

LEONARDO RUAN DE SOUZA CORREA

**USO DE SENSORES ORBITAL E TERRESTRE NA DELIMITAÇÃO DE ZONAS DE
MANEJO EM VITIVINICULTURA DE PRECISÃO**

Botucatu

2025

LEONARDO RUAN DE SOUZA CORREA

**USO DE SENSORES ORBITAL E TERRESTRE NA DELIMITAÇÃO DE ZONAS DE
MANEJO EM VITIVINICULTURA DE PRECISÃO**

Dissertação apresentada à Faculdade de Ciências Agrônômicas da Unesp Câmpus de Botucatu, para obtenção do título de Mestre em Engenharia Agrícola (Engenharia Agrícola).

Orientador: Luís Henrique Bassoi
Coorientador: Eduardo Antonio Speranza

Botucatu

2025

S729u

de Souza Correa, Leonardo Ruan

Uso de sensores orbital e terrestre na delimitação de zonas de manejo em vitivinicultura de precisão / Leonardo Ruan de Souza Correa. -- Botucatu, 2025

102 p.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrônomicas, Botucatu

Orientador: Luís Henrique Bassoi

Coorientador: Eduardo Antonio Speranza

1. Sensoriamento Remoto. 2. Agrupamento de Dados. 3. Viticultura de Precisão. 4. Índices de vegetação. I. Título.

CERTIFICADO DE APROVAÇÃO

Título:

USO DE SENSORES ORBITAL E TERRESTRE NA DELIMITAÇÃO DE ZONAS DE MANEJO EM VITIVINICULTURA DE PRECISÃO

AUTOR: LEONARDO RUAN DE SOUZA CORREA

ORIENTADOR: LUÍS HENRIQUE BASSOI

COORIENTADOR: EDUARDO ANTONIO SPERANZA

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Agrícola, pela Comissão Examinadora:

 Documento assinado digitalmente
LUIS HENRIQUE BASSOI
Data: 14/08/2025 11:11:08-0300
verifique em <https://validar.jf.gov.br>

Pesquisador Dr. LUÍS HENRIQUE BASSOI (Participação Virtual)
Embrapa Instrumentação / Empresa Brasileira de Pesquisa Agropecuária

 Documento assinado digitalmente
LUCIO ANDRE DE CASTRO JORGE
Data: 14/08/2025 11:59:24-0300
verifique em <https://validar.jf.gov.br>

Pesquisador Dr. LÚCIO ANDRÉ DE CASTRO JORGE (Participação Virtual)
Pesquisa e Desenvolvimento / Empresa Brasileira de Pesquisa Agropecuária

 Documento assinado digitalmente
PETERSON RICARDO FIORIO
Data: 14/08/2025 11:27:05-0300
verifique em <https://validar.jf.gov.br>

Prof. Dr. PETERSON RICARDO FIORIO (Participação Virtual)
Engenharia de Biosistemas / Escola Superior de Agricultura Luiz de Queiroz

Botucatu, 14 de agosto de 2025.

*Para meus pais,
por seu amor e apoio incondicional,*

dedico

AGRADECIMENTOS

Agradeço, primeiramente, a Deus e aos meus pais, Valdete Costa e Terezinha Monteiro, pelo amor, apoio incondicional e dedicação, que foram a base para que eu chegasse até aqui.

À minha namorada, Débora Lohana, por sua parceria, paciência e incentivo em cada etapa desta jornada. Sua presença foi fundamental para a conclusão deste trabalho.

Ao meu orientador, Luís Henrique Bassoi, e ao meu coorientador, Eduardo Antonio Speranza, pela confiança, disponibilidade e valiosos ensinamentos que moldaram a execução e a qualidade desta pesquisa.

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

Agradeço, ainda, à Embrapa Instrumentação de São Carlos e à UNESP/FCA, por oferecerem a estrutura e o ambiente acadêmico necessários para o desenvolvimento da pesquisa, bem como ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade de crescimento profissional e pessoal.

Um agradecimento especial à Vinícola Guaspari pela confiança e pelo apoio prestado, essenciais para a execução de parte deste estudo.

Por fim, agradeço a todos os colegas, amigos e familiares que, de diversas formas, contribuíram e me apoiaram ao longo deste percurso.

RESUMO

Zonas homogêneas (ZH) em vinhedos foram definidas utilizando-se quatro índices de vegetação derivados de sensores proximal (*Crop Circle ACS 430*) e orbital (imagens de satélite PlanetScope) ao longo de três safras (2017 a 2019). O objetivo foi subdividir um vinhedo cv. *Chardonnay*, localizado em Espírito Santo do Pinhal – SP, em setores com características uniformes de vigor vegetativo para otimizar o manejo utilizando o algoritmo de aprendizado de máquina não supervisionado *K-means*. Os resultados revelaram padrões consistentes, mas com diferenças significativas nos valores absolutos de reflectância entre as plataformas, devido às distintas larguras de banda e à sensibilidade de cada sensor. Observou-se que o sensor orbital, ao suavizar os ruídos ambientais inerentes às medições de campo, apresentou uma maior estabilidade nos dados. A análise de correlação de Pearson demonstrou que a concordância entre as plataformas é fortemente dependente da homogeneidade da área. A aplicação do algoritmo *K-means* para delimitar as ZH foi validada pelos métodos do cotovelo, silhueta e PCA, que indicaram consistentemente duas zonas ($K=2$) como a melhor configuração, oferecendo o equilíbrio ideal entre coesão interna e distinção externa. Embora a subdivisão em três zonas ($K=3$) ainda mantivesse alguma similaridade, a partir de quatro zonas ($K=4$) a dissimilaridade entre os dados proximal e orbital foi total. As tecnologias são complementares: o sensor proximal se destaca na captação de variações finas de alta frequência espacial, enquanto o sensor orbital é mais eficaz na produção de mapas de ZH mais suaves e de contornos nítidos, facilitando a visualização das ZH e, conseqüentemente, a aplicação prática das estratégias de viticultura de precisão.

Palavras-chave: sensoriamento remoto; agrupamento de dados; viticultura de precisão; índices de vegetação

ABSTRACT

Homogeneous zones (HZ) in vineyards were defined by using four vegetation indices derived from proximal (*Crop Circle ACS 430*) and orbital (images from PlanetScope satellite) sensors over three growing seasons (2017 to 2019). The objective was to subdivide the vineyard cv. *Chardonnay* at Espirito Santo do Pinhal, state of São Paulo, Brazil, into sectors with uniform vegetative vigor characteristics to optimize management through the unsupervised machine learning algorithm *K-means*. The results revealed consistent patterns but with significant differences in the absolute reflectance values between platforms, due to their distinct spectral bandwidths and sensor sensitivities. It was observed that the orbital sensor, by smoothing environmental noise inherent to field measurements, provided greater data stability. Pearson's correlation analysis showed that the agreement between platforms was strongly dependent on the homogeneity of the area. The application of the *K-means* algorithm to delimit the HZs was validated by the elbow, silhouette, and PCA methods, which consistently indicated two zones ($K=2$) as the optimal configuration, offering the best balance between internal cohesion and external separation. Although subdivision into three zones ($K=3$) still showed some consistency, from four zones ($K=4$) onward, dissimilarity between proximal and orbital data became complete. The technologies are complementary: the proximal sensor excels in capturing fine-scale, high-frequency spatial variations, while the orbital sensor is more effective in generating smoother, well-defined maps of homogeneous zones, thus facilitating the visualization of HZs and the practical application of precision viticulture.

Keywords: remote sensing; data grouping; precision viticulture; vegetation indices

LISTA DE ILUSTRAÇÕES

Figura 1 - Mapa de localização do vinhedo em estudo.....	37
Figura 2 - Sensor <i>Crop Circle ACS-430</i> (<i>Holland Scientific Inc., Lincoln, NE, EUA</i>) acoplado a um receptor GNSS HiPer® GGD (<i>TOPCON, Pleasanton, CA, EUA</i>) (A) e aquisição de dados de reflectância do dossel de videiras por caminhamento (B)	39
Figura 4 - Reamostragem dos pontos no Vesper 1.62 da área 1 e 2	43
Figura 5 - Fluxograma de Delimitação de Zonas Homogêneas via <i>K-means</i>	47
Figura 6 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017	66
Figura 7 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018.....	66
Figura 8 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019.....	67
Figura 9 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017	68
Figura 10 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018.....	69
Figura 11 - Zonas homogêneas ($K = 2$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019.....	69
Figura 12 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017	71
Figura 13 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018.....	71
Figura 14 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019.....	72
Figura 15 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017	74
Figura 16 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018.....	74
Figura 17 - Zonas homogêneas ($K = 3$) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019.....	74

LISTA DE TABELAS

Tabela 1 -Dadas dos estádios de maturação fenológico de vinhedo 'Chardonnay' durante os ciclos de produção de 2017, 2018 e 2019	40
Tabela 2 -Dadas de obtenção das imagens obtidas mais próximas aos estádios de maturação fenológico de vinhedo 'Chardonnay' durante os ciclos de produção de 2017, 2018 e 2019	42
Tabela 3 -Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2017	48
Tabela 4 -Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2018	49
Tabela 5 -Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2019	50
Tabela 6 -Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2017	51
Tabela 7 -Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2018	53
Tabela 8 -Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2019	54
Tabela 9 -Correlação de Pearson dos Índices de Vegetação utilizados como métricas de vigor e densidade vegetativa da área de estudo 1 e 2 para o ano de 2017, 2018 e 2019	55
Tabela 10 -Correlação de Pearson dos Índices de Vegetação utilizados como métricas fatores que ajudam a minimizar interferências externas da área de estudo 1 e 2 para o ano de 2017, 2018 e 2019	56
Tabela 11 -Médias de índices (K = 2) do sensor proximal na área 1	65
Tabela 12 -Médias de índices (K = 2) do sensor orbital na área 1	65
Tabela 13 -Médias de índices (K = 2) do sensor proximal na área 2	67
Tabela 14 -Médias de índices (K = 2) do sensor orbital na área 2	68
Tabela 15 -Médias de índices (K = 3) do sensor proximal na área 1	70
Tabela 16 -Médias de índices (K = 3) do sensor orbital na área 1	70
Tabela 17 -Médias de índices (K = 3) do sensor proximal na área 2	73
Tabela 18 -Médias de índices (K = 3) do sensor orbital na área 2	73

SUMÁRIO

1	INTRODUÇÃO.....	21
2	REVISÃO DE LITERATURA.....	23
2.1	Viticultura de Precisão.....	23
2.2	Sensoriamento Remoto.....	24
2.2.1	Sensoriamento remoto orbital.....	25
2.2.1.1	Sensoriamento orbital com PlanetScope.....	27
2.2.2	Sensoriamento remoto proximal.....	28
2.2.2.1	Sensoriamento proximal com CropCircle ACS-430.....	28
2.3	Índices de Vegetação e Análise da Cobertura Vegetal.....	29
2.3.1	NDVI (<i>Normalized Difference Vegetation Index</i>).....	30
2.3.2	RVI (<i>Ratio Vegetation Index</i>)	31
2.3.3	SAVI (<i>Soil Adjusted Vegetation Index</i>).....	31
2.3.4	EVI2 (<i>Two-Band Enhanced Vegetation Index</i>).....	32
2.4	Caracterização de zonas homogêneas na viticultura de precisão.....	32
2.5	Geoestatística na Viticultura de Precisão.....	33
2.6	Algoritmo de Agrupamentos.....	34
3	MATERIAL E MÉTODOS.....	37
3.1	Área de estudo.....	37
3.2	Escolha do estágio fenológico.....	38
3.3	Aquisição de Dados.....	39
3.3.1	Aquisição dos dados de refletância do sensor proximal dos anos de 2017 a 2018 (<i>Crop Circle ACS-430</i>).....	39
3.3.1.1	Aquisição dos dados de refletância do sensor proximais do ano de 2019 (<i>Crop Circle ACS-430</i>).....	39
3.3.1.2	Resultados das coletas do ciclo de maturação do sensor proximal.....	39

3.3.2	Aquisição dos dados de refletância do sensor orbital (PlanetScope).....	41
3.4	Pré-processamento.....	42
3.4.1	Compatibilização Espacial de Dados Proximais e Orbitais via Krigagem Local.....	42
3.4.2	Índices de vegetação.....	43
3.5	Estatística Descritiva (média, SD, CV%).....	44
3.6	Correlação de Pearson.....	45
3.7	Análise de Agrupamento.....	46
3.7.1	Cálculo de <i>K-means</i>	46
4	RESULTADOS.....	48
4.1	Análise da Estatística descritiva.....	48
4.1.1	Refletância (ρ)	48
4.1.2	Índices de vegetação.....	51
4.2	Análise da correlação de Pearson.....	54
4.3	Delimitação das zonas homogêneas.....	57
4.3.1	Determinação do número de zonas homogêneas por meio do número de agrupamentos.....	57
4.3.2	Gráficos de PCA (Análise de Componentes Principais).....	60
4.3.2.1	Análise de Componentes Principais para 2 zonas homogêneas $k=2$	61
4.3.3	Mapas de zonas homogêneas.....	64
4.3.3.1	Zonas homogêneas de $k=2$, da área 1.....	64
4.3.3.2	Zonas homogêneas de $k=2$, da área 2.....	67
4.3.3.3	Zonas homogêneas de $k=3$, da área 1.....	69
4.3.3.4	Zonas homogêneas de $k=3$, da área 2.....	72
4.3.3.5	Mapas com 4 zonas homogêneas ($k= 4$) da área de estudo 1 e 2	75
5	DISCUSSÃO.....	76

5.1	Análise das refletâncias.....	76
5.2	Análise dos índices de vegetação.....	77
5.3	Análise da correlação de Pearson.....	77
5.4	Delimitação das Zonas Homogêneas.....	78
5.4.1	Determinação do Número de Agrupamentos.....	78
5.4.2	Análise de Componentes Principais (PCA)	79
5.4.3	Avaliação de Subdivisões Adicionais (K = 3 e K = 4)	79
5.4.4	Mapas de Zonas Homogêneas.....	80
6	CONCLUSÕES.....	81
	REFERÊNCIAS.....	83
	ANEXO A - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017.....	100
	ANEXO B - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018.....	100
	ANEXO C - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019.....	101
	ANEXO D - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017.....	101
	ANEXO E - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018.....	102
	ANEXO F - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019.....	102

1 INTRODUÇÃO

No cenário global, a agricultura de precisão consolidou-se na virada do milênio, com estudos voltados inicialmente para culturas de grãos, que abriram caminho para sua aplicação na fruticultura e em vinhedos (Zhang; Wang; Wang, 2002). Em regiões vinícolas da Europa e América do Norte, o uso dessas tecnologias tem demonstrado ganhos significativos em qualidade e uniformidade de colheita (Bongiovanni; Lowenberg-Deboer, 2004).

No Brasil, as primeiras iniciativas de agricultura de precisão surgiram no final dos anos 1990, voltadas principalmente à soja e ao milho (Cherubin *et al.*, 2022). A adoção em vinhedos ocorreu na década de 2010, quando Miele, Flores e Alba (2014) destacaram o potencial do sensoriamento remoto para o manejo zonal, marcando o início da viticultura de precisão (VP) no país.

A VP vem se destacando pela redução no uso de insumos químicos e pela maior sustentabilidade do sistema produtivo, com estudos apontando até 25% de economia em fertilizantes sem prejuízo à produtividade (Wample; Mills; Davenport, 1999). Além disso, o manejo localizado reduz impactos ambientais, como a lixiviação de nutrientes e a contaminação hídrica (Auernhammer, 2001).

Nesse contexto, o sensoriamento remoto se consolidou como uma ferramenta essencial. O uso de imagens orbitais amplia a cobertura e a frequência de monitoramento, permitindo a detecção precoce de estresses hídricos e nutricionais (Ammoniaci *et al.*, 2021). Constelações de nano-satélites, como a PlanetScope, com resolução espacial de 3 m e revisita diária, têm se mostrado promissoras para o monitoramento dinâmico de vinhedos (Moletto-Lobos *et al.*, 2024).

Complementando o monitoramento via satélite, o sensoriamento proximal é fundamental na viticultura de precisão por fornecer dados de alta resolução espacial e temporal diretamente no nível da planta, permitindo a detecção precoce de variações e reduzindo medições trabalhosas e repetitivas (Visacarra Rossel; Mcbratney; Minasny, 2010). Segundo Brillante *et al.* (2020), um dos métodos mais empregados no Sensoriamento proximal para capturar a variabilidade espacial em vinhedos é o Índice De Vegetação Por Diferencial Normalizada (NDVI) para avaliação do dossel.

A integração desses dados de satélite com outras informações resultantes de fontes heterogêneas aprimora as aplicações da agricultura de precisão, permitindo que façam escolhas informadas sobre o manejo de culturas, detecção de doenças, estratégias de irrigação e previsões de produtividade (Rahali *et al.*, 2025). Esse conceito integra ferramentas de sensoriamento remoto e proximal para mapear variáveis como vigor vegetativo, umidade e nutrientes, permitindo decisões agronômicas diferenciadas em cada parte do talhão.

Aplicando o algoritmo *K-means* aos índices de vegetação obtidos por sensores proximal e orbital, foi possível delimitar zonas homogêneas (ZH) espacialmente consistentes e estatisticamente distintas, refletindo tanto as variações sazonais quanto as diferenças entre as duas áreas estudadas. A análise da formação desses agrupamentos ao longo dos anos permitiu avaliar o comportamento das ZH geradas por cada sensor e suas respectivas capacidades de representar a variabilidade do vinhedo.

O estudo teve como objetivo identificar e comparar os padrões espaciais gerados por quatro índices de vegetação em duas áreas adjacentes, caracterizadas por diferentes níveis de uniformidade de vigor vegetativo. As análises foram realizadas em um vinhedo durante as safras de 2017 a 2019, utilizando o algoritmo *K-means* e métricas de validação de agrupamento. A partir dos resultados, foram geradas e comparadas diferentes configurações de ZH, a fim de determinar qual sensor e qual número de zonas apresentaram melhor desempenho na representação da variabilidade espacial do vigor vegetativo.

2 REVISÃO DE LITERATURA

2.1 Viticultura de Precisão

A viticultura de precisão (VP) baseia-se na agricultura de precisão (AP), integrando tecnologias avançadas para otimizar a gestão dos vinhedos (Miele *et al.*, 2010). Seu objetivo é monitorar a saúde, vigor e necessidades fisiológicas das videiras, ajustando o manejo conforme as condições específicas, melhorando a qualidade e a competitividade do vinho (Ammoniacci *et al.*, 2021).

A VP utiliza tecnologias como GPS, sensoriamento remoto e SIG para gerenciar a variabilidade no campo, ajustando o cultivo das videiras de acordo com as condições locais (Arnó Satorra *et al.*, 2009; Matese e Gennaro, 2015) e permitindo a identificação de zonas que produzem lotes mais homogêneos durante a colheita. Essa uniformidade é um fator crucial para a qualidade na indústria vinícola (Kontoudakis *et al.*, 2011).

Além disso, grande parte das pesquisas em viticultura de precisão tem focado no uso de dados obtidos por sensoriamento remoto, conforme destacado por Matese, Di Gennaro e Santesteban (2019). Essas técnicas são fundamentais para monitorar e analisar a variabilidade espacial e temporal nas áreas de cultivo, permitindo uma gestão mais eficiente dos vinhedos (Thenkabail, 2003). A detecção remota oferece dados confiáveis sobre a variação espacial por meio de características biofísicas, oferecendo suporte à tomada de decisões (Jones e Barnes, 2000).

Sendo assim a VP nos fornece informações detalhadas sobre o desenvolvimento da vegetação, condições do solo e outros fatores agronômicos, contribuindo para a otimização da produção (Jafarbiglu e Pourreza, 2022) medindo localmente a variação nos fatores que influenciam o rendimento e a qualidade das uvas (solo, topografia, microclima, saúde da videira etc.) e aplicação de tratamentos específicos para a cultura (Bramley, 2005).

A VP possibilita a redução de custos com insumos, como fertilizantes e pesticidas, além de minimizar impactos ambientais, aumentar a produtividade e otimizar a gestão de informações, tornando o monitoramento mais eficiente (Wample; Mills; Davenport, 1999). Com o avanço das tecnologias, sua aplicação tem se

expandido, permitindo a automação e a otimização da produção de uvas em vinhedos (Benelli *et al.*, 2024).

2.2 Sensoriamento Remoto

O sensoriamento remoto (SR) é caracterizado pela obtenção de informações sobre um objeto sem a necessidade de contato físico com ele, muitas vezes a grandes distâncias (Shiratsuchi *et al.*, 2014). São utilizados elementos essenciais como plataformas, satélites, aeronaves, drones e veículos terrestres autônomos. A escolha da plataforma varia conforme a aplicação, já que cada uma possui pontos positivos e negativos (Jafarbiglu; Pourreza, 2022).

O SR parte do princípio de que cada objeto possui uma assinatura única de reflexão e emissão de energia. Essa característica distinta permite a identificação e análise de diferentes alvos na superfície terrestre, como vegetação, solo e água (Novo, 1992). A aquisição de dados de SR envolve três elementos principais: a fonte de energia eletromagnética, o alvo e o sensor (Silva, 1978).

A aquisição de informações no sensoriamento remoto é baseada na captação de radiação eletromagnética (REM) que abrange todo o espectro, desde ondas de rádio, microondas, infravermelho, visível, ultravioleta, até raios X e gama (Liu, 2015). Formaggio e Sanches (2017) explicam que toda matéria reflete, absorve, transmite ou emite REM de forma única, uma folha vegetal parece verde porque a clorofila absorve a REM nas faixas azul e vermelho do espectro visível, mas reflete no verde.

A energia eletromagnética é emitida ou refletida pelo alvo, interage com a atmosfera e é captada pelo sensor, que registra as informações. Essa interação entre os componentes é essencial para a coleta e interpretação dos dados (Lillesand; Kiefer, 1987). As imagens geradas capturam, de forma sequencial, a intensidade média da energia eletromagnética refletida por uma área do terreno que correspondente ao tamanho do pixel (Crósta, 1993).

Cada imagem gerada pelo SR possui um tipo de resolução, que define a capacidade do sistema óptico, que é o conjunto de características que definem a qualidade da imagem capturada (Campbell, 1996). Isso inclui os quatro tipos de resolução: espectral (a capacidade de distinguir diferentes cores de luz), espacial (o

nível de detalhe no solo), radiométrica (níveis de intensidade de energia) e temporal (frequência de aquisição de dados) (Barbosa; Novo; Martins, 2019). Essas resoluções determinam a precisão e a utilidade das informações coletadas.

Segundo Formaggio e Sanches (2017), quando um sensor capta cenas, podem ocorrer interferências que reduzem a qualidade das imagens. Os ruídos mais comuns estão associados a fatores atmosféricos, falhas nos detectores e distorções causadas pela plataforma, rotação terrestre, esfericidade e relevo. Batista (2019), afirma que, para minimizar esses problemas, métodos de processamento digital são aplicados, melhorando significativamente a qualidade das imagens e facilitando sua análise e interpretação.

Nos últimos anos, o lançamento de satélites de nova geração elevou o sensoriamento remoto a um novo patamar na agricultura (Navrozidis *et al.*, 2018). Esses satélites oferecem maior resolução espacial e frequência de aquisição de dados, sendo amplamente utilizados na agricultura de precisão para detectar doenças, monitorar cultivos e gerenciar recursos hídricos (Wang *et al.*, 2025), possibilitando a coleta de dados que fornecem informações essenciais para agricultores e gestores (Salgadoe *et al.*, 2018).

De acordo com Queiroz *et al.* (2022), a escolha do tipo de sensor no SR deve ser orientada pelos objetivos do estudo, uma vez que não há uma regra única para sua definição. Para Lorenzetti (2015), os sensores orbitais, por exemplo, são eficazes para cobrir grandes áreas, mas podem apresentar limitações em resolução espacial e temporal. Queiroz *et al.* (2022), dizem que, os sensores proximais são geralmente utilizados em escalas locais exigem maior esforço para a aquisição de dados espectrais.

2.2.1 Sensoriamento remoto orbital

O sensoriamento orbital é a coleta de dados sobre a superfície terrestre por meio de sensores em satélites, que captam radiação eletromagnética refletida ou emitida pelos objetos/alvos (Zhang *et al.*, 2024). Com isso, permite-se o monitoramento de grandes áreas em diversas faixas espectrais, sendo aplicado na

agricultura, meio ambiente, urbanismo e segurança (Lorenzetti, 2015; Queiroz *et al.*, 2022).

Devido ao formato não perfeitamente esférico da Terra, a altitude de um satélite varia conforme sua posição na órbita. O eixo maior do globo é geralmente utilizado para descrever a altura orbital (Kidder; Von De Haar, 1995). O satélite move-se em uma órbita elíptica, mantida constante e controlada por ajustes na terceira dimensão, com referência a estrelas no espaço (Liu, 2015).

Conforme Pereira, Manea e Loureiro aponta (2021), a seleção da órbita de um satélite é um fator crítico, diretamente relacionado ao objetivo da missão. Os satélites são categorizados em diferentes tipos de órbita, como as baixas (LEO), médias (MEO) e geoestacionárias (GEO). Segundo Mota e Hinckel (2013), a manobra de transferência entre essas órbitas é um processo complexo que demanda um cuidadoso planejamento e a aplicação de sistemas de propulsão eficientes.

Esses satélites capturam dados e imagens em várias faixas espectrais, permitindo a observação e análise de características geográficas, ambientais e naturais da Terra de uma perspectiva global (Formaggio; Sanches, 2017). De acordo com Zanotta, Ferreira e Zortea (2019), os sensores acoplados em satélites orbitas capturando informações em várias faixas do espectro eletromagnético.

Os satélites utilizam sensores que podem ser divididos em duas principais categorias: sensores passivos e sensores ativos. Almeida e Oliveira (2010), afirmam que, os sensores passivos captam radiação natural refletida ou emitida pela superfície terrestre, enquanto sensores ativos emitem sua própria energia e registram o sinal refletido pelo alvo.

Com a combinação de diferentes bandas espectrais por meio de equações matemáticas é possível gerar imagens onde cada cor representa uma característica específica da paisagem (Crosta, 1999). Por exemplo, faixa do vermelho é sensível à absorção da clorofila nas plantas, permitindo avaliar a saúde da vegetação e detectar áreas com problemas de crescimento (Jensen, 2009).

Nas plataformas orbitais, o imageador geralmente possui o formato de uma linha de células, e o movimento do satélite varre a superfície terrestre para a formação da imagem digital (Zhou *et al.*, 2015). O mecanismo de imageamento se baseia no princípio da técnica de imageamento por scanner multiespectral linear. A energia

refletida pela superfície do objeto ou alvo que é capturado pelo sensor embarcado no satélite (Rosa, 1990). Essas novas tecnologias de sensoriamento remoto orbital permitem o acesso a dados com resoluções espaciais cada vez maiores, facilitando assim o monitoramento e melhorando a tomada de decisão com maior assertividade e precisão (Blaschke e Kux, 2007).

Na agricultura, as imagens orbitais têm sido amplamente utilizadas para estudos de uso e ocupação do solo, análise do status nutricional dos dosséis das culturas, estimativa de biomassa em cultivos de dossel fechado, entre outros (Queiroz *et al.*, 2022). No entanto, apesar da ampla aplicabilidade das imagens orbitais na agricultura, algumas características como baixa resolução espacial e temporal, além da presença de nuvens nas cenas, podem limitar seu uso em determinadas situações (Queiroz *et al.*, 2022; Formaggio, 2017).

2.2.1.1 Sensoriamento orbital com PlanetScope

O sensoriamento orbital com a constelação de nanosatélites PlanetScope, que fornece imagens diárias com resolução espacial de aproximadamente 3 m, tem sido amplamente adotado para monitoramento agrícola de alta frequência. Em estudos de fenologia, séries temporais de NDVI derivadas do PlanetScope permitiram acompanhar as fases de desenvolvimento do trigo de inverno, mostrando correlações significativas com medições de campo realizadas por sensores GreenSeeker (Kokhan; Vostokov, 2019).

Em termos de precisão na estimativa de variáveis agronômicas, o PlanetScope demonstrou precisão moderada na predição de cobertura de dossel, rendimento e parâmetros de qualidade de grãos, como teor de proteína, em trigo cultivado sob condições mediterrâneas (Moletto-Lobos *et al.*, 2024). Estudos comparativos entre PlanetScope, Sentinel-2 e Landsat-8 indicaram que o PlanetScope apresenta maior sensibilidade a variabilidades de pequena escala na estimativa de rendimento de soja, destacando seu potencial para aplicações locais de zoneamento de manejo (Amankulova *et al.*, 2023).

A literatura também ressalta que a alta cadência diária e a disponibilidade global do PlanetScope favorecem o mapeamento dinâmico de zonas de manejo, possibilitando ajustes oportunos em aplicações de taxa variável de insumos. Segundo

a revisão técnica de Frazier e Hemingway (2021), o uso de dados de satélites como o PlanetScope tem reduzido o intervalo entre detecção de estresse hídrico e implementação de medidas de correção em lavouras comerciais.

2.2.2 Sensoriamento remoto proximal

O sensoriamento proximal se destaca por meio da técnica da espectroscopia de refletância. É uma abordagem que consiste na medição da refletância da radiação eletromagnética em diferentes comprimentos de onda, (Matese; Gennaro, 2015). Essa técnica envolve a coleta de dados em proximidade direta com o alvo de interesse, permitindo medições específicas no alvo (Homolová *et al.* 2013).

A resposta mais evidente observada por meio desses comprimentos de onda é o vigor vegetativo, que pode ser avaliado por índices de vegetação (Ammoniacci, *et al.*, 2021). A aplicação do sensoriamento proximal revela-se especialmente eficaz no monitoramento de vinhedos de pequena extensão, apresentando vantagens distintas em relação ao sensoriamento remoto orbital (Guadie *et al.*, 2015).

Esses sensores são capazes de obter a refletância do dossel vegetal em comprimentos de onda específicos que são chamados de espectro eletromagnético (Shiratsuchi, 2011). O espectro eletromagnético é uma representação gráfica que mostra a distribuição da radiação em diferentes regiões, organizada por comprimento de onda e frequência (Silva *et al.*, 2024). Conforme Ribeiro, Silva e Silva (2016), essa representação se estende desde os raios cósmicos até as ondas de rádio, com faixas fragmentadas em canais com peculiaridades próprias.

2.2.2.1 Sensoriamento proximal com CropCircle ACS-430

O sensor ativo de proximidade CropCircle ACS-430 tem sido amplamente utilizado na VP para monitorar o vigor das videiras por meio de índices espectrais. Conforme descrito por Darra *et al.* (2021), o ACS-430 carrega sua própria fonte de iluminação modulados em pulsos, o que permite medir refletância nas bandas

Vermelha (670 nm) e infravermelho próximo (800 nm) sem depender da radiação solar incidente.

O ACS-430 projeta um feixe de luz com campo de visão em torno de 32° a 6°, iluminando uma área aproximada de 1,25 m × 0,25 m quando posicionado a 1 m de altura. Os dados brutos são digitalizados e registrados por três detectores, que podem ser equipados com filtros passa-banda de 12,5 mm personalizados para calibrar precisamente as bandas de interesse (vermelha e NIR) (Onley; Thompson; Hejl, 2023).

Em aplicações práticas na vinicultura, um estudo em vinhedos de Thompson Seedless mostrou forte correlação ($R^2 = 0,87$) entre o NDVI proximal obtido pelo CropCircle e o NDVI de satélite Sentinel-2 durante o estágio de véraison, provando-se efetivo para estimativas de produtividade futura (Darra *et al.*, 2021). Os autores destacam que, ao combinar dados multi-safra de 2017, foi possível delinear variações espaciais no estado fenológico e relacioná-las diretamente ao rendimento, permitindo práticas de manejo mais direcionadas.

O uso do CropCircle em VP integra-se a um sistema mais amplo de agricultura de precisão, combinando sensores proximais, dados de satélite e SIG para mapeamento de zonas de manejo.

2.3 Índices de Vegetação e Análise da Cobertura Vegetal

Os Índices de vegetação (IVs) buscam realçar informações sobre a fitomassa verde contidas em dados de reflectância espectral, procurando minimizar efeitos indesejáveis causados por solos, atmosfera e variações da geometria (Fomaggio e Sanches, 2017). Cientistas desenvolveram os IVs para monitorar e quantificar as condições e distribuições espaciais das vegetações, usando os dados digitais de reflectâncias espectrais da radiação eletromagnética (Liu, 2015).

Os IVs podem ser definidos como formulações matemáticas desenvolvidas a partir de dados espectrais obtidos por sensores remotos, principalmente nas bandas do vermelho e do infravermelho próximo (Fomaggio e Sanches, 2017). Geralmente, a superfície da vegetação absorve a radiação na faixa eletromagnética do vermelho, e reflete na faixa de infravermelho próximo (NIR). Nesse caso, o índice de vegetação

pode ser uma razão, diferença ou várias combinações entre os valores de reflectância de VIS e NIR (Liu, 2015).

Por trás dos índices de vegetação que utilizam as faixas espectrais do infravermelho próximo (NIR) e do vermelho (*Red*) existe uma explicação teórica. Queiroz (2022), explica que, isso ocorre porque quanto mais ativa a vegetação, maior a absorção de luz solar na região do vermelho e maior a reflexão na região do infravermelho próximo, decorrente de fatores físicos, como a estrutura celular das folhas.

As culturas agrícolas em geral se comportam como alvos anisotrópicos em relação aos processos de interação da radiação eletromagnética. Portanto, as respostas a essas interações ocorrem com intensidades diferenciadas conforme haja mudanças nos ângulos da fonte de radiação e do sensor utilizado (Myneni; Williams, 1994).

2.3.1 NDVI (*Normalized Difference Vegetation Index*)

O índice de vegetação da diferença normalizada (NDVI) foi proposto por Rouse *et al.* (1973), e é calculado pela divisão entre a diferença da reflectância do infravermelho e do vermelho pela soma das mesmas variáveis. O cálculo produz um número que varia de -1 a 1 (D'Oliveira *et al.*, 2023). De acordo com Gameiro *et al.* (2016), quanto maior o índice, mais próximos de +1, maior a quantidade de vegetação no local, já valores mais baixos, próximos de 0, indicam pouca atividade de clorofila. E valores negativos, mais próximos de -1, podem estar relacionados com a água.

Este índice pode ser analisado por meio da interpretação de imagens de sensores remotos e, em particular, por valores obtidos em diferentes datas, que permitem avaliar a variação da área verde em certo período (Zanzarini *et al.*, 2013). Portanto, o NDVI é um índice de vegetação, que varia de acordo com o desenvolvimento da planta nas várias estações do ano, foi derivado para se detectar o desenvolvimento da vegetação e para se estimar o rendimento de sua biomassa (Prince, 1991). O NDVI é calculado por meio da Equação 1:

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (1)$$

Onde ρ_{NIR} é a refletância da banda do infravermelho próximo, ρ_{Red} e a refletância da banda do Vermelho.

2.3.2 RVI (*Ratio Vegetation Index*)

Entre os índices simples mais conhecidos estão o simple ratio (SR), proposto por Jordan (1969). Também conhecido por índice de Vegetação da Razão (RVI). Podendo ser um bom indicador do crescimento da cultura e da estimativa da biomassa (Liu, 2015). Ele baseia-se na razão entre a banda do infravermelho próximo, onde os valores aumentam com o aumento da vegetação, e a banda do vermelho, onde os valores diminuem com o aumento da vegetação (Galvanin *et al.*, 2014).

O RVI próximo de zero está associado a água, neve e nuvens. Quando é menor ou igual a 1, é característico de rochas e solo exposto. Valores maiores que 1 estão associadas à vegetação, sendo que valores mais altos refletem maior vigor (D'Oliveira *et al.*, 2023). O RVI é obtido por meio da Equação 2:

$$RVI = \frac{\rho_{NIR}}{\rho_{Red}} \quad (2)$$

Onde ρ_{NIR} é a refletância da banda do infravermelho próximo, ρ_{Red} e a refletância da banda do Vermelho.

2.3.3 SAVI (*Soil Adjusted Vegetation Index*)

Huete (1988) propôs o Índice de Vegetação Ajustado para o Solo introduzindo um fator no NDVI para incorporar o efeito da presença do solo, mantendo-se o valor de NDVI dentro de -1 a +1. Na equação do SAVI, é inserida a constante L, para minimizar o efeito do solo. O valor de L igual a 0,25 indica vegetação densa; 0,5 é indicativo de vegetação com densidade intermediária; quando L é igual a 1, a vegetação é rala ou com baixa densidade. Quando L for zero, então os valores de SAVI são iguais aos do NDVI (Huete, 1988)

Fomaggio e Sanches (2017), afirmam que, o fator L foi encontrado por tentativa e erro, até ser identificado um fator que tivesse dado resultados com iguais IVs tanto para solos claros quanto para solos escuros. O SAVI é determinado pela Equação 3.

$$SAVI = (1 + L) \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red} + L} \quad (3)$$

Onde ρ_{NIR} é a refletância da banda do infravermelho próximo, ρ_{Red} e a refletância da banda do Vermelho.

2.3.4 EVI2 (*Two-Band Enhanced Vegetation Index*)

O EVI2 foi desenvolvido por Jiang *et al.* (2008) como uma versão simplificada do EVI original, eliminando a banda azul para viabilizar sua aplicação em sensores multiespectrais desprovidos desse canal. O objetivo principal era manter o alto grau de similaridade com o EVI de três bandas, sobretudo em condições de influência atmosférica reduzida e em diferentes classes de uso do solo, enquanto se assegurava continuidade entre plataformas como MODIS e AVHRR.

A equação do EVI2 é definida por:

$$EVI_2 = 2,5 * \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + (2,4 * \rho_{Red}) + 1} \quad (4)$$

onde ρ_{NIR} e ρ_{Red} representam, respectivamente, as refletâncias das bandas do infravermelho próximo e do vermelho. O coeficiente 2,4 funciona como um ajuste de linearidade, e o termo constante “1” atua como correção de fundo de solo, conferindo estabilidade à relação em áreas de cobertura clara.

2.4 Caracterização de zonas homogêneas na viticultura de precisão

As zonas homogêneas (ZH) são mapas georreferenciados que subdividem o vinhedo em áreas de condições uniformes (Ferro; Catania, 2023, p. 25). Geralmente são áreas com características semelhantes, como textura, topografia, estado hídrico e níveis de nutrientes do solo (Khosla *et al.*, 2008, p. 87). Elas são concebidas para refletir interações consistentes entre a videira e o ambiente, de modo que práticas agronômicas padronizadas dentro de cada zona maximizem eficiência e uniformidade de produção (Pereyra *et al.*, 2022).

A alta heterogeneidade entre diferentes variáveis químicas do solo torna o resumo em zonas únicas um desafio que envolve aspectos agronômicos, matemáticos e computacionais (Córdoba *et al.*, 2016) implicando em mudanças estruturais nos processos de geração e de tomada de decisão, quanto ao uso das tecnologias agrícolas, geoespaciais e das informações para fins agrícolas (Luchiari Junior *et al.*, 2011, p. 60). A delimitação de ZH é um elemento central na viticultura de precisão, pois

permite segmentar o vinhedo em sub-regiões com condições agronômicas homogêneas (Lark, 1998).

O manejo do solo por zonas possibilita redução nos custos com análises e insumos, uma vez que a utilização de grids amostrais não é mais necessária, desta forma, reduz-se o número de amostras (Bottega *et al.*, 2019, p. 12), sendo que as variabilidades espaciais do solo podem receber tratamento uniforme. Um talhão assim subdividido facilita a gerência de insumos que podem ser aplicados por meio de mapas de prescrição (Oliveira; Brandão; Rodrigues, 2022, p. 18).

As ZM podem ser definidas por meio de várias camadas de informação (Santos *et al.*, 2022, p. 34). Essa técnica pode ser usada em colhedoras de uva permitem medições mais detalhadas da variabilidade dentro do talhão. (Arnó *et al.*, 2009, p. 780). ao adaptar práticas como irrigação e adubação às exigências específicas de cada zona, aumenta-se a eficácia das operações no vinhedo, potencializando tanto o rendimento quanto a qualidade final das uvas (Tagarakis *et al.*, 2013).

2.5 Geoestatística na Viticultura de Precisão

A geoestatística surgiu a partir dos trabalhos de Matheron (1962), que estabeleceram os fundamentos teóricos para modelagem de variáveis espaciais como funções aleatórias. Posteriormente, Journel e Huijbregts (1978) ampliaram esses conceitos ao desenvolver ferramentas computacionais para krigagem e análise de variogramas, consolidando a geoestatística como disciplina essencial para análise espacial em diversas áreas (Journel; Huijbregts, 1978, p. 45).

A Geoestatística é uma classe de estatística usada para analisar e prever os valores associados a fenômenos espaciais ou espaço-temporais (Rodrigues *et al.*, 2020). Fundamenta-se na modelagem da dependência espacial por meio do variograma/ e semivariograma, que quantifica a autocorrelação entre pares de pontos separados por distância h , e na interpolação via krigagem, método de mínima variância e não enviesado, ou seja, aquele com menor variância (Webster; Oliver, 2014).

Na VP, a geoestatística é empregada para mapear variáveis como propriedades do solo e da planta, permitindo a definição de ZH de manejo (Rodrigues

et al., 2020). Filippini Alba, Flores e Miele (2012) aplicaram geoestatística e SIG para modelar espacialmente atributos de solo em um vinhedo de Merlot no Vale dos Vinhedos (RS), empregando malha regular de amostras e variogramas esféricos, exponenciais e gaussianos para delinear zonas de manejo.

Carvalho *et al.* (2003) utilizaram procedimentos de krigagem para caracterizar a variabilidade de atributos físico-químicos de solo sob videira em Espírito Santo do Pinhal (SP), concluindo que todos os atributos exibiram dependência espacial significativa. Costa (2015) definiram, via krigagem de índices de vegetação (NDVI), zonas de vigor vegetativo em um vinhedo irrigado, correlacionando mapas de vigor com pesos de poda e rendimento de cachos.

A geoestatística é essencial à viticultura de precisão por permitir mapear e quantificar de forma rigorosa a variabilidade espacial de solo, clima e vigor das videiras, possibilitando a divisão do vinhedo em ZH de manejo. Com isso, é possível direcionar insumos e tratamentos com maior exatidão, reduzir custos operacionais e minimizar impactos ambientais, além de apoiar decisões agrônômicas mais embasadas e eficientes.

2.6 Algoritmo de Agrupamentos

O método de agrupamento *K-means* foi idealizado originalmente no contexto da taxonomia numérica por Sokal e Sneath (1963), como uma forma de agrupar objetos com base em similaridades de características multivariadas, lançando as bases teóricas para métodos de partição de dados. Posteriormente, MacQueen (1967) formalizou o algoritmo em seu trabalho “Alguns métodos para classificação e análise de observações multivariadas”, apresentando a versão sequencial do *K-means* e demonstrando sua aplicabilidade para grandes conjuntos de dados.

O algoritmo *K-means* inicia-se com a escolha de k centroides iniciais, que podem ser selecionados aleatoriamente ou por métodos heurísticos (Xu; Wunsch, 2008). Em seguida, cada observação do conjunto de dados é atribuída ao centroide mais próximo, normalmente pela distância euclidiana (Morissette; Chartier, 2013). Após a atribuição, recalcula-se cada centroide como a média aritmética dos pontos alocados ao grupo.

Esse processo de atribuição e recomputação repete-se até que não haja mais alteração nos grupos ou até atingir um critério de convergência (Lloyd, 1982). Manualmente, isso significa recalcular médias e reatribuir pontos passo a passo> Algoritmicamente, implementa-se um laço que executa essas etapas de forma eficiente, com complexidade aproximada $O(NKT)$, onde N é o número de observações, K o número de agrupamentos e T o número de iterações (Jain; Dubes; Nguyen, 1988).

O *K-means* é amplamente utilizado pela sua eficiência, e por oferecer grupos interpretáveis por centroides prototípicos, sendo fundamental em mineração de dados, segmentação de mercado e compressão de imagem (Jain; Dubes; Nguyen, 1988; Pham *et al.*, 2005). A escolha de k pode ser guiada por métodos como cotovelo, silhueta e Gap Statistic. Segundo Oliveira (2018) tanto o número de grupos (k) quanto a inicialização dos centroides desses grupos são aspectos relevantes que afetam o desempenho do algoritmo.

Estudos relacionados a delimitação de ZM, na viticultura, concluíram que a fusão de imagens de VANT (UAV) com mapas de NDVI de satélite, seguida de agrupamento por *K-means*, resultou em três classes espaciais de vigor vegetativo, oferecendo um suporte para estratégias diferenciadas de irrigação e adubação (MAZZIA; Foglia *et al.*, 2020). Morari, Castrignanò e Pagliarina (2009), afirmam que, a combinação de análise geoestatística multivariada com fuzzy c-means permite gerar zonas compactas e contínuas, otimizando a aplicação variável de insumos.

Já a aplicação de *K-means* em conjunto com o Índice de Vegetação por Diferença Normalizada (NDVI) e variáveis edáficas (teor de argila, CTC e matéria orgânica) em olivicultura permitiu o delineamento de duas ZH de manejo capazes de reduzir em até 75 % a densidade de amostragem de solo necessária para monitoramento e tomada de decisão agrônômica (Bougiouklis *et al.*, 2025).

Em viticultura, o *K-means* contribui para a definição de zonas de manejo, permitindo agrupar áreas de vinhas com características semelhantes de solo, clima e produtividade (Karapetsas *et al.*, 2023; Schmidtke *et al.*, 2024, p. 380). Tais zonas permitem manejar insumos (água, nutrientes) de forma mais precisa, otimizar a qualidade da uva e reduzir impactos ambientais.

Também foi utilizada a técnica de análise de componentes principais (PCA), pois é uma técnica estatística multivariada amplamente utilizada em sensoriamento

remoto para reduzir a dimensionalidade de grandes conjuntos de dados, transformando as variáveis originais correlacionadas em um novo conjunto de variáveis ortogonais (componentes principais) ordenadas de acordo com a variância explicada, de modo a manter o máximo de informação possível enquanto facilita a visualização e interpretação dos padrões espaciais (Arun, 2022).

No gráfico de PCA, cada ponto (pixel ou amostra) é plotado nos dois primeiros componentes principais, que juntos costumam explicar a maior parte da variância total, permitindo avaliar a coesão e separação dos agrupamentos obtidos pelo *K-means*, valores elevados de variância explicada em PC1 e PC2 indicam que a projeção bidimensional retém bem a estrutura original dos dados (Shlens, 2014).

Em aplicações a índices de vegetação, a PCA tem demonstrado eficácia na identificação de zonas de estresse hídrico e fenológico, mostrando-se capaz de evidenciar padrões de variabilidade espacial relevantes para manejo agrônomo, como ilustrado no estudo de Corrales, Rejas e Farjas (2023), em que componentes principais derivados de imagens Landsat 8 permitiram destacar áreas com diferentes níveis de estresse vegetal no Parque Nacional Cerro Azul Meámbar.

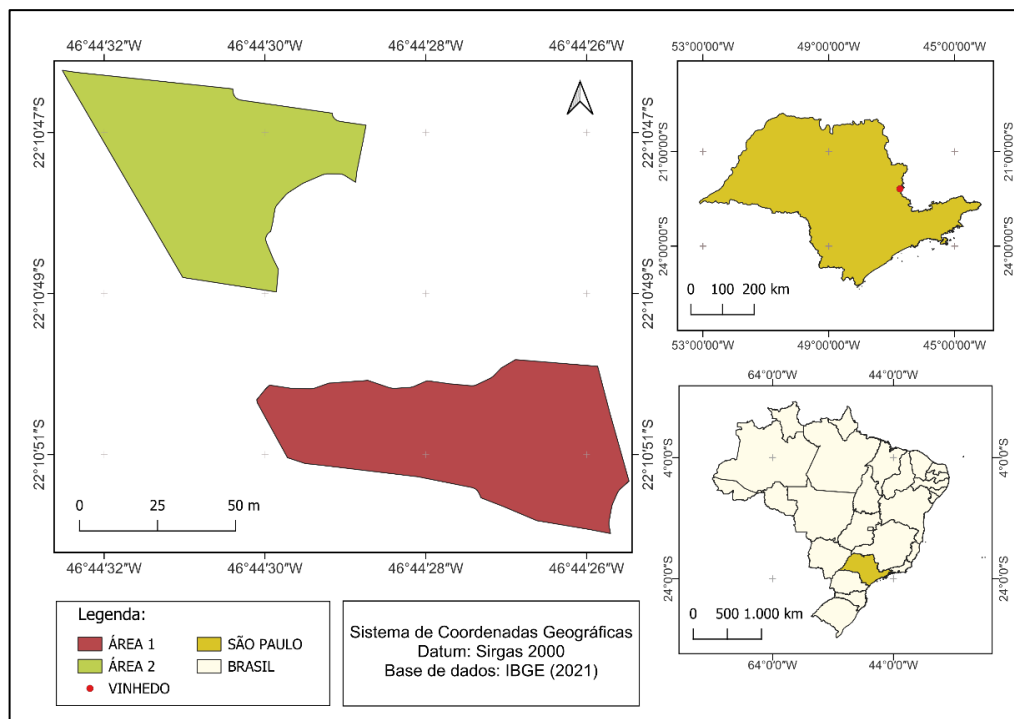
3 MATERIAL E MÉTODOS

3.1 Área de estudo

O vinhedo comercial de 1,1 ha situado a 22° 10' 49,1" Sul e 46° 44' 28,4" Oeste e em uma altitude média de 875 m, na Vinícola Guaspari, no município de Espírito Santo do Pinhal – SP, foi utilizado como objeto de estudo. Este mesmo vinhedo foi objeto de estudo de Oldoni (2019) e Silva (2020), com procedimentos de sensoriamento proximal para a determinação do índice de vegetação por diferença normalizada, delimitação de zonas de manejo (colheita) e coleta de dados referentes a produção de uvas para vinho de inverno.

O vinhedo foi implantado em 2008, onde as videiras *Vitis vinifera* L. cv. *Chardonnay* enxertadas sobre o porta-enxerto Paulsen 1103 foram plantadas no espaçamento de 2,5 entre fileiras e 1,0 m entre plantas (densidade de 4.000 plantas ha⁻¹), sustentadas em sistema de espaldeira e conduzidas em cordão Royat unilateral. As fileiras de plantas estavam orientadas na direção Leste-Oeste. O vinhedo encontrava-se dividido em duas áreas, as quais foram denominadas como área 1 e área 2 (Figura 2), sendo estas de 0,6 e 0,5 ha, respectivamente.

Figura 1 - Mapa de localização do vinhedo em estudo



Fonte: Elaborado pelo autor (2025)

As videiras foram cultivadas em ambiente irrigado por meio de sistema de gotejamento, dotado de uma linha lateral para cada fileira de plantas, um emissor a cada 0,5 m (dois emissores por planta), com vazão média aferida de 1,83 e 1,99 l h⁻¹ nas áreas 1 e 2, respectivamente, e uma válvula de derivação de água para cada área. O solo do vinhedo é classificado como Cambissolo Háplico, A moderado, e Neossolo Regolítico, A húmico, ambos eutróficos típicos, de textura argilosa com cascalho, apresentando na área 1 um complexo e na área 2 uma associação dos mesmos (Oldoni, 2019). Segundo a classificação de Köppen, o clima é Cwa, que se refere a climas subtropicais úmidos com invernos secos e verões quentes (Alvares *et al.*, 2013).

3.2 Escolha do estágio fenológico

Neste estudo, optou-se pela avaliação no estágio fenológico de maturação, pois é um dos estágios mais críticos, logo está associada a mudanças significativas na composição bioquímica das folhas e dos frutos, influenciando diretamente os valores de reflectância em diferentes bandas espectrais.

Neste estudo, foram avaliados separadamente os sensores proximal e orbital, com o objetivo de comparar sua eficiência na caracterização espectral da videira durante o estágio de maturação. Os sensores orbitais, embarcados em satélites, possibilitam o monitoramento em larga escala e contínuo ao longo do tempo, sendo úteis para analisar a variabilidade espacial e temporal da maturação. Contudo, sua resolução espacial e espectral pode limitar a detecção de variações sutis dentro do vinhedo.

Por outro lado, os sensores proximais, instalados em plataformas terrestres, fornecem medições em alta resolução, permitindo uma caracterização mais detalhada da reflectância das folhas e dos frutos. Essa abordagem possibilita compreender melhor as diferenças espectrais locais e capturar a variabilidade entre talhão com maior precisão. A análise individual das duas plataformas possibilitou identificar as vantagens e limitações de cada uma, contribuindo para avaliar seu potencial no monitoramento do vigor vegetativo e da maturação da videira.

3.3 Aquisição de Dados

3.3.1 Aquisição dos dados de refletância do sensor proximal dos anos de 2017 a 2018 (*Crop Circle ACS-430*)

Estas medidas de refletância do dossel foram realizadas por Oldoni (2019), com o objetivo de conhecer o comportamento espaço-temporal do índice NDVI durante os ciclos de produção.

Os dados foram adquiridos com um sensor ativo *Crop Circle ACS-430* (Holland Scientific Inc., Lincoln, NE, EUA) (

), por meio de caminhamentos em todas as fileiras de plantas, exceto no primeiro dia de leitura (41 dapp de 2017), quando as medições foram pontuais, a cada quatro plantas, em fileiras intercaladas. Durante todo o processo, o sensor foi posicionado na parte superior do dossel das videiras, a aproximadamente 0,3 m do topo, realizando 10 aquisições por segundo (Oldoni, 2019).

Figura 2 - Sensor *Crop Circle ACS-430* (Holland Scientific Inc., Lincoln, NE, EUA) acoplado a um receptor GNSS HiPer® GGD (TOPCON, Pleasanton, CA, EUA) (A) e aquisição de dados de reflectância do dossel de videiras por caminhada (B)



Fonte: Costa (2018), Apud Oldoni (2019, p. 29)

Oldoni (2019) também realizou o georreferenciamento dos valores de NDVI coletados no vinhedo utilizando receptores GNSS HiPer® GGD (TOPCON,

Pleasanton, CA, EUA) em configurações Base e Rover, para aprimorar a precisão posicional em tempo real pelo método RTK (Real Time Kinematic). No campo, o receptor rover foi acoplado ao datalogger do conjunto Crop Circle, enquanto o receptor base permaneceu fixo no ponto central da área estudada. Além disso, Oldoni coletou as coordenadas geográficas das primeiras e últimas plantas de cada fileira via GNSS-RTK, permitindo a determinação posterior do perímetro e a localização individual de cada planta em cada setor do vinhedo.

3.3.1.1 Aquisição dos dados de refletância do sensor proximais do ano de 2019 (Crop Circle ACS-430)

Para a aquisição dos dados de reflectância em 2019, Silva (2020), onde realizou caminhamentos por toda a área com o sensor *Crop Circle ACS-430* posicionado na parte superior do dossel das videiras, a aproximadamente 0,3 m do topo, registrando em média 10 aquisições por segundo. Usando a mesma metodologia de Oldoni (2019).

3.3.1.2 Resultados das coletas do ciclo de maturação do sensor proximal

A Tabela 1 reúne as datas em que o vinhedo '*Chardonnay*' atingiu o estágio fenológico de maturação nos ciclos de produção de 2017, 2018 e 2019. Observa-se que, no ciclo de 2017, a maturação ocorreu em 6 de abril; no ciclo de 2018, em 15 de abril; e, finalmente, em 22 de abril de 2019.

Tabela 1 - Datas dos estádios de maturação fenológico de vinhedo '*Chardonnay*' durante os ciclos de produção de 2017, 2018 e 2019

Estádio Fenológico	2017	2018	2019
Maturação	6 abril	15 abril	22 abril

Fonte: Oldoni (2019, p. 26); Silva (2020, p. 38).

3.3.2 Aquisição dos dados de refletância do sensor orbital (PlanetScope)

Para a análise dos ciclos de produção de 2017 a 2019, selecionaram-se cenas PlanetScope obtidas por uma constelação de aproximadamente 130 nanosatélites CubeSats, que fornecem cobertura diária de toda a superfície terrestre com resolução espacial nominal de 3 metros por pixel e quatro bandas espectrais (azul, verde, vermelho e infravermelho próximo), tendo como fonte a RedeMAIS/MJSP Esses produtos Analytic Ortho Scene (Level 3B) são voltados a aplicações quantitativas e passam por processamento que inclui calibração radiométrica, ortorretificação e correção atmosférica, garantindo alta qualidade para análises de índices de vegetação (PLANET LABS, 2023).

As cenas foram escolhidas de acordo com critérios de qualidade (“standard”) definidos pela Planet Labs, que exigem ângulo de elevação solar (`sun_elevation`) maior ou igual a 10° e ângulo fora-de-nadir (`view_angle`) inferior a 20° , com menos de 20% de pixels saturados, conforme consta na propriedade GeoJSON “`quality_category`”. Adicionalmente, limitou-se a cobertura de nuvens estimada (metadata field “`cloud_cover`”) a menos de 10% para assegurar visibilidade adequada do dossel vegetal.

No processamento radiométrico, cada cena Analytic é submetida a correções de darkfield/offset para remover viés de sensor e ruído escuro, utilizando tabelas mestras criadas a partir de coletas on-orbit em diferentes faixas de temperatura ((PLANET LABS, 2023; Roy *et al.*, 2021). Em seguida, os valores originais de 12 bits são ajustados para um intervalo de 16 bits, convertendo-se valores de número digital (DN) em radiância no topo do sensor (TOAR) e, por meio de coeficientes do arquivo XML, em reflectância no topo da atmosfera (TOA) (PLANET LABS, 2023).

A correção geométrica envolve ortorretificação via coeficientes polinomiais racionais (RPCs), alinhamento de bandas e projeção cartográfica para sistema UTM, sendo empregadas tanto informações de telemetria do satélite quanto pontos de controle no terreno (GCPs) e Modelos Digitais de Elevação (DEM) de alta resolução (30–90 m), resultando em precisão métrica inferior a 10 m RMSE no percentil 90.

O resultado inclui, além do arquivo principal GeoTIFF, máscaras de dados utilizáveis (UDM2) que identificam pixel a pixel regiões claras, sombreadas, com neblina ou cobertas por nuvens, permitindo filtrar áreas não confiáveis na análise de índices vegetação. Com isso, as cenas escolhidas próximas às datas de maturação

(Tabela 1) oferecem coerência temporal e espacial para avaliar o comportamento do NDVI e classificar zonas de vigor no vinhedo ao longo dos três anos estudados.

Tabela 2 - Datas de obtenção das imagens obtidas mais próximas aos estádios de maturação fenológico de vinhedo ‘Chardonnay’ durante os ciclos de produção de 2017, 2018 e 2019

Estádio fenológico	2017	2018	2019
Maturação	5 de abril	13 de abril	21 de abril

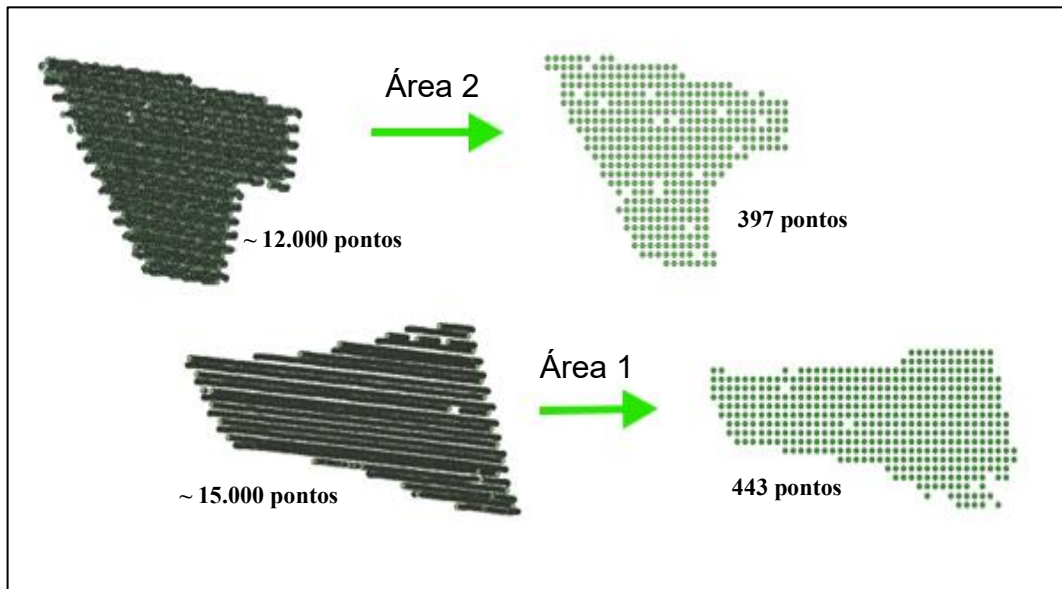
3.4 Pré-processamento

3.4.1 Compatibilização Espacial de Dados Proximais e Orbitais via Krigagem Local

Para compatibilizar espacialmente os dados de sensor proximal com as imagens PlanetScope de 3 m, utilizou-se o software Vesper 1.62 (Nasny; Mcbratney; Whelan, 2005) em seu modo de krigagem local, que ajusta automaticamente um variograma para cada ponto de interpolação a partir dos vizinhos mais próximos. Esse procedimento é especialmente indicado quando se trabalha com alta densidade amostral, no nosso caso, mais de 12.000 pontos por área, pois minimiza efeitos de heterogeneidade espacial que comprometeriam um modelo global de variograma e mantém a viés de estimativa dentro de limites aceitáveis (Oliveira; Grego; Brandão, 2022).

Enquanto a krigagem típica visa estimar valores em pontos onde não há dados (cenário de baixa densidade amostral) para aumentar a resolução de uma superfície, aqui o objetivo foi o oposto: reduzir a resolução de um conjunto já superamostrado, consolidando-o em uma grade regular de 3 m (Figura 3). Essa inversão de fluxo requer menos iteração manual na escolha de modelos de variograma globais, pois o modo automático do Vesper calcula e ajusta parametricamente os modelos para cada janela local sem intervenção do usuário.

Figura 3 - Reamostragem dos pontos no Vesper 1.62 da área 1 e 2



A krigagem com variograma automático usa algoritmos otimizados para estimar semivariogramas e parâmetros (alcance, patamar e pepita) em cada ponto de predição, empregando funções objetivo inteligentes e métodos como máxima verossimilhança para refinar iterativamente esses valores (Saavedra; Deutsch, 2024). Comparado a ajustes manuais repetitivos para cada local, o modo automático reduz o tempo de processamento e evita a instabilidade de modelos complexos (ex.: Gaussiano) que podem falhar em regimes de ajuste sem supervisão (Carvalho; Costa, 2021)

A reamostragem para a malha de 3 m foi implementada definindo-se um grid regular com espaçamento 3 metros em coordenadas UTM. Para cada nó dessa grade, o Vesper calcula os pesos e gera o valor estimado compondo assim um Raster GeoTIFF compatível com a grade amostral do PlanetScope.

3.4.2 Índices de vegetação

A escolha das bandas de infravermelho próximo (*NIR*) e vermelho (*Red*) baseou-se em sua compatibilidade espectral tanto com o sensor ativo *Crop Circle ACS-430* quanto com as imagens PlanetScope. O ACS-430 opera em três bandas principais, incluindo o canal *Red*, em 670 nm, e o canal *NIR*, em 880 nm. Já a constelação PlanetScope, com banda *Red* em 650–670 nm e *NIR* em 780–860 nm.

Foram calculados quatro índices de vegetação: NDVI (Normalized Difference Vegetation Index), que indica a densidade e saúde da vegetação; RVI (Ratio Vegetation Index), utilizado para avaliar vigor relativo; EVI2 (Two-Band Enhanced Vegetation Index), sensível a variações de clorofila e capaz de reduzir efeitos atmosféricos e do solo; e SAVI (Soil Adjusted Vegetation Index), que minimiza a influência do solo em áreas com cobertura vegetal baixa.

Para assegurar a geração apenas de índices de vegetação utilizáveis por ambos os sensores, selecionaram-se fórmulas que empregam exclusivamente as bandas Red e *NIR*. Essa escolha permite aproveitar ao máximo a congruência espectral entre os dados. Qualquer índice que dependesse de bandas não disponíveis em um dos sensores (exemplo: banda Blue ou Red Edge) foi descartado. Dessa forma, mantêm-se a consistência do cálculo e evitam-se vieses decorrentes de diferenças espectrais, o que é fundamental em estudos comparativos multianuais.

A transformação das bandas em índices de vegetação foi realizada no QGIS 3.34.9 (QGIS DEVELOPMENT TEAM, 2024) por meio da ferramenta calculadora Raster, que aceita expressões matemáticas definidas. Para cada expressão criada, uma para cada índice desejado, o QGIS gerou um novo raster GeoTIFF, mantendo a projeção original e a resolução especificada. Esse procedimento permitiu processar em lote todas as datas selecionadas, aplicando as mesmas configurações de cálculo e exportação para cada cena.

Área de processamento padronizada, bandas compatíveis e uso da calculadora Raster do QGIS 3.34.9 formaram, portanto, a base metodológica para transformar as reflectâncias Red e *NIR* em índices de vegetação comparáveis entre dados proximais e orbitais. Esse fluxo simplificou a análise multiescala e garantiu a integridade dos resultados.

3.5 Estatística Descritiva (média, SD, CV%)

A estatística descritiva foi aplicada para caracterizar o conjunto de dados analisado, utilizando métricas que permitem compreender a distribuição e a variabilidade das informações. Foram calculados os seguintes parâmetros estatísticos: média, valor máximo, valor mínimo, amplitude, desvio padrão (SD) e coeficiente de variação (CV%).

A média foi determinada pela soma de todas as observações dividida pelo número total de elementos, representando a tendência central dos dados. O máximo e o mínimo foram obtidos a partir dos valores extremos do conjunto de dados, e a amplitude foi calculada pela diferença entre esses valores, indicando a variação total observada.

Para avaliar a dispersão dos dados, foi calculado o desvio padrão (SD), que quantifica o grau de variação em relação à média. Além disso, o coeficiente de variação (CV%) foi utilizado para expressar essa dispersão em termos percentuais, permitindo uma análise comparativa entre diferentes conjuntos de dados. A classificação da variabilidade dos dados em relação à média foi realizada com base nos valores do coeficiente de variação (CV). De acordo com Wilding (1985), a variabilidade é considerada baixa para $CV \leq 15\%$, moderada para $15\% < CV \leq 35\%$ e alta para $CV > 35\%$.

3.6 Correlação de Pearson

Para a análise da relação linear entre as variáveis, foi utilizada a Correlação de Pearson, a qual mede a intensidade e a direção da associação entre variáveis quantitativas. A análise foi conduzida no software R (R Core Team, 2024), versão 4.3.3, utilizando o pacote ggplot2 para a visualização dos resultados.

Inicialmente, os dados foram verificados quanto à presença de outliers, normalidade e linearidade, condições essenciais para a aplicação da correlação de Pearson. A normalidade das variáveis foi avaliada por meio do teste de Shapiro-Wilk, assim como descrito por Devore (2006, p. 473), enquanto a linearidade foi inspecionada graficamente por meio de diagramas de dispersão gerados com o pacote ggplot2. Após essa etapa, o coeficiente de correlação de Pearson foi calculado e interpretado conforme a classificação tradicional, onde valores próximos de 1 indicam correlação positiva forte, valores próximos de -1 indicam correlação negativa forte e valores próximos de 0 sugerem ausência de relação linear.

3.7 Análise de Agrupamento

3.7.1 Cálculo de *K-means*

A análise foi conduzida inteiramente no ambiente RStudio, garantindo reprodutibilidade e rastreabilidade de todos os passos metodológicos. Inicialmente, cada variável foi submetida à padronização pelo método do Z-score, no qual se subtrai da medida bruta a média da variável e se divide pelo seu desvio-padrão. Essa transformação ajusta cada atributo para média zero e variância unitária, neutralizando diferenças de escala que poderiam fazer com que variáveis de maior dispersão dominassem o critério de minimização da soma dos quadrados dentro dos agrupamentos, elemento central do *k-means*.

Em seguida, o conjunto de dados padronizado foi segmentado em subconjuntos independentes por ano (2017, 2018 e 2019) e por área de estudo (Área 1 e Área 2). Essa divisão permitiu avaliar separadamente as dinâmicas temporais e espaciais, mantendo consistente o número de observações em cada grupo.

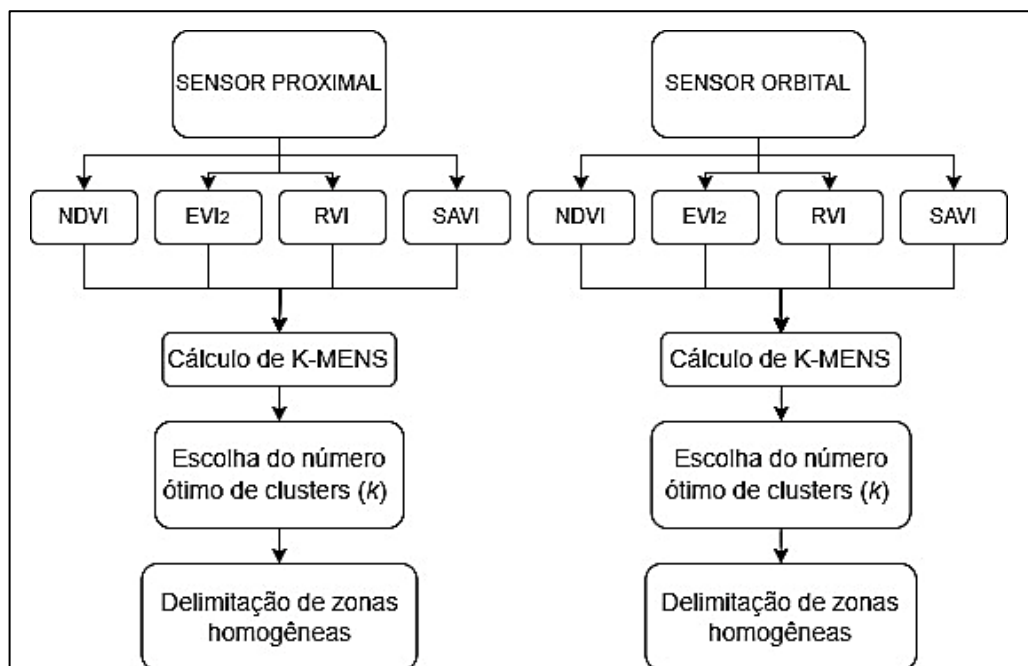
Para cada subconjunto, aplicou-se o algoritmo de partição *k-means*, cujo objetivo é alocar n observações em k agrupamentos ao minimizar a soma das distâncias quadráticas entre cada ponto e os centroides associado. O algoritmo inicia com a definição de k centroides em posições iniciais, selecionadas de forma aleatória diversas vezes, e procede por ciclos de atribuição: cada ponto é vinculado ao centroide mais próximo, e atualização: cada centroides é reposicionado na média aritmética dos pontos que lhe foram associados. A iteração prossegue até que a variação na soma dos quadrados dentro dos agrupamentos entre duas iterações consecutivas seja desprezível, indicando convergência (Forgy, 1965; Jain, 2010; Xu; Wunsch, 2008).

A escolha do número ótimo de agrupamentos (k) foi contabilizado por critérios internos de validação. Empregou-se o método do cotovelo para identificar o ponto de inflexão na curva de soma dos quadrados interna em função de k , e a silhueta média para quantificar a coesão e separação dos agrupamentos, com valores próximos de +1 apontando para partições bem definidas. Adicionalmente, avaliou-se a estabilidade dos agrupamentos por meio de execuções múltiplas com inicializações distintas, a fim de confirmar a robustez das configurações encontradas frente à aleatoriedade do processo.

Por fim, a consistência espacial dos agrupamentos foi validada através do coeficiente F1-Score, comparando os rótulos atribuídos pelo algoritmo. Esse índice corrige o acaso e fornece uma medida estatística do grau de concordância entre as duas tipificações. Os resultados permitiram a geração de mapas de zonas de manejo, refletindo distintas condições de cobertura e vigor vegetativo, com alta confiabilidade metodológica e aplicabilidade para práticas de monitoramento e manejo agrícola.

A Figura 4 apresenta de forma esquemática todo o processo de agrupamento via *k-means*, desde a obtenção e padronização dos índices de vegetação até a definição das ZH de manejo.

Figura 4 - Fluxograma de Delimitação de Zonas Homogêneas via *K-means*



4 RESULTADOS

4.1 Análise da Estatística descritiva

4.1.1 Refletância (ρ)

As Tabelas 3, 4 e 5 representam a análise da estatística descritiva os dados de refletância (ρ) nas faixas espectrais do Vermelho (ρ_{RED}) e Infravermelho Próximo (ρ_{NIR}) do sensor proximal *Crop Circle* e o sensor orbital da Planet. Os dados referem-se às áreas de estudo 1 com 443 pontos analisados e 2 com 397 pontos analisados, durante o estágio de maturação do ano de 2017, 2018 e 2019.

Os resultados obtidos na Tabela 3 do ano de 2017, mostraram que refletância média da banda *NIR* da área 1 foi de 37,01% no sensor proximal e 33,64% no sensor orbital. Já na área 2 a média da banda *NIR* foi de 37,38% no sensor proximal e 34,89% no sensor orbital. O coeficiente de variação (CV) manteve-se baixo ($CV \leq 15\%$), em torno de 3%, para ambas as áreas, demonstrando alta homogeneidade dos dados nessa banda.

Na faixa RED, a refletância média da área 1 do sensor proximal foi de 4,71%, e o sensor orbital foi de 10,04%. A área 2, apresentou valor médio de 4,52% no sensor proximal e 10,19% no sensor orbital. Contudo, o CV foi moderado ($15 < CV \leq 35\%$), especialmente na área 1 (17%) e baixo na área 2 (15%).

Tabela 3 - Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2017

ρ	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 1							
ρ_{NIR}	Prox.	37,01	39,18	33,74	5,44	1	3
	Orb.	33,64	35,74	31,37	4,37	0,8	2
ρ_{RED}	Prox.	4,71	8,22	3,36	4,86	0,8	17
	Orb.	10,04	12,36	8,78	3,58	0,7	7
Área 2							
ρ_{NIR}	Prox.	37,38	39,96	34,01	5,96	0,9	3
	Orb.	34,89	36,98	31,94	5,04	0,9	3
ρ_{RED}	Prox.	4,52	7,26	3,16	4,10	0,7	15
	Orb.	10,19	12,54	8,58	3,96	0,8	8

ρ : Refletância; Faixa de RED e *NIR* em (%); SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital.

Com relação a banda *NIR* no ano de 2018 (Tabela 4), o sensor proximal manteve valores médios de refletância mais elevados em ambas as áreas, como observado em 2017. Na área 1, a refletância média foi de 36,48% no sensor proximal e de 32,31% para o sensor orbital. Já a área 2 o sensor proximal registrou uma média ligeiramente superior, de 37,48%, e o sensor orbital atingiu 29,57%. Todos os dados de refletância da área 1 e 2 foram considerados com baixa variação ($CV \leq 15\%$).

Em relação banda *RED* (Tabela 4), a média na área 1 foi de 4,15% para o sensor proximal e 6,77% para o sensor orbital. Na área 2, a média da banda *RED* foi de 3,97% no sensor proximal e 8,06% no sensor orbital. O *CV* também ficou classificado com de baixa variação.

Tabela 4 - Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2018

ρ	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 1							
ρ_{NIR}	Prox.	36,48	38,88	33,7	5,19	0,8	2
	Orb.	32,31	35,58	29,78	5,8	1,1	4
ρ_{RED}	Prox.	4,15	5,66	3,28	2,39	0,4	9
	Orb.	6,77	9,57	5,34	4,23	0,9	14
Área 2							
ρ_{NIR}	Prox.	37,48	40,25	34,86	5,39	1	3
	Orb.	29,57	32,73	26,52	6,21	1	3
ρ_{RED}	Prox.	3,97	5,54	3,04	2,5	0,4	11
	Orb.	8,06	9,93	6,84	3,09	0,6	7

ρ : Refletância; Faixa de *RED* e *NIR* em (%); SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital.

Na banda *NIR* (Tabela 5), os resultados para a Área 1 em 2019 não apresentaram mudanças significativas em relação aos anos anteriores. Para o sensor proximal, a média de refletância foi de 36,64%, ligeiramente próximo à média de 2018 (36,48%) e à de 2017 (37,01%). Já para o sensor orbital, a média foi de 34,72%, marcando um aumento em relação a 2018 (32,31%) e um retorno a valores próximos aos observados em 2017 (33,64%). Os dados continuaram sendo classificados como de baixa variação.

Na Área 2 (Tabela 5) no ano de 2019, o comportamento da banda *NIR* no sensor proximal, apresentou média de refletância de 37,33%, continuando na mesma faixa de refletância em relação a 2018 (37,48%) e 2017 (37,38%). O sensor orbital,

por outro lado, registrou uma média de 32% de refletância, superior a média de 2018 (29,57%) e inferior 2017 (34,89%). Os CV também continuaram na mesma faixa em comparação aos anos anteriores, 3% para o sensor proximal e 7% para o sensor orbital.

Na banda RED (Tabela 5), a média de refletância na área 1 foi de 4,3%, bem próxima ao de 2018 (4,15%) e à de 2017 (4,71%). Por sua vez, o sensor orbital apresentou uma média de 5,85%, marcando uma redução em relação a 2018 (6,77%) e 2017 (10,04%). Sendo que o sensor proximal apresentou um CV de 21%, com a mais alta variação em relação aos demais dados, mas ainda sim sendo considerado com uma variação moderado ($15 < CV \leq 35\%$). O sensor orbital contínuo na faixa de variação de 11%.

Na área 2, no sensor proximal apresentou uma média de 4,23%, próxima à de 2018 (3,97%) e à de 2017 (4,52%), e o sensor orbital registrou uma média de 6,44%, inferior à de 2018 (8,06%) e 2017 (10,19%). Com um CV sendo classificado como baixo, 15% para o sensor proximal e 14% para o sensor orbital.

Tabela 5 - Estatísticas descritivas para refletância referentes a área de estudo 1 e 2 no ano de 2019

ρ	Sensor	Média	Máximo	Mímimo	Amplitude	SD	CV%
Área 1							
ρ_{NIR}	Prox.	36,64	43,45	33,06	10,39	1,4	4
	Orb.	34,72	37,68	31,35	6,33	1,2	3
ρ_{RED}	Prox.	4,3	8,02	2,51	5,51	0,9	21
	Orb.	5,85	8,04	4,66	3,38	0,6	11
Área 2							
ρ_{NIR}	Prox.	37,33	40,89	33,62	7,27	1	3
	Orb.	32	37,79	28,17	9,62	2,2	7
ρ_{RED}	Prox.	4,23	6,65	2,73	3,92	0,6	15
	Orb.	6,44	9,18	4,62	4,56	0,9	14

ρ : Refletância; SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital.

4.1.2 Índices de vegetação

Para 2017, a Área 1 (Tabela 6) apresenta valores médios de NDVI mais altos quando obtidos por sensor proximal (0,78) em comparação ao orbital (0,54), evidenciando que o sensor proximal captura uma maior variabilidade espectral da vegetação próxima ao solo. Além disso, o coeficiente de variação (CV%) do NDVI proximal (5%) é ligeiramente superior ao orbital (4%), sugerindo maior heterogeneidade espacial percebida pelo sensor de campo. Essa tendência se reflete também nos demais índices: o RVI proximal (média 9,26; CV 17%) mostra maior amplitude (8,31) e desvio-padrão (1,5) do que o orbital (média 3,37; CV 7%), indicando sensibilidade do sensor proximal a variações de biomassa ou estrutura foliar. O EVI₂ e o SAVI seguem padrão semelhante, com médias superiores e CV ligeiramente maiores no sensor proximal, apontando para maior resolução espectral e influência do efeito de solo minimizado localmente.

Comparando as Áreas 1 e 2, nota-se que a Área 2 tem médias de NDVI quase idênticas entre sensores (0,79 vs. 0,55) e CV menores (3% prox.; 4% orb.), sugerindo homogênea cobertura vegetal e menos variabilidade topográfica ou de manejo. Já o RVI na Área 2 mantém valores médios e amplitudes ligeiramente mais altos no proximal (9,39) que na Área 1, mas com CV reduzido (12% vs. 17%), o que pode indicar maior uniformidade na biomassa. Tanto o EVI₂ quanto o SAVI seguem esse padrão de menor variabilidade na Área 2.

Tabela 6 - Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2017

(continua)

IV	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 1							
NDVI	Prox.	0,78	0,85	0,59	0,26	0	5
	Orb.	0,54	0,59	0,46	0,13	0	4
RVI	Prox.	9,26	12,89	4,58	8,31	1,5	17
	Orb.	3,37	3,88	2,73	1,15	0,2	7
EVI ₂	Prox.	1,63	1,85	1,17	0,67	0,1	7
	Orb.	1,00	1,12	0,83	0,29	0,05	5
SAVI	Prox.	0,39	0,42	0,29	0,13	0	5
	Orb.	0,27	0,29	0,23	0,06	0	4

Tabela 6 - Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2017

(conclusão)

IV	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 2							
NDVI	Prox.	0,79	0,85	0,70	0,15	0,0	3
	Orb.	0,55	0,60	0,48	0,12	0,0	4
RVI	Prox.	9,39	12,47	6,45	6,02	1,1	12
	Orb.	3,44	3,94	2,84	1,10	0,2	7
EVI ₂	Prox.	1,67	1,88	1,31	0,56	0,09	5
	Orb.	1,02	1,13	0,86	0,27	0,05	5
SAVI	Prox.	0,39	0,41	0,37	0,04	0,0	2
	Orb.	0,27	0,29	0,24	0,06	0,0	4

IV: Índice de Vegetação; SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital.

Na área de estudo 1, para 2018 (**Erro! Fonte de referência não encontrada.**), o NDVI médio obtido por sensor proximal (0,80) é superior ao obtido por sensor orbital (0,65), refletindo maior sensibilidade local do sensor de campo à biomassa. O coeficiente de variação (CV) do NDVI proximal (3%) é metade do observado no orbital (6%), sugerindo que os valores proximais são mais estáveis e menos influenciados por fatores atmosféricos. Para o RVI, o sensor proximal apresentou média de 9,22 com CV de 9%, enquanto o orbital alcançou média de 4,86 com CV de 13%, indicando maior dispersão relativa nos dados orbitais. O EVI₂ proximal (média 1,70; CV 3%) também se mostrou mais consistente que o orbital (média 1,29; CV 7%), assim como o SAVI (proximal CV 3% vs orbital CV 6%), reforçando a tendência de menor variabilidade e maior precisão dos sensores proximais em captar nuances de vegetação.

Na área de estudo 2, observa-se padrão similar: o NDVI proximal (0,81) supera o orbital (0,57) e mantém CV baixo (3% vs 4%). O RVI proximal (10,11; CV 12%) apresenta valores médios e dispersão ligeiramente superiores aos da Área 1, sugerindo maior heterogeneidade de biomassa, enquanto o orbital (média 3,68; CV 7%) revela maior variabilidade relativa. Para EVI₂ e SAVI, a Área 2 mantém médias mais altas nos dados proximais (EVI₂ = 1,74; SAVI = 0,40) com CV de 4% e 3%, respectivamente, em comparação ao orbital (CV de 5% para EVI₂ e 4% para SAVI).

Tabela 7 - Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2018

IV	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 1							
NDVI	Prox.	0,8	0,84	0,71	0,13	0	3
	Orb.	0,65	0,73	0,54	0,19	0	6
RVI	Prox.	9,22	11,75	6,33	5,42	0,9	9
	Orb.	4,86	6,43	3,37	3,06	0,6	13
EVI ₂	Prox.	1,70	1,85	1,14	0,39	0,06	3
	Orb.	1,29	1,50	1,00	0,49	0,09	7
SAVI	Prox.	0,39	0,42	0,35	0,06	0	3
	Orb.	0,32	0,36	0,27	0,09	0	6
Área 2							
NDVI	Prox.	0,81	0,85	0,73	0,13	0	3
	Orb.	0,57	0,63	0,52	0,11	0	4
RVI	Prox.	10,11	13,89	7,14	6,75	1,2	12
	Orb.	3,68	4,36	3,16	1,2	0,3	7
EVI ₂	Prox.	1,74	1,88	1,51	0,37	0,06	4
	Orb.	1,07	1,21	0,95	0,26	0,05	5
SAVI	Prox.	0,4	0,42	0,36	0,06	0	3
	Orb.	0,28	0,31	0,26	0,05	0	4

IV: Índice de Vegetação; SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital

Para 2019, na Área 1 (Tabela 8), o NDVI médio calculado pelo sensor proximal (0,79) é ligeiramente maior que o valor orbital (0,71), mas apresenta coeficiente de variação (CV) de 6% contra 3% no sensor orbital, indicando maior heterogeneidade espacial detectada localmente. O RVI proximal (média 10,17; CV 22%) exibe amplitude elevada (15,88) e dispersão muito maior do que o orbital (média 5,99; CV 9%), evidenciando sensibilidade a extremos espectrais. O EVI₂ proximal (1,68; CV 8%) e o SAVI (0,39; CV 6%) também mostram maior variabilidade que suas contrapartes orbitais, com CVs de 4% e 3%, respectivamente, sugerindo que o sensor de campo capta nuances de vegetação que o sensor remoto suaviza.

Na Área 2, observa-se padrão semelhante: o NDVI proximal (0,80) supera o orbital (0,66) e mantém CV menor (4% vs 7%), indicando maior consistência local. O RVI proximal (10,41; CV 14%) apresenta dispersão inferior ao da Área 1, possivelmente devido a manejo ou cobertura mais uniforme, enquanto o RVI orbital exibe CV ainda maior (18%), refletindo maior ruído atmosférico ou variações de

resolução. Para EVI2 e SAVI, os sensores proximais têm médias superiores (EVI2 = 1,70; SAVI = 0,39) e CVs de 5% e 4%, em comparação aos orbitais (CVs de 10% e 7%).

Tabela 8 - Estatísticas descritivas para os índices de vegetação (IVs) referentes a área de estudo 1 e 2 no ano de 2019

IV	Sensor	Média	Máximo	Mínimo	Amplitude	SD	CV%
Área 1							
NDVI	Prox.	0,79	0,89	0,6	0,29	0	6
	Orb.	0,71	0,76	0,63	0,13	0	3
RVI	Prox.	10,17	20,87	4,99	15,88	2,3	22
	Orb.	5,99	7,33	4,41	2,92	0,6	9
EVI ₂	Prox.	1,68	2,00	1,19	0,81	0,13	8
	Orb.	1,42	1,59	1,22	0,36	0,69	4
SAVI	Prox.	0,39	0,44	0,29	0,14	0	6
	Orb.	0,35	0,38	0,31	0,06	0	3
Área 2							
NDVI	Prox.	0,8	0,87	0,68	0,19	0	4
	Orb.	0,66	0,77	0,56	0,21	0	7
RVI	Prox.	10,41	14,76	5,44	9,32	1,5	14
	Orb.	5,08	7,55	3,59	3,96	0,9	18
EVI ₂	Prox.	1,70	1,94	1,35	0,58	0,09	5
	Orb.	1,31	1,61	1,06	0,54	0,13	10
SAVI	Prox.	0,39	0,43	0,33	0,1	0	4
	Orb.	0,33	0,38	0,28	0,1	0	7

IV: Índice de Vegetação; SD: Desvio padrão; CV%: Coeficiente de variação; Prox.: Sensor Proximal; Orb.: Sensor Orbital

4.2 Análise da correlação de Pearson

Na Área 1, observa-se em 2017 (Tabela 9) correlações moderadas, com o NDVI Proximal apresentando $r = 0,402$ em relação ao NDVI Orbital e $r = 0,404$ em relação ao RVI Orbital. De modo semelhante, o RVI Proximal atingiu $r = 0,442$ (NDVI Orbital) e $r = 0,445$ (RVI Orbital), indicando concordância intermediária entre sensores. No ano de 2018, houve um aumento significativo desses coeficientes, com o NDVI Proximal $r = 0,532$ (NDVI Orbital) e $r = 0,520$ (RVI Orbital), e o RVI Proximal $r = 0,502$ (NDVI Orbital) e $r = 0,496$ (RVI Orbital). Esse incremento sugere que, sob condições

de vegetação mais estáveis e com melhor qualidade de aquisição dos dados, a consistência espectral entre sensores melhora. Em 2019, entretanto, as correlações caíram novamente, sendo $r = 0,290$ e $r = 0,287$ para o NDVI Proximal em confronto com NDVI e RVI Orbitais, e $r = 0,234$ e $r = 0,229$ para o RVI Proximal. Essa diminuição aponta para maior divergência nas medições, possivelmente influenciada por variações ambientais atípicas ou diferenças de calibração e resolução entre o sensor proximal e o orbital.

Já na Área 2 (Tabela 9), os coeficientes de correlação foram substancialmente mais baixos. Em 2017, o NDVI Proximal registrou $r = 0,110$ em relação ao NDVI Orbital e $r = 0,101$ frente ao RVI Orbital, enquanto o RVI Proximal apresentou $r = 0,106$ (NDVI Orbital) e $r = 0,098$ (RVI Orbital), evidenciando fraca relação entre as medições de campo e de satélite. Em 2018, houve pequena melhora, com valores oscilando entre $r = 0,145$ e $r = 0,168$, porém ainda em patamares baixos. Em 2019, por fim, as correlações tornaram-se negativas: o NDVI Proximal apresentou $r = -0,047$ (NDVI Orbital) e $r = -0,096$ (RVI Orbital), e o RVI Proximal, $r = -0,052$ e $r = -0,101$, respectivamente. Essa inversão sugere a presença de ruído, possíveis interferências do solo ou práticas de manejo distintas que afetaram de forma diversa cada sensor.

Tabela 9 - Correlação de Pearson dos Índices de Vegetação utilizados como métricas de vigor e densidade vegetativa da área de estudo 1 e 2 para o ano de 2017, 2018 e 2019

IV Ano		NDVI Prox.	RVI Prox.
ÁREA 1			
NDVI Orb.	2017	0,402	0,442
	2018	0,532	0,502
	2019	0,290	0,234
RVI Orb.	2017	0,404	0,445
	2018	0,520	0,496
	2019	0,287	0,229
ÁREA 2			
NDVI Orb.	2017	0,110	0,101
	2018	0,153	0,168
	2019	-0,047	-0,096
RVI Orb.	2017	0,106	0,098
	2018	0,145	0,156
	2019	-0,052	-0,101

IV: Índice de Vegetação; Prox.: Sensor Proximal; Orb.: Sensor Orbital

A Tabela 10 apresenta as correlações de Pearson entre os índices EVI2 e SAVI obtidos por sensor proximal e suas contrapartes orbitais (EVI2 Orbital e SAVI Orbital) nas Áreas 1 e 2, ao longo dos anos de 2017, 2018 e 2019. Esses índices incorporam fatores que visam minimizar interferências externas, como efeito de solo e atmosfera.

Na Área 1, observa-se em 2017 correlações moderadas, com o EVI2 Proximal correlacionando-se com o EVI2 Orbital em $r = 0,489$, e o SAVI Proximal com o SAVI Orbital em $r = 0,400$. Em 2018, há ligeiro aumento, atingindo $r = 0,535$ (EVI2) e $r = 0,529$ (SAVI), sugerindo melhor alinhamento entre sensores, provavelmente em função de condições atmosféricas mais estáveis e menor ruído. Em 2019, as correlações diminuem para $r = 0,287$ (EVI2) e $r = 0,276$ (SAVI), indicando aumento na divergência, possivelmente devido a variações ambientais ou discretas diferenças de sensibilidade dos sensores às interferências externas.

Na Área 2, as correlações iniciais em 2017 (Tabela 10) são baixas, com $r = 0,021$ (EVI2) e $r = 0,084$ (SAVI), evidenciando fraca relação entre medições de campo e satélite. Em 2018, nota-se leve melhora para $r = 0,162$ (EVI2) e $r = 0,151$ (SAVI), embora ainda em níveis baixos, o que pode refletir melhorias na aquisição dos dados ou menor influência de ruídos externos. Contudo, em 2019, as correlações tornam-se negativas ($r \approx -0,05$ para ambos os índices), sugerindo possíveis efeitos de solo ou manejo que ainda impactam as medições de forma divergente.

Tabela 10 - Correlação de Pearson dos Índices de Vegetação utilizados como métricas fatores que ajudam a minimizar interferências externas da área de estudo 1 e 2 para o ano de 2017, 2018 e 2019

(continua)

IV	Ano	EVI2 Prox.	SAVI Prox.
AREA 1			
EVI2 Orb.	2017	0,489	0,401
	2018	0,535	0,527
	2019	0,287	0,278
SAVI Orb.	2017	0,488	0,400
	2018	0,537	0,529
	2019	0,289	0,276

Tabela 10 - Correlação de Pearson dos Índices de Vegetação utilizados como métricas fatores que ajudam a minimizar interferências externas da área de estudo 1 e 2 para o ano de 2017, 2018 e 2019

(conclusão)

IV	Ano	EVI ₂ Prox.	SAVI Prox.
AREA 2			
EVI ₂ Orb	2017	0,021	0,022
	2018	0,162	0,150
	2019	-0,057	-0,048
SAVI Orb.	2017	0,083	0,084
	2018	0,164	0,151
	2019	-0,056	-0,047

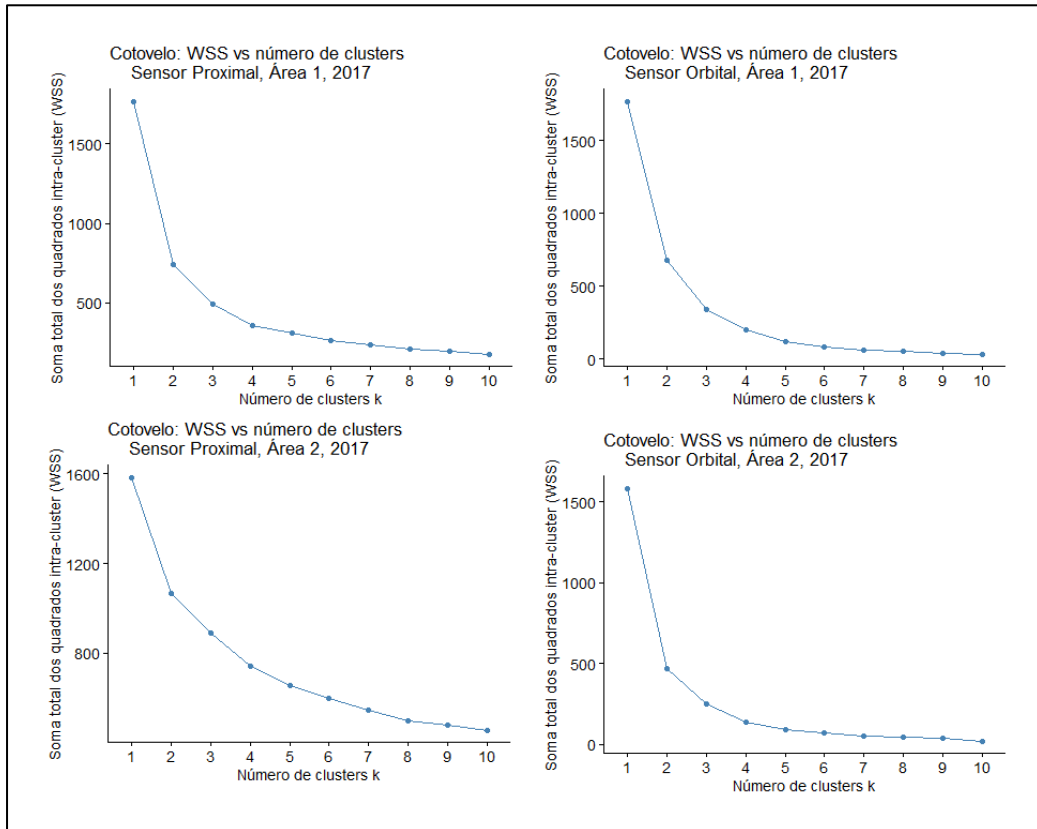
IV: Índice de Vegetação; Prox.: Sensor Proximal; Orb.: Sensor Orbital

4.3 Delimitação das zonas homogêneas

4.3.1 Determinação do número de zonas homogêneas por meio do número de agrupamentos


Analisando em conjunto os gráficos de cotovelo (Gráfico 1) e de silhueta (Gráfico 2) para o ano de 2017, nas duas áreas e em ambos os sensores, observa-se de forma consistente que a divisão em dois agrupamentos ($K = 2$) representa o melhor compromisso entre a compactação interna dos grupos e a sua separação mútua. No gráfico de cotovelo do sensor proximal na Área 1, a soma dos quadrados dentro dos agrupamentos cai bruscamente de cerca de 1.800 para 800 ao passar de $K = 1$ para $K = 2$, enquanto, a partir de $K = 3$, a redução torna-se muito menos acentuada, caracterizando claramente o “joelho” em $K = 2$. O mesmo padrão aparece no sensor orbital dessa mesma área, com queda expressiva até $K = 2$ e desaceleração subsequente, o que indica que subdivisões adicionais trazem ganhos marginais de compactação.

Gráfico 1 - Gráficos de cotovelo: WSS vs número de agrupamentos da área 1 e 2



Já os gráficos de silhueta (Gráfico 2) confirmam esse achado: no sensor proximal, Área 1, a largura média de silhueta salta de zero ($K = 1$) para aproximadamente 0,52 em $K = 2$, atingindo o valor máximo; à medida que K cresce, esse índice declina de forma contínua até cerca de 0,33 em $K = 10$, evidenciando perda progressiva de coesão interna e de distinção dentro dos agrupamentos. No sensor orbital, Área 1, a silhueta pula para cerca de 0,54 em $K = 2$ e depois mantém-se praticamente estável entre 0,53 e 0,58 para os valores superiores de K , chegando a um pico ligeiramente maior em $K = 9$, porém sem justificativa prática para a complexidade adicional.

Gráfico 2 - Silhueta média vs número de agrupamentos da área 1 e 2



a Área 2 do sensor proximal, embora o declive de WSS de $K = 1$ para $K = 2$ seja menos pronunciado do que na Área 1 (cai de aproximadamente 1.600 para 1.100), o ponto de “joelho” também se situa em $K = 2$ (Gráfico 1). A silhueta média atinge seu pico em torno de 0,29 para $K = 2$, havendo um segundo pico local em $K = 4$ (cerca de 0,28), mas ainda inferior ao de $K = 2$ (Gráfico 2). Isso sugere que, caso se deseje explorar subdivisões adicionais nessa área, $K = 4$ pode ser testado, embora com ganhos de separação menores. No sensor orbital da Área 2, o valor de silhueta chega a impressionantes 0,62 em $K = 2$, o maior entre todos os cenários analisados e cai gradualmente para cerca de 0,52 em $K = 7$, antes de uma leve recuperação, comprovando que duas classes já oferecem agrupamentos altamente coesos e bem distintos.

Diante desses resultados, foi gerado os mapas definitivos de ZH para $K = 2$ em todas as combinações de sensor e área, pois este valor equilibra de modo ideal a coesão e a separação dos grupos. Como complemento, foi produzido também os mapas com $K = 3$ e $K = 4$, a fim de avaliar se as subdivisões adicionais trazem algum

detalhe agrônômico relevante. A descrição dessas zonas deverá abordar suas localizações espaciais, a tonalidade correspondente ao valor médio do índice de vegetação e o significado prático de cada *Agrupamentos* no contexto de manejo de precisão.

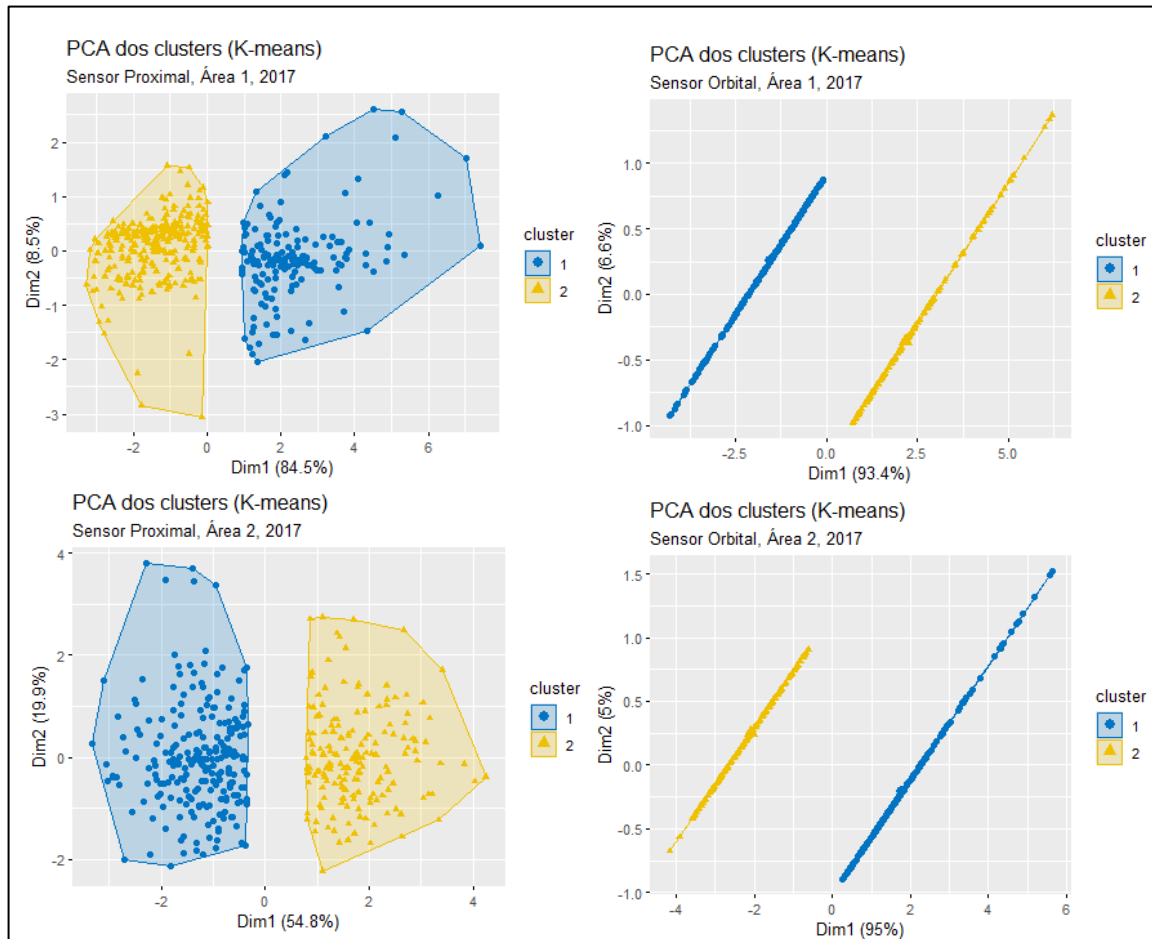
4.3.2 gráficos de PCA (Análise de Componentes Principais)

4.3.2.1 Análise de Componentes Principais para 2 zonas homogêneas $k=2$

A projeção das amostras nos dois primeiros componentes principais (Gráfico 3) no não de 2017 revela forte capacidade de discriminação dentro dos agrupamentos gerados pelo *K-means* em todos os cenários. No sensor proximal da Área 1, o componente 1 explica 84,5 % da variância e o componente 2, 8,5 %. Observa-se claramente que o Agrupamentos 1 (pontos azuis) e o Agrupamentos 2 (triângulos amarelos) ocupam regiões bem distintas: o primeiro concentra-se em valores positivos de PC1, enquanto o segundo se localiza na componente principal 1 (PC1) negativos, sem sobreposição significativa. Esse padrão indica alta homogeneidade interna e boa separação espacial entre as duas zonas, confirmando a escolha de $K = 2$ como ideal.

No sensor orbital da Área 1 (Gráfico 3), a PC1 retém 93,4 % da variância e na componente principal 2 (PC2), apenas 6,6 %, mas mesmo esse segundo componente é suficiente para mostrar agrupamentos linearmente separados. Os pontos azuis (Agrupamentos 1) alinham-se em um feixe que vai de valores negativos a positivos moderados de PC1, enquanto os triângulos amarelos (Agrupamentos 2) formam um feixe paralelo deslocado para a direita, sem qualquer intersecção. A quase total ausência de dispersão perpendicular ao eixo principal reforça a homogeneidade interna de cada zona.

Gráfico 3 - Análise de Componentes Principais (PCA) 2017, para k=2



Para o sensor proximal na Área 2 (Gráfico 3), os dois componentes explicam juntos 74,7 % da variância (54,8 % em PC1 e 19,9 % em PC2). Aqui nota-se uma distribuição mais ampliada em PC2, mas ainda assim há clara separação: o Agrupamentos 1 ocupa majoritariamente valores negativos de PC1 e varia verticalmente entre -2 e $+4$ em PC2, enquanto o Agrupamentos 2 fica em PC1 positivo, também com alcance similar em PC2. A forma poligonal em torno de cada nuvem de pontos evidencia agrupamentos relativamente compactos, embora com ligeira sobreposição marginal na região central de PC2.

Finalmente, no sensor orbital da Área 2 (Gráfico 3), PC1 retém 95 % da variância e PC2 apenas 5 %, resultando em dois feixes quase unidimensionais e estritamente paralelos. Os pontos azuis (Agrupamentos 1) alinham-se em PC1 elevados, enquanto os amarelos (Agrupamentos 2) seguem o mesmo vetor em PC1 menores, sem qualquer cruzamento. Essa configuração reforça que duas zonas

capturam quase toda a heterogeneidade espacial, sem ganho real em subdivisões superiores.

Nos gráficos de PCA referentes a 2018 com $K = 2$ (Gráfico 4), observa-se novamente forte capacidade de discriminação entre as duas ZH em todas as combinações de sensor e área, conferindo respaldo visual à escolha de duas classes.

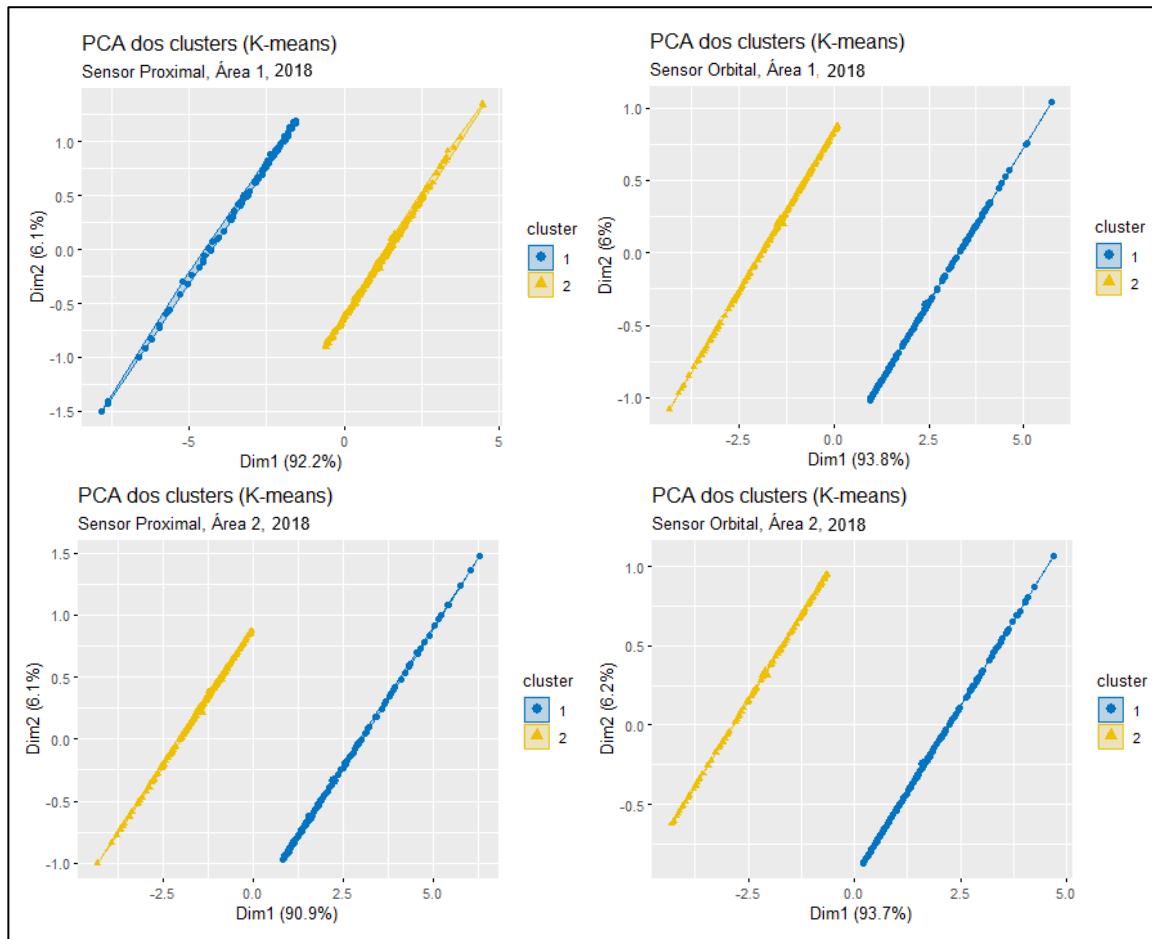
No sensor proximal, Área 1, os dois primeiros componentes explicam juntos 98,3 % da variância (92,2 % em PC1 e 6,1 % em PC2). Os pontos do Agrupamentos 1 (azuis) formam um feixe linear à esquerda do plano, enquanto os do Agrupamentos 2 (amarelos) alinham-se paralelamente, deslocados à direita, sem sobreposição perceptível. Essa configuração unidimensional reforça a homogeneidade interna de cada grupo e evidencia clara separação espacial.

Para a Área 2 do sensor proximal (Gráfico 4), PC1 explica 90,9 % da variância e PC2, 6,1 %, totalizando 97,0 %. Mais uma vez, dois feixes lineares e paralelos aparecem, mas com orientação invertida (Agrupamentos 1 à direita e Agrupamentos 2 à esquerda). A consistência desse padrão revela que as zonas diferenciadas mantêm perfis de índice muito distintos e coerentes em ambas as áreas.

No sensor orbital, Área 1 (Gráfico 4), PC1 retém 93,8 % da variância e PC2, 6,0 %. Aqui noto padrão semelhante: dois feixes quase unidimensionais e paralelos, com o Agrupamentos 2 deslocado para valores negativos de PC1 e o Agrupamentos 1 para valores positivos, sem interseção. A extraordinária retenção de variância em PC1 implica que quase toda a estrutura dos índices de vegetação se expressa num único eixo, e $K = 2$ capturas perfeitamente essa dicotomia.

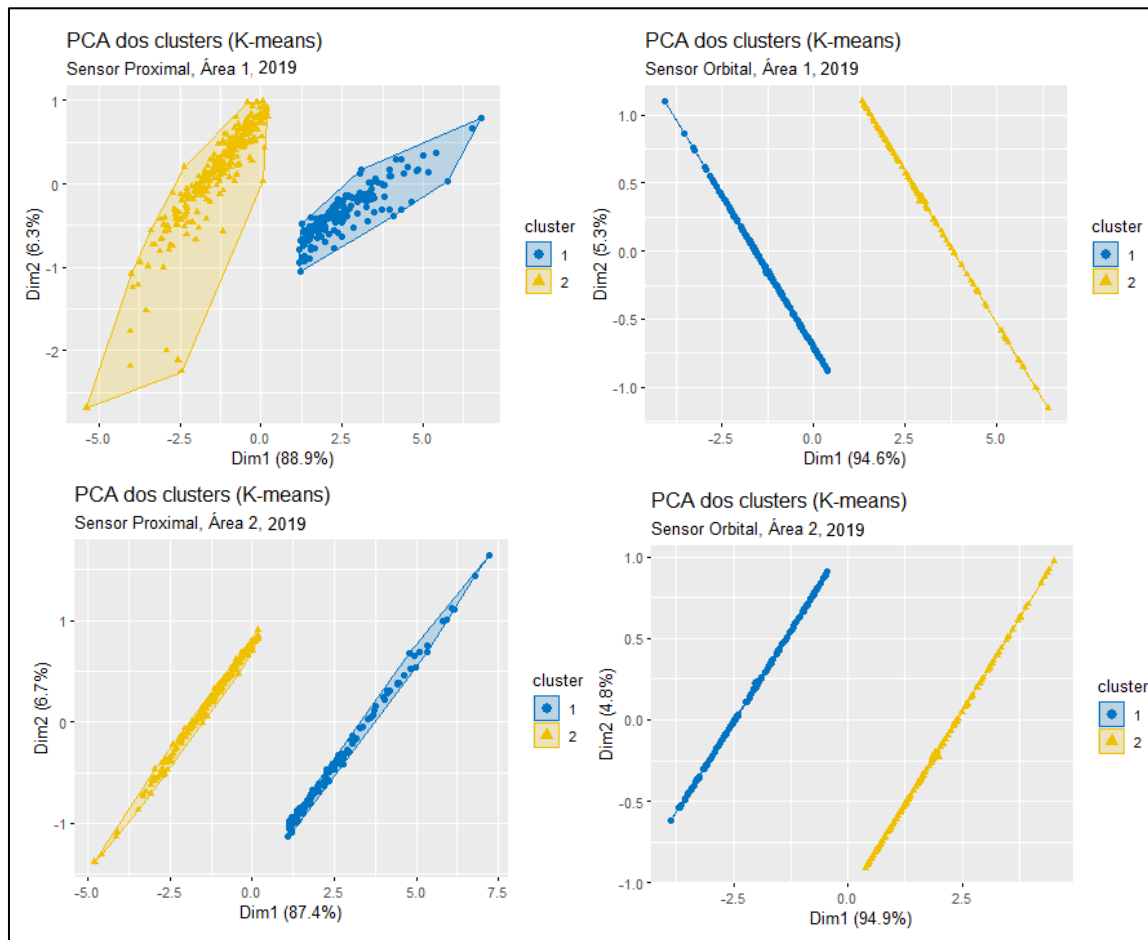
Por fim, no sensor orbital da Área 2, PC1 corresponde a 93,7 % e PC2 a 6,2 % da variância, totalizando 99,9 %. Os agrupamentos alinham-se em dois feixes paralelos, com o Agrupamentos 1 em PC1 positivos e Agrupamentos 2 em PC1 negativos, sem qualquer interseção. Essa configuração confirma que a variação dos índices se distribui quase que exclusivamente ao longo de um único componente, e que duas classes bastam para caracterizar toda a heterogeneidade espacial observada em 2018.

Gráfico 4 - Análise de Componentes Principais (PCA) 2018, para k=2



Análise dos gráficos de PCA para 2019 (Gráfico 5) revela que, em todas as combinações de sensor e área, os dois primeiros componentes explicam mais de 88 % da variância e discriminam claramente os dois agrupamentos sem sobreposição. No sensor orbital da Área 1, PC1 retém 94,6 % e PC2, 5,3 %, com os dois feixes paralelos e bem separados ao longo de PC1. Na Área 2 do mesmo sensor, PC1 chega a 94,9 % e PC2 a 4,8 %, também exibindo dois vetores lineares distintos. No sensor proximal da Área 2, PC1 e PC2 somam 94,1 % (87,4 % + 6,7 %), com feixes lineares paralelos sem interseção, e na Área 1 esse total é de 95,2 % (88,9 % + 6,3 %), mostrando leve dispersão vertical, mas mantendo clara separação em PC1. Em síntese, K = 2 mantém alta coesão interna e excelente separação espacial em 2019, validando a definição de duas ZH para todas as áreas e sensores.

Gráfico 5 - Análise de Componentes Principais (PCA) 2019, para k=2



4.3.3 Mapas de zonas homogêneas

4.3.3.1 Zonas homogêneas de k=2, da área 1

As análises de *K-means* realizadas para a Área 1, nos anos de 2017 a 2019 (Figura 5, Figura 7 e Figura 8), evidenciaram que tanto o sensor proximal quanto o orbital identificaram ZH de vigor vegetativo bastante semelhantes, apesar das diferenças de resolução e sensibilidade espectral. O sensor proximal, com maior detalhamento espacial, captou flutuações pontuais nos valores dos índices (NDVI, EVI2, RVI, SAVI), resultando em manchas de menor variabilidade interna; contudo, os contornos gerais das zonas de alto e baixo vigor coincidiram amplamente com os mapeamentos obtidos pelo sensor orbital, que, embora apresente menor variação dentro dos agrupamentos, manteve a disposição espacial das zonas.

Tabela 11 - Médias de índices (K = 2) do sensor proximal na área 1

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,81	1,71	10,18	0,40
	2 (baixo vigor)	0,74	1,53	7,70	0,37
2018	1 (alto vigor)	0,81	1,73	9,60	0,40
	2 (baixo vigor)	0,77	1,62	8,09	0,38
2019	1 (alto vigor)	0,82	1,77	11,28	0,40
	2 (baixo vigor)	0,74	1,53	7,97	0,36

Essas tabelas reforçam que, em ambiente de baixa variabilidade vegetativa, os contornos de zonas homogêneas são robustos a diferentes sensores. Embora o proximal revele maior amplitude nos valores absolutos, os padrões de distribuição espacial são fortemente análogos aos obtidos pelo sensor orbital.

Tabela 12 - Médias de índices (K = 2) do sensor orbital na área 1

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,56	1,04	3,51	0,28
	2 (baixo vigor)	0,52	0,95	3,16	0,26
2018	1 (alto vigor)	0,68	1,35	5,23	0,33
	2 (baixo vigor)	0,61	1,19	4,21	0,30
2019	1 (alto vigor)	0,73	1,49	6,29	0,36
	2 (baixo vigor)	0,68	1,36	5,27	0,34

Figura 5 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017

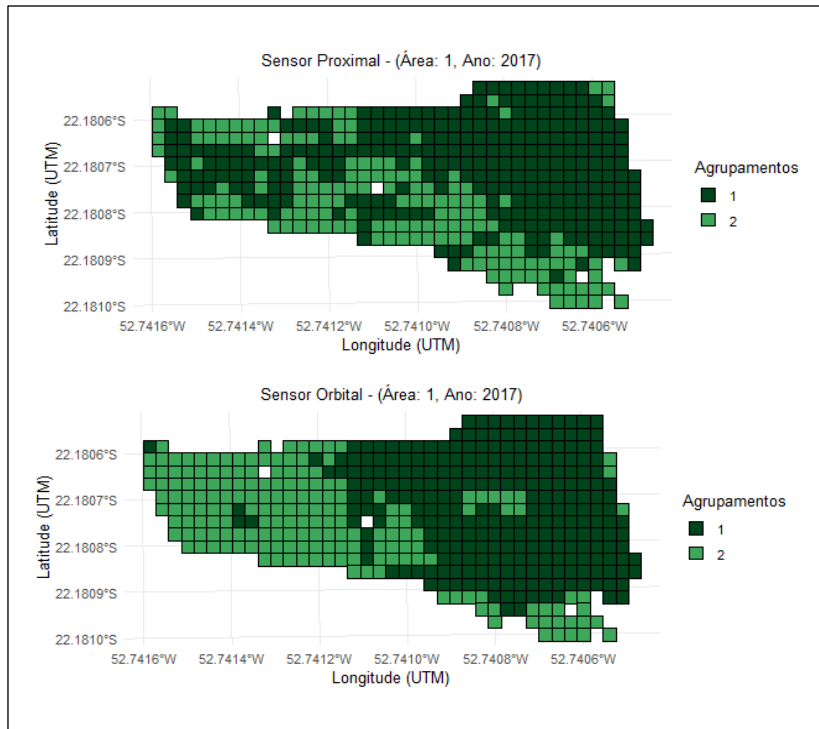


Figura 6 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018

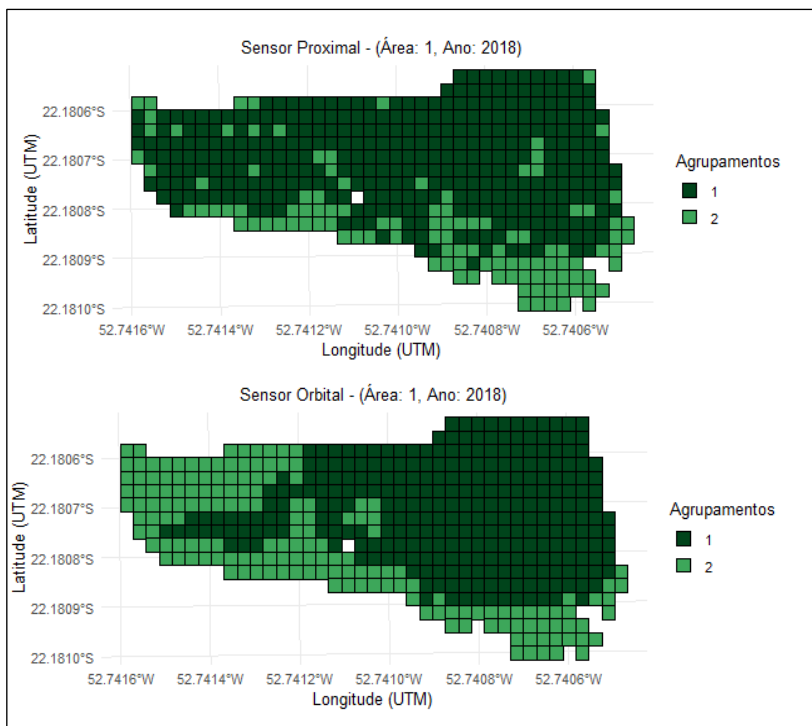
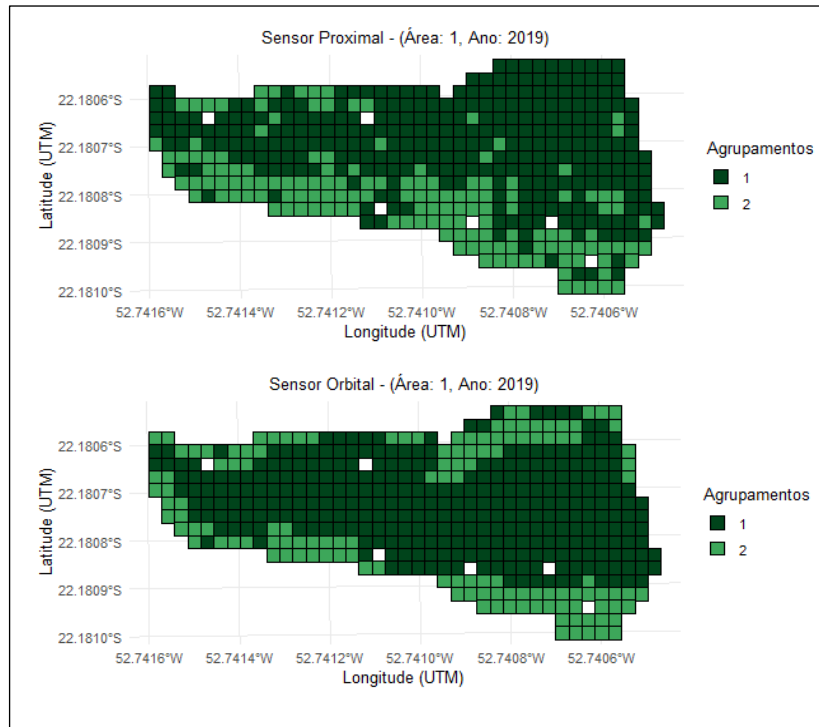


Figura 7 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019



4.3.3.2 Zonas homogêneas de k=2, da área 2

Na Área 2, nos anos de 2017 a 2019 (Figura 9, Figura 10 e Figura 11), cuja variabilidade espacial da vegetação é mais acentuada, observou-se que o sensor proximal tem maior dificuldade em destacar ZH claramente separadas, devido à presença de bolsões de diferença local que fragmentam os agrupamentos. Já o sensor orbital, por suavizar as flutuações pontuais, produziu mapas com menor variabilidade dentro dos agrupamentos e contornos mais nítidos, facilitando a identificação de áreas homogêneas mesmo em contexto de alta heterogeneidade.

Tabela 13 - Médias de índices (K = 2) do sensor proximal na área 2

(continua)

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,79	1,73	10,07	0,39
	2 (baixo vigor)	0,61	1,59	8,47	0,38

Tabela 13 - Médias de índices (K = 2) do sensor proximal na área 2

(conclusão)					
Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2018	1 (alto vigor)	0,82	1,79	10,85	0,41
	2 (baixo vigor)	0,79	1,68	9,01	0,39
2019	1 (alto vigor)	0,81	1,75	11,13	0,40
	2 (baixo vigor)	0,76	1,59	8,93	0,38

A Área 2 demonstra que o sensor orbital, ao reduzir o “ruído” de alta frequência espacial, facilita a distinção de zonas homogêneas em cenários de elevada heterogeneidade. Por outro lado, o sensor proximal oferece informações cruciais sobre microáreas de estresse que podem passar despercebidas pelo orbital.

Tabela 14 - Médias de índices (K = 2) do sensor orbital na área 2

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,57	1,08	3,65	0,28
	2 (baixo vigor)	0,53	0,98	3,26	0,26
2018	1 (alto vigor)	0,59	1,12	3,87	0,29
	2 (baixo vigor)	0,55	1,02	3,45	0,27
2019	1 (alto vigor)	0,71	1,41	5,83	0,35
	2 (baixo vigor)	0,62	1,19	4,32	0,31


Figura 8 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017

Figura 9 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018

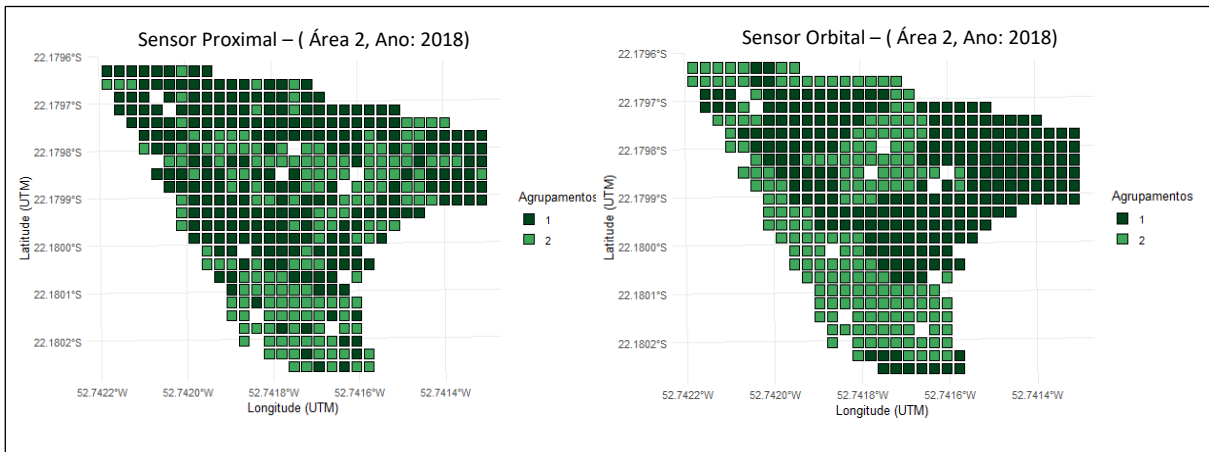



Figura 10 - Zonas homogêneas (K = 2) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019



4.3.3.3 Zonas homogêneas de k=3, da área 1

A aplicação de *K-means* com $k = 3$ na Área 1 (Figura 11, Figura 12 e Figura 13) revelou diferenças significativas entre os mapas obtidos pelos sensores proximal e orbital, tanto em termos de granulação espacial quanto de amplitude espectral dos agrupamentos. Enquanto o sensor proximal captou pequenas variações internas às ZH, mantendo padrões bem separados e fragmentados, o sensor orbital gerou zonas mais contínuas e suavizadas, com transições menos abruptas, o que evidencia a influência da resolução espacial e da sensibilidade espectral na delimitação de níveis de vigor vegetativo.

Tabela 15 - Médias de índices (K = 3) do sensor proximal na área 1

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,817	1,727	10,574	0,404
	2 (médio vigor)	0,771	1,596	8,488	0,381
	3 (baixo vigor)	0,703	1,457	6,871	0,347
2018	1 (alto vigor)	0,810	1,748	9,858	0,400
	2 (médio vigor)	0,789	1,683	8,835	0,390
	3 (baixo vigor)	0,752	1,571	7,581	0,371
2019	1 (alto vigor)	0,838	1,844	13,050	0,414
	2 (médio vigor)	0,797	1,710	10,021	0,394
	3 (baixo vigor)	0,728	1,502	7,712	0,359

Tabela 16 - Médias de índices (K = 3) do sensor orbital na área 1

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,566	1,067	3,614	0,280
	2 (médio vigor)	0,539	1,001	3,340	0,266
	3 (baixo vigor)	0,505	0,923	3,045	0,250
2018	1 (alto vigor)	0,697	1,406	5,608	0,344
	2 (médio vigor)	0,656	1,296	4,827	0,324
	3 (baixo vigor)	0,603	1,157	4,043	0,298
2019	1 (alto vigor)	0,730	1,504	6,418	0,361
	2 (médio vigor)	0,665	1,323	4,989	0,329
	3 (baixo vigor)	0,704	1,428	5,755	0,348

Figura 11 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017

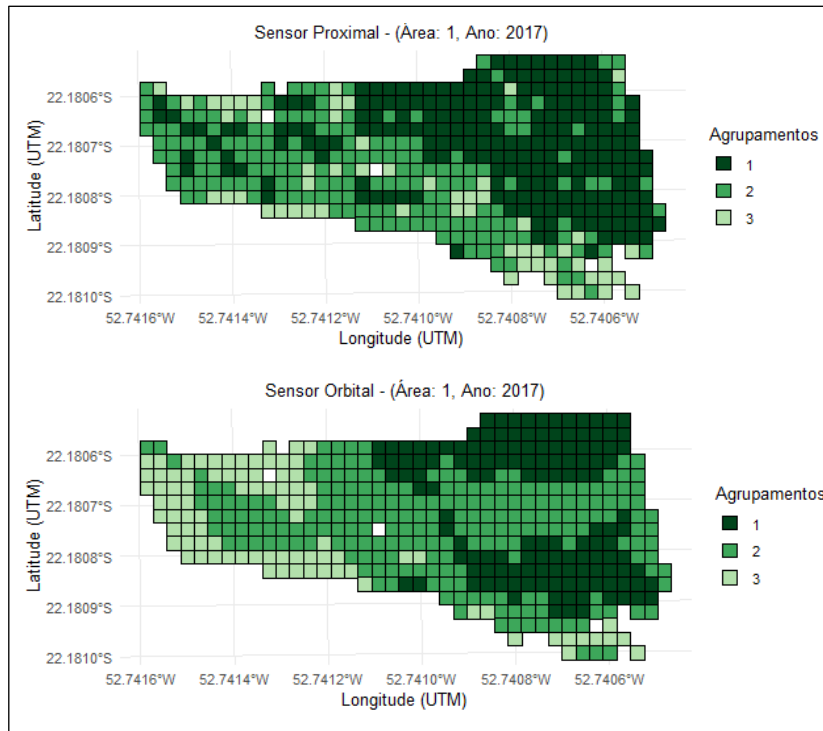


Figura 12 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018

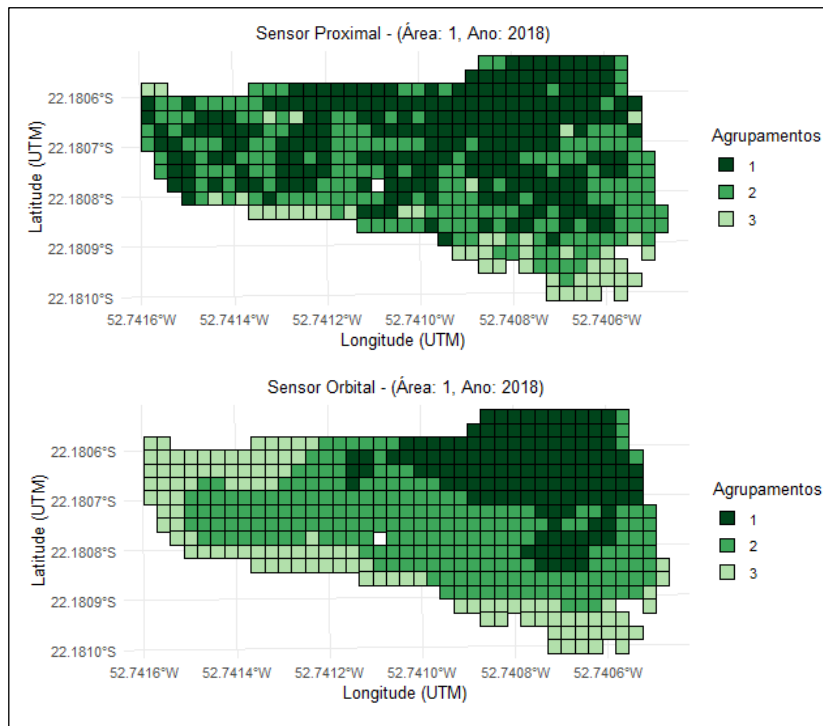
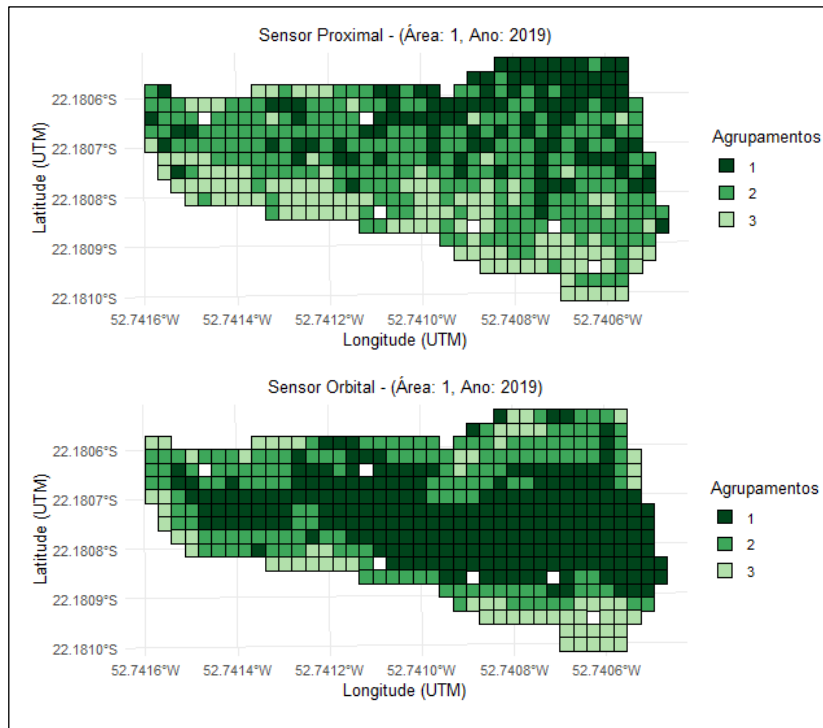


Figura 13 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019



4.3.3.4 Zonas homogêneas de k=3, da área 2

Os Agrupamentos por $k = 3$ na Área 2 (Figura 14, Figura 15 e Figura 16) ressaltou diferenças significativas na delimitação de ZH entre os sensores proximal e orbital. Enquanto o sensor proximal detalhou pequenas variações internas aos agrupamentos mantendo padrões fragmentados e bem separados, o sensor orbital gerou zonas mais contínuas e suavizadas, com menor amplitude espectral.

No sensor proximal, o Agrupamentos 2 (vigor médio) atingiu o pico de NDVI em 2018 (0,828), enquanto o Agrupamentos 3 (alto vigor) manteve elevado RVI em todas as safras ($\approx 10 - 11$), indicando bolsões de alta biomassa. As transições dentro dos agrupamentos são abruptas e fragmentadas, captando microáreas de estresse ou de vigor pontual que podem corresponder a variações de solo, drenagem ou manejo localizado.

Tabela 17 - Médias de índices (K = 3) do sensor proximal na área 2

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,807	1,731	10,074	0,393
	2 (médio vigor)	0,794	1,579	8,397	0,384
	3 (baixo vigor)	0,760	1,711	9,777	0,389
2018	1 (alto vigor)	0,828	1,807	11,201	0,409
	2 (médio vigor)	0,804	1,731	9,690	0,397
	3 (baixo vigor)	0,768	1,624	8,345	0,380
2019	1 (alto vigor)	0,822	1,776	11,634	0,406
	2 (médio vigor)	0,788	1,667	9,855	0,389
	3 (baixo vigor)	0,735	1,506	8,203	0,363

Tabela 18 - Médias de índices (K = 3) do sensor orbital na área 2

Ano	Agrupamentos	NDVI	EVI2	RVI	SAVI
2017	1 (alto vigor)	0,571	1,079	3,666	0,282
	2 (médio vigor)	0,538	0,999	3,328	0,266
	3 (baixo vigor)	0,525	0,926	3,056	0,251
2018	1 (alto vigor)	0,603	1,155	4,036	0,297
	2 (médio vigor)	0,573	1,081	3,688	0,283
	3 (baixo vigor)	0,539	0,999	3,340	0,266
2019	1 (alto vigor)	0,719	1,454	6,145	0,355
	2 (médio vigor)	0,664	1,298	4,960	0,328
	3 (baixo vigor)	0,602	1,136	4,037	0,297

Figura 14 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017




Figura 15 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018





Figura 16 - Zonas homogêneas (K = 3) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019



4.3.3.5 Mapas com 4 zonas homogêneas ($k=4$) da área de estudo 1 e 2

A aplicação de *K-means* com $k=4$ na Área 1 e 2 manteve o arranjo hierárquico de ZH observado para $k=3$, evidenciando uma gradação contínua de vigor vegetativo em nível de talhão. O aumento no número de agrupamentos não alterou substancialmente a disposição espacial das classes, em vez disso, os quatro níveis simplesmente refinaram as fronteiras já estabelecidas, subdividindo ligeiras variações de vigor dentro de cada faixa principal.

5 DISCUSSÃO

5.1 Análise das refletâncias

A análise dos dados de reflectância obtidos por sensores proximal e orbital durante o período de maturação da videira (2017 a 2019) revela padrões consistentes entre as duas plataformas de sensoriamento, embora com diferenças notáveis nos valores absolutos.

Para a banda do Infravermelho Próximo (ρ_{NIR}), os sensores proximais registraram médias de reflectância consistentemente mais altas do que os sensores orbitais, em todas as áreas e anos analisados. Na faixa do Vermelho (ρ_{RED}), um padrão oposto foi observado. Isso ocorre pois, segundo Argento *et al.* (2025), as plataformas de sensores ópticos atualmente disponíveis para monitoramento de vegetação fornecem informações diferentes em vários níveis temporais e espaciais.

A reflectância média dos sensores orbitais foi consistentemente maior do que a dos sensores proximais, em todos os anos e áreas. Por exemplo, em 2017, a média na faixa do vermelho (ρ_{RED}), do sensor orbital na área 1 foi de 10,04%, enquanto a do sensor proximal foi de 4,71%. Em 2018, os valores foram de 6,77% (orbital) contra 4,15% (proximal), e em 2019, de 5,85% (orbital) contra 4,30% (proximal).

Tattaris *et al.* (2016) e Zhang, Marzougui e Sankaran (2020), afirmam que, isso ocorre pois os dados capturados por sensores orbitais costumam reduzir os ruídos causados por mudanças ambientais devido aos horários de início e término das medições. Hilker *et al.* (2008), explica também que, as geometrias de visadas e solar ao longo do dia influenciam fortemente o Sensoriamento proximal e orbital. Além disso Roy *et al.* (2021), explica que, as variações observadas nos dados do PlanetScope podem ser resultado de ajustes feitos pelo próprio processo de correção atmosférica e de harmonização entre os diferentes satélites da constelação, que nem sempre representam perfeitamente as condições reais da superfície.

A análise temporal (2017 a 2019) também indica que os padrões de reflectância, tanto na banda ρ_{NIR} quanto na banda ρ_{RED} , mantiveram-se estáveis ao longo dos anos, com pequenas flutuações. As médias de reflectância do sensor proximal para a banda ρ_{NIR} , por exemplo, oscilaram entre 36,48% e 37,48%, enquanto as do sensor orbital ficaram entre 29,57% e 34,89%.

Quanto à variabilidade dos dados, medida pelo Coeficiente de Variação (CV), os resultados demonstram que a maioria dos parâmetros manteve uma baixa variação

($CV \leq 15\%$), indicando alta homogeneidade. Em 2017, o CV da banda ρNIR foi de apenas 3% em todas as áreas e sensores proximais. Da mesma forma, os CV's da banda ρRED foram moderados ou baixos, com a exceção do sensor proximal na área 1 em 2017 (17%), que foi classificado como moderado. Essa consistência nos CV's sugere que as propriedades de reflectância das áreas estudadas são relativamente uniformes durante o período de maturação, o que é um resultado relevante para a caracterização do vinhedo.

5.2 Análise dos índices de vegetação

A análise comparativa dos Índices de Vegetação (IVs) mostrou que o sensor proximal registrou valores médios consistentemente superiores aos do sensor orbital nos três anos de estudo (2017, 2018 e 2019) e em ambas as áreas. Assim como Kasimati *et al.* (2023), aponta que há diferenças na estruturação espacial dos IVs quando as imagens vêm de diferentes tipos de sensores.

Na visão de Argento *et al.* (2025), a variabilidade entre sensores indica que a escolha do dispositivo afeta a precisão e confiabilidade dos índices de vegetação, influenciando sua interpretação em estudos de campo e decisões de manejo de culturas. No entanto, Cruvinel Júnior, (2018), aponta que a variabilidade espectral ocorre em função de variáveis ambientais e tem pouca influência em função da qualidade do sensor.

Em relação à variabilidade espacial, o Coeficiente de Variação (CV%) apresentou comportamentos distintos. No NDVI, o CV proximal foi geralmente menor ou semelhante ao orbital, indicando alta homogeneidade da vegetação em escala de campo. Por outro lado, índices mais sensíveis, como o RVI, exibiram CVs proximais muito maiores. Isso evidencia que o sensor de campo é mais eficaz na detecção da heterogeneidade real da vegetação, que acaba sendo mascarada pela escala espacial do satélite.

5.3 Análise da correlação de Pearson

A análise de correlação de Pearson revelou que, nos anos de 2017 e 2018, a Área 1 apresentou fortes relações entre os índices de vegetação obtidos por sensores

proximal e orbital, indicando que ambos capturaram padrões espectrais semelhantes, embora o sensor de campo tenha demonstrado sensibilidade aumentada às oscilações locais. Em contraste, em 2019 houve uma queda notável nesses coeficientes. Kasimati *et al.* (2023), notou os mesmos resultados comparando um índice de vegetação obtido por sensor orbital vs. sensores proximais.

O estudo que empregado por Moletto-Lobos *et al.* (2024), com satélite PlanetScope e o sensor MicaSense que teve como objetivo avaliar diferenças nas respostas dos diferentes sensores, demonstrou que as baixas correlações de Pearson observadas devem-se, principalmente, às distintas larguras de banda e sensibilidades de cada sensor.

Na Área 2, por sua vez, as correlações entre sensores permaneceram consistentemente baixas em todos os anos e para todos os índices avaliados. A comparação entre as duas áreas ressalta que a Área 1 manteve correlações mais elevadas ao longo do período, refletindo possivelmente uma estrutura vegetativa mais homogênea e condições de manejo mais uniformes, facilitando a detecção simultânea por ambas as tecnologias. Já a Área 2, com correlações persistentemente baixas e maior dispersão nos coeficientes, evidencia maior complexidade espacial e desafios na integração dos dados.

5.4 Delimitação das Zonas Homogêneas

5.4.1 Determinação do Número de Agrupamentos

Os gráficos de cotovelo revelaram um “joelho” claro em $K = 2$ para ambos sensores e áreas, com queda expressiva da soma dos quadrados dentro dos agrupamentos entre $K = 1$ e $K = 2$ e redução marginal além deste ponto. A análise de *Silhueta* corroborou esse resultado, apontando picos de 0,52–0,54 em $K = 2$ no proximal e no orbital da Área 1, e valores ainda mais elevados (0,62) no orbital da Área 2. Esses indicadores refletem que dois grupos oferecem melhor combinação de coesão e separação, enquanto agrupamentos adicionais proporcionam ganhos marginais.

No estudo de Song *et al.* (2009), a aplicação do algoritmo de *fuzzy K-means* para a delimitação de zonas de manejo em lavouras de trigo indicou uma configuração de três zonas ($k = 3$) apresenta melhor desempenho. De forma semelhante, Kasimati

et al. (2023) também observaram que a divisão em três zonas representou a estrutura mais adequada para capturar a variabilidade espacial dos atributos avaliados em sistemas agrícolas.

Portanto, o uso de $K = 3$ e $K = 4$ permitiu avaliar ganhos marginais e identificar subdivisões potenciais, sem comprometer a interpretação agrônômica. Assim, a delimitação proposta assegura representatividade estatística e relevância prática para orientar decisões de campo.

Na Área 2 do sensor proximal, um segundo pico local em $K = 4$ sugere uma opção de subdivisão. Contudo, essa opção não apresenta ganho prático suficiente. A escolha por $K = 2$, portanto, maximiza a clareza das zonas e simplifica a aplicação em campo. Essa seleção padroniza o procedimento para os anos subsequentes.

5.4.2 Análise de Componentes Principais (PCA)

A PCA para $K = 2$ mostrou, em 2017 a 2019, que os dois primeiros componentes explicam entre 74 % e 95 % da variância, evidenciando forte discriminação bidimensional dos agrupamentos. No sensor proximal da Área 1, PC1 concentrava mais de 84 % da variância, separando nitidamente zonas de vigor em eixos positivos e negativos, enquanto PC2 refinava a distinção.

Já no orbital, PC1 ultrapassava 93 %, configurando feixes quase unidimensionais claramente paralelos. Na Área 2, o papel de PC2 foi mais significativo no proximal, mas a separação em PC1 manteve-se estável. Esses resultados reforçam a adequação de duas ZH e atestam coesão interna e baixa sobreposição, validando a escolha de $K = 2$ de maneira visual e estatística.

5.4.3 Avaliação de Subdivisões Adicionais ($K = 3$ e $K = 4$)

A inclusão de $K = 3$ e $K = 4$ permitiu examinar subdivisões com fins agrônômicos, identificando zonas de vigor baixo, médio e alto, bem como nuances internas. Em $K = 3$, PC1 e PC2 explicaram até 99 % da variância no orbital, com nuvens paralelas que destacam três níveis de vigor, enquanto no proximal surgiram pequenos bolsões de heterogeneidade. Para $K = 4$ (ANEXO A), o proximal da Área 2 exibiu forte contribuição de PC2 ($\approx 22\%$), indicando complexidade espacial que pode

corresponder a pequenas diferenças de solo ou manejo. Contudo, a fragmentação adicional não alterou substancialmente os contornos principais definidos por $K = 2$. Assim, as subdivisões compõem um detalhamento opcional para estudos avançados, sem substituir o mapa principal de duas zonas.

5.4.4 Mapas de Zonas Homogêneas

Os mapas gerados para $K = 2$ demonstraram boa correspondência entre os sensores, apesar das diferenças de amplitude nos valores dos índices (Denora *et al.*, 2022). O sensor proximal evidenciou manchas pontuais de variação fina, úteis para detectar pequenas áreas de estresse, enquanto o orbital forneceu zonas contínuas de vigor baixo e alto, facilitando a visualização macroespacial. Portanto, pode-se afirmar que ambas as tecnologias foram capazes de capturar uma tendência semelhante no desenvolvimento da vegetação (MEZERA *et al.*, 2021).

As médias de índices confirmaram consistência temporal (2017 - 2019), com agrupamentos estáveis ao longo dos anos. Os mapas paralelos de ZH, comparados entre si, mostraram maior homogeneidade na Área 1 e fragmentação na Área 2. São poucos os estudos que correlacionam dados de sensores proximal e orbital para a determinação da variabilidade de ZH por meio do algoritmo *K-means*. No entanto, diversos trabalhos destacam que o sensor proximal apresenta desempenho significativamente superior em termos de precisão espectral e espacial, quando comparado a outros tipos de sensores (Acharki, 2022; Mudereri *et al.*, 2019; Shimizu *et al.* 2020).

Em áreas com alta heterogeneidade espacial (Área 2), a definição de ZH a partir de índices de vegetação obtidos por sensor proximal tende a tornar as fronteiras dentro dos agrupamentos pouco perceptíveis, pois as variações pontuais de vigor criam fragmentações excessivas. Diferentemente, o sensor orbital, ao suavizar essas flutuações de alta frequência espacial, consegue delimitar ZH mais nítidas, conferindo maior clareza visual ao mapeamento. Nesses cenários, torna-se, portanto, mais eficaz e prático adotar ZH definidas a partir de dados orbitais, pois elas oferecem contornos estáveis que facilitam a interpretação e a aplicação no manejo de precisão.

6 CONCLUSÕES

Este trabalho evidenciou que os sensores proximais captam variações finas na refletância NIR e nos índices de vegetação, enquanto o sensor orbital oferece uma melhor suavização da heterogeneidade excessiva da área para ZH.

As correlações de Pearson indicaram boa concordância entre as plataformas nas unidades homogêneas da Área 1, que apresenta maior uniformidade nos dados de reflectância. No entanto, em áreas com maior heterogeneidade de reflectância, como a Área 2, a correlação entre alguns sensores chega a ser nula.

A análise de agrupamentos por *K-means*, validada pelos métodos do cotovelo, silhueta e PCA, indicou que duas ZH ($K = 2$) proporcionam o melhor equilíbrio entre coesão interna e distinção externa. Embora a subdivisão em três zonas ($K = 3$) ainda permita observar similaridades entre os diferentes sensores utilizados, a configuração de quatro ZH ($K = 4$) introduz zonas nas quais não foi possível identificar semelhança consistente entre os dados dos sensores proximal e orbital.

Apesar do conhecimento prévio de que diferentes plataformas de sensoriamento apresentam variações significativas, o estudo utilizou o algoritmo *fuzzy k-means* para quantificar o limite dessa discrepância. Na viticultura de precisão, é importante que os resultados de diferentes sensores sejam semelhantes, dada a similaridade da informação agrônômica, que no caso do estudo é vigor do dossel. Foi demonstrado que as imagens de satélite Planet possuem uma forte correlação com os dados dos sensores proximais (menos suscetíveis à interferência atmosférica) quando são definidas duas ZH (ZH). A relação se mantém minimamente aceitável com três ZH, contudo, a partir de quatro ZH, a dissimilaridade é total. Ressalta-se que essa convergência é estritamente dependente da homogeneidade da vegetação na área de estudo. Em cenários de heterogeneidade acentuada, a similaridade entre as ZH é inexistente.

REFERÊNCIAS

ACHARKI, S. PlanetScope contributions compared to Sentinel-2, and Landsat-8 for LULC mapping. **Remote Sensing Applications: Society and Environment**, v. 27, 2022. Disponível em: <https://doi.org/10.1016/j.rsase.2022.100774>.

ALMEIDA, J. A. P. de; OLIVEIRA, P. J. de. **Sensoriamento remoto I**. 1. ed. São Cristóvão: Universidade Federal de Sergipe, CESAD, 2010. 15 p.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, p. 711-728, 2013.

MANKULOVA, K. Comparison of PlanetScope, Sentinel-2, and Landsat 8 data in soybean yield estimation within-field variability with random forest regression. **Heliyon**, Amsterdam, v. 9, n. 6, June 2023. DOI: 10.1016/j.heliyon.2023.e17432.

AMMONIACI, M. *et al.* State of the art of monitoring technologies and data processing for precision viticulture. **Agriculture**, v. 11, n. 3, p. 201, 2021. Disponível em: <https://doi.org/10.3390/agriculture11030201>.

ANASTASIOU, E. *et al.* A multi-source data fusion approach to assess spatial-temporal variability and delineate homogeneous zones: a use case in a table grape vineyard in Greece. **Science of the Total Environment**, v. 684, p. 155–163, 22 maio 2019. DOI: 10.1016/j.scitotenv.2019.05.324.

ARGENTO, F. *et al.* A comparison of proximal and remote optical sensor platforms for N status estimation in winter wheat. **Computers and Electronics in Agriculture**, v. 232, 2025. Disponível em: [10.1016/j.compag.2025.107767](https://doi.org/10.1016/j.compag.2025.107767).

ARNÓ SATORRA, J. *et al.* Precision viticulture. Research topics, challenges and opportunities in site-specific vineyard management. **Spanish Journal of Agricultural Research**, v. 7, n. 4, p. 779-790, 2009.

ARUN, S. Principal component analysis (PCA) in the evaluation of vegetation indices derived from time-series remote sensing data: a review. **International Journal of Creative Research Thoughts (IJCRT)**, v. 10, n. 6, p. 955–965, Jun 2022.

ASELIN, L. **GeoDa versão 1.22.0.4**. 2023.

ASSIS, J. S. de; LIMA FILHO, J. M. P. Aspectos fisiológicos da videira irrigada. In: LEAO, P. C. de S.; SOARES, J. M. (Org.). **A viticultura no Semi-Árido brasileiro**. Petrolina: Embrapa Semi-Árido, 2000. cap. 7, p. 129-145. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/134241>. Acesso em: 12 jan. 2025.

AUERNHAMMER, H. Precision farming - the environmental challenge. **Computers and Electronics in Agriculture**, v. 30, n. 1, p. 31-43, 2001.

BAPTISTA, G. M. de M. **Sensoriamento remoto hiperespectral**. 2. ed. Rio de Janeiro: Interciência, 2019. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 5 jan. 2025.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e aplicações**. 1. ed. São José dos Campos: NPE, 2019.

BASHEER, S. A comparative analysis of PlanetScope 4-band and 8-band imageries for land use land cover classification. **Geomatica**, v. 76, n. 2, 2024. Disponível em: <https://doi.org/10.1016/j.geomat.2024.100023>.

BENELLI, A. *et al.* Precision viticulture: Automatic selection of the regions of interest from moving wagon hyperspectral images of grapes for efficient SSC prediction. **Smart Agricultural Technology**, v. 7, mar. 2024. Disponível em: <https://doi.org/10.1016/j.atech.2024.100434>.

BLASCHKE, T.; KUX, H. **Sensoriamento remoto e SIG avançados: novos sistemas sensores, métodos inovadores**. 2. ed. São Paulo: Oficina de Textos, 2007.

BONGIOVANNI, R.; LOWENBERG-DEBOER, J. Precision agriculture and sustainability. **Precision Agriculture**, v. 5, n. 4, p. 359-387, 2004.

BOTTEGA, E. L. *et al.* Zonas de manejo: a teoria na prática. **Revista Plantio Direto & Tecnologia Agrícola**, n. 171, p. 11-15, 2019.

BOUGIOUKLIS, G. *et al.* Precision soil sampling strategy for the delineation of management zones in olive cultivation using unsupervised machine learning methods. **Scientific Reports**, v. 15, n. 1, art. 89395, 2025.

BRAMLEY, R. G. V. Understanding variability in winegrape production systems 2. Within vineyard variation in quality over several vintages. **Australian Journal of Grape and Wine Research**, v. 11, p. 33-42, abr. 2005.

BRILLANTE, L. *et al.* Carbon isotope discrimination ($\delta^{13}C$) of grape musts is a reliable tool for zoning and the physiological ground-truthing of sensor maps in precision viticulture. **Frontiers in Environmental Science**, v. 8, 2020.

CAMPBELL, J. B. **Introduction to remote sensing**. New York: The Guilford Press, 1996. 622 p.

CARVALHO, M. P.; TAKEDA, E. Y.; FREDDI, O. S. Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP). **Revista Brasileira de Ciência do Solo**, v. 27, p. 695-703, 2003.

CARVALHO, P. R. M.; COSTA, J. F. C. L. Automatic variogram model fitting of a variogram map based on the Fourier integral method. **Computers & Geosciences**, v. 156, art. 104891, 2021. Disponível em: 10.1016/j.cageo.2021.104891.

CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229-242, 2014. Disponível em: <https://doi.org/10.1080/07038992.1996.10855178>.

CHERUBIN, M. R. *et al.* 25 years of precision agriculture in Brazil: a systematic review. **Agronomy**, v. 12, 2022.

COGLIATI *et al.* Continuous and long-term measurements of reflectance and sun-induced chlorophyll fluorescence by using novel automated field spectroscopy systems. **Remote Sensing of Environment**, v. 164, p. 270-281, jul. 2015.

CONLEY, M. M.; THOMPSON, A. L.; HEJL, R. W. Proximal Active Optical Sensing Operational Improvement for Research Using the CropCircle ACS-430, Implications

for Measurement of Normalized Difference Vegetation Index (NDVI). **Sensors**, Basel, v. 23, n. 11, art. 5044, 24 maio 2023. DOI: 10.3390/s23115044.

CÓRDOBA, M. A. *et al.* Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems Engineering**, v. 143, p. 95–107, 2016. DOI: 10.1016/j.biosystemseng.2015.12.00.

CORRALES, R. E.; REJAS, J. G. O.; FARJAS, M. Principal Component Analysis for the Identification of the Vegetal Status in the Cerro Azul Meámbar National Park, Honduras, Using a Landsat 8 Image from the Year 2018. **Environmental Sciences Proceedings**, v. 28, n. 1, art. 10, 2023. DOI: 10.3390/environsciproc202302801.

COSTA, B. R. S. **Zonas de vigor vegetativo para colheita seletiva em viticultura irrigada com base em sensoriamento proximal**. 2021. 228 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2021.

CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71-73, out. 1990. Disponível em: [https://doi.org/10.1016/0034-4257\(90\)90085-Z](https://doi.org/10.1016/0034-4257(90)90085-Z).

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1993. 170 p.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. ed. rev. Campinas, SP: IG/UNICAMP, 1999. 170p.

CRUVINEL JÚNIOR, S. A. **Monitoramento da Cultura Cafeeira a partir de Imagens de Alta Resolução Espacial**. 2018. 42 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Agrimensura e Cartográfica) – Universidade Federal de Uberlândia, Monte Carmelo, 2018.

CURTIS, A. E. *et al.* The Mystery of the Z-Score. **State-of-the-Art Review**, v. 16, n. 4, p. 124-130, ago. 2016. Disponível em:

<http://dx.doi.org/10.12945/j.aorta.2016.16.014>. Acesso em: 10 jan. 2025.

D'OLIVEIRA, P. S. *et al.* **Aplicações da agricultura de precisão em pastagens**. Circular Técnica 127. Juiz de Fora, MG, 29 p., jan. 2023.

DARRA, N. *et al.* Remote and proximal sensing-derived spectral indices and biophysical variables for spatial variation determination in vineyards. **Agronomy**, Basel, v. 11, n. 4, art. 741, 2021. DOI: 10.3390/agronomy11040741.

DENORA, M. *et al.* Validation of Rapid and Low-Cost Approach for the Delineation of Zone Management Based on Machine Learning Algorithms. **Agronomy**, v. 12, n. 1, p. 183, 2022. Disponível em: <https://doi.org/10.3390/agronomy12010183>.

DEVORE, J. L. **Probabilidade e estatística: para engenharia e ciências**. 6. ed. São Paulo: Cengage Learning, 2006.

ELVIDGE, C. D.; CHEN, Z. Comparison of broad-band and narrow-band red and near-infrared vegetation indices. **Remote Sensing of Environment**, v. 54, n. 1, p. 38-48, out. 1995. Disponível em: [https://doi.org/10.1016/0034-4257\(95\)00132-K](https://doi.org/10.1016/0034-4257(95)00132-K).

EPIPHANIO, J. C. N. *et al.* Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.

FERRO, M. V.; CATANIA, P. Technologies and Innovative Methods for Precision Viticulture: A Comprehensive Review. **Horticulturae**, v. 9, n. 3, art. 399, 2023. DOI: 10.3390/horticulturae9030399.

FILIPPINI ALBA, J. M.; FLORES, C. A.; MIELE, A. Modelagem espacial do solo para apoio à viticultura de precisão: Vale dos Vinhedos, Serra Gaúcha, Rio Grande do Sul, Brasil. **Revista Brasileira de Viticultura Enologia**, n. 4, p. 8–17, set. 2012.

FORGY, E. W. clusters analysis of multivariate data: efficiency versus interpretability of classifications. **Biometrics**, Washington, v. 21, n. 3, p. 768–780, 1965.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. 1. ed. São Paulo: Oficina de Textos, 2017. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 2 jan. 2025.

FRAZIER, A. E.; HEMINGWAY, B. L. A technical review of Planet smallsat data: practical considerations for processing and using PlanetScope imagery. **Remote Sensing**, Basel, v. 13, n. 19, art. 3930, 2021. DOI: 10.3390/rs13193930.

FRIDGEN, J. J. *et al.* Management zone analyst (MZA) software for subfield management zone delineation. **Agronomy Journal**, v. 96, n. 1, p. 100-108, 2004.

GALVANIN, E. A. S. *et al.* Avaliação dos índices de vegetação NDVI, SR e TVI na discriminação de fitofisionomias dos ambientes do Pantanal de Cáceres/MT. **Ciência Florestal**, v. 24, n. 3, p. 707-715, 2014.

GAMEIRO, S. *et al.* Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na sub-bacia hidrográfica do Baixo Jaguaribe, CE. **Terrae**, v. 13, n. 1/2, p. 15-22, 2016. Disponível em: <https://www.ige.unicamp.br/terrae/V13/PDFv13/TE067-2.pdf>. Acesso em: 15 dez. 2024.

GUADIE, A. *et al.* Synthesis and Characterization of Eucalyptus Pulp by Kraft Process for Paper Sheet Formation. **International Journal of Environmental Science and Technology**, v. 1, n. 2, p. 20-26, 2015.

HATFIELD, J. L. *et al.* Application of Spectral Remote Sensing for Agronomic Decisions. **Agronomy Journal**, v. 100, p. S-117–S-131, 2008.

HILKER, T. Separating physiologically and directionally induced changes in PRI using BRDF models. **Remote Sensing of Environment**, v. 112, n. 6, p. 2701 – 2710, 2008. Disponível em: doi:10.1016/j.rse.2008.01.011.

HOMOLOVÁ, L. *et al.* Review of optical-based remote sensing for plant trait mapping. **Ecological Complexity**, v. 15, p. 1-16, 2013.

HUANG, W. *et al.* Comparability of Red/Near-Infrared Reflectance and NDVI Based on the Spectral Response Function between MODIS and 30 Other Satellite Sensors Using Rice Canopy Spectra. **Sensors**, v. 13, p. 16023-16050, 2013. Disponível em: 10.3390/s131216023.

HUETE, A. R. A soil-adjusted vegetation index. **Remote Sensing of Environment (SAVI)**, New York, v. 25, n. 3, p. 295-309, ago. 1988.

JAFARBIGLU, H.; POURREZA, A. A comprehensive review of remote sensing platforms, sensors, and applications in nut crops. **Computers and Electronics in Agriculture**, v. 197, jun. 2022. Disponível em: <https://doi.org/10.1016/j.compag.2022.106844>.

JAIN, A. K. Data clustering: 50 years beyond *K-means*. **Pattern Recognition Letters**, Amsterdam, v. 31, n. 8, p. 651–666, Jun. 2010. doi: 10.1016/j.patrec.2009.09.011.

JAIN, A. K.; DUBES, R. C; NGUYEN, C. D. **Algorithms for Clustering Data**. Englewood Cliffs: Prentice Hall, 1948. 344 p.

JENSEN, J. R. **Sensoriamento Remoto do ambiente**. 2. ed. São José dos Campos: Parêntese, 2009.

JIANG, Z. *et al.* Development of a two-band enhanced vegetation index without a blue band and its application to AVHRR data. **Remote Sensing of Environment**, v. 112, p. 3833–3845, 2008. Disponível em: 10.1016/j.rse.2008.06.006.

JOHNEN, T.; BOETTCHER, U.; KAGE, H. An analysis of factors determining spatial variable grain yield of winter wheat. **European Journal of Agronomy**, v. 52, p. 297 – 306, 2014. Disponível em: <https://doi.org/10.1016/j.eja.2013.08.005>.

JONES, D.; BARNES, E. M. Fuzzy composite programming to combine remote sensing and crop models for decision support in precision crop management. **Agricultural Systems**, v. 65, n. 3, p. 137-158, 2000.

JORDAN, C. F. Derivation of leaf area index from quality of light on the Forest floor. **Ecology**, v. 50, p. 663-666, 1969.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining Geostatistics**. San Diego: Academic Press, 1978.

KARAPETSAS, N. *et al.* Delineating Natural Terroir Units in Wine Regions Using Geoinformatics. **Agriculture**, v. 13, art. 619, Mar. 2023.

KASIMATI, A. *et al.* Investigation of the similarities between NDVI maps from different proximal and remote sensing platforms in explaining vineyard variability. **Precision Agriculture**, v. 24, p. 1220–1240, 2023. Disponível em: <https://doi.org/10.1007/s11119-022-09984-2>.

KHOSLA, R. *et al.* A synthesis of multi-disciplinary research in precision agriculture: site-specific management zones in the semi-arid western Great Plains of the USA. **Precision Agriculture**, v. 9, p. 85–100, 2008. Disponível em: 10.1007/s11119-008-9057-1.

KIDDER, S. Q.; VON DE HAAR, T. H. **Satellite Meteorology: An Introduction**. New York, USA: Academic Press, 1995. 476 p.

KOKHAN, S.; VOSTOKOV, A. Application of nanosatellite PlanetScope data to monitor crop growth. In: INTERNATIONAL CONFERENCE ON ENERGY AND ENVIRONMENTAL PROTECTION IN GREEN TECHNOLOGIES – EEPG TECH 2019, 1., 2019, Kyiv. **Anais...** E3S Web of Conferences, v. 171, p. 02014, 2020. DOI: 10.1051/e3sconf/202017102014.

KONTOUDAKIS, N. *et al.* Influence of the heterogeneity of grape phenolic maturity on wine composition and quality. **Food Chemistry**, v. 124, n. 3, p. 767-774, fev. 2011. Disponível em: <https://doi.org/10.1016/j.foodchem.2010.06.093>.

LARK, R. M. Forming spatially coherent regions by classification of multivariate data: an example from the analysis of maps of crop yield. **International Journal of Geographical Information Science**, v. 12, p. 83–98, 1998.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and interpretation**. 2. ed. New York: John Wiley e Sons, 1987. 721 p.

LIMA FILHO, J. M. P. *et al.* Aspectos fisiológicos. In: SOARES, J. M.; LEAO, P. C. de S. (Org.). **A vitivinicultura no Semiárido brasileiro**. Embrapa Semiárido, 2009. cap. 3, p. 73-108. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/513781/a-vitivinicultura-no-semiarido-brasileiro>. Acesso em: 12 jan. 2025.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. São Paulo, SP: Oficina de Textos, 2015. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 25 dez. 2025.

LLOYD, S. Least Squares Quantization in PCM. **IEEE Transactions on Information Theory**, v. 28, n. 2, p. 129–136, 1982. DOI: 10.1109/TIT.1982.1056489.

LOBOS, I. T. *et al.* Evaluating PlanetScope and UAV Multispectral Data for Monitoring Winter Wheat and Sustainable Fertilization Practices in Mediterranean Agroecosystems. **Remote Sens.**, v. 16, n. 23, 2024. Disponível em: <https://doi.org/10.3390/rs16234474>.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. 1. ed. São Paulo: Blucher, 2015. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 05 fev. 2025.

LUCHIARI JUNIOR, A. *et al.* Zonas de manejo: teoria e prática. In: INAMASU, R. Y. *et al.* (Ed.). **Agricultura de precisão: um novo olhar**. São Carlos, SP: Embrapa Instrumentação, 2011. p. 60-64.

MACQUEEN, J. B. Some Methods for Classification and Analysis of Multivariate Observations. In: PROCEEDINGS OF THE FIFTH BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., 1967. **Proceedings...** Berkeley, 1967. v. 1, p. 281–297.

MATESE, A.; DI GENNARO, S. F. Technology in precision viticulture: a state of the art review. **International Journal of Wine Research**, p. 69-81, 2015. Disponível em: <https://www.dovepress.com/technology-in-precision-viticulture-a-state-of-the-art-review-peer-reviewed-fulltext-article-IJWR>.

MATESE, A.; DI GENNARO, S. F.; SANTESTEBAN, L. G. Methods to compare the spatial variability of UAV-based spectral and geometric information with ground autocorrelated data. A case of study for precision viticulture. **Computers and Electronics in Agriculture**, v. 162, p. 931-940, jul. 2019. Disponível em: <https://doi.org/10.1016/j.compag.2019.05.038>.

MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, n. 8, p. 1246–1266, 1962.

MAZZIA, G. *et al.* UAV and machine learning based refinement of a satellite-driven vegetation index for precision agriculture. **Sensors**, v. 20, n. 19, 2020.

MEZERA, J. *et al.* Comparison of Proximal and Remote Sensing for the Diagnosis of Crop Status in Site-Specific Crop Management. **Sensors (Basel)**, v. 22, n. 1, p. 19, 22 dez. 2021. DOI: 10.3390/s22010019.

MIELE, A. *et al.* Viticultura de precisão: Uma ferramenta tecnológica para melhorar a qualidade e a competitividade do vinho brasileiro. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2010, Ribeirão Preto. **Anais...** Ribeirão Preto: SBEA, 2010. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/870069>.

MIELE, A.; FLORES, C. A.; ALBA, J. M. F. Status atual da pesquisa de viticultura de precisão no Rio Grande do Sul: primeiros resultados da UP Uva para Vinho. In: [S.l.: s.n.], 2014. p. 266-272.

MINASNY, B.; MCBRATNEY, A. B.; WHELAN, B. M. **Vesper version 1.62**. Sydney: Australian Centre for Precision Agriculture. 2005.

MOLETTA-LOBOS, I. *et al.* Evaluating PlanetScope and UAV multispectral data for monitoring winter wheat and sustainable fertilization practices. **Remote Sensing**, v. 16, n. 23, 2024.

MORARI, F.; CASTRIGNANÒ, A.; PAGLIARINA, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. **Computers and Electronics in Agriculture**, v. 68, p. 97–107, 2009. DOI: 10.1016/j.compag.2009.05.003.

MOREIRA, M. A.; ASSUNÇÃO, G. V. **Princípios básicos, metodologias e aplicações de sensoriamento remoto na agricultura**. INPE, São José dos Campos, 1984. 70 p.

MORISSETTE, L.; CHARTIER, S. The *k-means* clustering technique: General considerations and implementation in Mathematica. **Tutorials in Quantitative Methods for Psychology**, v. 9, n. 1, p. 15–24, 2013.

MOTA, F. A. S.; HINCKEL, J. N. Estudo do desempenho dos diferentes sistemas propulsivos para a transferência de um satélite para uma órbita geoestacionária. In: ANAIS DO SBAI 2013, 2013. Disponível em: <http://www.sbai2013.ufc.br/pdfs/7800.pdf>.

MUDERERI, B. T. *et al.* Comparative analysis of PlanetScope and Sentinel-2 spaceborne sensors in mapping Striga weed using guided regularised random forest classification ensemble. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-2/W13, p. 701–708, 2019. Disponível em: [10.5194/isprs-archives-XLII-2-W13-701-2019](https://doi.org/10.5194/isprs-archives-XLII-2-W13-701-2019).

MYNENI, R. B.; WILLIAMS, D. L. On the relationship between FAPAR and NDVI. **Remote Sensing of Environment**, v. 49, n. 3, p. 200-211, 1994.

NAVROZIDIS, L. *et al.* Identification of purple spot disease on asparagus crops across spatial and spectral scales. **Computers and Electronics in Agriculture**, v. 148, p. 322-329, mar. 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.03.035>.

NOVO, E. M. L. M. **Sensoriamento remoto: Princípios e aplicações**. São Paulo: Edgard Blucher, 1992. 308 p.

OLDONI, H. **Zonas homogêneas de atributos de planta e do solo em vinhedo irrigado**. 2019. 144 p. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2019.

OLIVEIRA, A. F. **Favorecendo o desempenho do *k-means* via métodos de inicialização de centroides**. 2018. Dissertação (Mestrado Profissional em Ciência da Computação) – Centro Universitário Campo Limpo Paulista, Campo Limpo Paulista, SP, 2018.

OLIVEIRA, R. P.; BRANDÃO, Z. N.; RODRIGUES, H. M. Técnicas de Agricultura de Precisão para Criação de Zonas de Manejo usando Sensores Proximais e Software R na Fazenda Pamplona, Cristalina, GO (Estudo de Caso 1). In: **Experimentação on-farm na agricultura de precisão**. Passo Fundo: Embrapa Trigo, 2022. 154 p.

OLETTO-LOBOS, Í. *et al.* Evaluating PlanetScope and UAV Multispectral Data for Monitoring Winter Wheat and Sustainable Fertilization Practices in Mediterranean Agroecosystems. **Remote Sensing**, Basel, v. 16, n. 23, art. 4474, 2024. DOI: [10.3390/rs16234474](https://doi.org/10.3390/rs16234474).

ONLEY, M. M.; THOMPSON, A. L.; HEJL, R. Proximal Active Optical Sensing Operational Improvement for Research Using the CropCircle ACS-430, Implications for Measurement of Normalized Difference Vegetation Index (NDVI). **Sensors**, Basel, v. 23, n. 11, art. 5044, 24 maio 2023. DOI: [10.3390/s23115044](https://doi.org/10.3390/s23115044).

PEREIRA, F. S.; MANEA, S.; LOUREIRO, G. Órbitas terrestres e missões. In: WORKSHOP EM ENGENHARIA E TECNOLOGIA ESPACIAIS, 12., 2021, [S. l.]. [S. l.: s. n.], 2021.

PEREYRA, C. G. *et al.* Evaluation of site-specific management to optimise *Vitis vinifera* L. (cv. Tannat) production in a vineyard with high heterogeneity. **OENO One**, v. 56, n. 3, p. 1–11, 2022.

PHAM, D. N. *et al.* Selection of K in *K-means* clustering. **Proc. IMechE**, v. 219, n. C, p. 103 – 119, 2005.

PLANET LABS. **On-Orbit Radiometric Calibration of the Planet Satellite Fleet**. Pleasanton (CA): Planet Labs Inc., 2022. Disponível em: https://assets.planet.com/docs/radiometric_calibration_white_paper.pdf. Acesso em: 03 abr. 2025.

PLANET LABS. **PlanetScope**. In: PLANET LABS. *Planet Documentation*. [S. l.: s. n., s. d.]. Disponível em: <https://docs.planet.com/>. Acesso em: 03 abr. 2025.

PLANET LABS. **PlanetScope Scene Imagery Product Specification Letter**. Pleasanton (CA): Planet Labs Inc., 2023. Disponível em: https://assets.planet.com/docs/Planet_PSScene_Imagery_Product_Spec_letter_screen.pdf. Acesso em: 03 abr. 2025.

QUEIROZ, D. M. de *et al.* (org.). **Agricultura digital**. 2. ed. São Paulo: Oficina de Textos, 2022. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 5 jan. 2025.

R CORE TEAM. **R: A Language and an Environment for Statistical Computing**. Vienna, Austria: Foundation for Statistical Computing, 2024. Disponível em: <https://www.R-project.org/>. Acesso em: 05 jul 2024.

RAFIF, R. Crop Intensity Mapping Using Dynamic Time Warping and Machine Learning from Multi-Temporal PlanetScope Data. **Land**, v. 10, n. 12, p. 1384, 2021. Disponível em: <https://doi.org/10.3390/land10121384>.

RAHALI, L. *et al.* CubeSat constellations: New era for precision agriculture? **Computers and Electronics in Agriculture**, v. 230, mar. 2025.

RIBEIRO, G. de A.; SILVA, J. N. de C.; SILVA, J. B. da. Índice de Vegetação Ajustado ao Solo (IVAS): estado da arte e suas potencialidades. **Revista Brasileira de Geografia Física**, v. 9, n. 6, p. 2054–2074, 2016.

RODRIGUES, M. S. *et al.* Geoestatística e suas potencialidades na Agricultura 4.0. **Rev. Ciênc. Agron.**, v. 51, Fortaleza, CE, 2020. Disponível em: <https://doi.org/10.5935/1806-6690.20200095>.

ROGERS, C. A. *et al.* The Response of Spectral Vegetation Indices and Solar-Induced Fluorescence to Changes in Illumination Intensity and Geometry in the Days Surrounding the 2017 North American Solar Eclipse. **Journal of Geophysical Research: Biogeosciences**, v. 125, oct. 2020. Disponível em: <https://doi.org/10.1029/2020JG005774>.

ROSA, R. **Introdução ao Sensoriamento remoto**. 7. ed. Uberlândia: EDUFU, 1990. 136 p.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirecional reflectance measures. **Remote Sensing of Environment**, v. 51, n. 3, p. 375-384, 1995.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. In: SYMPOSIUM OF ERTS, 3., Greenbelt. **Anais...** Greenbelt: NASA, 1973. v. 1, p. 309-317.

ROY, D. P. *et al.* A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. **Remote Sensing of Environment**, v. 264, 2021. DOI: 10.1016/j.rse.2021.112586.

SAAVEDRA, L. D.; DEUTSCH, C. V. Automatic variogram calculation and modeling. **Computers & Geosciences**, v. 195, art. 105774, nov. 2024. Disponível em: [10.1016/j.cageo.2024.105774](https://doi.org/10.1016/j.cageo.2024.105774).

SALGADOE, A. *et al.* Quantifying the Severity of Phytophthora Root Rot Disease in Avocado Trees Using Image Analysis. **Remote Sensing**, v. 10, n. 2, fev. 2018.

SANTOS, J. C. F. dos. Estudo de Caso 2 - Definição de Zonas de Manejo, Calagem e Gessagem em Área de Produção de Soja na Fazenda Indaiá, Campo Mourão, PR. In: **Experimentação on-farm na agricultura de precisão**. Passo Fundo: Embrapa Trigo, 2022. 154 p.

SCHMIDTKE, L. M. *et al.* Exploring Interactions Between Vineyard Performance, Grape and Wine Composition and Subregional Boundaries—The Terroir of Barossa Shiraz. **Aust. J. Grape Wine Res.**, p. 375–389, 2024.

SHERMAN, G. E. *et al.* **Quantum GIS version 3.34.9**. 2024. Disponível em: <https://qgis.org/download/>. Acesso em: 03 jan. 2024.

SHIMIZU, K. *et al.* Comparison of Multi-Temporal PlanetScope Data with Landsat 8 and Sentinel-2 Data for Estimating Airborne LiDAR Derived Canopy Height in Temperate Forests. **Remote Sensing**, v. 12, n. 11, p. 1876, 2020. Disponível em: 10.3390/rs12111876.

SHIRATSUCHI, L. S. Integration of plant-based canopy sensors for site-specific nitrogen management. 2011. 157 f. Dissertação (Mestrado) – University of Nebraska, Lincoln, 2011.

SHIRATSUCHI, L. S. *et al.* Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. C. (Org.). **Agricultura de precisão: resultados de um novo olhar**. 1. ed. Brasília, DF: Embrapa, 2014. cap. 4, p. 58-73.

SHLENS, J. A tutorial on principal component analysis. **arXiv**, v. 1, 2014.

SILVA, L. F. Radiation and instrumentation in remote sensing. In: SWAIN, P. H.; DAVIS, S. M. (Ed.). **Remote Sensing: The Quantitative Approach**. New York: McGRAW-HILL, 1978. p. 21-135.

SILVA, T. M. M. Da. **Teor foliar de nitrogênio em videira fertirrigada e sua relação com atributos do solo e da planta**. 2020. 76 f. Dissertação (Mestrado em Agronomia) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2020.

SILVA, V. F. da *et al.* Caracterização espectral de espécies florestais nativas e a determinação de índices de vegetação obtida por geoprocessamento. **Revista Políticas Públicas & Cidades**, v. 13, n. 2, p. e1300, 2024. DOI: 10.23900/2359-1552v13n2-304-2024. Disponível em: <https://journalppc.com/RPPC/article/view/1300>. Acesso em: 27 set. 2025.

SOKAL, R. R.; SNEATH, P. H. **Principles of Numerical Taxonomy**. San Francisco: W. H. Freeman, 1963.

SONG, X. *et al.* Delineamento de zonas de manejo agrícola com dados de sensoriamento remoto de alta resolução. **Precision Agric.**, v. 10, p. 471- 487, 2009. Disponível em: <https://doi.org/10.1007/s11119-009-9108-2>.

STEFFEN, C. A. **Introdução ao sensoriamento remoto**. INPE. Divisão de Sensoriamento Remoto, v. 6, 2011. 35 p.

TAGARAKIS, A. *et al.* Management zones delineation using fuzzy clustering techniques in grapevines. **Precision Agriculture**, Dordrecht, v. 14, n. 1, p. 18–39, 2013. DOI: 10.1007/s11119-012-9275-4.

TANAJURA, E. L. X.; ANTUNES, M. A.; UBERTI, M. A. Avaliação de Índices de Vegetação Para a Discriminação de Alvos Agrícolas em Imagens de Satélites. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** Goiânia: Instituto Nacional de Pesquisas Espaciais, 2005. (CD-ROM).

TAO, H. *et al.* Proximal and remote sensing in plant phenomics: 20 years of progress, challenges, and perspectives. **Plant Communications**, v. 3, n. 6, nov. 2022. Disponível em: <https://doi.org/10.1016/j.xplc.2022.100344>. Acesso em: 03 dez. 2024.

TATTARIS, M. *et al.* A direct comparison of remote sensing approaches for high-throughput phenotyping in plant breeding. **Frontiers in Plant Science**, v. 7, p. 1131, 2016.

THENKABAIL, P. S. Biophysical and yield information for precision farming from near-real-time and historical Landsat TM images. **International Journal of Remote Sensing**, v. 24, n. 14, p. 2879-2904, 2003.

VESPER. Australian Centre for Precision Agriculture. **Vesper User Manual: Vesper 1.6**. Australian: Australian Centre for Precision Agriculture, 2006. 25 f.

VISACARRA ROSSEL, R. A.; MCBRATNEY, A. B.; MINASNY, B. Proximal Soil Sensing. **Geoscience world**, v. 14, n. 4, 2010.

WAMPLE, R. L.; MILLS, L.; DAVENPORT, J. R. Use of precision farming practices in grape production. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 4., 1998, Saint Paul, Estados Unidos. **Proceedings...** Minneapolis: University of Minnesota, 1999. p. 897-905.

WANG, X. *et al.* Remote sensing revolutionizing agriculture: Toward a new frontier. **Future Generation Computer Systems**, v. 166, jan. 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167739X24006551>.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for Environmental Scientists**. Second Edition. Chichester: Wiley, 2014.

WILDING, L. P. Spatial variability: its documentation, accommodation, and implication to soil surveys. In: NIELSEN, D. R.; BOUMA, J. (Ed.). **Soil Spatial Variability**. Wageningen: Pudoc, 1985. p. 166–194.

XU, R.; WUNSCH, D. **Clustering**. 1. ed. Wiley, 2008. 400 p.

XU, T. *et al.* Evaluating the potential of very high-resolution satellite data for the enhanced estimation of rice aboveground biomass by combining spectral and spatial information. **Computers and Electronics in Agriculture**, v. 239, 2025. Disponível em: <https://doi.org/10.1016/j.compag.2025.110997>.

YU, R. *et al.* Proximal sensing of vineyard soil and canopy vegetation provide direction in identifying vineyard spatial variability in plant physiology and berry chemistry. **OENO One**, v. 55, n. 2, 2021.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. São Paulo: Oficina de Textos, 2019.

ZANZARINI, F. V. *et al.* Correlação espacial do índice de vegetação (NDVI) de imagem Landsat/ETM+ com atributos do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 17, n. 6, p. 608–614, 2013.

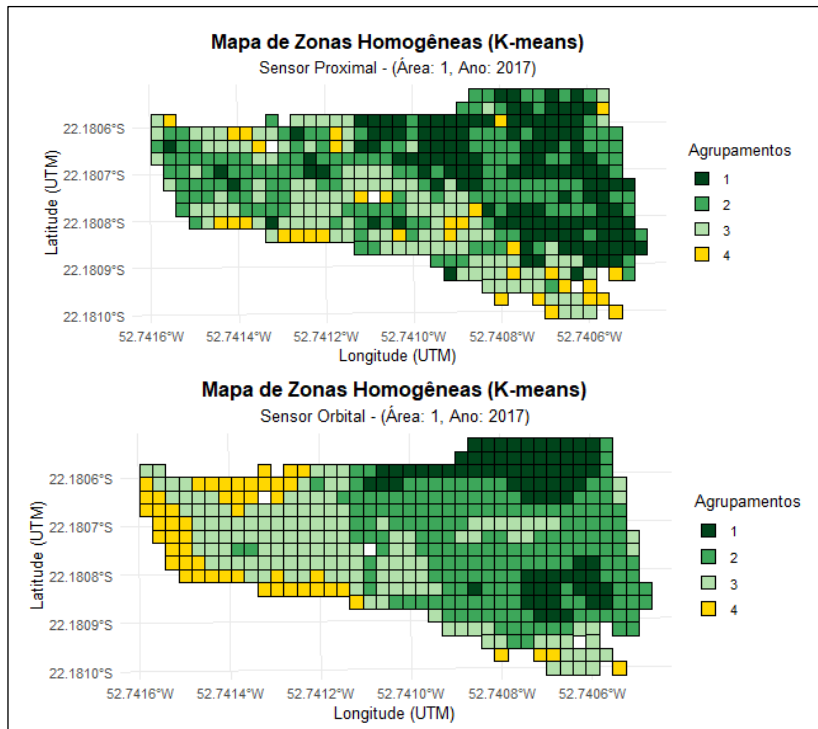
ZHANG, C.; MARZOUGUI, A.; SANKARAN, S. High-resolution satellite imagery applications in crop phenotyping: An overview. **Computers and Electronics in Agriculture**, v. 175, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105584>.

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

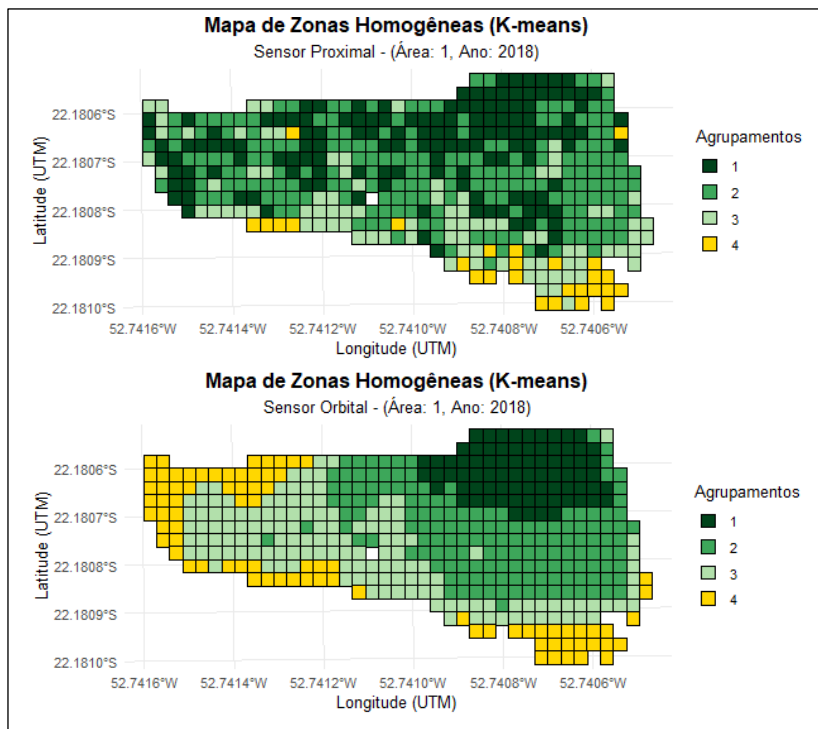
ZHANG, T. *et al.* Imaging geometric simulation and vibration influence analysis of rotary scanning remote sensing satellites. **Measurement**, v. 242, n. E, nov. 2024. Disponível em: <https://doi.org/10.1016/j.measurement.2024.116108>.

ZHOU, G. Q. An overview of in-orbit radiometric calibration of typical satellite sensors. **Copernicus Publications**, v. 40, n. 7, jun. 2015. Disponível em: [10.5194/isprsarchives-XL-7-W4-235-2015](https://doi.org/10.5194/isprsarchives-XL-7-W4-235-2015).

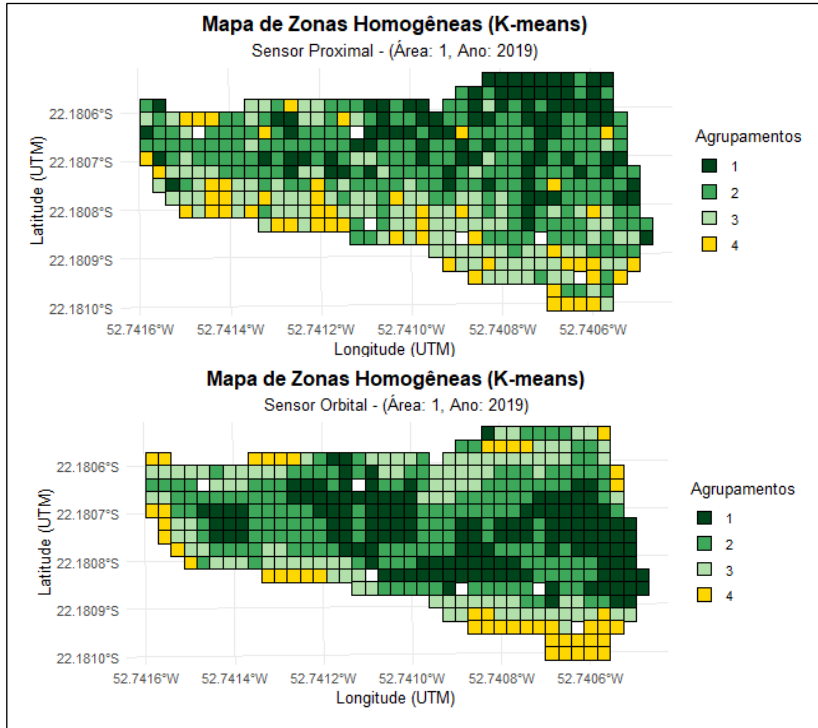
ANEXO A - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2017




ANEXO B - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2018



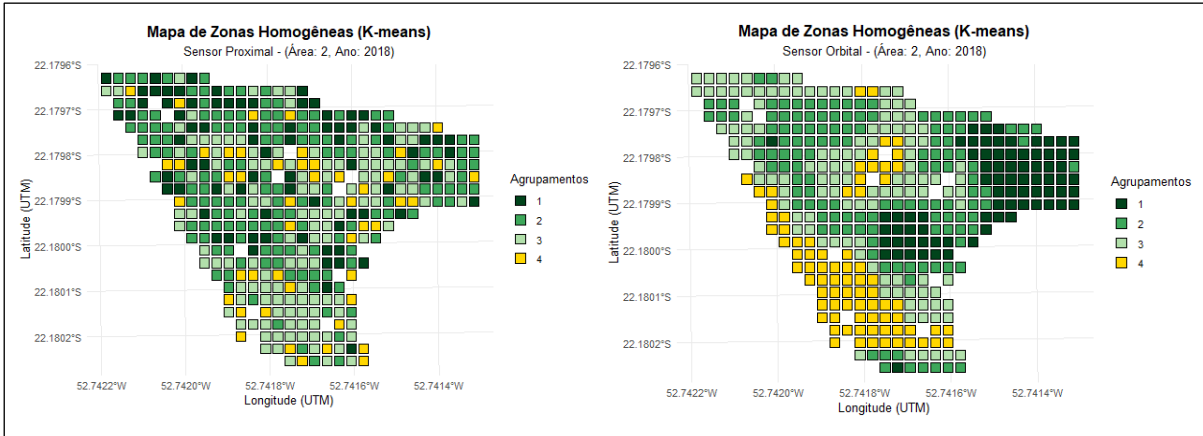
ANEXO C - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 1, ano de 2019



ANEXO D - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2017



ANEXO E - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2018



ANEXO F - Zonas homogêneas (K = 4) obtidas pelos sensores proximal e orbital na Área 2, ano de 2019

