *push-broom*, com largura de 290 km. A REM é captada de modo

passivo, com resoluções espaciais de 10, 20 e 60 metros, distribuídas em 13 bandas espectrais que contemplam desde o espectro do visível até infravermelho próximo (SWIR), com radiometria de 12-bits, conforme Tabela 1.

Tabela 1 Carac	terísticas d	los sensores mi	ultiespectrais dos satélite	s S2A e S2B
Resolução Espacial (m)	Banda	Nome	Comprimento de onda central (nm) – S2A	Comprimento de onda central (nm) – S2A
10 m	B02	Blue	496	492
	B03	Green	560	559
	B04	Red	664	665
	B08	NIR	835	833
20 m	B05	Red edge 1	703	703
	B06	Red edge 2	740	739
	B07	Red edge 3	782	779
	B08A	Red edge 4	864	864
	B11	SWIR 1	1613	1610
	B12	SWIR 2	2202	2185
60 m	B01	Aerossol	443	442
	B09	Water vapor	945	943
	B10	Cirrus	1373	1376

Fonte: ESA (2020a).

3.1.2 Índices de vegetação

A interação macroscópica da radiação eletromagnética com os objetos é denominada por reflectância, em que a intensidade da reflexão do alvo varia em função da interação entre o comprimento de onda e a superfície do objeto (MENESES; ALMEIDA, 2012). A interação entre o espectro eletromagnético e a vegetação varia conforme a espécie, o tipo de folha, o estádio de maturação (FORMAGGIO; SANCHES, 2017), alterações decorrentes de estresse hídrico, deficiências nutricionais, salinidade, ataque de pragas e doenças (KNIPLING, 1970). Outro fator são as variações verticais de altura, que ocasionam diferenças entre a realidade e as imagens obtidas remotamente.

Meneses e Neto (2001) definem que: no espectro do visível, os pigmentos foliares (clorofila, xantofila e carotenos) são responsáveis pela absorção da REM, o que ocasiona baixa reflectância quando comparados às outras porções da REM. Na porção do NIR (infravermelho próximo), as folhas aumentam consideravelmente sua reflectância em decorrência do espalhamento interno nas folhas (interação da energia incidente com a estrutura do mesófilo). Na região do infravermelho de ondas curtas (SWIR), existe uma elevada absorção da REM em função da absorção pela água, embora isso seja fortemente afetado pela disponibilidade de água nas folhas.

Para caracterizar a dinâmica temporal e o vigor da vegetação criaram-se índices de vegetação (IV), que são definidos pela soma, taxa de diferença ou outra combinação linear de reflectância entre dois ou mais comprimentos de onda (WIEGAND et al., 1991). Além disso, os IVs apresentam correlações entre a radiação solar e os tecidos fotossinteticamente ativos, servindo como indicativos das propriedades biofísicas das plantas e relacionadas com a produtividade e o balanço de energia da vegetação (FORMAGGIO; SANCHES, 2017). A facilidade em realizar essas operações e conseguir realçar características da vegetação é uma das vantagens do processamento digital de imagens (PDI).

O índice de vegetação mais simples de ser criado e compreendido é o *Simple Ratio*, o qual consiste na divisão da radiação refletida no infravermelho próximo pela refletida no vermelho. No *Simple Ratio*, os *pixels* situados nas áreas com vegetação resultarão em valores maiores do que 1, enquanto *pixels* de água e rocha resultarão em valores próximos a 1, porque para ambos não há praticamente nenhuma diferença de declividade de suas refletâncias entre as duas bandas (MENESES; ALMEIDA, 2012; DIDAN et al., 2015; FORMAGGIO; SANCHES, 2017).

Um dos índices comumente utilizados em sensores multiespectrais é o *Normalized Difference Vegetation Index* (NDVI), que computa a razão da diferença e da soma entre as bandas do infravermelho próximo e do vermelho (Equação (1), com valores variando entre -1 e +1. Esse índice tende a ser linearmente mais proporcional à biomassa, sendo mais apropriado para comparações ao longo do tempo numa mesma área em função da influência menor das condições atmosféricas, minimizando, assim, ruídos nas bandas, pela presença da radiação difusa, nuvens e sobras de nuvens, ângulo do sol, topografia e atenuação da atmosfera (DIDAN et al., 2015).

$$NDVI = \frac{NIR - RED}{NIR + RED}$$
(1)

em que: NIR: refletância no infravermelho próximo; RED: refletância no vermelho.

3.1.2.1 Índices de vegetação na faixa do visível

Apesar de a vegetação apresentar maior reflectância ao longo dos comprimentos de onda da região do infravermelho, câmeras fotográficas que registram comprimentos de onda além do visível possuem valor elevado. Aeronaves remotamente tripuladas estão sendo utilizadas para o monitoramento agrícola, por serem de fácil manipulação e apresentarem câmeras fotográficas embarcadas, que registram apenas no espectro do visível. Embora boa parte dos sensores não possua calibração radiométrica e atmosférica, as imagens são amplamente utilizadas para geração de dados fotogramétricos por meio de algoritmos de visão computacional robustos, que empregam técnicas de fotogrametria e constroem subprodutos como ortomosaicos e modelos digitais 3D (TURNER; LUCIEER; WATSON, 2012; WESTOBY et al., 2012). Esse procedimento minimiza limitações de calibração da fotogrametria tradicional, como a falta de definição geométrica de algumas feições e a dificuldade de separação entre elementos de terreno e de superfície (NEX; REMONDINO, 2013).

Mesmo com suas limitações, é possível avaliar a fenologia por índices de vegetação na faixa do visível, em função de sua fácil aquisição e baixo custo. Diversos autores propõem diferentes índices para ressaltar características específicas do dossel, como: *Excess Green* (ExG), Equação (2), *Green Leaf Index* (GLI), Equação (3), *Green Red Vegetation Index* (GRVI), Equação (4), *Red Green Blue Vegetation Index* (RGBVI), Equação (5) e *Visible Atmospherically Resistant Index* (VARI), Equação (6), que são amplamente empregados, em diversos estudos (MOTOHKA et al., 2010; ZHANG et al., 2019; ZHOU et al., 2017, POSSOCH et al., 2016).

$$Excess green = 2 * GREEN - RED - BLUE$$
(2)

$$GLI = \frac{GREEN - RED}{GREEN + RED}$$
(3)

$$GRVI = \frac{GREEN - RED}{GREEN + RED}$$
(4)

$$RGBVI = \frac{GREEN^2 - (BLUE * RED)}{GREEN^2 + (BLUE * RED)}$$
(5)

$$VARI = \frac{GREEN - RED}{GREEN + RED - BLUE}$$
(6)

em que: RED: refletância no vermelho; GREEN: refletância no verde; BLUE: refletância do azul.

O *Excess Green* (ExG), proposto por Woebbecke et al. (1995), foi desenvolvido para distinguir vegetação do solo exposto e dos resíduos da vegetação, resultando numa imagem de intensidade quase binária da área de interesse (MEYER; NETO, 2008).

O índice GLI, desenvolvido por Louhaichi, Borman e Johnson (2001), inicialmente, foi proposto para a pastagem de trigo. É um índice que computa a diferença normalizada das reflectâncias das faixas espectrais do azul, verde e vermelho e gera uma imagem em escala de cinza com amplitude de -1 a 1, em que valores negativos representam áreas de solo e valores positivos da vegetação (LIM SOON et al., 2019; LOUHAICHI; BORMAN; JOHNSON, 2001). Além disso, Hunt-Jr et al. (2013) e Ballesteros et al. (2018) afirmam que o GLI apresentou resultados robustos para avaliação da vegetação, podendo ser utilizado como fator indicativo de degradação vegetal, porquanto apresentaram boas correlações com alterações na clorofila foliar.

O índice GRVI, proposto por Tucker (1979) e adaptado por Bendig et al. (2015) é usado como indicativo da fenologia com potencial para extração de informações. Bendig et al. (2015) sugerem uma modificação no cálculo do índice: elevar cada banda ao quadrado para amplificar as diferenças entre elas. Esse índice é sensível às taxas fotossintéticas nos dosséis da floresta, pois as refletâncias em verde e vermelho são fortemente influenciadas por alterações nos pigmentos foliares (HARRIS GEOSPATIAL, 2019).

O RGBVI, proposto por Bendig et al. (2015), é um índice de vegetação de bandas do visível, que tem indicativo de ser um índice promissor por sua habilidade na distinção da vegetação, mas pouco investigado na literatura, para detalhar suas propriedades e características.

O VARI, elaborado por Gitelson et al. (2002), traz uma modificação para o índice NGRDI (*Normalized Green/Red Difference Index*), por apresentar baixa sensibilidade aos efeitos atmosféricos por subtrair a banda azul em seu denominador, o que atenua as diferenças de iluminação e os efeitos atmosféricos. Fang et al. (2016) mencionam também que as estimativas de vegetação por esse índice são estritamente ligadas às variações fenológicas da vegetação.

Dentre os trabalhos que utilizam IVs constuídos com as bandas RGB, destacam-se os trabalhos de Torres-Sánchez et al. (2014), Bendig et al. (2015) e Du e Noguchi (2017).

Torres-Sánchez et al. (2014) avaliaram a influência de diferentes alturas de voo (30 e 60 m) ao longo do ciclo do trigo por sete IV calculados a partir do espectro do visível. Os IVs testados foram: *Normalized Green-Red Difference Index* (NGRDI), *Excess-Green, Color Index of Vegetation* (CIVE), *Vegetativen, Excess Green* menos *Excess Red, Woebbecke index* e um IV criado pela combinação entre o *Excess-Green,* CIVE e *Vegetativen.* Os autores concluíram que os índices apresentam consistência temporal, possibilitando a deteção do trigo utilizando apenas o espectro do visível, em que o Excess-Green apresentou o melhor resultado para a altura de 30 m e desempenho muito semelhante aos demais para 60 m, seguido do *Vegetativen.* Os autores argumentam que o índice ExG apresentou maior acurácia e maior consistência temporal na fração vegetativa da imagem.

Bendig et al. (2015) combinaram IV e altura de planta do trigo para estimação de sua biomassa. Nesse estudo, os autores executaram três levantamentos de dados, a) um voo sobre a área de estudo, b) coletas da assinatura espectral do trigo a campo com um *FieldSpec3*, c) coleta destrutiva para estimação da biomassa. A partir de (a) os autores testaram os IVs *Green Red Vegetation Index* (GRVI), *Modified Green Red Vegetation Index* (MRGVI), *Red Green Blue Vegetation Index* (RGBVI). Os dados de (b) serviram para execução de cinco IVs: NDVI, *Soil Adjusted Vegetation Index* (SAVI), *Modified SAVI* (MSAVI), *Optimized Soil-Adjusted Vegetation Index* (OSAVI) e GnyLi. Os dados de (c) foram utilizados para avaliar o resultado da regressão linear com os *inputs* de altura e IV. Os autores concluíram que o melhor resultado foi o do índice GnyLi, que utiliza a faixa do

infravermelho próximo; o segundo melhor resultado foi atingido pelo índice GRVI, calculado apenas na faixa do visível, necessitando de maiores investigações sobre seu potencial.

Du e Noguchi (2017) monitoraram o crescimento do trigo e estimaram a produtividade associando índices de vegetação na faixa do visível com amostras de produtividade colhidas a campo três dias antes da colheita, na cidade de Hokkaido, no Japão. Para tanto, avaliaram cinco IVs o *Normalized Green-Blue Difference Index* (NGBDI), *Green-Red Ratio Index* (GRRI) e *Excess Green Vegetation Index* (ExG), *Visible-Band Difference Vegetation Index* (VDVI) e *Normalized Green-Red Difference Index* (NGRDI). Ao longo do ciclo vegetativo, foram realizados oito voos, sendo computada para cada IVs uma imagem acumulada (ou seja, uma imagem da soma de todos os voos). A partir dessas imagens acumuladas foi executada a regressão entre os valores dos índices com a produtividade (utilizando nove amostras de campo), em que os índices VDVI, NGBDI, GRRI e ExG apresentaram um R² de 0,94 e RMSE 0.02.

3.2 Veículos aéreos não tripulados

No sensoriamento remoto orbital, os sensores vão embarcados nas plataformas orbitais, chamadas de satélite, e os dados são registrados em imagens (FORMAGGIO; SANCHES, 2017). Em função da elevada altitude, os satélites possibilitam o monitoramento de grandes áreas, variando as quatro resoluções (espacial, temporal, radiométrica e espectral). Entretanto, o sensoriamento remoto orbital falha em disponibilizar imagens em resoluções espaciais maiores e com maior frequência temporal (BURKART et al., 2017), sob um custo acessível.

Para se ter maior detalhamento da área sob estudo, maior frequência de revisita e menor custo, faz-se necessária a utilização e sensores suborbitais (embarcados em aeronaves). Alguns satélites comerciais conseguem oferecer as características citadas, embora seja sob elevado custo, relacionado principalmente ao período de aquisição da imagem. Nesse sentido, sensores aerotransportados oferecem algumas vantagens, referentes à disponibilidade imediata, alteração dos comprimentos de ondas e larguras de bandas (YANG, 2012). Em contra partida, possuem custo e complexidade elevada, além da necessidade de planejamento dos voos (CAMPOS, 2017).

Os Veículos Aéreos Não Tripulados (VANTs) ganham destaque no mercado da geoinformação por sua versatilidade (SOUSA, 2018). O destaque se dá pela facilidade de utilização e por possibilitar maiores resoluções espacial e temporal, comparados aos sensores orbitais e aerotransportados, além de mobilidade do equipamento, baixo custo e

utilização de sensores especiais (multiespectrais, hiperespectrais e termais) embarcados (LACERDA, 2016).

O mercado de VANTs disponibiliza grande diversidade de modelos, sendo usualmente classificados conforme suas características técnicas, como aerodinâmica, tamanho e dinâmica de voo, dividindo-os em três categorias: asa-fixa, asa rotativa (multirrotor) e híbridos (ALVES JÚNIOR, 2015). As aeronaves de asa-fixa necessitam de uma pista para decolagem e pouso, ou uma catapulta para lançamento. Aeronaves com multirrotores decolam e pousam na vertical, apresentando facilidade na execução de manobras. Modelos híbridos decolam verticalmente com a habilidade de inclinar os motores ou parte da fuselagem para desenvolver um voo como aviões.

No entanto, é comum a todos o processo de reconstrução do espaço tridimensional a partir de imagens digitais. A fotogrametria digital relaciona as imagens digitais (espaçoimagem) a um sistema de coordenadas do terreno no espaço tridimensional (espaço fotogramétrico) (GOMARASCA, 2009). Nesse sentido, para a construção de um produto fotogramétrico é necessária uma série de cuidados em relação à aquisição das imagens e de seu processamento, a fim de garantir sua qualidade métrica (OLIVEIRA, 2017). Para a realização desses procedimentos, parâmetros de orientação interior e exterior, oriundos do sensor, precisam ser considerados e corrigidos.

Para a reconstrução do espaço tridimensional é necessário construir uma orientação interna e externa. A orientação interna visa estabelecer a relação entre o sistema de coordenada da câmera e o sistema de coordenada dos *pixels*, o que é feito com a recolocação das imagens em posição semelhante no momento da captura e reconstrução dos feixes de luz da câmera. Utilizando os parâmetros X₀, Y₀, Z₀ e os ângulos de rotação de Euler ômega (ω), phi (ϕ) e kappa (κ), é possível descrever a orientação da imagem no momento da captura. Com esses seis parâmetros, possibilita-se a recuperação da posição e altitude de cada fotografia, formando a orientação exterior. A orientação exterior determina a relação matemática entre as coordenadas da imagem (X₀, Y₀, Z₀) e as coordenadas do mundo real (X, Y, Z), conforme Figura 2 (JENSEN, 2009).

O emprego dos VANTs na fotogrametria destaca-se, pela coleta automática de pontos de homólogos nas imagens, a obtenção dos parâmetros de orientação exterior de forma direta pela coleta da posição pelos sensores dos giroscópios, acelerômetros, altímetros e bússola (OLIVEIRA, 2017), a junção automática de fotografias, a construção do MDS/MDT e utilização de *softwares* próprios. Vale ressaltar que mesmo com a elevada aplicabilidade de VANTs e seu baixo custo, os sensores acoplados podem elevar o preço de sua aquisição e inviabilizá-la. Logo, valendo-se dessas vantagens, diversos trabalhos empregam essa tecnologia para diferentes aplicações na área agrícola, seja na identificação e quantificação de doenças em culturas (TETILA et al., 2017), identificação de áreas agrícolas (SENTHILNATH et al., 2016; HALL et al., 2018), estimação da altura e biomassa

(SOUZA et al., 2017; PANAGIOTIDIS; ABDOLLAHNEJAD; SUROVÝ, 2016), estimação da densidade de plantas (JIN et al., 2017) ou levantamento topográficos (KRŠÁK et al., 2016).



Figura 2 Relação entre os sistemas de coordenadas da imagem e objeto: a) Ilustração das coordenadas da imagem e terreno (X₀, Y₀, Z₀ e X, Y, Z); b) Posicionamento dos ângulos de rotação de Euler (ω, φ e κ).

Fontes: a) Moriya (2015) e Hexagon (2019).

A detecção de culturas agrícolas envolve a utilização de IV, os quais, geralmente, utilizam bandas na faixa do visível e do infravermelho próximo. Todavia, alguns autores (TORRES-SÁNCHEZ et al., 2014; BENDIG et al., 2015) avaliam a aplicabilidade de IVs calculados apenas com bandas do visível com o intuito de extrair mais informações na faixa do visível sem o incremento de custo. Outra vantagem na utilização de imagens do espectro do visível é a detecção de plantas não-sadias, facilitando assim a supressão da doença (JIM, 2018; LACERDA, 2016).

Valendo-se disso, Torres-Sánchez et al. (2014) avaliaram a influência de diferentes alturas de voo (30 e 60 m), ao longo do ciclo do trigo, por sete IVs calculados a partir do espectro do visível. Os IVs testados foram: *Normalized Green-Red Difference Index* (NGRDI), *Excess-Green, Color Index of Vegetation* (CIVE), *Vegetativen, Excess Green* menos *Excess Red, Woebbecke index* e um IV criado pela combinação *Excess-Green,* CIVE e *Vegetativen.* Os autores concluíram que os índices apresentam consistência temporal, possibilitando a deteção do trigo utilizando apenas o espectro do visível, em que dentre a gama de índices testados o *Excess-Green* apresentou o melhor resultado.

Bendig et al. (2015) combinaram IV e altura de planta do trigo para estimação de sua biomassa. Nesse estudo, os autores executaram três levantamentos de dados: a) um voo sobre a área de estudo; b) coletas da assinatura espectral do trigo a campo com um *FieldSpec3*; c) coleta destrutiva para estimação da biomassa. A partir de (a) os autores testaram os IVs *Green Red Vegetation Index* (GRVI), *Modified Green Red Vegetation Index* (MRGVI), *Red Green Blue Vegetation Index* (RGBVI). Os dados de (b) serviram para

execução de cinco IVs: NDVI, Soil Adjusted Vegetation Index (SAVI), Modified SAVI (MSAVI), Optimized Soil-Adjusted Vegetation Index (OSAVI) e GnyLi. Os dados de (c) foram utilizados para avaliar o resultado da regressão linear com os *inputs* de altura e IV. Os autores concluíram que o melhor resultado foi o do índice GnyLi, que utiliza a faixa do infravermelho próximo; o segundo melhor resultado foi atingido pelo índice GRVI, calculado apenas na faixa do visível, necessitando de maiores investigações sobre seu potencial.

Tetila et al. (2017) avaliaram a capacidade de utilização de um VANT para a deteção de folhas de soja contaminadas com oídio em diferentes alturas de voo (1, 2, 4, 8 e 16 m). Os autores propuseram uma abordagem computacional, testando o método de segmentação *Simple Linear Iterative Clustering* (SLIC), associado aos algoritmos de classificação *Sequential Minimal Optimization* (SMO), Adaboost, J48, *Random Forest* e *Naive Bayes*. Para tanto, sobrevoaram a área ao longo de toda a safra utilizando uma câmera RGB em diferentes alturas para avaliar qual delas gerava maior precisão. Concluíram que alturas menores possibilitam maior detecção da doença, sendo a técnica SMO a melhor na detecção, embora a performace dos algoritmos tenham variado entre 90 a 98% de acerto.

Senthilnath et al. (2016) empregam VANTs para detecção de tomates com imagens RGB utilizando três algoritmos de agrupamento para deteção de *pixels* de tomate e nãotomate (EM, SOM e K-*means*). O voo foi elaborado no estádio final do tomate para possibilitar uma maior identificação dos alvos. A técnica EM apresentou melhores resultados na detecção da presença de tomates e de seu tamanho do que as demais.

Hall et al. (2018) propuseram-se a classificar o trigo numa lavoura pequena, cerca de 2 ha, com grande mistura espectral com o solo, com falhas de plantio. Para isso, os autores utilizaram um VANT com um sensor multiespectral (RGB e NIR) e avaliaram as combinações de textura, intensidade e saturação como entrada no classificador *Support Vector Machine* (SVM), juntamente a técnica *Object-oriented image* (OBIA). O resultado com maior acurácia para a detecção do trigo neste cenário foi obtido combinando-se o RGB, NIR, textura e intensidade.

Souza et al. (2017) construíram um Modelo Digital de Superfície para estimar a altura da cana-de-açúcar a partir da combinação de duas rotas de voo, nos sentidos Norte/Sul e Leste/Oeste, empregando uma câmera RGB. Os autores avaliaram se a direção do voo afetaria a altura estimada pela angulação solar e brilho na imagem. A utilização de ambos os voos apresentou bons resultados, com menor subestimação e superestimação da área.

Jin et al. (2017) utilizaram essa tecnologia para desenvolver e avaliar um método para estimar a densidade de plantio do trigo em sua emergência, sob diferentes alturas de voo em diferentes regiões (Gréoux, Avignon e Clermont, na França). Os autores criaram amostras de plantas e solo, elaborando o índice de vegetação MNVI (diferença entre os índices EGVI e ERVI) a partir das imagens RGB. Ambas as informações serviram como entrada para o classificador SVM. Os autores concluíram que a deteção do trigo depende do estágio de sobrevoo e da altura, necessitando de voos iguais ou infeirores a 7 m de altura. Na propriedade em Avignon, obtiveram resultados inferiores aos das demais, em função do estádio da cultura no momento de aquisição das imagens.

3.3 Agricultura de precisão

A agricultura reúne diversos desafios nas esferas econômica (políticas de preço, custeio de safra, aumento de produtividade), ambiental (preservação de recursos e uso consciente), segurança alimentar (produção de alimentos seguros, produção suficiente para a população, garantir qualidade da alimentação humana), logística de escoamento e desenvolvimento de tecnologias. Entretanto, sem a rentabilidade necessária para manter a atividade agrícola os demais desafios ficam em segundo plano. Tais condições criam um paradigma, o qual busca o aumento da lucratividade e garantia de uma agricultura sustentável (LIAGHAT; BALASUNDRAM, 2010).

Um dos preceitos da Agricultura de Precisão (AP) é aumentar a eficiência da utilização de recursos, reduzindo a incerteza nas tomadas de decisão para o manejo de áreas agrícolas (LIAGHAT; BALASUNDRAM, 2010). Para que isso seja possível, a AP busca compreender a variabilidade espacial e temporal dos fatores físicos, químicos e biológicos relacionados à produção para proporcionar o melhor manejo da área. A partir desses pressupostos é possível analisar as especificidades das áreas, permitindo que os agricultores conheçam as variações do campo e as gerenciem de forma distinta (LINDBLOM et al., 2017). Ao possibilitar isso, a AP aumenta a eficiência agrícola e a torna mais sustentável pela redução do uso de nutrientes, assim como a aplicação de fertilizantes e pesticidas (AUBERT; SCHROEDER; GRIMAUDO, 2012).

Além disso, a AP preza pela reorganização da agricultura ao utilizar recursos otimizados, mais eficientes e sustentáveis (SHIBUSAWA, 1998), possibilitando que os agricultores tomem decisões corretas no momento correto e de forma adequada (PIERCE; NOWAK, 1999). Para atingir essa meta, é necessário empregar métodos de coleta de dados e de análise espacial de variabilidade, que incluem a junção de tecnologias como aquisição remota de dados (sensores de umidade, condutividade elétrica etc.), Sistema de Navegação Global via Satélite, (*Global Navigation Satellite System*), sistemas de informação geográfica (SIG), maquinários agrícolas (monitores de produtividade, aplicadores a taxa variável etc.) (AUBERT; SCHROEDER; GRIMAUDO, 2012). Esses métodos influenciam positivamente no desempenho da atividade por reduzirem os custos e agilizarem o conhecimento sobre parâmetros que influenciam a produtividade, pela tecnificação e automatização dos

processos (BAZZI, 2011). Idealmente, o conjunto dessas técnicas permite que o agricultor aumente sua produtividade, reduza a correção nutricional e os impactos ambientais, poupando trabalho pela utilização de máquinas semiautônomas, aumentando o rendimento econômico e a precisão na tomada de decisão (LINDBLOM et al., 2017; PEDERSEN; LIND, 2017).

Bernardi et al. (2014) e Pedersen e Lind (2010) afirmam que a AP é um sistema controlado de três etapas: levantamento e obtenção de dados, interpretação de dados, execução do planejamento ou tomada de decisão, configurando-se como um sistema fechado (Figura 3). Logo, cada vez que o ciclo é realimentado ele se refina, melhorando a qualidade do sistema.





3.3.1 Atributos químicos e físicos do solo e produtividade agrícola

Segundo Flores e Alba (2014), a globalização dos mercados agrícolas associada à demanda de uma produção sustentável acarreta a necessidade de compreensão da capacidade produtiva e da variabilidade dos atributos relacionados ao solo. A exigência nutricional pelas culturas varia conforme fatores climáticos e ambientais, o tipo de cultivo e o potencial produtivo do solo.

O solo é caracterizado como um sistema trifásico, sendo constituído por uma fase sólida (com partículas minerais e orgânicas de composição derivada), uma fase líquida (solução do solo) e uma fase gasosa (ar do solo) (VILLA NOVA; BACCHI; REICHARDT, 1996). Os principais atributos do solo, que determinam seu potencial produtivo, são aqueles responsáveis por manter a água no solo e fornecer nutrientes.

As partículas da fração sólida são compostas por macro e micronutrientes, derivados do intemperismo de rochas, essenciais para o desenvolvimento adequado das plantas. Os

macronutrientes são o nitrogênio (N), fósforo (P), potássio (K), cálcio (Ca), magnésio (Mg) e enxofre (S), exigidos em maior quantidade pelas plantas. Já os micronutrientes, boro (B), cloro (Cl), cobre (Cu), ferro (Fe), manganês (Mn), molibdênio (Mo) e zinco (Zn) são necessários em menor quantidade (BROCH; RANNO, 2012). A avaliação destes é efetuada por uma análise química do solo, que permite medir a quantidade de cada atributo, identificar deficiências nutricionais e, por fim, corrigi-las a fim de reduzir os impactos na produtividade.

Além disso, as três fases do solo compõem a parte física, formada pela textura (partículas derivadas do material de origem do solo: silte, areia e argila), estrutura (arranjamento dos agregados), porosidade (espaços vazios do solo) e a densidade. Tais fatores afetam a capacidade de infiltração, retenção e disponibilização de água, assim como a penetração das raízes e a circulação do ar (BEUTLER et al., 2012). Para compreender as variáveis físicas do solo, é necessário analisar o sistema de plantio, o tráfego de maquinário e o relevo, o qual influencia no grau de intemperismo dos materiais, em função de sua localização (topo, meia encosta e encosta inferior) (FLORES et al., 2012). A avaliação é feita pela coleta de amostras indeformadas, que preservam a estrutura do solo, em que se analisa a textura, macro e microporosidade e densidade. Outra forma de análise é pela caracterização do perfil do solo.

Zhang, Yamasaki e Nanzyo (2002) indicam seis tipos de fatores que afetam a produção agrícola:

- comportamento da produtividade ao longo dos anos;
- características do relevo: altitude, declive, aspecto da paisagem, terraço, proximidade à bordadura e a rios e lagos;
- fatores relacionados ao solo: deficiências nutricionais, aplicação de adubos orgânicos, propriedades físicas e químicas e profundidade do solo.
- fatores inerentes à cultura: propriedades biofísicas da planta (índice de área foliar, biomassa, resistência a ataques), densidade de plantio, altura e porte da planta, qualidade do grão;
- fatores anômalos: ataque de pragas e plantas invasoras, eventos climáticos (secas, geadas e granizo);
- manejo: taxa de semeadura, rotação de culturas, aplicação de fertilizantes e pesticidas.

Além disso, o fator matéria orgânica proporciona melhora na estrutura do solo, maior (SARKER et al., 2018) retenção e fornecimento de nutrientes para as culturas, como também proporcionar maior diversidade de organismos no solo, que auxiliam na supressão de pragas, por reduzirem a palatabilidade das pragas (GARRATT et al., 2018). Logo, uma análise espacial destes fatores, proporcionada pelo emprego da geoestatística, pode indicar uma relação entre eles e quais influenciam a produtividade.

3.3.2 Zona de manejo

Para avaliar a variabilidade espacial dos fatores que afetam a produção agrícola, criou-se o conceito de Zona de Manejo (ZM), que são regiões com características comuns internamente, mas distintas entre si, para que cada uma tenha um manejo específico. O delineamento dessas ZMs utilizam dados referentes aos atributos químicos e físicos do solo, o relevo e a produtividade, de tal forma que sejam temporalmente estáveis e que caracterizem adequadamente a variação da produtividade (OLIVER, 2010), considerada, por muitos autores, a variável resposta de maior influência. Rodrigues Junior *et al.* (2011), por exemplo, enfatizam que ZMs são sub-regiões nas quais há uma combinação de fatores condicionantes da produtividade.

Entretanto, além dos fatores citados, existem diversas pesquisas que avaliam o potencial de índices de vegetação para a criação de ZMs. Chang et al. (2014) utilizaram as variáveis pH, N, P, K, Fe, Mn, Cu, Zn e matéria orgânica referentes ao solo, além da produtividade do tabaco e as leituras do NDVI pelo sensor ativo *GreenSeeker*, ao longo do cultivo para o delineamento das zonas de manejo. Os autores elaboraram as ZMs a partir dos dados de solo, como também pelo índice de vegetação, concluindo que o delineamento de ZM com índices de vegetação é possível.

Cicore et al. (2016) delinearam ZM para uma área cultivada com trigo utilizando os índices NDVI, SAVI, EVI (*Enhanced Vegetation Index*) e NDWI (*Normalized Difference Water Index*) obtido pelo satélite Landsat-8. Para a validação, coletaram-se 84 amostras num grid de 27 x 27 m para computar a biomassa. Os autores concluíram que o emprego do NDVI, dentre os índices utilizados, apresentou o maior R² (0,85) com a biomassa em comparação com os demais. Logo, o NDVI produziu resultados confiáveis para construção de ZMs para o trigo.

Georgi et al. (2018) propuseram o delineamento automático de ZMs empregando uma série temporal de sete anos (2009 a 2015) do sensor RapidEye, utilizando as bandas do verde, vermelho e do infravermelho próximo (NIR). A validação dos resultados foi efetuada analisando-se as produtividades da área sob estudo: uma fazenda de 120 ha na Alemanha. Os autores atestaram a variabilidade na geração das ZMs, conforme a quantidade de *inputs* utilizados como, por exemplo, a remoção de um ano-safra pela não disponibilidade de imagens. Para isso, os autores delinearam um *workflow* que seleciona automaticamente as imagens com base na porcentagem de nuvens, cálculo do NDVI, identificação da vegetação e seleção das melhores imagens com base no NDVI, extração da banda NIR, aplicação de um filtro pela mediana e divisão da área em 5 classes com base nesta banda. Os autores afirmam que a divisão da área, conforme as classes, varia de acordo com a quantidade de imagens e presença de nuvens, o que impacta diretamente no comparativo com a produtividade atingida naquele ano e com a média das produtividades. Todavia, embora esta abordagem forneça rapidez na detecção do potencial produtivo da área, ela está sob a limitação de trabalhar apenas com dados de satélite multiespectral.

Marino e Alvino (2018) propuseram a criação de ZMs a partir de IVs (SAVI e NDVI) obtidos por um sensor multiespectral embarcado num VANT, numa propriedade de 2 ha na Itália. Com esse objetivo, os autores realizaram dois voos em diferentes estádios do trigo (afilhamento e espigamento) e coletaram quatro pontos aleatórios na área para estimar a biomassa e LAI. Empregando o agrupamento hierárquico *Ward's* pelo método da mínima variância foi gerada uma ZM pelo NDVI, LAI e biomassa e outra com o SAVI, LAI e biomassa para cada estádio. No afilhamento, ambas as ZMs apresentaram resultados semelhantes, embora o SAVI tenha apresentado resultados melhores em função da mistura espectral do solo. No espigamento, em ambos os IVs (NDVI e SAVI), dividiram a área em três áreas homogêneas (baixa, média e alta), apresentando também resultados semelhantes.

Moreira e Santana (2018) construíram ZMs utilizando apenas o índice NDVI numa propriedade de 50 ha, localizada em São Desidério do Oeste, Bahia. Os autores detectaram quatro áreas de manejo e, a partir delas, coletaram amostras de solo em cada área, para análise dos atributos químicos pH, K, Ca, Mg e relação Ca/K. Pelos atributos químicos do solo, os autores confirmaram capacidades responsivas distintas nos nutrientes analisados nas ZMs.

Logo, como se demonstrou acima, é possível construir ZMs com dados espectrais provenientes de imagens de satélite (CICORE et al., 2016; GEORGI et al., 2018) e imagens de VANTs (MARINO; ALVINO, 2018; MOREIRA; SANTANA, 2018), por produzirem estimativas confiáveis de regiões homogêneas.

Gavioli (2017) propôs o delineamento de ZMs por etapas gerais: aquisição de dados, seleção de variáveis mais importantes, interpolação espacial, aplicação de técnicas de agrupamento, avaliação das classes geradas, construção do mapa referente às ZMs e avaliação das ZMs a campo (Figura 4).





A literatura aponta diversos métodos para a construção de ZMs que se dividem em métodos empíricos e métodos de análise de agrupamento. O método empírico utiliza a

distribuição os dados de produtividade associado ao conhecimento prévio da área para a delimitação das ZMs, resultando numa abordagem simples e subjetiva (FRAISSE; SUDDUTH; KITCHEN, 2001; XIANG, 2007). Os métodos de análise de agrupamento são técnicas mais complexas que proporcionam maior diferenciação entre as sub-regiões por avaliarem o grau de associação entre os atributos e sua variabilidade (LI et al., 2007).

3.3.2.1 Aquisição e análise de dados

A construção das ZMs, geralmente, envolve dados oriundos de coletas de solo. O estudo da variabilidade de parâmetros químicos e físicos do solo existe em decorrência de sua formação, dos processos de intemperismo e das ações antrópicas, podendo apresentar variabilidade nas direções horizontal e vertical. Em relação às ações antrópicas, o sistema de plantio (direto ou convencional) e a forma de aplicação influenciam principalmente na variabilidade horizontal do teor dos nutrientes (OLIVEIRA et al., 2007).

A amostra é um subconjunto de valores do fenômeno espacial que deve ser representativa da área, reproduzindo a distribuição e variabilidade espacial tanto em número de pontos, como em sua distribuição. Segundo Nanni et al. (2011), para determinar a quantidade de amostras e sua distribuição é necessário analisar a variabilidade do solo de cada propriedade, pois cada região terá comportamentos distintos. Os autores comentam que, no Brasil, geralmente, coleta-se uma amostra que representa de 1 ha⁻¹ até 5 ha⁻¹. Na maioria dos casos, essa decisão é motivada apenas por questões econômicas e práticas, por ser um procedimento com custo elevado.

Uma análise coerente do solo exige um olhar atento às formas de amostragem. Yamamoto e Landim (2013) listam três formas de amostragem comumente utilizadas na Agricultura de Precisão: aleatória simples, aleatória estratificada e aleatória sistemática. A amostragem aleatória simples é executada numa população constituída por um sorteio sem reposição dos pontos a serem amostrados, porém oferece os piores resultados por possibilitar a existência de pontos agrupados e regiões não amostradas. Na amostragem aleatória estratificada subdivide-se a região em subáreas de dimensões fixas e, dentro de cada subárea, escolhem-se, aleatoriamente, os pontos de amostragem. É mais vantajosa que a técnica anterior, mas possui problemas na forma da distribuição dos pontos. A amostragem sistemática cria uma malha regular a partir da qual é feita a coleta das amostras. Dentre os três métodos, esse é o que possui mais vantagens.

O delineamento de ZMs é, normalmente, efetuado com base na amostragem do solo a partir de uma grade regular (GILI et al., 2017; SARTORI, 2014; CHANG et al., 2014) ou de um grid irregular (BETZEK et al., 2018; SCHENATTO et al., 2017), que tem por objetivo investigar a variação dos atributos químicos e físicos do solo, como também topográficos e, assim, construir regiões com comportamento semelhante. Todavia, deve-se priorizar um sistema de amostragem que proporcione uma estimativa das características da área pela menor densidade possível, de modo que represente a variabilidade existente da área (NASCIMENTO, 2015).

Nesse sentido, Souza et al. (2014) avaliaram a quantidade de amostras necessárias, pela análise geoestatística, para comparar o semivariograma para duas áreas sob estudo. Na área 1 foram retirados 208, 205, 58 e 24 pontos amostrais e para área 2 retiraram-se 202 e 53 pontos, sendo avaliados os seguintes atributos: argila, areia, superfosfato simples, KCI e Calcário. Os autores concluíram que a quantidade de pontos interfere na krigagem, com aumento do erro da estimativa com amostragem inferior a 100 pontos.

Em contra partida, os autores Damian et al. (2020), Georgi et al. (2018), Marino e Alvino (2018), Scudiero et al. (2018) e Cicore et al. (2016) sugerem a possibilidade de construir Zonas de Manejo utilizando exclusivamente dados provenientes da reflectância da planta ou associados a outras variáveis. Esses autores elaboram ZMs com dados provenientes de sensores orbitais ou terrestres (como os acoplados em VANTs, por exemplo). Sugerem que, em decorrência da resposta espectral da planta estar relacionada à produtividade, que comumente é a variável objetivo, é possível utilizar dados provenientes de sensores. Para tanto, os autores empregam índices de vegetação ou bandas espectrais específicas, que registram o vigor vegetativo da planta para extrair informações de manejo.

Independente dos dados utilizados no processo, é crucial avaliar o comportamento das variáveis sob estudo. Aqui se enquadram as tarefas de checagem de pressupostos de normalidade e independência dos dados (ANDRIENKO; ANDRIENKO, 2006) que norteiam as possíveis etapas na construção de ZMs. A distribuição normal dos dados pode ser investigada pelos testes estatísticos de Shapiro-Wilk, Anderson-Darling e Kolmogorov-Smirnov.

Além disso, é necessário avaliar a influência de pontos discrepantes nos dados, que podem ser verificados por gráficos boxplot ou QQ-plot. Porém, antes da seleção de variáveis, recomenda-se avaliar se os dados originais possuem diferentes escalas de medição e se estas variam espacialmente. Em geral, variáveis agrícolas são medidas em escalas distintas e variam espacialmente, necessitando de um pré-processamento. Nesse sentido, os dados necessitam seguir uma mesma escala, tarefa que pode ser executada aplicando-se a padronização ou normalização dos dados. Schenatto et al. (2017) sugerem que esse procedimento reduz a sensibilidade dos algoritmos de agrupamento por utilizar a mesma escala para todas as variáveis.

3.3.2.2 Interpoladores

Os interpoladores têm como objetivo estimar valores para locais sem medições a partir de outros pontos, por funções que se baseiam no conceito de que locais mais próximos tendem a serem mais similares do que locais distantes (MIRANDA, 2010). Desse modo, dados pontuais são transformados em campos contínuos com padrões espaciais, que possibilitam a comparação com elementos espaciais contínuos. Em função do elevado custo econômico e laboral da aquisição de grades densas e representativas de variáveis, é necessário o uso de interpoladores.

Diversos métodos de interpolação com diferentes níveis de complexidade estão disponíveis na literatura, dentre eles, duas técnicas são amplamente utilizadas: o Inverso da Distância elevado a uma Potência (IDP) e a krigagem. Essas técnicas subdividem-se em interpoladores determinísticos (estimam novos pontos a partir dos mensurados, baseando-se na configuração espacial da amostra, como no IDP) e estatísticos (estimam novos pontos, seguindo um modelo estatístico baseado na correlação entre os dados e a distância, como na krigagem). Couto, Scaramuzza e Maraschini (2002) relatam que o desempenho dessas técnicas depende dos atributos a serem estimados.

Na técnica IDP, a interpolação é efetuada considerando-se o valor de seus vizinhos ponderado pelo inverso da distância entre o ponto de interesse e os vizinhos. Consequentemente, a influência de cada ponto amostrado é geralmente inversamente proporcional à distância do ponto a ser estimado (ALVES; VECCHIA, 2011). A potência escolhida na técnica IDP afeta a influência dos pontos mais distantes na estimação do ponto desejado (MAZZINI; SCHETTINI, 2009).

O interpolador krigagem é um método de geoestatístico que visa caracterizar uma variável em função de sua variabilidade e distribuição espacial (YAMAMOTO; LANDIM, 2013), para, assim, estimar novos pontos em locais não amostrados com base nos valores adjacentes. Isso é possível, pois cada ponto no espaço está relacionado de alguma forma com valores situados a certa distância (YAMAMOTO; LANDIM, 2013), em que sua influência é maior quanto menor for a distância entre os pontos (SOARES, 2014).

O semivariograma é uma ferramenta básica de suporte às técnicas de krigagem que permite representar quantitativamente a variação de um fenômeno regionalizado no espaço (JOURNEL; HUIJBREGTS, 1978). O cálculo da semivariância é comumente efetuado pelo estimador de Matheron (MATHERON, 1963), conforme Equação (7).

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(s_i) - Z(s_i + h)]^2$$
(7)

em que: h é a distância entre pares de observação, N(h) é o número de pares de observações $Z(s_i)$ e $Z(s_i + h)$ observados nas posições s_i e $s_i + h$.

Assim, é possível caracterizar a dependência espacial dos dados e seu comportamento, pois o semivariograma cresce conforme o acréscimo da distância até sua estabilização; tal comportamento indica a dependência espacial da variável (VIEIRA, 2000). Tais características (distância até a estabilização, amplitude do semivariograma etc.) são utilizadas para o ajuste de um modelo teórico. No semivariograma teórico (Figura 5), pode ser observado o comportamento descrito, em que a distância influencia a abrangência do campo estruturado, ou seja, até que distância os dados apresentam dependência espacial.



Figura 5 Semivariograma teórico. Fonte: Adaptado de Bodaghabadi (2018).

O ajuste do semivariograma envolve o emprego de diferentes modelos teóricos, os quais se dividem em duas categorias: transitivo e não transitivo, ou seja, quando o semivariograma atinge o patamar e quando não atinge o patamar (ISAAKS; SRIVASTAVA, 1989). Na literatura, os modelos teóricos transitivos mais empregados são o esférico, exponencial, gaussiano e a família Matérn (ISAAKS; SRIVASTAVA, 1989; VIEIRA, 2000; DIGGLE; RIBEIRO JR., 2007; CRESSIE, 2015). Para realizar o ajuste de modelos, a literatura propõe o emprego dos métodos Mínimos Quadrados, Mínimos Quadrados Generalizados, Mínimos Quadrados Ponderados, Máxima Verossimilhança e Máxima Verossimilhança Restrita. Dentre estes, Mello et al. (2005) sugerem que o método da Máxima Verossimilhança é o mais amplamente utilizado.

Entretanto, é necessário avaliar a qualidade de ajuste dos modelos, seja por técnicas baseadas na comparação entre os valores teóricos e empíricos, como na validação cruzada (FARACO et al., 2008), pelas métricas Erro Médio (EM, Equação (8), Erro Médio Reduzido (EMR, Equação (9), Desvio Padrão dos Erros Reduzidos (DPER, Equação (10) Erro Absoluto (EA, Equação (11), Raiz Quadrada do Erro Médio (RMSE, Equação (12) e Erro Médio Absoluto (MAE, Equação (13).
$$EM = \frac{1}{n} \sum_{i=1}^{n} Z(s_i) - \hat{Z}(s_i)$$
(8)

$$EMR = \frac{1}{n} \sum_{i=1}^{n} \frac{Z(s_i) - \hat{Z}(s_i)}{\sigma(\hat{Z}(s_i))}$$
(9)

DPER =
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} \frac{|Z(s_i) - \hat{Z}(s_i)|}{\sigma(\hat{Z}(s_i))}}$$
 (10)

$$EA = \sum_{i=1}^{n} |Z(s_i) - \hat{Z}(s_i)|$$
(11)

$$RMSE = \sqrt{\sum_{i=1}^{n} \frac{Z(s_i) - \hat{Z}(s_i)}{n}}$$
(12)

$$MAE = \sum_{i=1}^{n} \frac{Z(s_i) - \hat{Z}(s_i)}{n}$$
(13)

em que: n: quantidade de valores amostrados; $Z(s_i)$: valor da amostra observada no ponto; $\hat{Z}(s_i)$: valor predito pela krigagem no ponto s_i sem considerar a amostra $Z(s_i)$; $\sigma(\hat{Z}(s_i))$: desvio padrão da krigagem no ponto s_i .

Logo, após o ajuste e seleção dos modelos, é possível aplicar o interpolador krigagem, considerado superior aos outros métodos de interpolação por permitir o cálculo do erro associado às estimativas, chamado de variância de estimação (MARTINS, 2017). Segundo Isaaks e Srivastava (1989), existem vários tipos de krigagem: pontual, simples, ordinária, preditiva, universal, de blocos e outras. Dentre as técnicas de krigagem, uma das mais utilizadas é a krigagem ordinária, por sua simplicidade e pelos resultados que proporciona (YAMAMOTO; LANDIM, 2013). A krigagem ordinária se fundamenta na suposição da aleatoriedade da variação, na existência da dependência espacial e na estacionariedade de segunda ordem (média constante e a variância depende somente da distância e direção entre os pontos e não da sua posição absoluta) (OLIVER; WEBSTER, 2015). A krigagem ordinária é um método local, em que a estimativa de um ponto não conhecido resulta da combinação linear dos valores encontrados na vizinhança próxima (YAMAMOTO; LANDIM, 2013).

Gavioli et al. (2019) avaliaram dados químicos e físicos de solo pelas técnicas de interpolação krigagem ordinária, inverso da distância e inverso da distância ao quadrado, para a construção de zonas de manejo. Para tanto, os autores empregaram uma técnica de análise multivariada espacial (MULTISPATI-PCA), para a seleção de variáveis e, em seguida, avaliaram dos métodos de interpolação. Dentre as técnicas avaliadas, a krigagem ordinária apresentou os melhores resultados para a construção das ZMs.

23

Gardiman Junior et al. (2012) avaliaram cinco métodos de interpolação para espacialização da precipitação na bacia do rio Itapemirim/ES, com base numa série histórica de 1972 a 2002. Os métodos sob estudo foram o Inverso da Distância ao Quadrado (IDQ), Krigagem esférico, vizinho natural (com base nos polígonos de *Thielssen*), *Spline* regularizada e *Topo to Raster*. Dentre as técnicas empregadas, a krigagem pelo semivarioagrama esférico apresentou as melhores estimativas, seguido do IDQ, *Spline,* vizinho natural e *Topo to Raster*.

3.3.2.3 Técnicas de agrupamentos dados

Técnicas de agrupamento (*cluster*) têm por objetivo encontrar grupos de objetos similares numa base de dados por uma medida de similaridade pré-estabelecida (HAN; KAMBER, 2006), com padrões semelhantes entre si e dissimilares a outros grupos (VILLWOCK, 2009). Uma análise criteriosa de *cluster* deve lidar com a dimensionalidade e diferenciação dos dados, sendo capaz de definir diferentes formas e tamanhos relacionados aos dados, sendo robusta a presença de ruídos (DONI, 2004). As técnicas ou métodos de agrupamento dividem-se em: hierárquicos, particionados, exclusivo, difuso, completo e parcial (TAN; STEINBACH; KUMAR, 2005). Os métodos aqui discutidos serão os particionadores e hierárquicos.

Dentre os algoritmos de particionamento os mais utilizados para delimitar ZMs são o *K-means* e *Fuzzy c-means*. Ambos os algoritmos dividem um conjunto de *n* elementos em grupos disjuntos, por meio de uma função de distância, criando um centroide por grupo. Ambos efetuam a tarefa de agrupamento de modo automático, buscando criar grupos internamente homogêneos e heterogêneos entre si. Para tanto, seguem o critério da minimização da soma dos quadrados das distâncias entre os elementos e o centroide de cada grupo (GAVIOLI, 2017).

Dentre esses, o *K-Means* é um método não hierárquico que agrupa as variáveis de interesse em K dimensões do espaço, em que K se refere ao número de grupos estabelecidos. A partir de parâmetros de entrada como: número de classes prováveis contidas, número de interações realizadas e distância mínima entre *pixels*, pelo cálculo da distância Euclidiana (distância de similaridade), o sistema realiza o agrupamento dos dados com características semelhantes em classes (SCHOWENGERDT, 1983; MATHER, 1999; MOREIRA, 2001). Entretanto, ao utilizar essa técnica para agrupar dados espaciais os grupos resultantes podem ser espacialmente fragmentados, pois ela não considera o grau de relação espacial dos dados (SOOR et al., 2018; WOLF; KNAAP; REY, 2019).

Os algoritmos de agrupamento hierárquico dividem sucessivamente os elementos do conjunto numa quantidade específica de grupos, resultando num único grupo que contenha

todos os *n* elementos ou em *n* grupos com um único elemento (XU; WUNSCH II, 2009). Logo, algoritmos hierárquicos são subdivididos em aglomerativo (em que no final do processo todos os elementos reúnem-se num único *cluster*) ou divisivo (em que cada grupo é formado por um único elemento) e a visualização dos elementos pertencentes a cada grupo é possível por meio de um dendograma (Figura 6), o qual ilustra o particionamento das classes conforme o seu grau de associação.



Figura 6 Dendograma ilustrando o procedimento do método hierárquico aglomerativo (à esquerda) e do método hierárquico divisivo (à direita).

Fonte: Xu e Wunsch II (2009).

Vale ressaltar que, no método aglomerativo, a junção dos grupos ocorre pela união dos *clusters* mais semelhantes. Para tanto, o algoritmo utiliza uma função de distância para calcular a proximidade dos *n* grupos (XU; WUNSCH II, 2009), ou seja, uma medida de dissimilaridade. Logo, os métodos aglomerativos se diferenciam pelo cálculo da distância, sendo os mais comuns: *average linkage, complete linkage, centroid* linkage, single *linkage, median linkage* e *Ward* (XU; WUNSCH, 2009), conforme Figura 7.



Figura 7 Representação das funções de distância single linkage, complete linkage, average linkage e centroid linkage, pelo método aglomerativo.

De forma simplificada, o método *single linkage* aglomera grupos que apresentam a menor distância entre os elementos de cada grupo. Já o método *complete linkage* executa o oposto, aglomerando grupos que possuem a maior distância entre os seus elementos. O método *average linkage* reúne os grupos que possuem a menor distância média entre eles. O *centroid linkage* calcula o centroide de cada grupo e aglomera os grupos que possuem os centroides mais próximos (XU; WUNSCH II, 2009). Todavia, o agrupamento de dados geoespaciais, considerando apenas os atributos das variáveis, pode resultar em grupos espacialmente descontínuos (REY; ARRIBAS-BEL; WOLF, 2019). Para tanto, é possível adotar uma matriz de contiguidade, ou seja, uma matriz que expresse a similaridade espacial entre dois ou mais pontos. Isso limita a aglomeração de grupos seguindo duas restrições, uma baseada numa métrica de distância (qual a menor/maior/média distância entre grupos) e outra na conexão espacial entre os grupos (CARVALHO et al., 2009).

As matrizes de contiguidade baseadas em bordas compartilhadas dividem-se em três categorias: atributos que compartilham as mesmas arestas (Torre), atributos que compartilham os mesmos vértices (Bispo) e atributos que compartilham os mesmos vértices e arestas (Rainha). A Figura 8 ilustra os tipos de contiguidade, em que dado um quadrado com 9 elementos, os elementos espacialmente relacionados ao 5º elemento se alteram conforme a contiguidade utilizada. Utilizando a contiguidade tipo Torre, o 5º elemento é considerado vizinho apenas dos elementos 2, 4, 6 e 8; já na contiguidade tipo *Bispo* apenas os elementos 1, 3, 7 e 8 são considerados vizinhos; enquanto na contiguidade tipo Rainha todos os elementos são considerados vizinhos do 5º elemento pelas regras utilizadas.

I	2	3
4	5	6
7	8	9

T -	2	3	
4	5	6	
7	8	9	

rook contiguity - edges only 2, 4, 6, 8 are neighbors of 5

bishop contiguity - corners only I, 3, 7, 9 are neighbors of 5 queen contiguity - edges and corners 5 has eight neighbors

2

5

8

I

4

7

3

6

9

Figura 8 Ilustração dos tipos de contiguidade: torre (*rook*), bispo (*bishop*) e rainha (*queen*).

Fonte: Alhessi (2020).

Também é possível construir uma restrição espacial utilizando os algoritmos *K-nearst Neighbors* (KNN). De forma simplificada, dado um elemento qualquer, o KNN considera *K* elementos mais próximos como seu vizinho ao invés de selecionar aqueles que de fato compartilham alguma borda (REY; ARRIBAS-BEL; WOLF, 2019). Isso flexibiliza a quantidade de vizinhos por ponto, em razão de o usuário selecionar arbitrariamente o *K* desejado. Logo, um agrupamento hierárquico aglomerativo que una os grupos utilizando uma medida de dissimilaridade associada à restrição espacial (matriz de contiguidade), resultará em grupos com atributos e regiões geograficamente concisas (REY; ARRIBAS-BEL; WOLF, 2019).

3.3.2.3.1 Critérios de avaliação dos agrupamentos

O processo de determinação da quantidade de agrupamentos num conjunto de dados é comumente realizado por índices estatísticos que se dividem em três categorias: medidas de coeficiente externo, interno e "critérios relativos" (CHARRAD et al., 2014). As medidas de coeficiente interno consistem na comparação dos resultados dos agrupamentos com resultados previamente sabidos. Para dados agrícolas, também é possível comparar os grupos a partir de informações externas, como por exemplo, pela produtividade (BAZZI et al., 2013). As medidas de coeficiente interno extraem informações ao longo do processo de agrupamento, como por exemplo: compacidade (o quão relacionado são os elementos dos grupos), separabilidade (quão distintos são os elementos dos grupos, pela distância entre os centroides dos grupos), dentre outras (LIU et al., 2010), para estimar o ajuste dos agrupamentos pela sua similaridade. As medidas de coeficiente externo mensuram a similaridade entre dois grupos a partir de informações previamente conhecidas, dentre estas técnicas estão a entropia e o V-*measure* (LIU et al., 2010; ROSENBERG; HIRSCHBERG, 2007).

As métricas baseadas na estimativa por critérios relativos enfatizam a comparação do mesmo algoritmo em diferentes parâmetros, a fim de fornecer uma referência para decidir qual deles pode melhor revelar as características dos objetos (XU; WUNSCH, 2009). Dentre as métricas baseadas em critérios relativos, estão os índices Calinski-Harabasz (conhecido como *Variance Ratio Criterion*), Davies-Bouldin e o Coeficiente de Silhueta.

O índice Calinski-Harabasz (CH) descreve a razão entre a similaridade interna dos grupos (*Between Cluster Similarity – BCM*) e as similaridades entre os grupos (*Within Cluster Similarity*) (SCUDIERO et al., 2018), conforme Equação (14). Quanto maior for o valor do índice CH maior é a homogeneidade interna das classes e as diferenças entre grupos.

$$CH = \frac{BCM}{k-1} \cdot \frac{N-k}{WCS}$$
(14)

em que: n é a quantidade total de elementos e k é a quantidade de classes. BCM é a distância entre *clusters* $\sum_{i=1}^{k} n_i \cdot d(z_i, n_{tot})^2$, sendo z_i o centro do grupo c_i e n_i a quantidade de elementos em c_i ; WCS é $\sum_{i=1}^{k} \sum_{x \in c_i} d(x, z_i)^2$, em que x é um elemento que pertence ao agrupamento c_i .

O índice Davies Bouldin (DB) avalia a separação entre o i-ésimo e j-ésimo agrupamento, que deve ser o maior possível entre os agrupamentos e o menor possível dentro do agrupamento (Equação (15) (MAULIK; BANDYOPADHYAY, 2002). Quanto menor for o valor melhor será a separação entre grupos e a similaridade interna dos grupos.

$$DB = \frac{1}{K} \sum_{i=1}^{K} \max_{i,j \neq i} \frac{S_i + S_j}{d_{i,j}}$$
(15)

em que: $S_i = \frac{1}{c_i} \sum x_j \in c_i ||x_j - v_i||$ é uma medida de dispersão dentro do agrupamento *i*, K é o número de agrupamentos, x_j é um vetor n dimensional atribuído ao *cluster i*, v_i é o centro do *cluster i*, c_i representa o *cluster i*, ||.|| é a distância euclidiana e $d_{i,j} = ||v_i - v_j||$ é a distância entre o centro do *cluster i e j*.

O coeficiente de silhueta (CS) mensura a qualidade da interna e a separação externa dos grupos (VENDRAMIN; CAMPELLO; HRUSCHKA, 2010). Esse índice expressa a relação entre um elemento e os demais elementos do mesmo grupo com um outro segundo melhor grupo para aquele elemento (*Next Best Fit Cluster*) (WOLF; KNAAP; REY, 2019). O valor desse coeficiente, para um ponto p, é denotado pela Equação.(16).

$$CS_p = \frac{b_p - a_p}{\max(a_p, b_p)} \tag{16}$$

em que: a_p é a média das distâncias entre o ponto p e todos os demais pontos pertencentes ao mesmo grupo e b_p é a média das distâncias entre o ponto p e todos os pontos do grupo mais próximos que contenham p.

Além disso, outra análise estatística que pode ser utilizada para avaliar se os grupos são estatisticamente diferentes entre si é a análise de variância - ANOVA (para dados que seguem distribuição normal de probabilidade) ou por *Kruskal-Wallis* (para dados que não seguem distribuição normal). O teste *Kruskal-Wallis* (KW) é utilizado para comparar três ou mais grupos de dados independentes e permite analisar se os diferentes grupos provêm da mesma distribuição.

3.3.2.4 Avaliação da zona de manejo

Os métodos citados anteriormente possibilitam avaliar a qualidade dos grupos a serem utilizados. Entretanto, é necessário também avaliar se os grupos podem ser tratados como subáreas de gerenciamento de acordo com outra variável alvo (SALEH; BELAL, 2014). Essa variável alvo pode ser desde parâmetros de solo, gerenciamento da área, como também a produtividade. Bazzi et al. (2013) recomendam que o emprego da variável produtividade para avaliar as ZMs geradas.

4 MATERIAL E MÉTODOS

Esta pesquisa foi segmentada em 3 etapas de execução, representadas pelo fluxograma (Figura 9), abrangendo as safras de verão 2018/2019 e inverno 2019. A etapa inicial contemplou tarefas de coletas de dados a campo, subdivididas em subetapas: aquisição de imagens por VANT, download de imagens Sentinel-2, coleta de produtividade, coleta do estádio vegetativo e amostragem de solo (realizada uma única vez e anterior a safra de verão 2018/2019). Posteriormente, fez-se o processamento dos dados: construção de ortomosaicos e Modelo Digital de Terreno (MDT), normalização de bandas, construção dos Índices de Vegetação (IV), *resample* de imagens para 5 e 10 m, correlação entre variáveis, seleção de IVs, delineamento de Zonas de Manejo e análise de ZMs. Por fim, as etapas de análise exploratória dos dados (produtividade, amostragem de solo e dos IVs) e interpolação de variáveis (5 m).



Figura 9 Fluxograma geral da dissertação com as etapas de coletas de dados a campo (A), processamento dos dados (B) e análise exploratória (C).

4.1 Área de estudo

A área sob estudo possui 49,2 ha dedicado à agricultura (Figura 10), localizada no município de Cascavel - PR, nas coordenadas 24°41'S e 53°29'W, com altitude média de 653 m e declividade média de 6,4%. O clima é temperado (Köppen – Cfb), com verão moderado e sem período de seca (APARECIDO et al., 2016), o solo da região é caracterizado como um latossolo vermelho distroférrico (EMBRAPA, 2013). O manejo da área é feito seguindo o sistema de plantio direto, adotado há mais de 10 anos, cultivando apenas culturas para fins comerciais (soja, milho, aveia e trigo). A área sob estudo não adota técnicas de agricultura precisão para manejo.



Figura 10 Área sob estudo localizada no município de Cascavel - Paraná, com enfoque na divisão dos cultivares de soja NA5909RG e BRS1003IPRO, pontos de monitoramento, controle, elevação e ortomosaico.

O presente estudo analisou duas safras, sendo uma de verão (2018/2019) e outra de inverno (2019), cultivadas com soja e trigo, respectivamente. Na safra de verão foram utilizados dois cultivares: BRS1003IPRO e NA5909RG (Figura 10), sendo o cultivar NA5909RG semeado de forma agrupada e o BRS1003IPRO semeado de forma equidistante. A semeadura equidistante consiste na colocação de uma semente a cada 0,08 m, com espaçamento entre linhas de 0,45 m; a semeadura agrupada utiliza-se de três a quatro sementes a cada 0,45 m, com espaçamento entre linhas de 0,45 m; a semeadura de 0,45 m (BALBINOT et al., 2018), totalizando uma população de 266.667 plantas.ha⁻¹ para ambos os cultivares. O

cultivar NA5909RG apresenta porte médio de planta, com exigência média à fertilização (ROOS, 2019); o BRS1003IPRO é geneticamente modificado com tolerância ao herbicida glifosato, apresenta porte de aproximadamente 0,70 a 0,95 m (EMBRAPA, 2019a). A semeadura da área ocorreu se iniciou em 30/10/2018 e se estendeu por 7 dias, sendo concluída em 06/11/2018. A colheita foi finalizada em 02/03/2019, totalizando ciclo de aproximadamente 124 dias.

Na safra de inverno, o cultivar de trigo semeado foi o BRS Sanhaço, sob espaçamento de 0,17 m, sendo 58 sementes por metro e semeada entre 17/05/2019 a 20/05/2019. A colheita iniciou em 18/09/2019 e foi finalizada em 27/09/2019, totalizando ciclo de aproximadamente 140 dias. Esse cultivar possui boa capacidade de perfilhamento em regiões mais frias, apresentando boa resistência às manchas foliares, giberela, debulha e ao acamamento (EMBRAPA, 2019b).

4.2 Coleta de dados

As coletas de dados a campo envolveram cinco etapas distintas (Figura 9A): monitoramento da área por um VANT, aquisição de imagens do sensor Sentinel-2, determinação do estádio vegetativo das culturas, amostragem de solo e produtividade. Para a soja, o monitoramento fenológico (aquisição de imagens e mensuração do estádio) seguiu o estipulado por Farias, Nepomuceno e Neumaier (2007), sendo realizados três voos ao longo do estádio vegetativo e três voos no estádio reprodutivo. A revisita na área seguiu um intervalo de sete dias para o monitoramento contínuo da lavoura, entretanto, sendo remarcada conforme atividades agrícolas da fazenda (aplicações de defensivos), disponibilidade de equipamento e condições climáticas (Tabela 2, detalhamento no Apêndice A).

Para o trigo, foi executado um voo no afilhamento, dois voos no alongamento, dois voos no florescimento e um voo na maturação, conforme a escala fenológica Feeks-Large (1954). A duração dos estádios fenológicos do trigo alterou-se conforme as condições climáticas da área, apresentando um período maior no alongamento (Tabela 2).

	Coleta de			
Cultura	dados	Equipamento	Condição climática	Estádio
Soja	22/11/2018	Mavic Pro	Céu claro sem nuvens	Semeadura
	06/12/2018	Mavic Pro	Céu claro sem nuvens	V3
	12/12/2018	Mavic Pro	Céu com nuvens finas e esparsas (início); Céu com nuvens concentradas com sombreamento (fim)	V5 a V12
	20/12/2019	Mavic Pro	Céu com nuvens finas e esparsas (início); Céu com nuvens concentradas com sombreamento (fim)	V7 a V16
	11/01/2019	Mavic Pro	Céu com nuvens finas e esparsas (início); Céu com nuvens concentradas com sombreamento (fim)	R1
	21/01/2019	Mavic Pro	Céu com nuvens finas e esparsas (início); Céu com nuvens concentradas com sombreamento (fim)	R3
	06/02/2019	Mavic Pro	Céu claro com nuvens finas e esparsas (início); Céu com nuvens esparsas (fim)	R4 a R5.1
	23/02/2019	Mavic Pro	Céu com nuvens finas e esparsas (início) Céu com nuvens concentradas com sombreamento (fim)	R5.1 a R5.5
Trigo	11/06/2019	Phantom 4 Pro	Céu com nuvens finas e esparsas	Afilhamento
	30/06/2019	Mavic Pro	Céu claro sem nuvens	Alongamento
	18/07/2020	Mavic Pro	Céu claro com nuvens finas e esparsas (início); Céu com nuvens finas e esparsas (fim)	Alongamento
	01/08/2020	Mavic Pro	Céu claro sem nuvens	Alongamento
	22/08/2020	Phantom 4 Pro	Céu claro com nuvens finas e esparsas	Florescimento
	04/09/2019	Phantom 4 Pro	Céu claro com nuvens finas e esparsas	Maturação

 Tabela 2
 Janela para a previsão das coletas de campo, monitoramento efetuado e condição climática

4.2.1 Aquisição de imagens por VANT

Para o monitoramento vegetativo foram utilizados dois VANTs (Tabela 2): Mavic Pro e Phantom 4 Pro, conforme a disponibilidade do equipamento. O VANT Mavic Pro (Figura 11), desenvolvido pela empresa DJI é uma aeronave multirrotor do tipo quadricóptero, pesando aproximadamente 0,7 kg e, em condições ideais, possui autonomia de voo de 27 min (alimentado por uma bateria de *lithium* 3S de 3.830 mAh). Esse VANT rastreia o código C/A das constelações *Global Positioning System* (GPS) e *Global Navigational Satellite System* (GLONASS), com acurácia de 10 m, possui uma câmera RGB com resolução de 12,35 mega*pixel*, equipada com sensor tipo CMOS 1/2,3" (4000 x 3000 *pixel*), com distância focal de 4,73 mm e velocidade máxima do obturador 1/8000 s.



Figura 11 Veículo aéreo não tripulado Mavic PRO. Fonte: DJI (2014).

O VANT Phantom 4 Pro (Figura 12), desenvolvido pela empresa DJI é uma aeronave multirrotor do tipo quadricóptero, pesando, aproximadamente, 1,3 kg, com autonomia de voo de 30 min (alimentado por uma bateria de *LiPO* sS de 6.000 mAh), em condições ideais. Esse VANT rastreia o código C/A das constelações *Global Positioning System* (GPS) e *Global Navigational Satellite System* (GLONASS), com acurácia de 10 m. Possui uma câmera RGB com resolução de 20 mega*pixels*, equipada com sensor tipo CMOS 1/2,8" (4000 x 3000 *pixel*), com distância focal de 35 mm e velocidade máxima do obturador 1/8000 s.



Figura 12 Veículo aéreo não tripulado Phantom 4 PRO. Fonte: DJI (2014).

4.2.1.1 Planejamento e realização dos voos

O planejamento dos voos foi realizado no aplicativo multiplataforma DroneDeploy, disponibilizado de forma gratuita. Para isso, estipulou-se imagear uma área 10% maior do que a original para reduzir problemas no ortomosaico. A sobreposição vertical e horizontal foi de 75% para os voos da soja e 80% para os do trigo (Figura 13). A aquisição das

imagens foi feita no modo automático, ou seja, a câmera embarcada realizava o ajuste do ISO, balanço de branco e exposição. No plano de voo para a soja adotou-se altura de 90 m, necessitando de, aproximadamente, 42 min para o sobrevoo completo da área, resultando num *Ground Sample Distance* (GSD) teórico de 2,8 cm. Para o trigo, adotou-se altura de 100 m, necessitando de, aproximadamente, 59 min para o sobrevoo completo da área, resultando num GSD teórico de 3,0 cm. A mudança dos parâmetros de altura, sobreposição e velocidade do voo ocorreu por problemas técnicos que ocorreram na etapa de processamento de alguns voos. Além disso, a decolagem do voo sempre ocorreu no mesmo local para reduzir as variações do GSD. Um único plano de voo foi mantido para todas as coletas por safra.





Considerando a autonomia de voo de ambas as aeronaves em, aproximadamente, 20 min., foram necessárias quatro baterias para a cobertura total da área. Por fim, a janela de voo utilizada foi das 11 h às 14 h, tendo como objetivo reduzir o sombreamento, assim como utilizar a melhor angulação solar. A maioria dos voos foi realizada das 11 h às 12:30 h.

Para efetuar a correção geométrica das imagens obtidas, foram posicionados 12 pontos de controle (*Ground control points -* PC) ao longo da área de estudo (Figura 10), demarcados por piquetes de madeira ou bandeiras (Figura 14A). Os PCs foram confeccionados numa chapa de madeira compensada com dimensão de 50 x 50 cm, sendo posicionados a 4 cm do solo (Figura 14B) ou confeccionados em lona de vinil (Figura 14C).



Figura 14 Materialização do *Ground control point* (PC): A) demarcação piquete; B) PC a campo; C) demarcação e posicionamento do PC.

A coleta das coordenadas geográficas dos PCs foi obtida com um receptor GNSS, TechGeo GTR/G2 rastreando nas fases L1/L2. Para o levantamento dos pontos, foram utilizados dois receptores, simultaneamente instalados a cada dois PCs, com tempo de permanência de 30 min (Figura 15). Posteriormente, efetuou-se o pós-processamento dos pontos pelo Posicionamento por Ponto Preciso (PPP), utilizando a estação mais próxima à área de estudo (localizada no INCRA, Cascavel), pela Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS (RBMC), serviço disponibilizado pelo IBGE. Essa estação está a 12 km em linha reta da área de estudo.



Figura 15 Receptores geodésicos da TechGeo GTR/G2 na área sob estudo.

4.2.2 Dados de altura e estádio fenológico das culturas

O monitoramento fenológico da soja (altura das plantas e definição do estádio) foi efetuado em 12 pontos distribuídos aleatoriamente na área de estudo (Figura 10, pontos em amarelo). Em cada ponto, determinou-se o estádio fenológico da soja seguindo a

metodologia proposta por Farias, Nepomuceno e Neumaier (2007) que, de forma simplificada, quantifica todos os nós ao longo de seu desenvolvimento (seja no vegetativo ou reprodutivo) como também a medição de sua altura. A altura foi mensurada do solo até o dossel da cultura, com três repetições por ponto e aquisição de fotos como registro (Figura 16). Desta forma, ao longo da safra (Tabela 2), registrou-se o desenvolvimento da soja nos pontos monitorados (Figura 10).

A determinação do estádio fenológico do trigo ocorreu ao longo de 12 pontos (Figura 10, pontos em marrom). Em cada ponto foi determinado o estádio conforme a escala fenológica de desenvolvimento Feeks-Large (1954) (Figura 17). Não foi executada a medição da altura do dossel.



Figura 16 Monitoramento da soja no ponto 12 em 21/11/2018. A) Fotografia vertical ilustrando a condição da soja; B) Fotografia ilustrando o estádio vegetativo.



Figura 17 Monitoramento do trigo em 04/09/2019: A) Fotografia vertical do trigo; B) Fotografia ilustrando o estádio vegetativo.

4.2.3 Grade amostral de solo

Para caracterizar o solo da área sob estudo, foi realizada uma coleta de solo (présemeadura da soja) para analisar a variação dos atributos químicos alumínio (Al³⁺), cálcio (Ca²⁺), capacidade de troca catiônica (CTC), cobre (Cu), ferro (Fe), acidez potencial (H+Al₃), potássio (K), magnésio (Mg²⁺), manganês (Mn), matéria orgânica (MO), fósforo (P), pH (extraído em solução de CaCl₂), zinco (Zn), soma de bases (V%); e após a colheita do trigo a coleta de resistência à penetração (RSP). No arranjo do experimento a campo foi considerada uma grade regular de 90 x 90 m, sendo utilizados apenas pontos em que o centroide estivesse no interior da área sob estudo, totalizando 63 pontos amostrais (Figura 18), com densidade de 1,4 pontos por ha, que atendessem ao critério de pelo menos 30 pares para cada ponto na criação do semivariograma para a krigagem (CRESSIE, 2015), considerada como a mínima utilizada para amostragens de solo na Agricultura de Precisão (SARTORI, 2014).

Para a análise química do solo, dentro de um raio de 5 m a partir do centroide do ponto, foram coletadas 4 subamostras de 0-20 cm por um trado mecânico. Todas as subamostras foram homogeneizadas num recipiente, compondo, assim, uma única amostra, que foi acondicionada num saco plástico previamente identificado e enviado para análise laboratorial.



Figura 18 Grade amostral de solo, com grid utilizado e centroides.

A coleta de resistência à penetração (RSP) foi executada por um penetrômetro de impacto, que consiste numa haste metálica com o cone em sua extremidade inferior e um corpo metálico de peso conhecido (4 kg) na porção central. Seu funcionamento se dá pelo deslocamento do corpo metálico até certa altura conhecida. Durante o impacto, a energia potencial do corpo metálico armazenada pela elevação é usada para inserir a haste do cone no solo. A profundidade de penetração é obtida pela aplicação de uma quantidade de energia constante que é usada para mensurar a penetração do solo (VAZ et al., 2002). A metodologia de aquisição dos dados e cálculo da RSP seguiu os pressupostos de (STOLF et al., 2014; VAZ et al., 2002).

A resistência à penetração foi mensurada nos 63 pontos amostrais (Figura 18), com três repetições por ponto na profundidade de 0-20 cm. Em cada ponto foi retirada a cobertura superficial do solo (palhada) e efetuada a medição. Para o cálculo da RSP foi considerada a média das três repetições. Coletaram-se também amostras de umidade do solo para posterior correção da RSP.

4.2.4 Dados de produtividade das culturas

Para a determinação da produtividade da soja, efetuou-se uma coleta manual de 5 m lineares com três repetições (três linhas seguidas) nos 12 pontos monitorados (Figura 19A), quando a cultura atingiu o estádio R8, seguindo metodologia semelhante a Mendes et al. (2003). As plantas foram acomodadas em sacos de ráfia para serem trilhadas e limpas de forma mecânica. Os grãos foram pesados e corrigidos a 13% de umidade. A coleta de produtividade do trigo também foi realizada manualmente em 32 pontos (Figura 19B), distantes linearmente em 180 m, com três repetições por ponto. Foi coletado 1 m² de plantas de trigo por ponto (GUO et al., 2018), um dia antes da colheita mecanizada da área. As plantas foram acomodadas em sacos de ráfia para serem trilhadas e limpas de forma mecânica, sendo os grãos pesados e corrigidos a 13% de umidade.



Figura 19 Pontos amostrais de produtividade: A) soja; B) trigo.

4.2.5 Aquisição de imagens Sentinel-2

As imagens orbitais utilizadas no estudo são provenientes do sensor Sentinel-2, disponibilizadas pela Agência espacial Europeia (ESA) de forma gratuita. A base de dados foi construída para as duas culturas sob estudo, contemplando o período de 01/12/2018 a 30/03/2019 (para a soja) e 01/05/2019 a 15/08/2019 (para o trigo). Desse período, foram filtradas apenas as cenas com porcentagem de nuvens inferior a 20% para os *tiles* 22JBT e 21JZN. Posteriormente, as imagens foram recortadas para a área de interesse e foi aplicada a correção atmosférica convertendo as imagens de topo de atmosfera (*Top-Of-Atmosphere* - TOA) para base de atmosfera (*Bottom-Of-Atmosphere* - BOA), pelo método ATCOR3 (MULLER-WILM, 2018). Esse procedimento foi necessário para remover a influência da atmosfera nas imagens, a qual comumente altera a reflectância dos alvos (RANI; MANDLA; SINGH, 2017). Todos os procedimentos citados foram realizados por *scripts* em Python pelas bibliotecas *Sen2Cor, Rasterio* e *Numpy*.

Para avaliar a correlação das imagens de VANT com as do sensor orbital, selecionaram-se cinco imagens ao longo do ciclo da soja (12/12/18, 17/12/18, 26/01/19, 31/01/19 e 02/03/19) e seis para o trigo (11/06/19, 30/06/19, 18/07/19, 01/08/19 e 22/08/19). O critério de seleção de imagens se deu pela proximidade da cena com o voo realizado.

4.3 Processamento de dados

4.3.1 Geração de ortomosaicos

O processamento dos voos foi efetuado no *software* Agisoft Photoscan, licença gratuita, seguindo as etapas de: (1) importação das imagens e PCs; (2) avaliação da qualidade das imagens; (3) alinhamento das imagens (processo de *tie points*); (4) demarcação dos PCs nas fotos alinhadas; (5) realinhamento das imagens; (6) criação e classificação da nuvem densa de pontos; (7) Geração do Modelo Digital de Superfície (MDS); (8) ortomosaico das imagens. Todos os procedimentos adotados seguiram a metodologia presente no manual do *software* Agisoft Photoscan (AGISOFT, 2016).

A etapa (1) consistiu na importação das imagens e dos PCs corrigidos pelo sistema PPP do IBGE, necessário para efetuar a demarcação dos PCs nas imagens na etapa (4). Em (1) definiu-se também o sistema de coordenadas *datum* SIRGAS 2000. A avaliação da qualidade das imagens (2) consistiu no processo de calibração da câmera, necessário para efetuar o alinhamento inicial das imagens (3). O procedimento (4) consiste na locação de cada PC identificado nas imagens listadas pelo *software*. Após isso, foi realizado um novo alinhamento das imagens, conforme os PCs informados (5), com o intuito de aumentar a acurácia da ortofoto que foi gerada.

De modo simplificado, a nuvem de pontos (6) é o processo de utilização das informações de localização de cada imagem na construção de uma nuvem densa de pontos. A construção da nuvem de pontos (6) é reflexo do procedimento de alinhamento das imagens (3 e 5). O alinhamento consistiu na identificação de pontos homólogos (feições semelhantes) entre várias imagens para a criação de um novo no espaço 3D, esse processo é denominado de aerotriangulação. Como consequência, o *software* criou uma nuvem de pontos esparsa (*tie points*). Entretanto, para melhorar a representação da superfície 3D, *softwares* especializados na reconstrução de objetos e cenas (PhotoScan, Pix4Dmapper) utilizam dois métodos combinados de computação visual: *structer from motion* (SFM) e *multi-view stereo* (MVS) (SOUZA et al., 2017). A compreensão destas etapas é de alta complexidade, haja vista que a maioria dos *softwares* não expõem análises detalhadas do processo para sua avaliação (JAMES et al., 2017), demandando simulações e comparações empíricas dos resultados.

Nesse sentido, os *softwares* constroem a nuvem densa de pontos (6) para aumentar a quantidade de pontos obtidos das imagens que serão utilizados como base para a criação do MDT ou MDS (7) (GEIPEL et al., 2018). Vale ressaltar que, juntamente ao processo de criação da nuvem de pontos, foi necessário avaliar os pontos, pois o processo pode gerar pontos com erros de projeção, baixa precisão e qualidade geométrica (AGISOFT, 2016). Sendo assim, os pontos com elevações além ou abaixo da média dos demais foram removidos. A partir da nuvem de pontos foi possível executar o processo de triangulação dos pontos para a construção do terreno ou da superfície, gerando o MDT ou o MDS (ZIETARA, 2017). Por fim, a partir do MDS criou-se o ortomosaico (8). Os subprodutos das etapas (4), (6), (7) e (8) podem ser observados conforme Figura 20.



Figura 20 Etapas de processamento no *software* Photoscan para o voo 18/07/19 (trigo): A) *Tie points*; B) Nuvem densa de pontos; C) Modelo digital de elevação; D) Ortomosaico.

Os procedimentos citados foram executados no computador AMD FX-8150 *Bulldozer*, com 8 núcleos e 8 *threads*, *clock* base de operação de 3,6 GHz e máximo de 4,2 GHz e uma placa gráfica *Bluecase* 750Ti de 2 GB de memória, que trabalha numa frequência de 1020 MHz. O computador utilizado possui 8 GB (2 x 4) de memória RAM, modelo *Corsair Vengeance* operando a 1600 MHz. Nessa máquina, o processamento de cada voo levou em média 3 dias.

A elevação da área sob estudo foi extraída do modelo digital do terreno do voo 22/11/2018. A escolha desse voo se deu por que a área havia sido recém-semeada e,

portanto, estava com baixa cobertura superficial. A resolução espacial deste MDT foi de 14,2 cm, posteriormente foi modificada para uma resolução de 5 m. Esse procedimento está detalhado na secção 4.3.4.

4.3.2 Normalização das imagens

A partir dos ortomosaicos executou-se o recorte da área para a remoção de árvores, locais com sombreamento (pela presença de árvores ao redor da lavoura - Figura 20) e demais alvos de não interesse. Tal procedimento foi efetuado a partir de um *buffer* interno de 10 m. Para a construção de demais subprodutos, os ortomosaicos foram decompostos nos três canais de cor RGB. Para cada banda executou-se o processo de normalização, que consistem na razão entre uma banda e a soma das três Equações (17) dos Números Digitais (DN) das imagens, ou seja, sua escala de cinza.

$$R_{norm} = \frac{R}{R+G+B}; \quad G_{norm} = \frac{G}{R+G+B}; \quad B_{norm} = \frac{B}{R+G+B}$$
(17)

em que: R: valor do Número Digital (DN) da banda do vermelho; B: valor de DN da banda do azul; G: valor de DN da banda do azul.

O processo de normalização visou reduzir as distorções causadas pelas luzes e sombras, recomendado por Cheng et al. (2001), Saberioon et al. (2014), Torres-Sánchez et al. (2014), Zhou et al. (2017) e Ballesteros et al. (2018). Esse procedimento também visou amenizar o impacto da não correção atmosférica das imagens. No presente estudo não se fez a correção atmosférica das imagens de VANT em função da altura utilizada para o levantamento aéreo ser baixa (90 e 100m), sendo a interferência da atmosfera considerada insignificante. Não foi executada a correção radiométrica das imagens pela utilização de sensores que registram dados apenas na faixa do visível e por não haver nenhum equipamento disponível para esse procedimento.

Os procedimentos de normalização também foram executados para as imagens do sensor Sentinel-2, embora esse produto possua correção atmosférica e radiométrica. Todos os procedimentos citados foram realizados em *Python*, utilizando a biblioteca *Rasterio* (1.1.0).

Esse os demais procedimentos em diante foram executados no computador com as seguintes configurações: processador Intel i5 8ª geração, com 4 núcleos e 8 *threads*, *clock* base de operação de 1,8 GHz e máximo de 3,9 GHz, com 24 GB de memória RAM. Esse computador possui uma placa gráfica NVDIA GeForce MX130 de 2 GB de memória, que trabalha numa frequência de 1020 MHz.

4.3.3 Índices de vegetação

Com o objetivo de aumentar a capacidade de detecção de anomalias na área sob estudo, foram construídos índices de vegetação a partir das imagens normalizadas RGB. Os Os IVs avaliados foram: *Excess Green* (ExG), *Green Leaf Index* (GLI), *Green Red Vegetation Index* (GRVI), *Red Green Blue Vegetation Index* (RGBVI), *Visible Atmospherically Resistant Index* (VARI) e *Normalized Difference Vegetation Index* (NDVI), apresentados no item 3.1.2.1.

Os índices criados apenas na faixa do visível foram criados para as imagens adquiridas por VANTs e para o sensor Sentinel-2. Apenas para o Sentinel-2 foi construído o índice de vegetação NDVI. Todos os procedimentos citados foram realizados em *scripts* em *Python*, utilizando a biblioteca *Rasterio* (1.1.0).

4.3.4 Seleção do índice de vegetação

Originalmente, os ortomosaicos e seus produtos derivados possuíam resolução espacial de 3,4 cm, com tamanho entre 1,6 a 2,1 GB. Logo, para reduzir o tempo de processamento e o custo de armazenamento dos IVs para as tarefas subsequentes, aplicou-se a técnica de *resample* nas imagens. O *resample* consiste na modificação da resolução espacial, podendo ser executada tanto para o aumento quanto redução da resolução (*downsampling* e *upscaling*, respectivamente). No presente estudo, foi aplicado um filtro de média móvel para a redução (*upscaling*) de sua resolução espacial, criando imagens com resolução espacial de 5 m e 10m. Essa técnica também foi executada para o MDT da área sob estudo.

O *upscaling* dos IVs do VANT para a resolução espacial de 10 m, ocorreu a partir de uma grade previamente estabelecida (imagem do Sentinel-2), para se ter a equivalência entre as imagens (Figura 21). Para tanto, considerando uma grade de *pixels* de G(i,j) do sensor Sentinel-2, a partir da localização do seu centroide (latitude e longitude $\alpha_s(i,j)$, $\beta_s(i,j)$, respectivamente) aplicou-se um filtro de média móvel em todos os *pixels* de VANT s(i,j) inseridos dentro das extremidades do *pixel*. Isso possibilitou a comparação entre os IVs construídos pelas imagens dos VANTs com os do Sentinel-2.



Figura 21 Esquema do grid de *pixels* de imagens de satélite s(i,j) e G(i,j) numa dada latitude $\alpha_s(i,j)$ e longitude $\beta_s(i,j)$, sendo o grid G(i,j) do sensor Sentinel-2 (B) utilizado para construção do *upscaling* da imagem de VANT (A).

A partir do *resample* calculou-se a correlação de Spearman entre os IVs do VANT (agora com 10 m de resolução) e Sentinel-2. Esse procedimento foi executado para todas as cenas mais próximas da data de sobrevoo com o VANT. Também foi calculada a correlação entre os IVs do VANT com a interpolação dos dados de produtividade. A seleção dos melhores índices de vegetação se baseou naqueles que apresentaram maior correlação com o sensor orbital Sentinel-2 e maior correlação com a produtividade.

Todos os procedimentos citados foram realizados em *scripts* em *Python*, utilizando aa bibliotecas *Rasterio* (1.1.0), *Pandas* (0.25) e *Scipy* (1.3.2).

4.4 Análise estatística dos dados

Esta etapa compreendeu as tarefas de: remoção de *outliers* (A); construção de histogramas das cenas de ambos os sensores (VANT e Sentinel-2) (B); análise exploratória dos dados (C); avaliação da distribuição normal dos dados pelos testes Shapiro-Wilk, Anderson-Darling e Kolmogorov-Smirnov a 5% de significância (D); e interpolação dos dados (E). As variáveis consideradas com distribuição normal de probabilidade foram as que passaram em pelo menos dois dos testes utilizados. Para os dados pontuais (variáveis químicas e físicas do solo, e produtividade) executaram-se as tarefas A, C, D e E. Para o conjunto de dados dos sensores orbitais e suborbitais executaram-se as tarefas de A, B, C e D.

Para os dados pontuais, as etapas B, C e D foram executadas em R, utilizando os pacotes geoR, *raster, sp, stats, ggplot2 e maptools*. Já para os dados em *raster,* as etapas A, B e C foram realizadas em Python pelos pacotes *Rasterio, Sklearn* e *Numpy*.

Após avaliar a normalidade dos dados das variáveis químicas e físicas do solo, os dados foram transformados pela técnica Yeo-Johnson (YEO; JOHNSON, 2000), Equação (18). Uma das vantagens desta transformação é sua robustez a números negativos e a 0, além de possibilitar a construção de sua inversa.

$$\psi(\lambda, y) = \begin{cases} ((y+1)^{\lambda} - 1)/\lambda & \text{if } \lambda \neq 0, y \ge 0\\ \log(y+1) & \text{if } \lambda = 0, y \ge 0\\ -[(-y+1)^{2-\lambda} - 1)]/(2-\lambda) & \text{if } \lambda \neq 2, y < 0\\ -\log(-y+1) & \text{if } \lambda = 2, y < 0 \end{cases}$$
(18)

em que: y é uma lista de *n* número positivos ou negativos e λ é o expoente a ser elevado.

Em seguida, foi executada a análise geoestatística, que contemplou a avaliação da existência de tendência direcional, anisotropia e krigagem. Quando existente a tendência direcional e anisotropia nos dados, os modelos foram ajustados. Os modelos teóricos avaliados foram o exponencial e família Matérn, com k variando de 1, 1,5 e 2. A qualidade do ajuste do modelo e seus parâmetros foi avaliada pelas métricas Erro Médio (EM), Erro Médio Reduzido (EMR), Desvio Padrão dos Erros Reduzidos (DPER), Erro Absoluto (EA) e pelo critério de Akaike. O grau de dependência espacial (EPR) das variáveis foi avaliado pelo índice proposto por Cambardella et al. (1994), em que EPR menor que 0,25 é considerado como dependência espacial forte, EPR entre 0,25 e 0,75 como dependência espacial média e acima de 0,75 como fraca dependência espacial. Em seguida, avaliaram-se a presença e a influência de *outliers* na krigagem ordinária. Esse procedimento foi executado conforme a metodologia proposta por Dalposso et al. (2012).

Para os dados de produtividade, usou-se o interpolador Inverso da Distância Elevado a uma Potência (IDP), com potência elevada a quarta para a soja e ao quadrado para o trigo. O critério de seleção da melhor potência para a técnica IDP se baseou na interpolação que apresentou o menor *Root Mean Square Error* (RMSE) e *Mean Square Error* (MSE). Isso foi possível pela validação cruzada no processo de interpolação, testando possíveis potências dentro de um intervalo de 1 a 4, variando em 0,05.

Para dados provenientes de sensores orbitais e suborbitais (VANT e Sentinel-2) a detecção e remoção dos *outliers* foram realizadas pelo desvio padrão dos dados, removendo os valores maiores ou menores que três vezes o desvio padrão. Os *pixels* considerados como *outliers* foram removidos e substituídos pela média dos 9 *pixels* mais próximos. Além disso, avaliou-se também a distribuição normal dos dados e transformações pelas funções logarítmica (x + 1), exponencial, raiz cúbica e Yeo-Johnson.

4.5 Delineamento de zonas de manejo

Antes de fazer o processo de delineamento das ZMs e a correlação, todas as variáveis estudadas (dados de solo, produtividades e índices de vegetação do VANT e Sentinel-2), foram padronizadas pelo método Z-score (Equação (19). O intuito foi reduzir a sensibilidade dos algoritmos de agrupamento pelas diferentes escalas dos dados (SCHENATTO et al., 2017).

$$Z = \frac{x - \mu}{\sigma} \tag{19}$$

em que: Z: variável normalizada; x: valor da variável de interesse; μ : média da variável; σ : desvio padrão da variável.

Para a construção das ZMs utilizou-se a técnica de agrupamento hierárquico aglomerativo pelo método *Ward* com restrição espacial dos grupos pelas matrizes de contiguidade (Rainha, Torre e *KNN*, com k = 15). As ZMs foram confeccionadas de três formas distintas: para cada cultura (soja e trigo) e para os dados provenientes do solo, sempre utilizando todas as variáveis disponíveis. Testaram-se também ZMs com 2, 3, 4 e 5 grupos, confeccionadas por três métodos de contiguidade: Rainha, Torre e KNN, todos utilizando a medida de dissimilaridade Ward's.

As ZMs da soja e trigo foram executadas a partir dos índices de vegetação com maior correlação ao sensor orbital Sentinel-2, utilizando todas as datas de sobrevoo disponíveis. As ZMs pelo conjunto de variáveis químicas e físicas utilizaram todos os dados disponíveis. Esses procedimentos foram realizados em *Python* utilizando as bibliotecas *libpysal* e *esda.*

4.5.1 Análise das zonas de manejo

A validação das zonas de manejo geradas se dividiu em duas etapas. A primeira foi a verificação se havia ou não diferença estatística significativa entre as subáreas geradas para cada Zona de Manejo. A segunda etapa foi a comparação entre as ZMs geradas com a variável alvo: produtividade.

Assim, na primeira etapa, a escolha da quantidade de Zonas de Manejo a serem utilizadas para cada conjunto de dados deu-se pelos índices Calinski-Harabasz (CH, Equação (14), Davies Bouldin (DB, Equação (15), o índice Coeficiente de Silhueta Médio (CSM, Equação (16) e o *Mean Path Silhouette* (MPS), que corresponde à média geral da métrica *Path Silhouette* (WOLF; KNAAP; REY, 2019). Outro critério utilizado para verificar se

os grupos eram distintos entre si foi a análise de variância não-paramétrica por Kruskal-Wallis (KW).

Esses procedimentos foram realizados em Python, utilizando as bibliotecas *libpysal,* esda, scipy e sklearn.

5 RESULTADOS E DISCUSSÕES

Esta seção está organizada em 3 etapas: a primeira etapa se refere à análise exploratória dos dados coletados no monitoramento das culturas (fenologia e produtividade) e variáveis do solo; a segunda etapa contempla a análise dos sensores orbitais (Senrtinel-2) e suborbitais (VANT); a terceira compreende o estudo das Zonas de Manejo construídas com os dados de solo, IVs para a soja e para o trigo.

5.1 Análise exploratória espacial e temporal das culturas e do solo

5.1.1 Monitoramento fenológico da soja

O monitoramento fenológico da soja (22/11/2018 a 08/02/2019) permitiu avaliar o crescimento dos cultivares nos 12 pontos distribuídos na área (Figura 10). Para isso, foi computada a média das três repetições para cada ponto. O porte de ambos os cultivares é semelhante, embora a partir de 11/01/2018 o cultivar NA5909RG passou a ter um porte ligeiramente inferior o BRS1003IPRO (Figura 22). Isso ocorreu pelo ataque de lagartas na área cultivada com NA5909RG, o que reduziu sua área foliar e penalizou seu desenvolvimento (Figura 23). Os pontos de monitoramento apresentam variabilidade dos estádios fenológicos, assim como a altura das plantas. No geral, para o estádio reprodutivo o cultivar BRS1003IPRO se desenvolveu mais rapidamente do que a NA5909RG.



Figura 22 Altura da soja ao longo do período monitorado (06/12/18 a 09/02/19) para os cultivares BRS1003IPRO e NA5909RG.



Figura 23 Evolução do desenvolvimento da soja ao longo do monitoramento para os cultivares BRS1003IPRO e NA5909RG.

5.1.2 Interpolação dos dados de produtividade

A análise exploratória dos dados de produtividade (soja e trigo) indicou que eles não apresentaram distribuição normal de probabilidade, sendo transformados por Yeo-Johnson. A análise de *outliers* indicou a presença de um ponto discrepante nos dados de trigo, com produtividade equivalente a 5.218 kg.ha⁻¹, valor superior à média da área. Entretanto, após a verificação *posteriori* dos dados de produtividade do trigo, constatou-se que esse valor não foi um erro e optou-se por mantê-lo. Já para a produtividade da soja, não foi constatado nenhum *outlier*.

Quanto ao processo de interpolação, a escolha da técnica de IDP em vez da krigagem ocorreu pela quantidade insuficiente de pontos de produtividade de soja e trigo, em que o semivariograma não se estabilizou com o acréscimo da distância. No IDP, adotou-se a potência a quarta para soja, pois atingiu menores valores de RMSE (292 kg.ha⁻¹) e MSE (236 kg.ha⁻¹), e uma potência ao quadrado para o trigo, com RMSE (925 kg.ha⁻¹) e MSE (1148 kg.ha⁻¹).

No mapa de produtividade verifica-se que houve tendências espaciais diferentes para as duas culturas analisadas (Figura 24). Na safra 2018/2019 de soja, a região norte da área teve produtividade 36% superior (4.436 kg.ha⁻¹) às demais, reduzindo no sentido Norte/Sul, com valores abaixo de 2.843 kg.ha⁻¹ (Figura 24). Possivelmente, essa diferença se deu em função dos dois cultivares semeados na área, ficando evidente o desempenho superior do cultivar NA5909RG em comparação com o BRS1003IPRO, mesmo sob penalização de ataque de pragas.

A produtividade do trigo na safra 2019 variou entre 2.915 e 3.646 kg.ha⁻¹, em que a região ao sul da área registrou maiores produtividades em comparação às outras. Destaca-se que uma única região teve produtividade superior a 5.218 kg.ha⁻¹ (Figura 24).



Figura 24 Mapa de produtividade da soja, trigo e média das produtividades.

5.1.3 Interpolação das variáveis do solo

Ao avaliar a distribuição das variáveis químicas e físicas do solo, apenas as variáveis MO, pH e CTC apresentaram distribuição normal de probabilidade e, por isso, não foram transformadas, enquanto as demais (Al³⁺, Ca²⁺, CTC, Cu, Fe, H+Al₃, K, Mg²⁺, Mn, MO, P, pH, Zn, V% e RSP) foram. Após a transformação por Yeo-Johnson, essas variáveis passaram em pelo menos dois dos três testes de normalidade empregados (Shapiro-Wilk, Anderson-Darling e Kolmogorov–Smirnov).

Pela análise geoestatística, as variáveis CTC, MO, zinco e resistência à penetração apresentaram média dependência espacial, enquanto as demais (Al³⁺, Ca²⁺, Cu, Fe, H+ Al₃, K, Mg²⁺, Mn, P, pH, SB e V%) apresentaram forte dependência espacial. Os modelos com melhor ajuste foram o Exponencial para as variáveis Fe, H+ Al₃, K, Mn, P, SB; Família Márten com k igual a 1 para o Cu e CTC, k igual 1,5 para o Ca²⁺ e k igual a 2 para o Mg²⁺, pH, MO, Zn, V% e RSP. O critério de seleção de ajuste dos modelos foi selecionar os que apresentassem os menores valores de EM, EMR, DPER, DPEM, EA, critérios AIC e BIC.

Dentre as variáveis analisadas, apenas Al³⁺, K, Fe e V% possuíam *outliers*. Para essas variáveis, avaliou-se a influência dos *outliers* na krigagem ordinária conforme metodologia de Dalposso et al. (2012). A krigagem ordinária demonstrou-se robusta a *outliers*, pois na comparação dos mapas krigados (com e sem *outliers*), as medidas de acurácia Exatidão Global (EG) e índice Kappa foram superiores a 90% e 0,85, respectivamente, construindo mapas semelhantes. A krigagem da variável Al³⁺ sem *outliers* exibiu ilhas com maior concentração (1,41 a 2,04 cmol_c.dm⁻³) de alumínio ao norte da área, o que não ocorreu no mapa com *outliers* (Figura 25). A presença dessas ilhas foi comum em

todas as variáveis analisadas (Figura 25). Logo, optou-se pela manutenção desses valores na base de dados, haja vista que o interpolador krigagem é robusto à presença de *outliers* (DALPOSSO et al., 2012; BODAGHABADI, 2018).



Figura 25 Mapas das variáveis alumínio, ferro, potássio e V%, com a presença e ausência de *outliers*.

A análise das concentrações das variáveis químicas seguiu a interpretação de SBCS/NEPAR (2015) para os mapas da Figura 26. O alumínio (Al³⁺) registrou concentrações muito baixas (<0,3 cmol_c.dm⁻³) e baixas (0,3 a 0,9 cmol_c.dm⁻³), ao sudoeste da área, e concentrações média a alta (0,9 a 2,5 cmol_c.dm⁻³) deslocando-se do sul para a região norte (Figura 26). O cálcio (Ca²⁺) possui concentrações de média a muito alta, variando de 1,85 a 6,98 cmol_c.dm⁻³, em que a concentraçõe aumenta do norte (valores médios) ao sul (valores muito altos). A CTC possui concentração média (11,68 a 12,97 cmol_c.dm⁻³) ao norte da área e concentração alta (15,54 a 18,11 cmol_c.dm⁻³) e isolada na porção centro-sul área. O cobre (Cu) possui concentração muito alta (4,98 a 19,13 mg.dm⁻³) em toda a área de estudo, embora isso se intensifique na região sul. As concentrações de ferro (Fe) variam entre médias (20 a 45 mg.dm⁻³), na região sul da área, a altas (> 45 mg.dm⁻³). As concentrações da acidez potencial (H+ Al₃) foram classificadas como muito altas ao longo de toda a área, em que uma porção na região da área centro-sul apresentou valores de 12,23 a 14,74 cmol_c.dm⁻³. Prezotti e Guarçoni (2013) comentam que valores elevados de (H+ Al₃) são um indicativo de solos com teores elevados de MO.

Já o potássio (K) apresentou concentrações elevadas (0,33 a 0,43 cmol_c.dm⁻³) a muito elevadas (0,43 a 1,15 cmol_c.dm⁻³), crescendo no sentido norte-sul. O magnésio (Mg²⁺) apresentou concentrações média (0,77 a 0,9 cmol_c.dm⁻³) e alta (0,9 a 1,85 cmol_c.dm⁻³), distribuídas ao longo da área e muito alta (>1,82 cmol_c.dm⁻³), localizada na porção centro-oeste. O manganês (Mn) tem alta (54 a 100 mg.dm⁻³) e elevada (100 a 267 mg.dm⁻³) concentração, crescendo no sentido leste-oeste. A matéria orgânica (MO) possui boa concentração, variando de alta (2,7% a 3,3%), distribuída por toda a área, a muito alta (>3,3%) no centro da área. O pH exibiu uma mancha com concentração baixa e média

(4 até 4,4 e 4,4 a 4,9, respectivamente) que se estende na porção superior até a parte inferior da área.

O fósforo (P) apresentou baixa concentração em toda a área (<4 mg.dm⁻³). A saturação de bases (V%) com concentrações variando de baixa < 23,61%, média (23,61 a 37,52%) a alta (37,52 a 58,18%). A soma de bases (SB) possui concentrações muito baixa (< 3,69 cmol_c.dm⁻³), baixa (3,69 a 4,55 cmol_c.dm⁻³) e média (acima de 4,55 cmol_c.dm⁻³), com a porção norte e leste com valores mais baixos e sudoeste com valores médios. Utilizando a saturação por bases como um indicativo de fertilidade, tem-se que 12,3% podem ser considerados como baixa a média fertilidade, indicando que os cátions Ca⁺, Mg⁺ e K⁺ estão sendo neutralizados pelo H⁺ ou Al³⁺ (SBCS/NEPAR, 2015). O zinco tem concentrações variando de baixa à média (0,4 a 0,8 e 0,8 a 1,2 mg.dm⁻³) ao longo da área.

A resistência à penetração (RSP) na camada de 0 a 20 cm foi superior a 3 MPa, considerados acima do nível crítico para o desenvolvimento radicular (TORMENA; SILVA; LIBARDI, 1998). Segundo Debiasi et al. (2010), esse comportamento é comum em cerca de 45% das lavouras paranaenses, as quais apresentaram um grau de compactação considerável na camada entre 10 e 20 cm do solo. Todavia, outra possibilidade para os valores elevados da RSP está no equipamento adotado, ou seja, no penetrômetro de impacto. Além disso, a umidade do solo, em média estava em 19%.



Figura 26 Mapas das variáveis químicas e físicas do solo.

5.2 Análise de dados derivados de sensores orbitais e suborbitais

O monitoramento das safras resultou em 12 voos, sendo seis por cultura (Figura 27). Vale ressaltar que nem todos os voos realizados foram processados em função de problemas técnicos (imagens com baixa acurácia geométrica que impossibilitaram o alinhamento do voo), conforme ocorrido no voo em 11/01/2019. Para a soja, outro evento relevante foi a redução da área foliar do cultivar NA5909RG (porção superior da área) em decorrência de um ataque de pragas (Figura 23), entre o intervalo de 20/12/18 a 11/01/2019. Ao longo do monitoramento do trigo, não foi registrado nenhum evento adverso (ataque de pragas).

A análise dos histogramas dos índices de vegetação (ExG, GLI, GRVI, RGBVI, VARI), para ambas as culturas (soja e trigo), possibilitou caracterizar uma alta variabilidade dos dados antes e após as etapas de remoção de *outliers* e *resample* dos ortomosaicos (0,034 m para 5 m). A etapa de remoção de *outliers* foi fundamentada na remoção dos

53

pixels com valores maiores ou menores que três vezes o desvio padrão, em que a quantidade de pontos variou conforme o voo e análise pelo boxplot para cada IV e voo (Apêndices F e G).

A investigação da normalidade dos conjuntos de dados de VANTs (soja e trigo) pelos testes Shapiro-Wilk, Anderson-Darling e Kolmogorov–Smirnov demonstrou que em nenhuma das cenas foi obtida uma distribuição normal de probabilidade a 5% de significância, antes ou após a remoção dos *outliers* e a aplicação das transformações logarítmica (x + 1), exponencial, raiz cúbica e Yeo-Johnson. O mesmo ocorreu para os dados derivados do Sentinel-2 (Apêndices G e H). Os mapas de cada índice de vegetação para os sensores constam nos apêndices B até E.



Figura 27 Ortomosaicos para a soja e trigo.

Tal condição é comum para dados oriundos de sensoriamento remoto, seja para sensores orbitais (BARETH et al., 2015; DAMIAN et al., 2020) ou suborbitais, como os de VANTs (CAMBRAIA FILHO, 2019; MARINO; ALVINO, 2018). Uma das razões da não normalidade dos dados é a elevada densidade de informações, o que acarreta uma maior variabilidade dos dados, implicando a assimetria e curtose do conjunto de dados. Além disso, o monitoramento da soja e do trigo ao longo do seu ciclo permitiu a extração de comportamentos relacionados às dinâmicas temporais de ambas as culturas.

Os histogramas da soja (Figura 28), para todos os IVs, concentraram valores entre 0 e 0,25, independente da cena analisada, com valores baixos do alvo quando analisado apenas na faixa do visível, em função da elevada absorção da clorofila nessa região do espectro (FORMAGGIO; SANCHES, 2017). Barbosa et al. (2019) relatam comportamentos semelhantes ao analisarem os índices *Modified Green Red Vegetation Index* (MGRVI), GLI, *Modified Photochemical Reflectance* (MPRI), RGBVI, ExG e VEG (*Vegetativen*) no monitoramento da pastagem numa propriedade do estado de Minas Gerais, Brasil. Xu et al. (2019), ao monitorarem arbustos de pequeno porte (*Haloxylon ammodendron*) na província de Xinjiang, China, utilizando um VANT e IVs derivados do visível, também obtiveram valores negativos ou próximos a zero para as porções de vegetação detectada, visto que o alvo possuía baixa cobertura foliar. Cambraia Filho (2019) no monitoramento de diferentes alvos de vegetação (agricultura, floresta plantada, campo, pastagem) no bioma cerrado por um VANT também relatou valores baixos para os índices construídos a partir da faixa do visível, em que os IVs GLI, NGRDI e VARI, variam de -0,167 a 0,069 para o milho. Vale ressaltar que os padrões encontrados variam conforme as condições de aquisição das imagens, o período observado (uma série temporal de 1 ano, de fevereiro de 2018 a janeiro de 2019) e as condições da lavoura monitorada (vigor vegetativo, distribuição de chuvas etc.).

Outro padrão se destaca a partir da cena 21/01/19, que é a divisão do histograma em duas partes distintas, uma com valores negativos e outra com valores positivos, o que aconteceu em função do comportamento espectral distinto dos dois cultivares na área e pelo impacto do ataque de pragas sofrido.



Figura 28 Histograma dos índices de vegetação ExG, GLI, GRVI, RGBVI e VARI para a soja pelo VANT.

Nos histogramas de todos os IVs para o trigo (Figura 29), detecta-se a variabilidade ao longo das cenas, além dos diferentes comportamentos captados por cada IV. Dentre todos, o VARI reuniu os maiores valores, concentrados de 0 a 0,2 até a cena 22/08/2019 e depois entre -0,2 e 0. Todavia, essa mudança na amplitude dos valores para o trigo se modificou a partir da cena 22/08/2019, ocorrendo em todos os IVs analisados.



Figura 29 Histograma dos índices de vegetação ExG, GLI, GRVI, RGBVI e VARI para o trigo pelo VANT.

A fim de comparar os resultados obtidos pelo VANT, executou-se o mesmo procedimento para as imagens do sensor Sentinel-2/BOA. As cenas utilizadas para avaliar o padrão da soja foram: 12/12/2018, 17/12/2018, 26/01/2019, 31/01/2019 e 02/03/2019, sendo o maior intervalo entre as cenas dos sensores de sete dias (Figura 30). Todos os índices derivados da faixa do visível apresentam valores baixos, variando no máximo até 0,3, independente da cena analisada, com exceção do VARI que apresentou valores superiores. Em todos os índices também é possível destacar a divisão do histograma em dois segmentos a partir da cena 31/01/2019.

Ao comparar os IVs do visível com o NDVI, os valores alteram-se em função da menor absorção da REM pela planta na faixa do infravermelho médio. Outro fato

interessante é que embora o sensor Sentinel-2 apresente correção atmosférica, os padrões encontrados são semelhantes aos do VANT, embora estes dados possuam menor densidade granulométrica (10 m).



Figura 30 Histograma dos índices de vegetação ExG, GLI, GRVI, NDVI, RGBVI e VARI para a soja pelo sensor Sentinel-2.

O mesmo procedimento foi executado para o trigo, utilizando cenas do sensor Sentinel-2/BOA mais próximas dos voos com VANT. As cenas utilizadas foram: 10/06/2019, 30/06/2019, 10/07/2019, 30/07/2019 e 24/08/2019, sendo o maior intervalo entre as imagens de ambos os sensores em até 7 dias (Figura 31). Assim como na soja, os índices derivados da faixa do visível apresentam valores baixos, variando no máximo até 0,3 independente da imagem analisada, com exceção do VARI. Esse IV registrou valores superiores na imagem 30/07/2019, quando o trigo estava no estádio fenológico de alongamento do trigo. Além disso, em comparação com os demais, o VARI apresentou maior variabilidade dos dados, caracterizado por um histograma mais alongado. Novamente, o NDVI apresentou valores superiores, embora siga a mesma tendência que os demais índices analisados.



Figura 31 Histograma dos índices de vegetação ExG, GLI, GRVI, NDVI, RGBVI e VARI para o trigo pelo sensor Sentinel-2.

Outro procedimento adotado para avaliar o grau de similaridade entre os sensores (VANT e Sentinel-2/BOA) foi a correlação de Spearman. A escolha desse teste ocorreu por todos os IVs em ambas as culturas não seguirem distribuição normal de probabilidade. A correlação foi avaliada de três formas distintas: entre os IVs do visível dos sensores Sentinel-2 e VANT, entre IVs do visível do VANT com o NDVI do Sentinel-2/BOA, entre os IVs do VANT com a produtividade. Para tanto, as imagens do VANT foram escalonadas (*resample*) para 10 m de resolução espacial.

A correlação entre os IVs do VANT e Sentinel-2 tanto para a soja (Figura 32, A1) quanto para o trigo (Figura 32, B1) foram consideradas moderadas a forte (CALLEGARI-JACQUES, 2003). Para soja, as correlações variavam de 0,41 a 0,92 e, no geral, os índices GRVI e VARI demonstram comportamento ligeiramente superior aos demais. Já para o trigo, as correlações variaram de 0,40 a 0,87, com os índices GRVI e VARI apresentando a mesma tendência.

Ao analisar a correlação entre IVs do visível (VANT) com o NDVI do Sentinel-2/BOA, em ambas as culturas (Figura 32, B1 e B2), tem-se que as correlações variaram de
moderadas a forte, sendo 0,40 a 0,93 para a soja e de 0,67 a 0,71 para o trigo. Embora o desempenho de todos os IVs seja próximo, os índices GRVI e VARI se destacaram.



Figura 32 Correlação de Spearman entre os IVs extraídos do VANT e Sentinel-2 para soja e trigo; sendo A1 a correlação entre IVs (VANT e Sentinel-2) para soja; A2 a correlação entre IVs (VANT e Sentinel-2) para trigo; B1 a correlação entre IVs VANT com NDVI do Sentinel-2 para soja; B2 a correlação entre IVs VANT com NDVI do Sentinel-2 para trigo.

Analisando a correlação entre os IVs do VANT com a produtividade, as culturas apresentaram comportamentos distintos (Figura 33). Na soja, até a cena 20/12/2018, as correlações foram baixas e positivas (variando de 0,05 a 0,5), mas a partir da cena 21/01/19 as correlações foram altas e negativas (-0,04 a -0,87). Uma possível explicação deste comportamento inverso se dá pelo ataque de pragas ocorrido no período (20/12/18 a 21/01/19).

Ao analisar a produtividade da área e os IVs, tem-se que a região mais produtiva registrou as menores magnitudes dos IVs (Figura 34). Ou seja, a correlação negativa entre essas variáveis (IVs e produtividade) configura esse resultado.

No trigo, as correlações entre IVs e produtividade foram positivas (variando entre 0,24 a 0,49), com correlações ligeiramente superiores para os índices GLI e RGBVI, mas com valores muito próximos entre si (Figura 33).



Figura 33 Correlação de Spearman entre os IVs calculados pelo VANT e produtividade da soja e trigo.



Figura 34 Comparação entre o índice de vegetação VARI ao longo do período monitorado para a soja com a produtividade.

Para verificar o comportamento da soja para cada cultivar, analisou-se a correlação para cada cultivar de soja com a produtividade (Figura 35). O cultivar NA5909RG (Figura 35) apresentou correlações inferiores às do cultivar BRS1003IPRO (Figura 35), pelo comportamento inverso e descrito anteriormente. Em função das variedades apresentarem características distintas de reflectância e manejo, optou-se na sequência por construir as Zonas de Manejo para cada cultura e por cultivar utilizada. Além disso, utilizando como critério a maior correlação entre os IVs do VANT com o Sentinel-2/BOA optou-se por construir as Zonas de Manejo apenas para os IVs GRVI e VARI por estes apresentarem os maiores valores de correlação.



Figura 35 Correlação de Spearman entre os IVs VANT e produtividade da soja para os cultivares NA5909RG (esquerda) e BRS1003IPRO (direita).

As correlações entre IVs do Sentinel-2 e produtividade da soja (Figura 36) foram moderadas e positivas (0,23 a 0,75) até 17/12/18, após essa data houve declínio da correlação em 26/01/19, com correlações fortes negativas. Já para o trigo, as correlações foram moderadas e positivas (variando entre 0,24 a 0,41), com correlações ligeiramente superiores nos índices GLI e RGBVI, embora próximos entre si (Figura 39). Ambas as culturas apresentaram comportamento semelhante aos IVs do VANT com as produtividades (Figura 33).



Figura 36 Correlação de Spearman entre os IVs calculados pelo Sentinel-2 para soja (esquerda) e trigo (direita) com produtividade.

5.3 Análise das zonas de manejo

A construção das zonas de manejo avaliou três tipos de matriz de contiguidade (*Rainha, Torre* e KNN) para quatro subgrupos (2 a 5 classes), todos pela medida de dissimilaridade *Ward's*. Todas as variáveis foram padronizadas pela fórmula *Z-score* (Equação (19), sendo as imagens utilizadas com resolução espacial de 5 m (VANT) e 10 m

(Sentinel-2). As ZMs foram delineadas para cinco subconjuntos de dados: variáveis químicas e físicas do solo, índices de vegetação GRVI e VARI para a soja e o trigo, para imagens de VANT e do Sentinel-2. Em virtude da presença de dois cultivares com manejos distintos na safra 2018/2019 de soja, optou-se por construir uma ZM para cada cultivar e fazer sua análise de forma independente. Optou-se também por não construir ZMs utilizando ambas as culturas, em função da divisão de as ZMs ocorrerem exatamente entre os cultivares da soja.

A determinação da melhor quantidade de grupos foi pelos índices estatísticos de ajuste de agrupamento: Coeficiente de Silhueta Médio (CSM), Calinski-Harabasz (CH), Davies Bouldin (DB), Mean Path Silhouette (MPS). Além disso, para verificar se as ZMs construídas eram significativamente diferentes entre si, utilizou-se a análise de variância não-paramétrica Kruskal-Wallis (KW), conforme elaborado por Marino e Alvino (2018). Os procedimentos citados foram repetidos para todos os subconjuntos de dados.

5.3.1 Zonas de manejo para o solo

A construção das ZMs para o subconjunto das variáveis químicas e físicas do solo envolveu 16 variáveis: alumínio (Al³⁺), cálcio (Ca²⁺), CTC, cobre (Cu), ferro (Fe), acidez potencial (H+Al₃) potássio (K), magnésio (Mg²⁺), manganês (Mn), matéria orgânica (MO), fósforo (P), pH, zinco (Zn), soma de bases (SB), saturação de bases (V%), resistência à penetração de 0-20 cm (RSP) e elevação. Não foram atribuídos pesos diferentes às variáveis.

Ao comparar as ZMs pelas diferentes técnicas utilizadas (Figura 37), tem-se um comportamento semelhante entre os métodos *Rainha* e *Torre* para ZMs com dois e três grupos. As ZMs pelo método KNN se diferenciaram das demais técnicas, sendo que a ZM com dois grupos abrangeu uma área maior que a dos demais métodos. No método KNN apenas o grupo 1 se subdividiu conforme o acréscimo de ZMs.





Nota: Os retângulos denotam as ZMs com melhor desempenho.

Avaliando a qualidade do ajuste das ZMs, os índices CSM e CH apresentam piores resultados conforme o aumento das ZMs em todos os métodos de contiguidade (Tabela 3). Essas métricas sugeriram que ZMs com menor quantidade de grupos foram mais homogêneas e distintas entre si. Já para o índice DB, para os métodos Rainha e Torre, as ZMs com dois grupos também obtiveram valores menores, indicando assim melhor formação de grupo.

Todavia, os métodos citados anteriormente são criticados por não aferirem a coerência espacial e a coerência dos atributos (WOLF; KNAAP; REY, 2019). Para contornar esse problema, adotou-se o índice Path Silhouette (WOLF; KNAAP; REY, 2019), a partir do qual foi calculada a sua média para cada classe (MPS – *Mean Path Silhouette*). De forma semelhante ao índice CSM, quanto maior for o valor do índice, melhor será a coesão entre os valores das variáveis e sua localização. Como resultado, as ZMs com dois grupos também apresentaram os melhores resultados para o índice MPS (Tabela 3).

Além disso, para avaliar se os grupos de cada ZM foram significativamente diferentes entre si, calculou-se a ANOVA não-paramétrica Kruskal-Wallis. Esse teste considerou como significativas as ZMs com quatro e cinco grupos para o método Rainha, a ZM com cinco grupos para o método Torre, e a ZM com dois grupos para o KNN. Logo, considerando-se as restrições impostas pelo KW e as métricas citadas anteriormente, o método de contiguidade Rainha com quatro grupos apresentou os melhores resultados.

Método	Grupo	CSM	СН	DB	MPS	KW
	2	0,34	10.982	1,18	0,38	ns
	3	0,26	7.809	1,17	0,26	ns
Rainha	4	0,25	6.808	1,34	0,28	*
	5	0,24	6.327	1,58	0,33	*
	2	0,32	9.693	1,27	0,38	ns
T	3	0,24	6.886	1,23	0,26	ns
Torre	4	0,24	6.342	1,49	0,30	ns
	5	0,22	5.812	1,63	0,32	*
	2	0,38	12.345	1,03	0,31	*
	3	0,25	8.355	1,30	0,22	ns
KNN	4	0,23	6.820	1,70	0,29	ns
	5	0,23	5.990	1,57	0,26	ns

 Tabela 3
 Índices de ajuste das ZMs para o subconjunto variáveis do solo

Notas: CSM: Coeficiente de Silhueta Médio; CH: Calinski-Harabasz; DB: Davies Bouldin; MPS: *Mean Path Silhouette*; KW: Kruskal-Wallis; *: p-valor < 0,05; ^{ns}: p-valor > 0,05.

Métodos, grupos e valores em negrito apresentaram melhor desempenho.

5.3.2 Zonas de manejo por imagens de VANT para a soja

Em virtude dos diferentes manejos e cultivares utilizadas na safra da soja optou-se pela análise independente de cada região (A para o cultivar NA5909RG e B para o BRS1003IPRO). Para ambos os cultivares, a construção das ZMs do subconjunto dos IVs GRVI e VARI do VANT foram utilizadas 6 imagens durante todo o ciclo vegetativo da cultura (06/12/2018, 12/12/2018, 20/12/2018, 21/01/2019, 06/02/2019 e 23/02/2019).

Ao analisar as ZMs por cultivar e por diferentes métodos, notam-se padrões distintos na sua formação (Figura 38). Um fator comum a todas foi a fragmentação espacial das ZMs pelo método KNN, principalmente pelo cultivar NA5909RG (Figura 38A), o que elucida a variabilidade nas regiões. Entretanto, tal comportamento pode ocorrer pelo KNN considerar como vizinhos os 15 pontos mais próximos, forçando assim a formação de classes com características semelhantes, mas que respeitem essa restrição espacial. Logo, a utilização desse método de contiguidade exige maior quantidade de testes para averiguar formação de ZMs espacialmente homogêneas.



Figura 38 Mapas de 2 a 5 zonas de manejo pelos índices GRVI e VARI do VANT pelos métodos Rainha, Torre e KNN para os cultivares de soja NA5909RG (A) e BRS1003IPRO (B).

Nos métodos Rainha e Torre, para ambos os IVs, existiu uma predominância de um grupo em todas as ZMs para os cultivares NA5909RG (Figura 38A) e BRS1003IPRO (Figura 38B), compondo os grupos 1 e 3, respectivamente. Outra peculiaridade foi que, em todas as ZMs, uma porção na borda oeste da área se manteve constante independente do acréscimo de grupos.

Analisando o cultivar NA5909RG/GRVI pelo método Rainha, somente as ZMs com dois grupos apresentaram divisões semelhantes, pois o acréscimo de grupos implicou a fragmentação espacial dos grupos na área para a ZM com duas zonas (Figura 38A). Em contrapartida, as ZMs do método Torre foram mais homogêneas e se subdividiram apenas numa faixa à esquerda da área. Uma das razões foi a presença de anomalias dos ortomosaicos (por exemplo, modificação das condições climáticas ao longo do voo). Essa mesma faixa também ocorreu para as ZMs construídas pelo índice VARI, ficando mais evidente no método Torre (Figura 38A). Logo, as ZMs pelo VARI foram visualmente homogêneas e com grupos espacialmente bem definidos.

65

Nota: Os retângulos denotam as ZMs com melhor desempenho.

Já para o cultivar BRS1003IPRO (Figura 38B), os métodos de contiguidade Rainha e Torre se assemelharam apenas nas ZMs com dois grupos em ambos IVs. Outra característica compartilhada foi que o aumento de ZMs não causou fragmentação do grupo 2 (borda ao leste da área). As ZMs do cultivar BRS1003IPRO, pelo método Rainha, formaram grupos espacialmente mais definidos e homogêneos.

O teste KW indicou que todas as ZMs foram significativas a 95% de probabilidade (Tabela 4). Entretanto, as ZMs pelo KNN foram descartadas por sua inconsistência espacial. As demais métricas indicaram que as ZMs com dois grupos obtiveram desempenho superior em pelo menos três das quatro métricas (CSM, CH, DB e MPS) para todos os métodos de contiguidade e IVs. Entretanto, os métodos *Rainha* e *Torre* tiveram as ZMs com os melhores resultados com dois grupos para o GRVI e VARI, respectivamente, em ambos os cultivares.

			NA5909RG						BRS1	003IPF	२०	
IV	Método	Grupo	CSM	СН	DB	MPS	KW	CSM	СН	DB	MPS	KW
		2	0,33	1.523	1,39	0,35	*	0,28	4.088	1,37	0,33	*
	Dainha	3	0,10	1.283	1,91	0,15	*	0,19	2.988	1,55	0,18	*
	Rainna	4	0,05	1.070	1,97	0,04	*	0,12	2.221	2,17	0,11	*
		5	0,04	932	2,38	-0,02	*	0,05	1.834	2,13	0,05	*
		2	0,31	1.415	1,48	0,35	*	0,28	4.043	1,38	0,32	*
	Τ	3	0,19	950	2,21	0,20	*	0,17	2.722	1,86	0,21	*
GRVI	Torre	4	0,14	782	1,75	0,09	*	0,14	2.136	1,98	0,13	*
		5	0,10	700	2,01	0,00	*	0,13	1.805	2,42	0,12	*
		2	0,18	2.031	1,78	0,15	*	0,29	4.084	1,38	0,32	*
		3	0,16	1.710	1,62	0,09	*	0,20	3.417	1,54	0,15	*
	KININ	4	0,11	1.469	1,72	0,03	*	0,15	2.612	1,76	0,12	*
		5	0,11	1.324	1,66	-0,05	*	0,09	2.110	2,19	0,12	*
		2	0,32	1.532	1,42	0,36	*	0,28	4.035	1,38	0,32	*
	Dainha	3	0,18	1.305	1,89	0,22	*	0,20	2.832	1,41	0,16	*
	Rainna	4	0,14	1.047	1,89	0,14	*	0,12	2.202	1,78	0,05	*
		5	0,10	907	1,93	0,05	*	0,12	1.836	2,35	0,05	*
		2	0,33	1.549	1,39	0,36	*	0,28	4.064	1,38	0,32	*
	Torro	3	0,11	1.044	1,81	0,11	*	0,19	3.036	1,53	0,17	*
VARI	Tone	4	0,11	928	2,32	0,02	*	0,12	2.249	1,89	0,04	*
		5	0,11	830	2,31	0,09	*	0,05	1.810	2,42	0,09	*
		2	0,32	1.532	1,42	0,36	*	0,29	4.064	1,36	0,31	ns
		3	0,17	1.791	1,55	0,09	*	0,19	2.920	1,55	0,18	*
	NININ	4	0,10	1.537	1,69	0,03	*	0,13	2.329	1,82	0,11	*
		5	0,11	1.358	1,65	0,04	*	0,10	2.077	1,97	0,07	*

Tabela 4 Índices de ajuste das ZMs para o subconjunto índices GRVI e VARI do VANT pelos métodos Rainha, Torre e KNN para os cultivares NA5909RG e BRS1003IPRO da soja

Notas: CSM: Coeficiente de Silhueta Médio; CH: Calinski-Harabasz; DB: Davies Bouldin; MPS: *Mean Path Silhouette*; KW: Kruskal-Wallis; *: p-valor < 0,05; ^{ns}: p-valor > 0,05.

Métodos, grupo e valores em negrito apresentaram melhor desempenho.

Ao analisar as áreas de cada ZM observaram-se pequenas diferenças. Para as ZMs com dois grupos no GRVI/NA5909RG, o grupo 1 teve 17,09 ha (88,3%) e o grupo 2 teve

2,25 ha (11,6%). Para o VARI/NA5909RG os grupos tiveram 17,02 (88%) ha e 2,32 ha (12%), respectivamente. Logo, o método utilizado para construção de ZMs com duas classes para a soja torna-se indiferente. O mesmo ocorreu para o cultivar BRS1003IPRO, em que a ZM do GRVI abrangeu 15,04 ha (62,7%) no grupo 1 e 8,96 ha (37,3%) no grupo 2, enquanto o VARI teve 14,65 (61%) e 9,36 ha (39%), respectivamente.

Analisando-se os valores dos índices das ZM por IV, denotam-se valores baixos dos índices ao longo das datas utilizadas. Os grupos 1 e 2 do GRVI/NA5909RG resultaram numa média de 0,01 e 0,02, enquanto para o VARI/NA5909RG foi de 0,02 e 0,04 (Tabela 5). Já para o GRVI/ BRS1003IPRO o valor médio dos índices foi de 0,03 e 0,04, para as classes 1 e 2 e 0,05 para o VARI/BRS1003IPRO (Tabela 5).

IV	- Grupo		11/06/19	30/06/19	18/07/19	01/08/19	22/08/19	04/09/19	Média
		Mín.	-0,06	-0,04	-0,03	0,05	-0,01	-0,12	-0,04
		Máx.	0,03	0,02	0,16	0,12	0,07	0,04	0,07
	GRVI-1	Média	-0,02	-0,01	0,07	0,08	0,03	-0,07	0,01
		Med.	-0,02	-0,01	0,07	0,08	0,03	-0,07	0,01
		Mín.	-0,08	-0,06	-0,04	0,06	0,02	-0,11	-0,04
		Máx.	0,02	0,00	0,15	0,15	0,12	0,05	0,08
ő	GRVI-2	Média	-0,02	-0,02	0,07	0,12	0,05	-0,06	0,02
1 60		Med.	-0,02	-0,02	0,07	0,12	0,05	-0,06	0,02
59		Mín.	-0,10	-0,08	-0,06	0,08	-0,01	-0,18	-0,06
ΔA		Máx.	0,05	0,04	0,22	0,20	0,11	0,06	0,11
	VARI - 1	Média	-0,03	-0,03	0,10	0,14	0,04	-0,10	0,02
		Med.	-0,03	-0,03	0,11	0,14	0,04	-0,11	0,02
		Mín.	-0,12	-0,11	-0,06	0,09	0,02	-0,16	-0,06
		Máx.	0,04	-0,02	0,23	0,25	0,17	0,06	0,12
	VARI - Z	Média	-0,04	-0,04	0,10	0,20	0,08	-0,09	0,04
		Med.	-0,04	-0,04	0,10	0,20	0,05 $-0,01$ $-0,12$ -0.01 $0,12$ $0,07$ $0,04$ 0.012 $0,08$ $0,03$ $-0,07$ 0.012 $0,06$ $0,02$ $-0,11$ -0.012 $0,15$ $0,12$ $0,05$ 0.012 $0,15$ $0,12$ $0,05$ $-0,06$ $0,12$ $0,05$ $-0,06$ 0.012 $0,08$ $-0,01$ $-0,18$ -0.012 $0,08$ $-0,011$ $-0,18$ -0.012 $0,020$ $0,111$ $0,06$ 0.014 $0,044$ $-0,110$ 0.0144 $0,09$ $0,022$ $-0,164$ $0,200$ $0,088$ $-0,099$ $0,200$ $0,088$ $-0,099$ $0,200$ $0,088$ $-0,099$ $0,200$ $0,088$ $-0,099$ $0,111$ $-0,022$ $-0,033$ $0,111$ $-0,022$ $-0,033$ $0,077$ $0,055$ $-0,075$ $0,177$ $0,144$ $0,100$ $0,114$ $0,085$ $0,022$ $0,115$ $0,099$ 0.015 $0,114$ $0,055$ $-0,077$ $0,244$ $0,155$ $0,099$ $0,188$ $0,111$ $0,000$ $0,188$ $0,111$ $0,000$ $0,188$ $0,111$ $0,000$ $0,188$ $0,111$ $0,000$ $0,188$ $0,111$ $0,000$ $0,188$ $0,111$ $0,000$	0,04	
		Mín.	-0,14	-0,09	-0,04	-0,02	-0,09	-0,09	-0,08
		Máx.	0,09	0,13	0,17	0,19	0,03	0,03	0,11
	GRVI-I	Média	-0,01	0,04	0,08	0,11	-0,02	-0,03	0,03
		Med.	-0,01	0,04	0,09	0,11	-0,02	-0,03	0,03
		Mín.	-0,06	-0,04	-0,06	0,07	0,05	-0,05	-0,01
0		Máx.	0,03	0,00	0,12	0,17	0,14	0,10	0,09
Ř	GRVI-2	Média	-0,02	-0,02	0,03	0,14	0,08	0,02	0,04
3311		Med.	-0,02	-0,02	0,03	0,15	0,08	0,02	0,04
100		Mín.	-0,09	-0,06	-0,03	0,11	0,05	-0,07	-0,02
RS		Máx.	0,04	0,02	0,21	0,24	0,15	0,09	0,12
В	VARI - I	Média	-0,03	-0,02	0,07	0,18	0,11	0,00	0,05
		Med.	-0,03	-0,02	0,07	0,18	0,11	0,00	0,05
		Mín.	-0,09	-0,06	-0,03	0,11	0,05	-0,07	-0,02
		Máx.	0,04	0,02	0,21	0,24	0,15	0,09	0,12
	VARI-Z	Média	-0,03	-0,02	0,07	0,18	0,11	0,00	0,05
		Med.	-0,03	-0,02	0,07	0,18	0,11	0,00	0,05

 Tabela 5
 índices de vegetação GRVI e VARI do VANT para os cultivares NA5909RG e BRS1003IPRO da soja

Nota: Mín.: Mínimo; Máx.: Máximo; Med.: Mediana.

5.3.3 Zonas de manejo por imagens de VANT para o trigo

A construção das ZMs do subconjunto de dados índices GRVI e VARI para o trigo (safra 2019) utilizou 6 cenas que abrangeram todo o ciclo vegetativo da cultura (11/06/2019, 30/06/2019, 18/07/2020, 01/08/2020, 22/08/2020 e 04/09/2019). O comportamento das ZMs ilustra padrões distintos de formação pelos IVs e métodos de contiguidade (Figura 39). A formação das ZMs pelo KNN diferiu dos demais métodos por apresentar ZMs espacialmente fragmentadas, comportamento semelhante ao descrito paras as ZMs da soja. Tal condição fica evidente na ZMs com cinco grupos do VARI.



Figura 39 Mapas de 2 a 5 zonas de manejo pelos índices GRVI (A) e VARI (B) do VANT para o trigo pelos métodos Rainha, Torre e KNN.

Nota: os retângulos denotam as ZMs com melhor desempenho.

Ambos IVs realçaram as curvas de nível da área pelas ZMs criadas pelos métodos Rainha e KNN. Esse comportamento é um indicativo da diferença do vigor da vegetação, o que ocasionou a confusão com o solo. Outro fator agravante foi a não correção radiométrica das imagens utilizadas, embora a correlação dos dados de VANT com o sensor Sentinel-2/BOA tenha apresentado resultados elevados. Bendig et al. (2015) comentam que a qualidade dos resultados obtidos com VANTs está sujeita às variações da atmosfera ao longo do voo, ou seja, variações da incidência da radiação como também a exposição da imagem afeta os subprodutos gerados. Os autores defendem que, mesmo com resultados VANTs às inferiores. os são vantajosos quando comparados coletas com espectroradiômetros de campo, que são caros e consumem muito tempo. Outra desvantagem é pelas aquisições pontuais e não contínuas, como as de VANTs.

Apenas para a ZMs com dois grupos, o GRVI apresentou divisões semelhantes pelos métodos Rainha e Torre. Nas demais ZMs, apenas o grupo 3 se manteve constante (concentrado na porção leste da área), mas com diferente abrangência de área. O método Rainha do GRVI demonstrou maior susceptibilidade as curvas de nível. Já para o VARI, os métodos de contiguidade resultaram em ZMs completamente distintos. Nos métodos Rainha e Torre, a porção sul da área (grupos 2 e 3, respectivamente) manteve-se indissolúvel conforme o acréscimo de grupos.

A análise de variância por Kruskal-Wallis indicou que todas as classes são significativas as 95% de probabilidade (Tabela 6). Logo, levando em conta as restrições impostas pelo KW e as métricas já citadas, para ambos os IVs as ZMs com duas classes obtiveram os melhores resultados, ambas pelo método de contiguidade Rainha.

IV	Método	Grupo	CSM	СН	DB	MPS	KW
		2	0,25	7.122	1,32	0,33	*
	Delate a	3	0,13	5.870	1,72	0,19	*
	Rainna	4	0,10	4.299	1,91	0,13	*
		5	0,08	3.557	1,89	0,09	*
		2	0,22	6.685	1,43	0,35	*
	T	3	0,08	4.422	2,08	0,26	ns
GRVI	Iorre	4	0,05	3.497	2,06	0,21	*
		5	0,04	2.829	2,30	0,17	*
		2	0,31	7.664	1,15	0,24	*
		3	0,18	7.426	1,38	0,09	*
	KNN	4	0,11	5.848	2,01	0,04	*
		5	0,08	4.982	2,22	0,06	*
		2	0,26	7.498	1,28	0,31	*
	Delate a	3	0,10	5.469	1,67	0,13	*
	Rainna	4	0,06	4.299	1,63	0,02	*
		5	-0,01	3.721	1,93	0	*
		2	0,23	5.224	1,32	0,34	*
	-	3	0,01	3.554	1,53	0,03	*
VARI	Iorre	4	-0,02	2.925	2,31	0,02	*
		5	-0,01	2.599	2,84	0,05	*
		2	0,30	10.839	1,16	0,18	ns
		3	0,20	7.368	1,44	0,08	*
	KNN	4	0,08	5.938	1,53	-0,03	*
		5	0,07	5.048	1,73	-0,05	*

 Tabela 6
 Índices de ajuste das ZMs para o subconjunto índices de vegetação GRVI e

 VARI do VANT para o trigo

Notas: CSM: Coeficiente de Silhueta Médio; CH: Calinski-Harabasz; DB: Davies Bouldin; MPS: *Mean Path Silhouette*; KW: Kruskal-Wallis; *: p-valor < 0,05; ^{ns}: p-valor > 0,05.

Métodos, grupo e valores em negrito apresentaram melhor desempenho.

De forma semelhante à soja, as diferenças de abrangência das áreas para cada ZM foram pequenas, em que 30,85 ha (70,8%) pertencem ao grupo 1 e 12,72 ha (29,19%) ao grupo 2 para o GRVI, enquanto para o VARI 31,02 ha (71,2%) pertence ao grupo 1 e 12,55

ha (28,8%) ao grupo 2. Ou seja, o método e o índice adotados foram indiferentes para ZMs com dois grupos.

A análise dos valores dos índices das ZMs por IV denotou valores baixos ao longo das datas utilizadas, com 0,03 e -0,01 para o GRVI nos grupos 1 e 2; 0,04 e -0,02 para o VARI nos grupos 1 e 2 (Tabela 7).

IV - Classe		11/06/19	30/06/19	18/07/19	01/08/19	22/08/19	04/09/19	Média
	Mín.	-0,14	-0,09	-0,04	-0,02	-0,09	-0,09	-0,08
	Máx.	0,09	0,13	0,17	0,19	0,03	0,03	0,11
GRVI-1	Média	-0,01	0,04	0,08	0,11	-0,02	-0,03	0,03
	Med.	-0,01	0,04	0,09	0,11	-0,02	-0,03	0,03
	Mín.	-0,14	-0,09	-0,07	-0,04	-0,09	-0,10	-0,09
	Máx.	0,05	0,10	0,12	0,14	0,01	0,01	0,07
GRVI-2	Média	-0,05	-0,01	0,03	0,06	-0,04	-0,04	-0,01
	Med.	-0,03	-0,01	0,03	0,06	-0,04	-0,04	0,00
	Mín.	-0,21	-0,13	-0,07	-0,03	-0,13	-0,14	-0,12
	Máx.	0,13	0,20	0,22	0,26	0,04	0,05	0,15
VARI - 1	Média	-0,02	0,06	0,12	0,16	-0,04	-0,05	0,04
	Med.	-0,02	0,06	0,13	0,16	-0,04	-0,05	0,04
	Mín.	-0,21	-0,14	-0,12	-0,06	-0,14	-0,15	-0,13
	Máx.	0,07	0,15	0,18	0,23	0,01	0,02	0,11
VARI - 2	Média	-0,07	-0,01	0,05	0,09	-0,07	-0,07	-0,02
	Med.	-0,05	-0,01	0,05	0,09	-0,07	-0,07	-0,01

 Tabela 7
 índices de vegetação GRVI e VARI do VANT paro o trigo

Nota: Mín.: Mínimo; Máx.: Máximo; Med.: Mediana.

5.3.4 Zonas de manejo pelo Sentinel-2 para a soja

A construção das ZMs para o subconjunto dos IVs GRVI e VARI do Sentinel-2 envolveu 5 imagens durante todo o ciclo vegetativo da soja (12/12/2018, 17/12/2018, 26/01/2019, 31/01/2019 e 03/02/2019). Um fator comum em todas as ZMs foi a fragmentação espacial das classes causada pelo KNN, mais evidente no índice VARI em ambos os cultivares (Figura 40A e B).

Analisando o cultivar NA5909RG/GRVI, os métodos de contiguidade apenas geraram resultados semelhantes com ZMs de dois e três grupos, distinguindo-se na divisão da área, conforme o acréscimo de grupos (Figura 40A). A partir disso, ZMs da NA5909RG/GRVI com mais grupos formaram um grupo pequeno e localizado nas extremidades (grupo três para o Rainha e cinco para o Torre). Esse comportamento sugere que o acréscimo de ZMs não agregou informações. Já para a NA5909RG/VARI, cada método de contiguidade formou uma ZM distinta (Figura 40A). Entretanto, da mesma forma que no GRVI, as ZMs com cinco

grupos resultaram na definição de um grupo de área pequena (grupo três para o Rainha e grupo cinco para o Torre e KNN).

As ZMs do cultivar BRS1003IPRO/GRVI, os métodos Rainha e Torre geraram resultados semelhantes até quatro grupos, em que apenas na ZM com cinco grupos o arranjo espacial do grupo 5 se diferenciou (Figura 40B). Repetindo os comportamentos observados anteriormente, as ZMs construídas pelo BRS1003IPRO/GRVI também se diferenciaram conforme o método de contiguidade adotado (Figura 40B). As semelhanças compartilhadas entre as ZMs foram a definição de um grupo na borda ao leste da área (grupo três em todos os métodos) e a formação de um grupo pequeno na borda oeste da área (grupo cinco para o Rainha e quatro para o KNN).



a soja pelos métodos Rainha, Torre e KNN, cultivares NA5909RG (A) e BRS1003IPRO (B).

Nota: Os retângulos denotam as ZMs com melhor desempenho.

Considerando as limitações impostas pelo teste KW (Tabela 8) a seleção das ZMs ocorreu pelo desempenho superior em pelo menos três dos quatro índices de ajuste utilizados. Para o cultivar NA5909RG, as ZMs com dois grupos apresentaram resultados superiores pelos métodos Torre (GRVI) e *Rainha* (VARI). Já para o BRS1003IPRO, a ZM

com três grupos apresentou melhor desempenho pelo Torre (GRVI), enquanto para o VARI foi pela ZM com dois grupos pelo método Rainha, conforme retângulos nas Figura 40A e B.

Sendo assim, pela semelhança entre as ZMs para o cultivar NA5909RG torna-se indiferente o método de contiguidade utilizado, pois os grupos 1 e 2 obtiveram área de 12,3 ha e 7 ha para o GRVI e 13,2 ha e 6 ha para o VARI. Ou seja, uma diferença de área de 8,2% e 12,3% por grupo. Já para o cultivar BRS1003IPRO, o GRVI totalizou uma área de 11 ha, 10,6 ha e 2,3 ha para os grupos 1, 2 e 3. Para o VARI, foi uma área de 13,2 ha e 10,7 ha, para os grupos 1 e 2. Entretanto, ao comparar os índices de ajustes das ZMs para o BRS1003IPRO pelo VARI reuniu melhores valores, sendo escolhida por essa razão.

Além das características citadas, as ZMs delineadas pelo Sentinel-2 e VANT para a soja não se assemelham, sugerindo que os sensores evidenciam padrões distintos.

				NA	5909R	G			BRS	1003IP	RO	
IV	Método	Grupo	CSM	СН	DB	MPS	KW	CSM	СН	DB	MPS	KW
		2	0,25	766	1,29	0,25	ns	0,28	1.266	1,28	0,20	ns
	Deinhe	<u>3</u>	0,17	718	1,49	0,12	ns	0,26	1.024	1,16	0,10	*
	Rainna	4	0,09	564	2,02	0,11	*	0,22	886	1,34	0,09	*
		5	0,10	465	1,79	0,04	*	0,19	809	1,59	0,14	*
		2	0,26	925	1,29	0,23	*	0,29	1.301	1,25	0,20	ns
	Torro	<u>3</u>	0,14	646	1,82	0,19	*	<u>0,26</u>	<u>1.136</u>	<u>1,22</u>	0,13	*
GRVI	Torre	4	0,12	491	1,73	0,11	ns	0,25	931	1,27	0,10	*
		5	0,06	404	2,13	0,12	ns	0,18	805	1,68	0,15	*
		2	0,25	798	1,28	0,24	*	0,29	1.207	1,30	0,37	*
		3	0,15	668	1,68	0,16	*	0,22	894	1,33	0,24	*
	KININ	4	0,13	524	1,67	0,11	*	0,19	840	1,95	0,17	*
		5	0,10	453	1,87	0,10	*	0,19	743	1,78	0,14	*
		<u>2</u>	0,24	736	1,40	0,25	*	<u>0,27</u>	<u>1.091</u>	<u>1,35</u>	0,24	*
	Deinke	3	0,14	624	1,76	0,17	*	0,24	941	1,34	0,15	*
	Rainna	4	0,11	466	2,05	0,16	*	0,23	732	1,26	0,08	*
		5	0,10	401	1,73	0,11	*	0,23	636	1,24	0,01	*
		2	0,24	743	1,39	0,29	ns	0,26	953	1,45	0,40	*
	Танка	3	0,13	581	1,85	0,17	*	0,21	715	1,43	0,26	*
VARI	Torre	4	0,10	449	2,09	0,18	*	0,11	635	1,80	0,18	*
		5	0,10	368	1,93	0,14	*	0,13	587	1,59	0,15	*
		2	0,24	800	1,41	0,24	*	0,27	1.084	1,37	0,26	ns
		3	0,15	593	1,74	0,10	*	0,25	887	1,29	0,14	*
	KININ	4	0,10	477	1,83	0,03	*	0,24	709	1,23	0,02	*
		5	0,11	415	1,63	-0,03	*	0,21	627	1,53	0,04	*

Tabela 8Índices de ajuste das ZMs para o subconjunto índices GRVI e VARI do
Sentinel-2, pelos métodos Rainha, Torre e KNN para os cultivares NA5909RG e
BRS1003IPRO da soja

Notas: CSM: Coeficiente de Silhueta Médio; CH: Calinski-Harabasz; DB: Davies Bouldin; MPS: *Mean Path Silhouette*; KW: Kruskal-Wallis; *: p-valor < 0,05; ^{ns}: p-valor > 0,05. métodos, grupo e valores em negrito apresentaram melhor desempenho para o cultivar NA5909RG;

Métodos, grupo e valores sublinhados apresentaram melhor desempenho para o cultivar BRS1003IPRO.

Em média, os valores dos índices GRVI para cada ZM foram baixos, enquanto as do VARI foram superiores (Tabela 9). Para o GRVI, o cultivar NA5909RG obteve em média 0,15 e 0,14 dos índices para os grupos 1 e 2, enquanto para o BRS1003IPRO foi de 0,15 (grupos 1 e 2) e 0,18 (grupo 3). Enquanto para o VARI, a média foi de 0,41 e 0,39 para os grupos 1 e 2 do cultivar NA5909RG e 0,44 e 0,41 no cultivar BRS1003IPRO.

Mesmo com a variação dos valores dos índices entre os IVs no Sentinel-2, os valores registrados foram superiores aos das ZMs pelo VANT, principalmente para o VARI. Embora as resoluções espaciais dos sensores sejam diferentes (5 m para o VANT e 10m para o Sentinel-2), as diferenças entre elas foram elevadas, possivelmente justificadas pelas resoluções espaciais. Logo, é provável que a não correção radiométrica das imagens do VANT afetem negativamente o desempenho dos índices de vegetação.

IV	//Grupo		12/12/18	17/12/18	26/01/19	31/01/19	02/03/19	Média
		Mín	0.06	0.21	0.18	-0.11	0.12	0.09
		Máx.	0.15	0.26	0.25	0.02	0.40	0.22
	GRVI - 1	Média	0.10	0.24	0.22	-0.09	0.29	0.15
		Med.	0.09	0.24	0.22	-0.09	0.29	0.15
		Mín.	0.02	0.20	0.20	-0.11	0.01	0.07
		Máx.	0,10	0,27	0,25	0,06	0,32	0,20
С С	GRVI-2	Média	0,07	0,24	0,23	-0,08	0,22	0,14
19C		Med.	0,07	0,24	0,23	-0,08	0,22	0,13
29(Mín.	0,10	0,00	0,63	0,52	-0,23	0,20
Ϋ́		Máx.	0,37	0,90	0,87	0,83	0,04	0,60
2	VARI - I	Média	0,21	0,59	0,75	0,66	-0,17	0,41
		Med.	0,21	0,65	0,75	0,67	-0,18	0,42
		Mín.	0,05	0,01	0,61	0,58	-0,21	0,21
	\/A PL _ 2	Máx.	0,21	0,71	0,88	0,81	0,12	0,54
	VAIN - 2	Média	0,14	0,51	0,76	0,70	-0,15	0,39
		Med.	0,14	0,53	0,76	0,70	-0,16	0,39
		Mín.	0,01	0,24	0,21	0,04	-0,03	0,09
	GR\/L_1	Máx.	0,10	0,28	0,27	0,25	0,21	0,22
		Média	0,05	0,27	0,24	0,12	0,06	0,15
		Med.	0,05	0,27	0,24	0,11	0,06	0,14
		Mín.	0,04	0,23	0,21	-0,05	0,03	0,09
	GR\/I - 2	Máx.	0,11	0,29	0,27	0,14	0,30	0,22
_		Média	0,07	0,26	0,24	0,04	0,16	0,15
8		Med.	0,07	0,26	0,24	0,04	0,16	0,15
ЦЦ		Mín.	0,05	0,23	0,19	-0,01	0,13	0,12
03	GRVI - 3	Máx.	0,14	0,27	0,25	0,17	0,32	0,23
10	Cittin C	Média	0,10	0,25	0,22	0,09	0,22	0,18
RS		Med.	0,10	0,25	0,22	0,09	0,22	0,18
B		Mín.	0,07	0,13	0,69	0,57	-0,10	0,27
	VARI - 1	Máx.	0,32	0,69	0,93	0,85	0,35	0,63
		Media	0,16	0,38	0,81	0,73	0,11	0,44
		Med.	0,16	0,38	0,81	0,73	0,11	0,44
		Min.	0,01	-0,09	0,72	0,57	0,07	0,26
	VARI - 2	Max.	0,20	0,47	0,91	0,83	0,52	0,59
	_	Media	0,10	0,19	0,82	0,73	0,23	0,41
		Med.	0,10	0,18	0,82	0,73	0,21	0,41

Tabela 9Índices de vegetação GRVI e VARI do Sentinel-2 para os cultivares NA5909RG
e BRS1003IPRO da soja

Nota: Mín.: Mínimo; Máx.: Máximo; Med.: Mediana.

5.3.5 Zonas de manejo pelo Sentinel-2 para o trigo

As ZMs para o subconjunto dos índices GRVI e VARI do Sentinel-2 contemplaram 5 imagens em todo o ciclo do trigo (10/06/2019, 30/06/2019, 10/07/2019, 04/08/2019 e 24/08/2019). Nesse subconjunto de dados, as ZMs construídas pelo método KNN não resultaram em grupos espacialmente fragmentados como nos demais subconjunto de dados (Figura 41). Por esse motivo, elas foram consideradas na seleção da ZM pelos índices de ajuste. Além disso, em ambos os índices, as ZMs pelo KNN apresentaram divisão espacial de grupos semelhante (Figura 41A e B), embora o mesmo não tenha acontecido com os demais índices.

Em ambos os índices os métodos de contiguidade Rainha e Torre construíram ZMs com divisões espaciais distintas entre si (Figura 41A e B). Dentre os índices e métodos, o Torre para o GRVI apresentou consistência nos grupos conforme o acréscimo, ou seja, os grupos não se permutaram. Outro fator relevante foi que pelas imagens do Sentinel-2 as curvas de nível não se destacaram tanto nos agrupamentos, embora a contiguidade KNN apresentasse maior susceptibilidade. Isso sugere que o decréscimo da resolução espacial não afetou a construção da ZM.



Figura 41 Mapas de 2 a 5 zonas de manejo pelos índices GRVI (A) e VARI (B) do Sentinel-2 pelos métodos Rainha, Torre e KNN para o trigo.

Nota: Os retângulos denotam as ZMs com melhor desempenho.

O teste Kruskal-Wallis indicou que todas as classes são significativas a 95% de probabilidade (Tabela 10). Logo, para o GRVI a contiguidade Rainha obteve as melhores métricas para a ZM com dois grupos, enquanto para o VARI foi pelo método KNN, também

para dois grupos. Em virtude da abrangência dos grupos divergirem (36,8 e 6,7 ha para os grupos, 1 e 2 do GRVI; 23,7 e 19,8 ha do VARI, grupos 1 e 2), a seleção da melhor ZM se deu pela que obteve as melhores métricas. Sendo assim, a ZM pelo VARI foi a escolhida.

IV	Método	Grupo	CSM	СН	DB	MPS	KW
		2	0,40	2.672	0,87	0,28	*
	Dainha	3	0,21	2.418	0,90	0,04	*
	Rainna	4	0,14	1.957	1,55	0,11	*
		5	0,12	1.829	2,47	0,02	*
		2	0,26	2.109	1,13	0,30	*
	Torro	3	0,20	2.045	1,23	0,21	*
GRVI	Tone	4	0,06	1.759	3,42	0,08	*
		5	0,07	1.611	2,96	0,06	*
		2	0,36	3.532	0,95	0,22	*
		3	0,27	3.258	1,08	0,13	*
	NININ	4	0,19	2.798	1,29	0,05	*
		5	0,16	2.303	1,27	0,00	*
		2	0,33	2.775	0,94	0,23	*
	Dainha	3	0,27	2.675	1,01	0,14	*
	Rainna	4	0,26	2.099	1,52	0,08	*
		5	0,14	1.757	1,96	0,11	*
		2	0,30	2.929	1,00	0,15	*
	Torro	3	0,12	2.022	1,65	0,24	*
VARI	Tone	4	0,10	1.623	1,57	0,16	*
		5	0,10	1.424	2,66	0,09	*
		2	0,35	3.513	0,96	0,22	*
		3	0,26	3.240	1,10	0,11	*
	NININ	4	0,19	2.795	1,30	0,07	*
		5	0,07	5.048	1,73	-0,05	*

Tabela 10	Índices	de a	ajuste	dos	agrupamentos	para	o subconjur	nto índ	lices de	e veget	ação
	GRVI e	VAR	RÍ do S	Sentir	nel-2 para o trig	0				•	-

Notas: CSM: Coeficiente de Silhueta Médio; CH: Calinski-Harabasz; DB: Davies Bouldin; MPS: *Mean Path Silhouette*; KW: Kruskal-Wallis; *: p-valor < 0,05; ^{ns}: p-valor > 0,05.

Métodos, grupo e valores em negrito apresentaram melhor desempenho.

As ZMs delineadas pelo VANT e Sentinel-2 novamente se distinguiram na formação dos grupos, como também nos valores médios dos índices por grupo. Assim como na ZM delineada pelos dados do Sentinel-2 para a soja, em média, os valores dos índices para o trigo também foram superiores as ZMs construídas pelas imagens do VANT. O VARI resultou em índices com valores de 0,33 e 0,45 para os grupos 1 e 2 (Tabela 11).

Tabela 11	Indices de	vegetação	GRVI e	VARI do	Sentinel-2	paro o trigo

IV/Classe		10/06/19	30/06/19	10/07/19	04/08/19	24/08/19	Média
	Mín.	-0,19	0,06	0,00	0,18	0,17	0,04
	Máx.	0,05	0,44	0,30	0,27	0,53	0,32
GRVI-I	Média	-0,06	0,28	0,18	0,23	0,41	0,21
	Med.	-0,06	0,28	0,18	0,23	0,41	0,21
	Mín.	-0,24	-0,10	-0,15	0,11	-0,05	-0,09
	Máx.	-0,04	0,30	0,19	0,24	0,44	0,22
GRVI-2	Média	-0,12	0,13	0,08	0,20	0,29	0,12
	Med.	-0,12	0,14	0,08	0,21	0,31	0,12
	Mín.	-0,30	-0,12	-0,21	0,33	-0,07	-0,07
	Máx.	-0,01	0,50	0,37	0,70	0,81	0,47
VARI - I	Média	-0,12	0,27	0,19	0,77	0,53	0,33
	Med.	-0,11	0,28	0,20	0,60	0,55	0,31
	Mín.	-0,23	0,19	0,06	0,60	0,26	0,18
	Máx.	0,07	0,64	0,48	0,71	0,87	0,56
VAIN - 2	Média	-0,06	0,47	0,31	0,87	0,65	0,45
	Med.	-0,05	0,47	0,31	0,87	0,65	0,45

Nota: Mín.: Mínimo; Máx.: Máximo; Med.: Mediana.

5.3.6 Zonas de manejo e produtividade

As zonas de manejo delineadas pelas imagens de VANT e do Sentinel-2 não se assemelham em ambas as culturas (Figura 42), por possuírem grupos espacialmente diferentes. Outro fator é que em ambos os conjuntos de dados (VANT e Sentinel-2), os grupos também não se assemelham às produtividades. Desta forma, os índices de vegetação derivados da faixa do visível foram pouco promissores no delineamento de zonas de manejo para expectativa de produtividade num curto período.

As ZMs da soja criadas pelo VANT dividiram a área no sentido leste/oeste, enquanto a produtividade cresceu no sentido norte/sul. Já para o trigo, as ZMs pelo VANT apresentaram um comportamento ligeiramente semelhante à produtividade, embora não descrevam o mesmo comportamento. As ZMs do Sentinel-2 sugeriram uma divisão no sentido nordeste/sudoeste para o cultivar NA5909RG da soja, embora também não se aproximem da divisão pela produtividade. Para o trigo as ZMs se dividiram no sentido norte/sul, embora a classe 2 se assemelhe mais à divisão pela produtividade.

Logo, os resultados das ZMs das culturas analisadas indicaram que não houve um padrão universal de variação, além da não semelhança com a produtividade. Isso sugere que os índices de vegetação são altamente influenciados pelas condições edafoclimáticas (ROMAN et al., 2008) e, talvez, a quantidade de sobrevoos e a quantidade de safras analisadas tenham sido inferiores ao necessário para minimizar o impacto dos fatores externos. Damian et al. (2020), construíram ZMs pelo índice NDVI do sensor Landsat-8 para três áreas no Rio Grande Sul, utilizando dados de 2009 a 2015. Os autores descrevem

comportamento semelhante, ou seja, que o NDVI não seguiu as mesmas variações que os dados de produtividade para a soja e o trigo.



Figura 42 Zonas de manejo com melhor desempenho pelos índices de ajuste para o GRVI e VARI do VANT e Sentinel-2 com a produtividade.

Em relação à quantidade de ZMs, Lorbieski (2020) encontrou resultados semelhantes. Nesse trabalho, o autor analisou um conjunto de dados de quatro safras (2013/2014 a 2016/2017) pelos índices de vegetação NDVI, EVI, SAVI, OSAVI, WDVI, WDRVI pelo sensor Landsat-8 e variáveis químicas e físicas do solo. Utilizando diferentes combinações de IVs para os agrupamentos, o autor também obteve os melhores ajustes de agrupamentos para ZMs com duas classes.

A literatura comumente apresenta o delineamento de ZMs utilizando dados de vegetação derivados da região do infravermelho, empregando assim as bandas NIR e *RedEdge* na composição dos índices de vegetação, ocasionando resultados semelhantes entre as ZMs construídas com a produtividade e biomassa das culturas. Esses trabalhos, geralmente, empregam os índices NDVI, SAVI, EVI, NDWI etc. para dados espectrais de sensores orbitais (DAMIAN et al. 2020; LORBIESKI, 2020; GEORGI et al., 2018; CICORE et al., 2016) e NDVI e SAVI para dados de VANTs (MARINO; ALVINO, 2018; MOREIRA; SANTANA, 2018). Entretanto, dificilmente se avalia a eficiência no delineamento de ZMs por

dados espectrais da região do visível. Em decorrência dos resultados discutidos, conclui-se que IVs derivados do visível não apresentaram bons desempenhos. Logo, é provável que resultados superiores estejam condicionados ao emprego de índices derivados do infravermelho.

6 CONCLUSÕES

Veículos Aéreos Não-Tripulados são uma tecnologia extremamente promissora e barata, amplamente aplicados para detecção de falhas de plantio, construção de Modelos Digitais de Terreno, dentre outros produtos. Todavia, os índices de vegetação derivados da faixa do visível dos VANTs demonstraram-se pouco promissores no delineamento de zonas de manejo dinâmicas, ou seja, aquelas para cada cultivar.

Os índices avaliados obtiveram correlações fortes com as imagens do sensor Sentinel-2/BOA, fato que promove o questionamento sobre o quão útil é o ganho na periodicidade de imagens com VANTs, tendo-se em vista a complexibilidade e o elevado custo computacional para a construção dos ortomosaicos. De forma semelhante aos sensores orbitais, a aquisição de imagens com VANTs também está sujeita a condições atmosféricas ideais, incrementando, assim, a complexibilidade de obtenção de imagens. Nesse sentido, mesmo que VANTs demonstrem ser uma alternativa viável no sensoriamento remoto, os custos relacionados aos levantamentos de campo e processamento de imagens também possuem elevado impacto e devem ser mensurados.

Os índices de vegetação obtidos com VANT que apresentaram melhores correlações com o sensor Sentinel-2/BOA foram o GRVI e VARI. A avaliação das zonas de manejo indicou que os melhores índices de ajuste de agrupamento foram para dois grupos, independente da cultura avaliada. Já para o subconjunto do solo, a melhor zona de manejo foi para quatro grupos. Ressalta-se que para cada cultura foi obtido um resultado distinto, indicando que ao avaliar mais anos-safras tem-se a necessidade de atribuir pesos distintos para diferentes culturas agrícolas. A adoção da restrição de contiguidade na construção dos agrupamentos resultou em zonas de manejo mais homogêneas e concisas, sem a necessidade na aplicação de filtros para redução dos ruídos.

Os índices derivados do visível não apresentaram bons resultados para o delineamento das zonas de manejo, independente do sensor utilizado (VANT ou Sentinel-2). Em maioria, os métodos de contiguidade Rainha e Torre apresentaram bom desempenho no delineamento das ZMs, construindo grupos espacialmente homogêneos, com resultados semelhantes entre si. Dentre os três métodos avaliados, o KNN apresentou os piores resultados.

7 TRABALHOS FUTUROS

Para averiguar todo o potencial da metodologia proposta e os resultados apresentados é necessário o monitoramento de mais safras, assim como uma malha mais densa na coleta de dados de produtividade. Georgi et al. (2018) relatam que a quantidade de safras necessárias para delinear zonas de manejo de expectativa de produtividade está entre 3 e 6 safras. Os autores comentam que, em áreas agrícolas com alta dinamicidade e sem adoção de práticas de Agricultura de Precisão, é necessário um maior período de monitoramento. Tal medida visa compensar o impacto das diferentes repostas espectrais das culturas agrícolas como também as variações edafoclimáticas.

O presente trabalho propôs-se a delinear zonas de manejo apenas com imagens oriundas da região do visível. Todavia, são necessários estudos complementares para avaliar o potencial da metodologia com imagens adquiridas na região do infravermelho próximo. Outro critério a ser investigado é a quantidade de imagens necessárias para caracterizar uma safra, ou seja, se diferentes densidades de voos caracterizariam melhor a área.

Ao longo deste trabalho, detectou-se uma deficiência na literatura sobre critérios para seleção de índices de vegetação na faixa do visível, o que implica a necessidade de desenvolvimento de métodos para esse procedimento. Além disso, a redução do custo computacional do processamento de grandes *datasets* tornará possível a construção zonas de manejo por imagens de VANTs em menor escala (5 cm a 30 cm).

REFERÊNCIAS

AGISOFT LLC. **Agisoft photoscan user manual**. 2016. Disponível em: <www.agisoft.ru>. Acesso em: 24 de nov. 2019.

ALHESSI, M. XYZ Geolog blog. **Contiguity-based spatial weights matrix using ArcGIS and PySAL**. 2020. Disponível em: https://spatiolog.blogspot.com/2019/01/contiguity-based-spatial-weights-matrix.html. Acesso em: 7 abr. 2020.

ALVES JÚNIOR, L. R. A. Análise de produtos cartográficos obtidos com câmera digital não métrica acoplada a um veículo aéreo não tripulado em áreas urbanas e rurais no estado de Goiás. 113 f. 2015. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Goiânia - GO, 2015.

ALVES, E. D. L.; VECCHIA, F. A. S. Análise de diferentes métodos de interpolação para a precipitação pluvial no Estado de Goiás. **Revista Acta Scientiarum**, Maringá, v. 33, n. 2, p.193-197, 2011.

ANDRIENKO, N.; ANDRIENKO, G. **Exploratory analysis of spatial and temporal data**: a systematic apporach. Germany: Springer, 2006.

APARECIDO, L. E. O.; ROLIM, G. S.; RICHETTI, J.; SOUZA, P. S.; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the state of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405–417, 2016.

AUBERT, B. A.; SCHROEDER, A.; GRIMAUDO, J. IT as enabler of sustainable farming: an empirical analysis of farmers' adoption decision of precision agriculture technology. **Decision Support Systems**, v. 54, n. 1, p. 510–520, 2012.

BAIO, F. H. R.; SILVA, S. P.; CAMOLESE, H. S.; NEVES, D. C. Financial analysis of the investment in precision agriculture techniques on cotton crop. **Engenharia Agrícola**, v. 37, n. 4, p. 838–847, 2017.

BALBINOT, A. A. J.; SANTOS, E. L.; COELHO, A. E.; AGASSI, C. J.; CHICOWSKI, A. S. **Agrupamento de plantas de soja na linha de semeadura**. Embrapa: Londrina – PR, 2018. (Circular técnica 146).

BALLESTEROS, R.; ORTGA, J. F.; HERNANDEZ, D.; DEL CAMPO, A.; MORENO, M. A. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, n. p. 66–75, May 2018.

BARBOSA, B. D. S.; FERRAZ, G. A. S.; GONÇALVES, L. M.; MARIN, D. B.; MACIEL, D. T.; FERRAZ, P. F. P.; ROSSI, G. RGB vegetation indices applied to grass monitoring: a qualitative analysis. **Agronomy Research**, v. 17, n. 2, p. 349–357, 2019.

BARETH, G.; AASEN, H.; BENDIG, J.; GNYP, M. L; BOLTEN, A.; JUNG, A. Low-weight and UAV-based hyperspectral full-frame cameras for monitoring crops: spectral comparison with portable spectroradiometer measurements. **Photogrammetrie Fernerkundung Geoinformation**, v. 1, p. 69–79, 2015.

BAZZI, C. L. **Software para definição e avaliação de unidades de manejo em agricultura de precisão**. 111 f. 2011. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – PR, 2011.

BAZZI, C. L.; SOUZA, E. G.; URIBE-OPAZO, M. A.; NÓBREGA, L. H. P.; ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agricola**, v. 34, n. 5, p. 952–964, 2013.

BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why. Trends in global landcover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115–128, maio 2015.

BENDIG, J.; YU, K. AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GYNP, M. 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.

BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, Á. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão**: resultados de um novo olhar. 1. ed. Brasília - DF: Embrapa, 2014.

BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A. Rectification methods for optimization of management zones. Computes and Electronics in Agriculture. V.146, n.1, 1-11, 2018.

BEUTLER, A. N.; MUNARETO, J. D.; Ramão, C. L.; GALON, L.; DIAS, N. P.; POZZEBON, B. C.; RODRIGUES, L. A. T.; MUNARETO, G. S.; GIACOMELI, R.; RAMOS, P. V. Propriedades físicas do solo e produtividade de arroz irrigado em diferentes sistemas de manejo. **Revista Brasileira de Ciencia do Solo**, v. 35, n. 5, p. 1601–1607, 2012.

BODAGHABADI, M. B. Is it necessarily a normally distributed data for kriging? A case study: soil salinity map of Ghahab area, central Iran. **Desert**, v. 23, n. 2, p. 284–293, 2018.

BROCH, D. L.; RANNO, S. K. Fertilidade do solo, adubação e nutrição da cultura da soja. In: **Tecnologia e produção**: soja e milho 2011/2012. Maracaju – MS: Fundação MS, 2012. p. 3-39.

BURKART, A. HECHT, V. L.; KRASKA, T.; RASCHER, U. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. **Precision Agriculture**, v. 19, p. 1–13, 2017.

CALLEGARI-JACQUES. **Bioestatística**: princípios e aplicações. Porto Alegre: Artmed, 2003.

CAMBARDELLA, C.A.; MOORMAN, T. B; PARKIN, T.B.; NOVACK, J. M; KARLEN, D. L; TURCO, R. F; KNOPKA, A.E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society America Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.

CAMBRAIA FILHO, D. J. **Utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do cerrado**. 147 f. 2019. Dissertação (Mestrado em Geociências Aplicadas) - Universidade de Brasília, Brasília – DF, 2019.

CAMPOS, T. L. D. L. **Discriminação de espécies arbóreas nativas da floresta estacional semidecidual e da exótica eucalyptus urograndis W. Hill ex Maiden utilizando dados hiperespectrais**. 105 f. 2017. Dissertação (Mestrado em Agronomia) - Universidade Estadual de Maringá, Maringá – PR, 2017.

CARVALHO, A. X. Y.; ALBUQUERQUE, P. H. M.; JUNIOR, G. R. A.; GUIMARÃES, R. D. Spatial hierarchical clustering. **Revista Brasileira de Biometria**, v. 27, n. 3, p. 411–442, 2009.

CHANG, D.; ZHANG, J.; ZHU, L.; SHAO-HUA GE, P. L; GUO-SHUN L. Delineation of management zones using an active canopy sensor for a tobacco field. **Computers and Electronics in Agriculture**, v. 109, p. 172–178, 2014. Elsevier B.V.

CHARRAD, M.; GHAZZALI, N.; BOITEAU, V.; NIKNAFS, A. Nbclust: an R package for determining the relevant number of clusters in a data set. **Journal of Statistical Software**, v. 61, n. 6, p. 1–36, 2014.

CHENG, H. D. JIANG, X. H.; SUN, Y.; WANG, J. Color image segmentation: advances and prospects. **Pattern Recognition**, v. 34, n. 12, p. 2259–2281, 2001.

CICORE, P.; SERRANO, J.; SHAHIDIAN, S.; SOUSA, A.; COSTA, J. L.; SILVA, J. R. M. Assessment of the spatial variability in tall wheatgrass forage using LANDSAT 8 satellite imagery to delineate potential management zones. **Environmental Monitoring and Assessment**, n. 188, v. 513, n. 9, p. 1-11, 2016.

CORTI, M.; CAVALLI, D.; CABASSI, G.; MARINO GALLINA, P.; BECHINI, L. Does remote and proximal optical sensing successfully estimate maize variables? A review. **European Journal of Agronomy**, v. 99, p. 37–50, jun. 2018. Elsevier.

COUTO, E. G.; SCARAMUZZA, J. F.; MARASCHINI, J. F. Influência dos métodos de interpolação dos dados nos mapas usados na agricultura de precisão. SIMPÓSIO INTERNACIONAL DE AGRICULTURA DE PRECISÃO, Viçosa - MG, 2002. **Anais...** Viçosa - MG: UFV, 2002. p. 1-5. 1 CD-ROM.

CRESSIE, N. A. C. Statistics for spatial data (Rev. ed.). Canada: John Wiley & Sons, 2015, 928 p.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; JOHANN, J. A.; BORSSOI, J. A. Comparison measures of maps generated by geostatistical methods. **Engenharia Agricola**, v. 32, n. 1, p. 174–183, 2012.

DAMIAN, J. M.; CASTRO PIAS, O. H.; CHERUBIN, M. R.; FONSECA, A. Z.; FORNARI, E. Z.; SANTI, A. L. Applying the NDVI from satellite images in delimiting management zones for annual crops. **Scientia Agricola**, v. 77, n. 1, p. 1–11, 2020.

DEBIASI, H.; LEVIEN, R.; TREIN, C. R.; CONTE, O.; KAMIMURA, K. M. Produtividade de soja e milho após coberturas de inverno e descompactação mecânica do solo. **Pesquisa Agropecuária Brasileira**, v. 45, p. 603-612, 2010.

DIDAN, K.; MUNOZ, A. B.; SOLANO, R.; HUETE, A. **MODIS Vegetation index user's** guide (MOD13 Series). The University of Arizona. 2015.

DIGGLE, P.J.; RIBEIRO JR., P.J. **Model-based geostatistics**. New York: Springer, 2007. 230 p.

DJI. **Mavic Pro**. 2014. Disponível em: https://www.dji.com/br/mavic>. Acesso em: 1 maio 2019.

DOERGE, T. A. Management zone concepts. **Site-Specific Management Guidelines**, 2000. 4 p.

DONI, M. V. **Análise de cluster**: métodos hierárquicos e de particionamento. 92 f. 2004. Graduação (Bacharelado em Análise de Sistemas) - Universidade Presbiteriana Mackenzie, São Paulo, 2004. DU, M.; NOGUCHI, N. Monitoring of wheat growth status and mapping of wheat yield's within-field spatial variations using color images acquired from UAV-camera System. **Remote Sensing**, v. 9, n. 3, p. 0-14, 2017.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Características da soja - BRS 1003IPRO**. 2019a. Disponível em: https://www.embrapa.br/soja/busca-de-solucoes-tecnologicas/-/produto-servico/2917/soja---brs-1003ipro. Acesso em: 19 abr. 2019.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Características do trigo BRS Sanhaço**. 2019b. Disponível em: https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3642/trigo---brs-sanhaco. Acesso em: 21 maio 2019.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema brasileiro de classificação de solos**. 3. ed. Rio de Janeiro: Embrapa – SPI, 2013. 412 p.

ESA. Sentinel-2. 2020^a. Disponível em: https://sentinel.esa.int/web/sentinel/missions/sentinel-2. Acesso em: 22 jan. 2020.

EUROPEAN SPACE AGENCY - ESA. **Copernicus**. 2020b. Disponível em: http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4>. Acesso em: 21 jan. 2020.

EUROPEAN SPACE AGENCY - ESA. **Sentinel-2**. 2020a. Disponível em: https://sentinel.esa.int/web/sentinel/missions/sentinel-2. Acesso em: 22 jan. 2020.

FANG, S.; TANG, W.; PENG, Y.; GONG, Y.; DAI, C.; CHAI, R.; LIU, K. Remote estimation of vegetation fraction and flower fraction in oilseed rape with unmanned aerial vehicle data. **Remote Sensing**, v. 8, n. 5, p. 416, maio 2016.

FARACO, M. A.; URIBE-OPAZO, M. A. SILVA, E. A.; JOHANN, J. A.; BORSSOI, J. A. Seleção de modelos de variabilidade espacial para elaboração de mapas temáticos de atributos físicos do solo e produtividade da soja. **Revista Brasileira de Ciência do Solo**, Viçosa - MG, v. 32, n. 2, p. 463-476, 2008.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da soja**. Londrina - PR: Embrapa, 2007. (Circular Técnica 48).

FLORES, C. A.; ALBA, J. M. F. A pedologia e a Agricultura de Precisão. *In*: BERNARDI, A. C. C., NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de Precisão, Resultados de um novo olhar**. Brasília: EMBRAPA. 2014.

FLORES, C. A.; ALBA, J. M. F. A pedologia e a agricultura de precisão. In: BERNARDI, A. C. C. et al. (Ed. téc.). – **Agricultura de precisão**: resultados de um novo olhar. 1. ed. Brasília, DF: Embrapa, 2014. p.36-47. Cap. 2.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto da vegetação**. 1. ed. São Paulo: Oficina de textos, 2017.

FRAISSE, C. W.; SUDDUTH, K. A.; KITCHEN, J. R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **International Journal of the American Society of Agricultural and Biological Engineers**, Joseph, v. 1, n. 44, p. 155-166, 2001.

GARDIMAN JUNIOR, B. S.; MAGALHÃES, I. A. L.; FREITAS, C. A. A.; CECILIO, R. A. Análise de técnicas de interpolação para espacialização da precipitação pluvial na bacia do rio Itapemirim (ES). **Revista Ambiência**, Guarapuava, v. 8, n. 1, p. 61-71, 2012.

GARRATT, M. P. D. GARRATT, M. P. D.; BOMMARCO, R.; KLEIJN, D.; MARTIN, E.; MORTIMER, S. R.; REDLICH, S.; SENAPATHI, D.; STEFFAN-DEWENTER, I.; ŚWITEK, S.; TAKÁCS, V.; VAN GILS, S.; VAN DER PUTTEN, W. H.; POTTS, S. G. Enhancing soil organic matter as a route to the ecological intensification of European Arable Systems. **Ecosystems**, v. 21, n. 7, p. 1404–1415, 2018.

GAVIOLI, A. **Módulos computacionais para seleção de variáveis e análise de agrupamento para definição de zonas de manejo**. 128 f. 2017. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – PR, 2017.

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.

GE, Y.; THOMASSON, J. A.; SUI, R. Remote sensing of soil properties in precision agriculture: A review. **Frontiers of Earth Science**, v. 5, n. 3, p. 229–238, 2011.

GEORGI, C.; SPENGLER, D.; ITZEROTT, S.; KLEINSCHMIT, B. Automatic delineation algorithm for site-specific management zones based on satellite remote sensing data. **Precision Agriculture**, v. 19, n. 4, p. 684–707, 2018.

GEIPEL, J.; LINK, J.; CLAUPEIN, W.; Assessing Biodiversity in Boreal Forests with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. **Remote Sensing**, v. 10, n. 2, p. 338, 2018.

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.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002.

GOMARASCA, M. A. Basics of geomatics. New York: Springer, 2009.

GUO, C. et al. Integrating remote sensing information with crop model to monitor wheat growth and yield based on simulation zone partitioning. **Precision Agriculture**, v. 19, n. 1, p. 55–78, 2018.

HALL, O.; DAHLIN, S.; MARSTORP, H.; BUSTOS, M. F. A.; ÖBORN, I.; JIRSTRÖM, M. Classification of maize in complex smallholder farming systems using UAV imagery. **Drones**, v. 2, n. 3, p. 22, 2018.

HAN, J.; KAMBER, M. **Data mining**: concepts and techniques. 2. ed. San Francisco: Elsevier Inc., 2006.

HARRIS GEOSPATIAL. **Broadband greenness**. 2019. Disponível em: https://www.harrisgeospatial.com/docs/BroadbandGreenness.html#Green6>. Acesso em 17 fev. 2020.

HEXAGON. **Angular Measurement on the horizontal plane**. 2019. Disponível em: https://novatel.com/solutions/attitude. Acesso em: 15 mar. 2020.

HUNT-JR E. R.; P. C. DORAISWAMYA; MCMURTREYA J. M.; DAUGHTRYA, C. S. T.; PERRY, E. M.; AKHMEDOVA B. Remote sensing leaf chlorophyll content. **Agronomy Journal**, v. 103, n. 2, p. 1090–1099, 2013.

ISAAKS, E. H.; SRIVASTAVA, R. M. An introduction to applied geostatistics. New York: Oxford University, 1989. 560 p.

JAMES, M. R.; ROBSON, S.; D'OLEIRE-OLTMANNS, S.; NIETHAMMER, U. Optimising UAV topographic surveys processed with structure-from-motion: Ground control quality, quantity and bundle adjustment. **Geomorphology**, v. 280, p. 51–66, 2017.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. Trad. José Carlos Neves Epiphanio et al. 2. Ed. São José dos Campos – SP: Parêntese, 2009.

JIM, A. S. Identificação e caracterização espectral da ferrugem *(Austropuccinia psidii)* do eucalipto por imagens de alta resolução obtidas de veículos aéreos não tripulados *(VANT) e em laboratório (espectroradiômetro).* 101 f. 2018. Tese (Doutorado em Ciência Florestal) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu – SP, 2018.

JIN, X.; LIU, S.; BARET, F. HEMERLÉ, M. COMAR, A. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. **Remote Sensing of Environment**, v. 198, p. 105–114, 2017.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining geostatistics**. London: Academic Press, 1978. 600 p.

KNIPLING, E. Physical and physiological basis for the reflectance of visible and near infrared radiation from vegetation. **Remote Sensing of Environment**, v. 1, p. 155–159, 1970.

KRŠÁK, B.; BLIŠŤAN, P.; PAULIKOVÁ, A.; PUŠKÁROVÁ P.; KOVANIC.; PALKOVÁ J.; ZELIZNAKOVÁ V. Use of low-cost UAV photogrammetry to analyze the accuracy of a digital elevation model in a case study. **Measurement. Journal of the International Measurement Confederation**, v. 91, p. 276–287, 2016.

LACERDA, V. S. Estimativa do índice de severidade de ferrugem asiática na cultura da soja por meio de imagens obtidas com aeronave remotamente pilotada. 60 f. 2016. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta – PR, 2016.

LARGE, E. C. Growth stages in cereals illustration of the feekes scale. **Plant Phatology**, v. 3, p. 128–129, 1954.

LI, X.; PAN, Y. C.; GE, Z. Q.; ZHAO, C. J. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agricultural Sciences in China**, v. 6, n. 2, p. 180-188, 2007.

LIAGHAT, S.; BALASUNDRAM, S. K. A review: the role of remote sensing in precision agriculture. **American Journal of Agricultural and Biological Science**, v. 5, n. 1, p. 50–55, 2010.

LIM SOON, E.; ISMAIL, R.; HASHIM, W.; BAHARUM, A. The use of VARI, GLI, and VIGREEN formulas in detecting vegetation in aerial images. **International Journal of Technology**, v. 10, n. 7, p. 1385–1394, 2019.

LINDBLOM, J.; LUNDSTRÖM, C.; LJUNG, M.; JONSSON, A. Promoting sustainable intensification in precision agriculture: review of decision support systems development and strategies. **Precision Agriculture**, v. 18, n. 3, p. 309–331, 2017.

LIU, Y.; LI, Z.; XIONG, H.; GAO, X.; WU, J. Understanding of internal clustering validation measures. INTERNATIONAL CONFERENCE ON DATA MINING - ICDM, Washington D. C. 2010. **Proceedings – IEEE Computer Society ...** Washington D. C., 2010. p. 911-916.

LORBIESKI, R. **Regionalização de área agrícola usando dados de imagens aéreas e coletras de campo**. 108 f. 2020. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – PR, 2020.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**. v. 16, n. 1, p. 65–70, 2001.

MA, Y.; WU, H.; WANG, L.; HUANG, B.; RANJAN, R.; ZOMAYA, A.; JIE, W. Remote sensing big data computing: challenges and opportunities. **Future Generation Computer Systems**, v. 51, p. 47–60, 2015.

MARINO, S.; ALVINO, A. Detection of homogeneous wheat areas using multi-temporal UAS images and ground truth data analyzed by cluster analysis. **European Journal of Remote Sensing**, v. 51, n. 1, p. 266–275, 2018.

MARTINS, R. C. **Definição de zonas de manejo por índices de vegetação obtidos por sensoriamento remoto e mapas de produtividade**. Dissertação (Mestrado em Agricultura de Precisão), Universidade Federal de Santa Maria, RS, 2017.

MATHER, P. M. **Computer processing of remotely-sensed images**: an introduction. 2. ed. Chichester: John Wiley e Sons, 1999, 292 p.

MATHERON, G. Principles of geostatistics. Economic Geology, v. 58, p. 1246-1266, 1963.

MAULIK, U.; BANDYOPADHYAY, S. Performance evaluation of some clustering algorithms and validity indices. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 12, p. 1650–1654, 2002.

MAZZINI, P. L. F.; SCHETTINI, C. A. F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase-sinópticos. **Brazilian Journal Aquatic Science Technology**, v. 13, n. 1, p. 53-64, 2009.

MELLO, J. M. de; BATISTIA, J. L. F.; RIBEIRO JUNIOR, P. J.; OLIVEIRA, M. S. Ajuste e seleção de modelos espaciais de semivariograma visando à estimativa volumétrica de Eucaliptus grandis. **Scientia Florestalis**, v.1, n.69, p.25-37, 2005.

MENDES, I. C.; HUNGRIA, M.; VARGAS, M. A. T. Soybean response to starter nitrogen and Bradyrhizobium inoculation on a Cerrado oxisol under no-tillage and conventional tillage systems. **Revista Brasileira de Ciência do Solo**, v. 27, n. 1, p. 81–87, 2003.

MENESES, P. R.; ALMEIDA, T. Introdução ao processamento de imagens de sensoriamento remoto. Brasília: UNB, 2012.

MENESES, P. R.; NETTO, J. DA S. M. **Sensoriamento remoto**: reflectância dos alvos naturais. Brasília: Universidade de Brasília, 2001. p. 157–199.

MEYER, G.E.; NETO, J.C. Verification of color vegetation indices for automated crop imaging applications. **Computational. Electronic Agriculture**, v. 63, p. 282–293, 2008.

MIRANDA, J. I. Fundamentos de sistemas de informações geográficas. 2. ed. Brasília - DF: Embrapa, 2010.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos: INPE, 2001. 250 p.

MOREIRA, M. C.; SANTANA, C. C. Definição de zonas de manejo a partir de índice de vegetação da diferença normalizada - NDVI em área de cerrado do oeste da Bahia. CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA – CONBEA 47, 2018, Brasília - DF. **Anais...** 2018. Brasília - DF. p. 0–3.

MORIYA, É. A. S. Identificação de bandas espectrais para detecção de cultura de canade-açúcar sadia e doente utilizando câmara hiperespectral embarcada em vant. 147 f. 2015. Dissertação (Mestrado em Ciências Cartográficas) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Presidente Prudente – SP, 2015.

MOTOHKA, T.; NASAHARA, K. N.; OGUMA, H.; TSUCHIDA, S. Applicability of Green-Red Vegetation Index for remote sensing of vegetation phenology. **Remote Sensing**, v. 2, n. 10, p. 2369–2387, 2010.

MULLA, D. J. Sensing in Agriculture Review Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps 5. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, 2013.

MÜLLER-WILM, U. **Sen2Cor**. Configuration and user manual. S2-PDGS-MPC-L2A-SUM-V2.5.5. Luton, Bedfordshire, UK: Telespazio VEGA, 2018. 54 p.

MZUKU, M.; KHOSLA, R.; REICH, R.; INMAN, D.; SMITH, F.; MACDONALD, L. Spatial variability of measured soil properties across site-specific management zones. **Soil Science Society of America Journal**, v. 69, n. 5, p. 1572–1579, 2005.

NANNI, M. R.; POVH, F. P.; DEMATTÊ, J. A. M.; OLIVEIRA, R. B.; CHICATI, M. L.; CEZAR, E. Optimum size in grid soil sampling for variable rate application in site-specific management. **Scientia Agricola**, v. 68, n. 3, p. 386–392, 2011.

NASA. Technical specifications. 2020. Disponível em: https://modis.gsfc.nasa.gov/about/specifications.php. Acesso em: 10 mai. 2020.

NASCIMENTO, A. L. DO. Estratégia de amostragem para caracterização da variabilidade espacial dos atributos físicos e químicos do solo. 44 f. 2015. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa – MG, 2015

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: a review. **Applied Geomatics**, v. 6, p. 1–15, 2013.

OLIVEIRA, F. H. T.; ARRUDA, J. A.; SILVA, I. F.; ALVES, J. C. Amostragem para avaliação da fertilidade do solo em função do instrumento de coleta das amostras e de tipos de preparo do solo. **Revista Brasileira de Ciência do Solo**, v. 31, n. 5, p. 973–983, 2007.

OLIVEIRA, L. T. Avaliação do uso de sensor termal a bordo de VANT através de análises radiométricas, espectrais, espaciais e posicionais. 131 f. 2017. Dissertação (Mestrado em Sensoriamento Remoto) - Instuto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

OLIVER, M. A. Geostatistical applications for precision agriculture. London, United Kingdom: Springer, 2010.

OLIVER, M.A.; WEBSTER, R. **Basic steps in geostatistics**: the variogram and kriging. New York: Springer. 2015.

PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, v. 00, n. 00, p. 1–19, 2016.

PEDERSEN, S. M.; LIND. **Precision Agriculture: Technology and Economic Perspectives**. Switzerland: Springer. 2010.

PEDERSEN, S. M.; LIND, K. M. **Precision agriculture**: technology and economic perspectives. New York: Springer, 2017.

PIERCE F. J.; NOWAK P. Aspects of precision agriculture. **Advances in Agronomy**, v. 67, p. 1-85, 1999.

POSSOCH, M.; BIEKER, S.; HOFFMEISTER, D.; BOLTEN, A. A.; SCHELLBERG, J.; BARETH, G. Multi-temporal crop surface models combined with the RGB vegetation index from UAV-based images for forage monitoring in grassland. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. 2016. **Proceedings...** 2016. v. XLI-B1, p. 991–998.

PREZOTTI, L. C.; GUARÇONI, M. A. **Guia de interpretação de análise de solo e foliar**. Vitória - ES: INCAPER, 2013. 104 p.

RANI, N.; MANDLA, V. R.; SINGH, T. Evaluation of atmospheric corrections on hyperspectral data with special reference to mineral mapping. **Geoscience Frontiers**, v. 8, n. 4, p. 797–808, jul. 2017.

REY, S. J.; ARRIBAS-BEL, D.; WOLF, L. J. **Geographic data science with PySAL and the PyData stac**k. 2019. Disponível em: https://geographicdata.science/book/intro. Acesso em: 10 jan. 2020.

RODRIGUES JUNIOR, F. A.; VIEIRA, L. B.; QUEIROZ, D. M.; SANTOS, N. T. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 8, p. 778–787, 2011.

RODRIGUES JUNIOR, F. A; VIEIRA, L. B.; QUEIROZ, D. M.; SANTOS, N. T. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, n. 31, p. 778–787, 2011.

ROMAN, M.; URIBE-OPAZO, M.A.; NÓBREGA, L.H.P.; JOHANN, J.A. Spatial variability of tiller mean number and wheat yield. **Bragantia**, v. 67, p. 361-370, 2008.

ROOS. **Cultivar NA 5905 RG**. 2019. Disponível em: http://sementesroos.com.br/wp-content/uploads/2018/01/roos-folder-2018-5909.png>. Acesso em: 25 fev. 2019.

ROSENBERG, A.; HIRSCHBERG, J. V-Measure: A conditional entropy-based external cluster evaluation measure. JOINT CONFERENCE ON EMPIRICAL METHODS IN NATURAL LANGUAGE PROCESSING AND COMPUTATIONAL NATURAL LANGUAGE LEARNING - EMNLP-CoNLL 2007. **Proceedings...** Prague, Czech Republ: Association for Computational Linguistics, June, 2007. p. 410–420.

SABERIOON, M. M.; AMIN, M. S. M.; ANUAR, A. R.; CHOLIZADEH, A.; WAYAYOK, S.; KHAIRUNNIZA-BEJOD, S. Assessment of rice leaf chlorophyll content using visible bands at

different growth stages at both the leaf and canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 32, n. 1, p. 35–45, 2014.

SAIFUZZAMAN, M.; ADAMCHUK, V.; BUELVAS, R.; BISWAS, A.; PRASHER, S.; RABE, N.; ASPINALL, D.; JI, W. Clustering tools for integration of satellite remote sensing imagery and proximal soil sensing data. **Remote Sensing**, v. 11, n. 9, p. 1036, 2019.

SALEH, A.; BELAL, A. A. Delineation of site-specific management zones by fuzzy clustering of soil and topographic attributes: a case study of east Nile Delta, Egypt. **IOP Conference Series: Earth and Environmental Science**, v. 18, p. 1-6, 2014.

SARKER, T. C.; INCERTI, G.; SPACCINI, R.; PICCOLO, A.; MAZZOLENI, S.; BONANOMI, G. Linking organic matter chemistry with soil aggregate stability: Insight from 13C NMR spectroscopy. **Soil Biology and Biochemistry**, v. 117, p. 175–184, 2018. Pergamon.

SARTORI, A. A. D. C. Geoestatística multivariada na delimitação de zonas de manejo na cultura de cana-de-açúcar. 143 f. 2014. Tese (Doutorado em Agronomia), Universidade Estadual Paulista "Julio de Mesquita Filho", Botucatu - SP, 2014.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BETZEK, N.; GAVIOLI, A. BENEDUZZI, H. M. Use of the farmer's experience variable in the generation of management zones. **Semina: Ciências Agrárias**, v. 38, n. 4, p. 2305–2322, 2017.

SCHOWENGERDT, R. A. Techniques for image processing and classification in remote sensing. New York: Academic Press, 1983. 249 p.

SCUDIERO, E.; TEATINI, P.; MANOLI, G.; BRAGA, F.; SKAGGS, T. H.; MORARI, F. Workflow to establish time-specific zones in precision agriculture by spatiotemporal integration of plant and soil sensing data. **Agronomy**, v. 8, n. 11, p. 253, 2018.

SENTHILNATH, J.; DOKANIA, A.; KANDUKURI, M.; RAMESH, K. N.; ANAND, G. OMKAR, S. N. Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV. **Biosystems Engineering**, v. 146, p. 16–32, 2016. Landslides.

SHIBUSAWA, S. Precision farming and terramechanics. In: ASIA-PACIFIC REGIONAL CONFEFERENCE, 5, Seoul, Korea, 1998. **Proceedings...** Seoul, Korea: ISTVS, 1998.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. Lisboa: Oficina de textos, 2014.

SOCIEDADE BRASILEIRA DE CIÊNCIA DO SOLO. Núcleo Estadual do Paraná. SBCS/NEPAR. **Manual de adubação e calagem para o estado do Paraná**. 2. ed. Curitiba: Sociedade Brasileira de Ciência do Solo, 2015.

SOOR, S.; CHALLA, A.; DANDA, S.; DAYA SAGAR, B. S.; NAJMAN, L. **Extending k-means to preserve spatial connectivity**. IEEE International Geoscience and Remote Sensing Symposium - IGARSS. Valencia, Spain. jul. 2018, p.6959–6962.

SOUSA, H. L. Sensoriamento remoto com VANTs: uma nova possibilidade para a aquisição de geoinformações. **Revista Brasileira de Geomática**, v. 5, n. 3, p. 326, 2018.

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, 2017.

SOUZA, Z. M.; SOUZA, G. S.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, v. 44, n. 2, p. 261–268, 2014.

STOLF, R.; MURAKAMI, J. H.; BRUGNARO, C.; SILVA, L. G.; SILVA, L. C. F.; MARGARIDO, L. A. C. Penetrômetro de impacto stolf - Programa computacional de dados em excel-VBA. **Revista Brasileira de Ciencia do Solo**, v. 38, n. 3, p. 774–782, 2014.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. Introduction do data mining. 1. ed. Boston, Massachusetts: Pearson, 2005.

TETILA, E. C.; BRANDOLI MACHADO, B.; BELETE, N. A. D. S.; GUIMARAES, D. A.; PISTORI, H. Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 12, p. 2190–2194, 2017.

TORMENA, C. A.; SILVA, A. P.; LIBARDI, P. L. Caracterização do intervalo hídrico ótimo de um Latossolo Roxo sob plantio direto. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 22, n. 3, p. 573-581, 1998.

TORRES-SÁNCHEZ, J.; PEÑA, J. M.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Multitemporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. **Computers and Electronics in Agriculture**, v. 103, p. 104–113, 2014.

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

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

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on structure from motion (SfM) point clouds. **Remote Sensing**, v. 4, n. 12, p. 1392-1410, 2012.

USGS - Science for a Changing World. **Landsat 8**. Landsat Missions. 2020. Disponível em: https://landsat.usgs.gov/landsat-8. Acesso em: 10 fev. 2020.

VAZ, C. M. P.; PRIMAVESI, O. PATRIZZI, V. C.; IOSSI, M. F.; Influência da umidade na resistência do solo medida com penetrômetro de impacto. São Carlos – SP: Embrapa Instrumentação, 2002. (Comunicado Técnico 51).

VENDRAMIN, L.; CAMPELLO, R. J. G. B.; HRUSCHKA, E. R. Relative clustering validity criteria: a comparative overview. **Statistical Analysis and Data Mining**, v. 8, n. 5, p. 497-511, 2010.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R.F.; ALVAREZ V., V.H.; SCHAEFER, G.R., (eds.). **Tópicos em ciência do solo**. Viçosa - MG, Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p. 1-54.

VILLA NOVA, N.; BACCHI, O. O.; REICHARDT, K. POTENCIAL DA ÁGUA NO SISTEMA SOLO - PLANTA ESTIMADO ATRAVÉS DA FASE DE VAPOR. **Scientia Agricola**, v. 53, n. 1, p. 194, 1996.

VILLWOCK, 2009; TÉCNICAS DE AGRUPAMENTO E DE HIERARQUIZAÇÃO NO CONTEXTO DE KDD – APLICAÇÃO A DADOS TEMPORAIS DE INSTRUMENTAÇÃO GEOTÉCNICA-ESTRUTURAL DA USINA HIDRELÉTRICA DE ITAIPU. 124 f. 2009. Tese **Tese** (Métodos numéricos em Engenharia) - Universidade Federal do Paraná, Curitiba – PR,

2009.

WESTOBY, M. J.; BRASINGTON, J.; GLASSER, N.; HAMBREY, M. J.; REYNOLDS, J. M. "Structure-from-Motion" photogrammetry: A low-cost, effective tool for geoscience applications. **Geomorphology**, v. 179, p. 300–314, 2012.

WHELAN, B.; TAYLOR, J. **Precision agriculture for grain production systems**. 1. ed., Collingwood: CSIRO, 2013. v. 1, p.199.

WIEGAND, C. L.; RICHARDSON, A. J.; ESCOBAR, D. E.; GERBERMANN, A. H. Vegetation indices in crop assessments. **Remote Sensing of Environment**, v. 35, n. 2–3, p. 105–119, 1991.

WOEBBECKE, D. M.; MEYER, G. E.; V. B. K.; MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. **Trans. ASAE,** v. 38, p. 259-269. 1995.

WOLF, L. J.; KNAAP, E.; REY, S. Geosilhouettes: geographical measures of cluster fit. **Environment and Planning B: Urban Analytics and City Science**, v. 0, n. 0, p. 1–19, 2019.

XIANG, L. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agriculture Sciences**, Maryland, v. 6, n. 2, p. 180-188, 2007.

XU, J.; GU, H.; MENG, Q.; CHENG, J.; LIU, Y.; JIANG, P.; SHENG, J.; DENG, J.; BAI, X. Spatial pattern analysis of *Haloxylon ammodendron* using UAV imagery. A case study in the Gurbantunggut Desert. **International Journal of Applied Earth Observation and Geoinformation**, v. 83, n. A. 101891, nov. 2019.

XU, R.; WUNSCHH II, D. C. Clustering. 1. ed. New Jersey: John Wiley & Sons, Inc., 2009.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística**: conceito e aplicações. 1. ed. São Paulo: Oficina de textos, 2013.

YAN, J.; MA, Y.; WANG, L.; CHOO, K.-K. R.; JIE, W. A cloud-based remote sensing data production system. **Future Generation Computer Systems**, v. 86, p. 1154–1166, 2018. Elsevier B.V.

YANG, C. A high-resolution airborne four-camera imaging system for agricultural remote sensing. **Computers and Electronics in Agriculture**, v. 88, p. 13–24, 1 out. 2012.

YEO, I. N. K.; JOHNSON, R. A. A new family of power transformations to improve normality or symmetry. **Biometrika**, v. 87, n. 4, p. 954–959, 2000.

YUZUGULLU, O.; LORENZ, F.; FRÖHLICH, P.; LIEBISCH, F. Understanding Fields by Remote Sensing: Soil Zoning and Property Mapping. **Remote Sensing**, v. 12, n. 7, p. 1116, 2020.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, p. 693–712, 2012.

ZHANG, F.-S.; YAMASAKI, S.; NANZYO, M. Waste ashes for use in agricultural production: I. Liming effect, contents of plant nutrients and chemical characteristics of some metals. **Science of The Total Environment**, v. 284, n. 1–3, p. 215–225, 4 fev. 2002.

ZHANG, X.; ZHANG, F.; QI, Y.; DENG, L.; WANG, X.; YANG, S. New research methods for

vegetation information extraction based on visible light remote sensing images from an unmanned aerial vehicle (UAV). **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. feb., p. 215–226, 2019.

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

ZIETARA, A. M. Creating digital elevation model (DEM) based on ground points extracted from classified aerial images obtained from Unmanned Aerial Vehicle (UAV). 92 f. 2017. Master (Master of Science in Civil and Environmental Engineering) - Norwegian University of Science and Technology, Norway, 2017. APÊNDICES
APÊNDICE A



Figura 43 Descrição das condições climáticas dos voos de VANT. A: céu claro sem nuvens, B: céu com nuvens finas e esparsas, C: céu com nuvens concentradas com sombreamento.

APÊNDICE B



Figura 44 Índices de vegetação ExG, GLI, GRVI, RGBVI e VARI pelo VANT ao longo do ciclo de desenvolvimento da soja (06/12/2018 a 23/02/2019), com resolução espacial de 5 m.

APÊNDICE C



Figura 45 Índices de vegetação ExG, GLI, GRVI, RGBVI e VARI do VANT ao longo do ciclo de desenvolvimento do trigo (11/06/2019 a 04/09/2019), com resolução espacial de 5 m.

APÊNDICE D



Figura 46 Índices de vegetação ExG, GLI, GRVI, NDVI, RGBVI e VARI do Sentinel-2 ao longo do ciclo de desenvolvimento da soja (12/12/2018 a 02/03/2019), com resolução espacial de 10 m.

APÊNDICE E



Figura 47 Índices de vegetação ExG, GLI, GRVI, RGBVI e VARI do Sentinel-2 ao longo do ciclo do trigo (10/06/2019 a 24/08/2019), com resolução espacial de 10 m.

APÊNDICE F



Figura 48 Boxplot dos índices de vegetação com *outlier* ExG, GLI, GRVI RGBVI e VARI do VANT para a soja.

APÊNDICE G



Figura 49 Boxplot dos índices de vegetação com outlier ExG, GLI, GRVI RGBVI e VARI do VANT para o trigo.

APÊNDICE H



Figura 50 Boxplot dos índices de vegetação com outlier ExG, GLI, GRVI RGBVI e VARI do Sentinel-2 para a soja.

APÊNDICE I



Figura 51 Boxplot dos índices de vegetação com *outlier* ExG, GLI, GRVI RGBVI e VARI do Sentinel-2 para o trigo.