

JOSÉ RENAN DA SILVA E SILVA

**COMPARAÇÃO NA DELIMITAÇÃO DE ZONAS DE MANEJO POR SENSOR
PROXIMAL E ORBITAL EM VITIVINICULTURA DE INVERNO**

Botucatu

2026

JOSÉ RENAN DA SILVA E SILVA

**COMPARAÇÃO NA DELIMITAÇÃO DE ZONAS DE MANEJO POR SENSOR
PROXIMAL E ORBITAL EM VITIVINICULTURA DE INVERNO**

Dissertação apresentada à Faculdade de
Ciências Agronômicas da UNESP Campus
de Botucatu, para obtenção do título de
Mestre em Engenharia Agrícola.

Orientador: Dr. Luís Henrique Basso

Coorientador: Dr. Eduardo Antônio
Speranza

Botucatu

2026

S586c

Silva, José Renan da Silva e

Comparação na delimitação de zonas de manejo por sensor proximal e orbital em vitivinicultura de inverno / José Renan da Silva e Silva. -- Botucatu, 2026

124 p. : tabs., mapas

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

Orientador: Luís Henrique Basso

Coorientador: Eduardo Antônio Speranza

1. Viticultura de precisão. 2. Vinho de inverno. 3. Índices de vegetação. 4. Sensoriamento remoto. 5. Zonas de manejo. I. Título.

CERTIFICADO DE APROVAÇÃO

Título:

COMPARAÇÃO NA DELIMITAÇÃO DE ZONAS DE MANEJO POR SENSOR PROXIMAL E ORBITAL EM VITIVINICULTURA DE INVERNO

AUTOR: JOSÉ RENAN DA SILVA E SILVA

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: 27/01/2026 12:19:30-0300
Verifique em <https://validar.iti.gov.br>Pesquisador Dr. LUÍS HENRIQUE BASSOI (Participação Virtual)
Embrapa Instrumentação / Empresa Brasileira de Pesquisa Agropecuária Documento assinado digitalmente
LUCIANO GEBLER
Data: 27/01/2026 16:59:55-0300
Verifique em <https://validar.iti.gov.br>Pesquisador Dr. LUCIANO GEBLER (Participação Virtual)
Agricultura de Precisão / Embrapa Uva e Vinho Documento assinado digitalmente
PETERSON RICARDO FIORIO
Data: 27/01/2026 16:32:43-0300
Verifique em <https://validar.iti.gov.br>Prof. Dr. PETERSON RICARDO FIORIO (Participação Virtual)
Engenharia de Biosistemas / Escola Superior de Agricultura Luiz de Queiroz

Botucatu, 27 de janeiro de 2026.

Dedico:

À Deus, pela força e livramento;

À minha mãe, pelo orgulho e incentivo;

À minha família, pelo carinho constante;

À minhas filhas que tem sido a minha motivação diária;

À minha esposa, pelo apoio incansável mesmo na distância;

E aos meus orientadores, pela dedicação e pelo conhecimento compartilhado.

AGRADECIMENTOS

À Universidade Estadual Paulista “Júlio de Mesquita Filho” - UNESP/FCA e ao Programa de Pós-Graduação em Engenharia Agrícola, pela confiança e pela oportunidade de concretizar o sonho de atuar como pesquisador, contribuindo para o avanço da ciência e para o desenvolvimento da agricultura que sustenta milhões de pessoas em todo o mundo.

Aos docentes que, por meio das disciplinas ministradas e do compartilhamento de conhecimento, contribuíram de forma direta e indireta para minha formação acadêmica e científica.

À coordenação e vice-coordenação do Departamento de Engenharia Agrícola, bem como à Seção Técnica da Pós-Graduação de Botucatu, pelo suporte e dedicação ao longo desta jornada.

Àqueles que me auxiliaram nos alojamentos, proporcionando acolhimento e cuidado durante minha permanência.

Aos meus pais, pelo apoio incondicional, em especial à minha mãe, cuja força e presença foram fundamentais nos momentos de maior dificuldade, especialmente após o acidente que quase me fez desistir.

À minha esposa, pela dedicação incansável, pelo apoio constante e pela parceria em cada etapa desta trajetória. Sua presença ao meu lado foi essencial para que este sonho se tornasse realidade.

Ao meu orientador, Dr. Luis Henrique Bassoi, e ao meu coorientador, Dr. Eduardo Antônio Speranza, pela orientação, pela disponibilidade em esclarecer dúvidas e pela confiança depositada neste projeto desde o início até sua conclusão.

À Embrapa Instrumentação, pela abertura e pelo suporte oferecido à realização da pesquisa.

À Vinícola Guaspari, em Espírito Santo do Pinhal, pelo apoio para a execução de parte deste estudo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil – CAPES – Código de financiamento 001.

Finalmente, aos membros da banca examinadora, registro meus sinceros agradecimentos pela disponibilidade e pelas valiosas contribuições que enriqueceram este trabalho.

“Confie no Senhor e faça o bem; assim você habitará na terra e desfrutará segurança. Deleite-se no Senhor, e ele atenderá aos desejos do seu coração. Entregue o seu caminho ao Senhor; confie nele, e ele agirá.”

RESUMO

As condições edafoclimáticas e o manejo do vinhedo influenciam diretamente a maturação das uvas e suas características enológicas. Nesse contexto, a variabilidade espacial pode ser gerenciada por meio do sensoriamento remoto proximal e orbital, contribuindo para a delimitação de zonas de manejo na viticultura de precisão. Este estudo teve como objetivo avaliar a aplicabilidade de imagens orbitais de alta resolução na delimitação de zonas de manejo em vinhedos de uvas para vinho de inverno, comparando qualitativamente seus resultados com aqueles obtidos por sensoriamento proximal. O experimento foi conduzido em três vinhedos comerciais localizados em Espírito Santo do Pinhal (SP), nos ciclos produtivos de 2018 e 2019. Foram analisados seis índices de vegetação (NDVI, RVI, MSR, RDVI, IPVI e SAVI), aplicando-se pré-processamento das imagens, interpolação por krigagem, análise estatística descritiva, avaliação de autocorrelação espacial pelo índice de Moran e agrupamento por k-means para definição das zonas de manejo. Os sensores proximais apresentaram maior sensibilidade na detecção de pequenas variações no vigor do dossel, enquanto as imagens orbitais evidenciaram padrões espaciais mais amplos e contínuos. A comparação entre os sensores foi realizada de forma qualitativa, considerando as diferenças na natureza e escala dos dados obtidos por cada plataforma. Ambos os sensores demonstraram maior estabilidade na definição de duas zonas de manejo ao longo dos ciclos avaliados. A integração das informações provenientes das duas plataformas mostrou-se complementar, contribuindo para uma delimitação consistente das zonas de manejo. Os resultados indicam que o uso combinado de sensoriamento proximal e orbital pode ampliar o suporte técnico à tomada de decisão na viticultura de precisão, favorecendo o manejo localizado e a otimização das práticas agrícolas.

Palavras-chave: viticultura de precisão; vinho de inverno; índice de vegetação; sensoriamento remoto; agrupamentos por K-means.

ABSTRACT

Soil and climate conditions and vineyard management directly influence grape ripening and oenological characteristics. In this context, spatial variability can be managed through proximal and orbital remote sensing, contributing to the delimitation of management zones in precision viticulture. This study aimed to evaluate the applicability of high-resolution orbital images in delimiting management zones in vineyards of winter wine grapes, qualitatively comparing the results with those obtained by proximal remote sensing. The experiment was conducted in three commercial vineyards located in Espírito Santo do Pinhal (SP), during the 2018 and 2019 production cycles. Six vegetation indices (NDVI, RVI, MSR, RDVI, IPVI, and SAVI) were analyzed using the management zone definitions. Proximal sensors showed greater sensitivity in detecting small variations in canopy vigor, while orbital images revealed broader and more continuous spatial patterns. The comparison between the sensors was carried out qualitatively, considering the differences in the nature and scale of the data obtained by each platform. Both sensors demonstrated greater stability in defining two management zones throughout the evaluated cycles. The integration of information from the two platforms proved to be complementary, contributing to a consistent delimitation of the management zones. The results indicate that the combined use of proximal and orbital sensing can expand the technical support for decision-making in precision viticulture, favoring localized management and the optimization of agricultural practices.

Keywords: precision viticulture; winter wine; vegetation index; remote sensing; K-means clustering.

LISTA DE ABREVIATURAS E SIGLAS

NDVI	Normalized Difference Vegetation Index
RVI	Ratio Vegetation Index
MSR	Modified Simple Ratio
RDVI	Renormalized Difference Vegetation Index
IPVI	Infrared Percentage Vegetation Index
SAVI	Soil Adjusted Vegetation Index
IoT	Internet of Things
ACS-430	Sensor óptico ativo utilizado no estudo
GeoSCOUT	Datalogger utilizado em conjunto com o sensor proximal
SIG	Sistema de Informação Geográfica
ARP	Aeronave Remotamente Pilotada
RGB	Red, Green, Blue (Vermelho, Verde, Azul)

LISTA DE SÍMBOLOS

ρ	Reflectância do dossel vegetativo
Δ	Diferença
λ	Comprimento de onda
I de Moran	Índice de autocorrelação espacial
CV	Coeficiente de variação
k	Número de agrupamentos no método k-means
μ	Média aritmética
σ^2	Variância
σ	desvio padrão
m	metros
ha	hectare
nm	nanômetro
°C	graus Celsius

SUMÁRIO

1	INTRODUÇÃO	21
2	REVISÃO DE LITERATURA	23
2.1	Panorama e características da viticultura.....	23
2.2	Tecnologias utilizadas no uso da agricultura de precisão	24
2.3	Variabilidade do vigor em videiras estimada por índices de vegetação derivados do sensoriamento remoto.....	26
3	MATERIAL E MÉTODOS	33
3.1	Área de Estudo e Período Analisado	33
3.2	Fenologia e somatório térmico de cultivares de videira.....	34
3.3	Coleta e Processamento de Dados Proximais.....	35
3.4	Coleta e Processamento de Dados Orbitais	41
3.5	Zonas de Manejo a partir de Sensores Proximais e Orbitais	42
4	RESULTADOS E DISCUSSÃO	48
4.1	Índices de Vegetação	48
4.2	Definição do número de agrupamentos (k) para as áreas A1, A2 e A3 ...	65
4.2.1	<i>Largura média da Silhueta da área A1.....</i>	69
4.2.2	<i>Curva Elbow (método do cotovelo) para área A1.....</i>	70
4.2.3	<i>Largura média da Silhueta da área A2.....</i>	71
4.2.4	<i>Curva Elbow (método do cotovelo) para área A2.....</i>	72
4.2.5	<i>Largura média da Silhueta na área A3.....</i>	73
4.2.6	<i>Curva Elbow (método do cotovelo) para a área A3.....</i>	74
4.3	Dispersão K-Means dos valores padronizados da área (A1, A2 e A3).....	75
4.3.1	<i>Dispersão para os proximais (A1)</i>	76
4.3.2	<i>Dispersão para os orbitais (A1)</i>	76
4.3.3	<i>Dispersão para os proximais (A2)</i>	77
4.3.4	<i>Dispersão para os orbitais (A2)</i>	77
4.3.5	<i>Dispersão para os proximais (A3)</i>	78
4.3.6	<i>Dispersão para os orbitais (A3)</i>	78
4.4	Mapa dos agrupamentos (zonas de manejo) para área A1.....	79
4.5	Mapa dos agrupamentos (zonas de manejo) para área A2.....	80
4.6	Mapa dos agrupamentos (zonas de manejo) para área A3.....	81
4.7	Validação estatística dos agrupamentos das áreas A1, A2 e A3	82
4.7.1	<i>Testes de comparação de médias</i>	82

4.7.2	<i>Comparação de médias do proximal (A1)</i>	85
4.7.3	<i>Comparação de médias dos orbitais (A1)</i>	86
4.7.4	<i>Comparação de médias dos proximal (A2)</i>	87
4.7.5	<i>Comparação de médias dos orbitais (A2)</i>	88
4.7.6	<i>Comparação de médias do proximal (A3)</i>	89
4.7.7	<i>Comparação de médias dos orbitais (A3)</i>	90
4.8	<i>Comparação de médias</i>	93
4.8.1	<i>Sensor proximal área A1</i>	93
4.8.2	<i>Sensor orbital área A1</i>	95
4.8.3	<i>Sensor proximal área A2</i>	96
4.8.4	<i>Sensor orbital área A2</i>	97
4.8.5	<i>Sensor proximal área A3</i>	100
4.8.6	<i>Sensor orbital área A3</i>	101
4.9	<i>Autocorrelação espacial (Moran I)</i>	102
4.9.1	<i>Sensor proximal área A1</i>	104
4.9.2	<i>Sensor orbital área A1</i>	106
4.9.3	<i>Sensor proximal área A2</i>	108
4.9.4	<i>Sensor orbital na área A2</i>	110
4.9.5	<i>Sensor proximal área A3</i>	113
4.9.6	<i>Sensor orbital área A3</i>	114
5	CONCLUSÕES	118
	REFERÊNCIAS	119

1 INTRODUÇÃO

A viticultura de precisão é definida, entre outros aspectos, pelo mapeamento da variabilidade espacial e temporal dos fatores que são internos ao vinhedo. Nesse contexto, a análise temporal se destaca como um ponto importante a ser considerado, ao contrário do que acontece, por exemplo, em culturas anuais, onde a atenção do manejo está voltada para o aspecto espacial. As videiras permanecem consistentes de um ciclo de produção para outro, o que requer uma análise atenta para compreender as relações de interdependência entre causas e efeitos ao longo do tempo, assim como entre qualidade e produtividade.

A importância da variação das condições naturais na prática agrícola voltada para a produção de vinhos é clara no cultivo de videiras. A relevância desse aspecto decorre da interação de vários fatores ambientais que afetam de maneira significativa o processo de maturação das uvas, exercendo uma influência direta na composição das frutas e nas características enológicas que lhes são próprias (Costa, 2021). Essas características essenciais de espaço e tempo que geram essas variações são uma das razões para o avanço de tecnologias que reconhecem os limites de áreas de manejo mais homogêneas, permitindo um manejo distinto para cada área na agricultura de precisão.

A variabilidade de atributos é particular de cada zona de manejo das videiras, refletindo nas propriedades da planta e podendo ser detectada por sensores orbitais de alta resolução, o que torna o estudo de grandes áreas mais acessível para a gestão do plantio e também reduz gastos. Um dos parâmetros frequentemente observados para indicar a variabilidade em um vinhedo é o vigor vegetativo das videiras. As características desuniformes evidenciam as diferenças nas condições ambientais que são naturais para uma determinada área de cultivo. No que diz respeito à viticultura de precisão (VP), a inferência sobre o estado de desenvolvimento vegetativo das videiras é realizada, estimando-se os índices de vegetação obtidos a partir da reflectância (ρ) do seu dossel vegetativo (Costa, 2021).

Estudos como os de Matese *et al.* (2019) e Urretavizcaya *et al.* (2016) mostram que o uso de sensores proximais para definir zonas de manejo pelo vigor das plantas é um grande aliado para melhorar a produtividade, a irrigação e o uso de nutrientes, trazendo até 15% mais uniformidade na maturação e reduzindo em 10% o consumo

de insumos. Outros trabalhos realizados como os de Farinassi *et al.* (2022) e Costa (2021) também comentam sobre o uso dessa ferramenta que vem contribuindo para o manejo preciso das videiras.

Essa abordagem tem se revelado eficaz, tanto na identificação de variações espaciais dentro dos vinhedos quanto na validação prática em campo, mostrando ganhos reais em eficiência produtiva e na sustentabilidade do manejo. Os sensores proximais tornam possível monitorar, em tempo real, as variações fisiológicas das plantas, o que permite que a intervenção agrônômica ocorra de acordo com as necessidades de cada talhão.

Paralelo a isso, há um notável aprimoramento na qualidade dos sensores orbitais disponíveis no mercado. Os satélites de alta resolução espacial têm se mostrado ferramentas promissoras para o mapeamento do vigor vegetativo em áreas agrícolas. Essa inovação tecnológica expande as oportunidades de uso dos sensores orbitais na viticultura de precisão, permitindo a definição à distância de zonas de manejo com nível de detalhamento adequado às aplicações agrícolas, especialmente quando combinada com análises estatísticas e geoespaciais consistentes.

Entendendo esses contextos, esta pesquisa buscou explorar a viabilidade da utilização de imagens orbitais de alta resolução na viticultura de inverno, avaliando seis índices de vegetação (NDVI, RVI, MSR, RDVI, IPVI e SAVI) e contrastando-os com informações coletadas de sensores proximais. O estudo foi realizado em três vinhedos comerciais situados no estado de São Paulo ao longo de dois anos sucessivos (2018 e 2019), com o objetivo de verificar a praticidade e eficácia dessas ferramentas para o delineamento de zonas de manejo e para o aprimoramento das práticas de manejo vitivinícola.

2 REVISÃO DE LITERATURA

2.1 Panorama e características da viticultura

Os registros iniciais da prática da viticultura remontam à idade do Bronze, datando aproximadamente de 3500 anos a.C., conforme evidenciado por descobertas arqueológicas realizadas em uma antiga cidade comercial turca denominada Kannish (Leão, 2000). Este achado arqueológico proporciona conhecimento histórico da origem e disseminação da viticultura, contribuindo para a compreensão da trajetória evolutiva dessa prática ao longo do tempo.

No início dos anos 1960, a viticultura comercial no Brasil começou a se expandir de locais restritos aos estados do Sul e áreas específicas no leste de São Paulo e Sul de Minas Gerais para outras regiões. Então, houve uma significativa expansão da fronteira vitícola, caracterizada pelo estabelecimento de plantações de uvas no Vale do Submédio São Francisco, seguindo pelas regiões norte do Paraná, noroeste de São Paulo e Norte de Minas Gerais. Nas regiões tradicionais, os sistemas de produção foram ajustados ao longo do tempo, em resposta às oportunidades e demandas do mercado. A pesquisa desempenhou um papel crucial no apoio ao empreendedorismo dos viticultores brasileiros, fornecendo tecnologias essenciais que contribuíram significativamente para o atual estágio de desenvolvimento do setor (Camargo *et al.*, 2011).

A viticultura é a disciplina científica dedicada ao estudo dos cultivos de uvas, suas variedades e a capacidade de produção em diferentes regiões do mundo, considerando as características climáticas e de temperaturas específicas de cada localidade (Silva, 2023). Por outro lado, a vinicultura focaliza a análise detalhada do processo de produção de vinhedos. Dessa forma, a vitivinicultura constitui-se como a integração sinérgica entre o cultivo de uvas e todas as fases relacionadas à produção vinífera (Rodrigues, 2022).

A viticultura tropical caracteriza-se por ser prevalente em regiões cujas temperaturas mínimas não atingem níveis adequados para induzir a dormência da videira. Nesse contexto, a planta mantém um crescimento contínuo e, mediante a aplicação de tecnologias apropriadas, torna-se viável a obtenção de duas ou mais colheitas anuais no mesmo vinhedo (Camargo *et al.*, 2011). Este modelo de cultivo,

adaptado às condições climáticas específicas, permite a maximização do potencial produtivo da videira ao longo do ano.

O crescimento inicial dos ramos e folhas nas plantas viníferas coincide concomitantemente com a formação e o desenvolvimento das estruturas florais, marcando o início do ciclo de desenvolvimento. Nesse estágio, as plantas iniciam suas atividades fotossintéticas, transacionando da fase heterotrófica para a autotrófica (Regina *et al.*, 2006). A subsequente etapa do ciclo fenológico da videira envolve a floração e o desenvolvimento dos frutos. Após o processo de polinização e fixação dos frutos, ocorre a formação das bagas, marcada pela divisão celular e pelo acúmulo de reservas, resultando no incremento do volume celular (Duchêne; Schneider, 2005). Esse complexo processo fenológico, interligado e sequencial, desempenha um papel crucial no desenvolvimento das videiras e, por conseguinte, na produção de uvas destinadas à elaboração de vinhos.

A fase de maturação representa a terceira etapa no ciclo fenológico da videira, abrangendo o período que se estende até a colheita das uvas. Este estágio é caracterizado por uma série de transformações físicas e bioquímicas que influenciam de maneira significativa a coloração, consistência, tamanho e composição química das bagas. Durante a maturação, ocorrem processos como a acumulação de açúcares, elementos essenciais para a qualidade e características sensoriais dos frutos. O entendimento preciso dessas transformações na maturação é fundamental para a tomada de decisão estratégica relacionada ao momento ideal de colheita, visando a obtenção de uvas de elevada qualidade enológica (Conde *et al.*, 2007).

2.2 Tecnologias utilizadas no uso da agricultura de precisão

Com o objetivo de mitigar o impacto ambiental e econômico das práticas agrícolas atuais, é imperativo realinhar a tecnologia agrícola, promovendo estratégias de gestão mais sustentáveis capazes de preservar a produtividade das terras em explorações agrícolas de diferentes escalas. Ao redirecionar tecnologias como agricultura de precisão, biotecnologia, *software* de apoio à decisão, melhoramento de plantas e práticas de gestão, alinhadas ao entendimento das interações e mecanismos nos agroecossistemas, é possível aprimorar e integrar esses elementos como parte de uma abordagem holística e de uma estratégia de gestão sustentável a longo prazo (Basso, 2014).

A vitivinicultura de precisão destaca-se pela incorporação de tecnologias avançadas, tais como Internet das Coisas (IoT), drones, robôs e satélites, que possibilitam a condução de estudos detalhados em toda a área cultivada, viabilizando a tomada de decisões embasadas em dados precisos e promovendo uma gestão eficiente e sustentável das práticas vitícolas (Francisco, 2013). Essa prática acaba sendo semelhante da agricultura de precisão usualmente utilizada, que se constitui como a administração refinada da variabilidade temporal e espacial em vinhedos, objetivando aprimorar o rendimento econômico da atividade agrícola, seja por meio do aumento da produtividade ou da qualidade, bem como pela redução dos custos de produção (Francisco, 2013).

A implementação da agricultura de precisão (AP) requer a avaliação da heterogeneidade presente nas áreas cultivadas, demandando a caracterização da dependência espacial de variáveis relevantes. Este procedimento fundamenta-se no monitoramento georreferenciado dessas condições e na predição espacial, tipicamente realizada por meio da aplicação de técnicas geoestatísticas (Costa, 2021).

No que lhe diz respeito, a análise geoestatística busca caracterizar uma variável por meio do exame de sua distribuição e variabilidade espaciais, visando também a determinação das incertezas correspondentes. Essa abordagem instrumentaliza a compreensão aprofundada da estrutura espacial dos dados, permitindo uma avaliação mais robusta das relações e padrões presentes na variabilidade da variável em questão. O foco central reside na identificação e interpretação dos padrões espaciais, possibilitando uma inferência mais precisa sobre as características e comportamentos da variável em diferentes localidades da área de estudo (Yamamoto e Landim, 2013).

A presença ou não de estresse nos diversos estádios fenológicos pode ser obtida através do sensoriamento remoto proximal ou orbital que identifica as características que identificam o estresse sem a necessidade do contato físico com a planta. A detecção de variações na reflectância, relacionadas à densidade da cobertura vegetal, representa uma das primeiras aplicações dos dados obtidos remotamente. Seu objetivo é avaliar a intensidade com que diversos materiais, incluindo solos, rochas e vegetação, refletem a radiação eletromagnética em diferentes comprimentos de onda do espectro (Jensen, 2009; Homolová *et al.*, 2013).

O uso da agricultura de precisão possibilita a detecção, monitoramento e avaliação de diversas doenças em diferentes culturas, por meio da análise de dados obtidos por sensores proximais e orbitais, que identificam alterações na reflectância

associadas a mudanças fisiológicas nas plantas, como redução do teor de clorofila, necroses foliares e variações na estrutura do dossel. Essas alterações modificam a resposta espectral nas faixas do visível e do infravermelho próximo, podendo ser identificadas por índices de vegetação, o que permite a delimitação espacial de áreas com possível incidência de doenças e a adoção de intervenções localizadas. Ao mesmo tempo, permite identificar precocemente o estresse hídrico nas plantações (Calderón *et al.*, 2013). Esses dados são utilizados para orientar de forma mais precisa o planejamento das intervenções ao longo do crescimento das plantas, implementar práticas de manejo específicas, realizar a seleção criteriosa de cachos e otimizar o processo de colheita (Braga, 2009).

2.3 Variabilidade do vigor em videiras estimada por índices de vegetação derivados do sensoriamento remoto

O potencial completo dos dados de sensoriamento remoto orbital é alcançado apenas por meio de uma interpretação adequada. Essa compreensão é essencial para extrair informações úteis das imagens capturadas pelos sensores remotos (Jensen, 2009). Por esses e outros motivos, confirmar a veracidade e a precisão de dados oriundos do sensoriamento remoto orbital com outros dados como os do sensoriamento remoto proximal e dados de campo é imprescindível, elevando o nível de confiabilidade do estudo.

A interpretação visual e a classificação digital se distinguem principalmente pela presença de um componente subjetivo. Enquanto a interpretação visual se apoia no uso da imagem como um mapa de referência, no qual um usuário identifica e delimita os elementos desejados, a classificação digital emprega algoritmos para identificar categorias com base nos níveis digitais presentes (Jensen, 2011). A interpretação visual de imagens implica na identificação de objetos representados e na atribuição de significados a eles. Durante esse processo, o intérprete delimita visualmente um objeto e associa a ele um significado semântico. Isso pode envolver a categorização do uso do solo em uma região específica, a identificação do tipo de solo, a medição da temperatura, o índice de vegetação ou qualquer outro atributo que seja relevante para o mapeamento desejado (Florenzano, 2012).

O sensoriamento remoto na viticultura oferece benefícios significativos, sendo a capacidade de coletar informações em larga escala e em tempo real um dos mais

destacados. Essa capacidade possibilita aos viticultores obter informações detalhadas sobre as condições de seus vinhedos, permitindo a tomada de decisões informadas de maneira ágil e eficiente. Isso não apenas otimiza o manejo das videiras, mas também contribui para o aprimoramento da qualidade e produtividade na produção de uvas e vinhos (Taylor, 2000).

A abordagem do sensoriamento remoto proximal se caracteriza pela aquisição de dados em estreita proximidade com o objeto de interesse, possibilitando medições minuciosas e específicas. Esse método permite a análise de assinaturas espectrais associadas a diferentes componentes do sistema solo-planta, viabilizando a identificação de variações na composição química foliar, no teor de clorofila e no estado fisiológico das plantas (Homolová *et al.*, 2013). A integração do sensoriamento próximo por aeronaves remotamente pilotadas (ARP) é o resultado do avanço notável de duas tecnologias maduras nas últimas décadas: os veículos multirrotor (Yang *et al.*, 2017) e a fotogrametria baseada em *Structure-from-Motion* (Westoby *et al.*, 2012; Granshaw, 2016). Nesse contexto, o protocolo adotado baseou-se na aquisição de imagens no espectro RGB visível, capturadas por câmera embarcada em ARP durante missões planejadas com rotas de voo previamente definidas, garantindo sobreposição adequada entre imagens e cobertura homogênea da área de estudo para posterior processamento fotogramétrico. Esta abordagem representa uma convergência avançada de tecnologias que desempenham um papel crucial em uma variedade de aplicações, incluindo topografia, inspeções ambientais e levantamento de áreas remotas, destacando-se como uma ferramenta versátil e eficiente no campo do sensoriamento remoto (Colomina; Molina, 2014).

O sensoriamento remoto orbital consiste na obtenção de informações sobre a superfície terrestre mediante sensores embarcados em satélites que circulam a órbita do planeta (Florenzano, 2007). Esses satélites capturam dados e imagens em diversas faixas espectrais, proporcionando a observação e análise abrangente de características geográficas, ambientais e naturais da Terra a partir de uma perspectiva global (Formaggio; Sanches, 2017). Essa metodologia permite a extração de informações espectrais e espaciais dos alvos, possibilitando a geração de índices de vegetação e a avaliação da variabilidade dentro da área, sendo particularmente relevante em aplicações de agricultura de precisão e monitoramento ambiental.

Entre as variadas opções de satélites existentes, os nanossatélites emergem como uma alternativa notável. O emprego de pequenos, micros e nanossatélites

representa uma tendência universal irreversível (Filho, 2013). Esses nanossatélites, de dimensões reduzidas, estão ganhando destaque na comunidade espacial devido à sua versatilidade, eficiência e à tendência global de adotar soluções mais compactas para missões espaciais. A crescente aceitação dessas plataformas menores está transformando a dinâmica da exploração espacial, oferecendo oportunidades inovadoras para uma variedade de aplicações, desde observação da Terra até experimentos científicos em órbita (Heidt *et al.* 2000).

A empresa Planet oferece imagens capturadas por seus nanossatélites em dois produtos distintos: o "*PlanetScope Visual*" e o "*PlanetScope Analytic*". Ambas as opções são georreferenciadas, ortorretificadas e passam por correções radiométricas, o que facilita sua integração em softwares de sensoriamento remoto e Sistemas de Informações Geográficas (SIGs). A diferença principal entre os dois produtos reside na forma de entrega. Enquanto o Visual é disponibilizado em uma composição de cores semelhante às aquelas percebidas pelo olho humano, com 8 bits, o Analytic é entregue com 4 bandas espectrais de 12 bits cada, incluindo vermelho, verde, azul e infravermelho próximo (Engesat, 2019).

O sistema de satélites PlanetScope opera em uma órbita circular, heliossíncrona e descendente, com inclinação variando de 51,6° a 98°, circulando a altitudes que variam entre 390 e 500 km, dependendo da órbita específica. As bandas individuais desses satélites apresentam uma resolução radiométrica de 12 bits por pixel, enquanto a resolução espacial atinge três metros. Quanto à resolução espectral, ela é discriminada da seguinte forma: 455 - 515 nm para a banda azul, 500 - 590 nm para a banda verde, 590 - 670 nm para a banda vermelha e 780 - 860 nm para a banda do infravermelho próximo. Uma característica notável é o curto tempo de revisita diário, permitindo a disponibilização das imagens apenas 24 horas após a coleta (Engesat, 2019).

Esses nanossatélites com tecnologias mais avançadas e de alta resolução proporcionam análises mais precisas no estudo agrícola e especificamente para a viticultura em estudo, pois possibilitam o cálculo e a análise dos Índices de Vegetação (IV), formulações matemáticas que utilizam a reflectância do dossel vegetal em diferentes faixas do espectro eletromagnético para avaliar características específicas. Esses índices viabilizam a comparação temporal e espacial da atividade fotossintética terrestre, simplificando o acompanhamento das variações sazonais, interanuais e de

longo prazo nos atributos estruturais, fisiológicos e biofísicos da vegetação (Thenkabail; Smith; Pauw, 2000).

Os índices de vegetação desempenham um papel fundamental na avaliação das condições das vinhas, possibilitando estabelecer correlações com o rendimento e com outros parâmetros relevantes, como a concentração de clorofila nas folhas (Caruso *et al.*, 2017) e o teor de nitrogênio e de água na região da copa (Giovos *et al.*, 2021). Esses índices são aplicados para monitorar a saúde das videiras, identificar áreas sob estresse, otimizar a irrigação, avaliar a maturação das uvas e até mesmo prever a produtividade (Xue; Su, 2017).

Combinações ponderadas de bandas espectrais no domínio do verde, do vermelho e do infravermelho próximo (NIR) são utilizadas no monitoramento de propriedades biológicas relevantes, como biomassa, teor de água nas folhas e concentração de clorofila (Tucker, 1979). A validação concentrou-se no NDVI (Índice de Vegetação da Diferença Normalizada), concebido por Rouse *et al.* (1973), um índice de vegetação estrutural amplamente adotado em aplicações agrícolas, devido à sua consistente correlação com o crescimento das culturas, especialmente em estágios iniciais e intermediários de desenvolvimento. Entretanto, em condições de alta biomassa ou dossel muito denso, o NDVI pode apresentar o fenômeno de saturação, no qual o índice tende a estabilizar-se próximo ao seu valor máximo, reduzindo sua sensibilidade para diferenciar variações adicionais no vigor vegetativo. Em contrapartida, a análise da razão simples entre o NIR e o canal vermelho revelou uma significativa correlação com o desenvolvimento das plantas e seus estágios de crescimento, destacando-se como um dos primeiros índices de vegetação estudados (Birth; Mcvey, 1968).

Os índices de vegetação normalizados, como o NDVI, são expressos em uma escala que varia de -1 a 1, na qual valores próximos de zero geralmente estão associados a superfícies não vegetadas, como solo exposto, enquanto valores negativos tendem a indicar corpos d'água ou sombras. Essa caracterização é resultado da reflexão mais equilibrada entre as faixas do vermelho e do infravermelho próximo, produzindo valores de NDVI próximos de zero (Pereira; Silva; Pamboukian, 2016). Por outro lado, valores situados entre 0 e 1 indicam presença de vegetação, sendo que, quanto mais próximos de 1, maiores tendem a ser a densidade e o vigor do dossel vegetal. Quando a vegetação se encontra em condições saudáveis, ocorre

maior absorção na faixa do vermelho e maior reflectância no infravermelho próximo, elevando os valores do índice (Ribatski; Santos; Neto, 2018; Jensen, 2009).

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

Onde o NDVI (*Normalized Difference Vegetation Index*) é calculado pela diferença entre ρ_{NIR} e ρ_{RED} dividida pela soma de ambos. Nesse índice, ρ_{NIR} representa a reflectância no infravermelho próximo e ρ_{RED} a reflectância na banda do vermelho.

A faixa espectral do infravermelho próximo (NIR) demonstra alta sensibilidade às alterações nas características da vegetação, apresentando considerável potencial para investigações (Jorge *et al.*, 2019).

É possível com essas faixas espectrais realizar a análise de diversos índices de vegetação importantes além do NDVI. O Índice de Razão Simples (*Ratio Vegetation Index* - RVI), também conhecido como *Simple Ratio* (SR), é calculado pela razão entre a reflectância no infravermelho próximo (NIR) e no vermelho (RED), segundo a equação 2.

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

Nesse índice, ρ_{NIR} indica a reflectância no infravermelho próximo e ρ_{RED} a reflectância na banda do vermelho.

Essa relação linear apresenta alta sensibilidade ao aumento de biomassa foliar em estádios iniciais, mas tende a saturar em dosséis densos devido ao achatamento da curva de resposta espectral (Jordan, 1969).

Para contornar a saturação do RVI em coberturas fechadas, o *Modified Simple Ratio* (MSR), definido pela equação (3), propõe a transformação ampliando a faixa dinâmica do índice e mantendo sensibilidade em grandes valores de vegetação. Estudos demonstram que o MSR discrimina melhor variações sutis de clorofila e área foliar em copas densas, seja por plataformas aéreas não tripuladas ou sensores proximais (Sakamoto *et al.*, 2014).

$$MSR = \frac{RVI-1}{\sqrt{RVI+1}} \quad (3)$$

O MSR (*Modified Simple Ratio*) é determinado como o quociente de RVI menos um pela raiz quadrada de RVI mais um. Nesse índice, RVI representa o *Ratio Vegetation Index*, obtido pela razão entre ρ_{NIR} (reflectância no infravermelho próximo) e ρ_{RED} (reflectância na banda do vermelho).

O *Renormalized Difference Vegetation Index* (RDVI) é uma combinação do NDVI e do RVI, resultando na equação (4), que minimiza a influência do solo e da topografia, além de apresentar uma correlação consistente com parâmetros biofísicos, como a área foliar, durante os estágios iniciais e intermediários de desenvolvimento (Roujean; Breon, 1995).

$$RDVI = \frac{\rho_{NIR} - \rho_{RED}}{\sqrt{\rho_{NIR} + \rho_{RED}}} \quad (4)$$

O RDVI (*Renormalized Difference Vegetation Index*) resulta da diferença entre ρ_{NIR} e ρ_{RED} dividida pela raiz quadrada da soma de ρ_{NIR} e ρ_{RED} . Em RDVI, ρ_{NIR} corresponde à reflectância no infravermelho próximo e ρ_{RED} à reflectância na banda do vermelho.

O *Infrared Percentage Vegetation Index* (IPVI) é uma simplificação do NDVI, definido como a equação (5), gerando valores entre 0 e 1 que facilitam interpretações diretas do conteúdo relativo de vegetação. O IPVI minimiza artefatos em áreas de baixa reflectância vermelha, eliminando a diferença entre as bandas, o que o torna prático para sensores portáteis e avaliações rápidas em campo (Lillesaand; Kiefer; Chipman, 2008).

$$IPVI = \frac{\rho_{NIR}}{\rho_{NIR} + \rho_{RED}} \quad (5)$$

O IPVI (*Infrared Percentage Vegetation Index*) expressa-se como a razão de ρ_{NIR} pela soma de ρ_{NIR} com ρ_{RED} . Nesse índice, ρ_{NIR} é a reflectância no infravermelho próximo e ρ_{RED} a reflectância na banda do vermelho.

O *Soil Adjusted Vegetation Index* (SAVI), criado por Huete, traz um fator de correção de solo L na equação (6), com L variando de 0 a 1, de acordo com a

quantidade de solo exposto. Essa compensação atenua o efeito do fundo de solo em coberturas esparsas e retarda a saturação em canopies densos, melhorando as estimativas de biomassa inicial e transpiração das culturas (Huete, 1988).

$$SAVI = \frac{\rho_{NIR} - \rho_{RED}}{(\rho_{NIR} + \rho_{RED} + L)} \times (1 + L) \quad (6)$$

SAVI (*Soil Adjusted Vegetation Index*) incorpora o fator L multiplicando a diferença de ρ_{NIR} e ρ_{RED} pelo termo $(1 + L)$ e dividindo pelo somatório de ρ_{NIR} , ρ_{RED} e L. Onde, ρ_{NIR} representa a reflectância no infravermelho próximo, ρ_{RED} a reflectância na banda do vermelho e L o fator de correção de solo adimensional, que varia de 0 (cobertura total de vegetação) a 1 (solo completamente exposto).


3 MATERIAL E MÉTODOS

3.1 Área de Estudo e Período Analisado

Foram analisados três vinhedos comerciais na Vinícola Guaspari, situada no município de Espírito Santo do Pinhal - SP: A1 (1,50 ha; 22°10'41,11"S; 46°42'11,77"O), A2 (0,82 ha; 22°10'30,58"S; 46°42'1,20"O) e A3 (0,97 ha; 22°10'26,50"S; 46°42'2,29"O). As regiões se encontram a altitudes que oscilam entre 1150 e 1200 metros. Costa (2021) examinou esses mesmos vinhedos anteriormente, utilizando técnicas de sensoriamento remoto proximal para estabelecer índices de vegetação por diferença normalizada, definir zonas de manejo (colheita) e coletar informações sobre a produção de uvas para a produção de vinhos de inverno.

As plantações de vinhas ocorreram em 2006 (A1) e 2010 (A2 e A3), com as variedades *Vitis vinifera* L. cv. As variedades de Cabernet Franc e Cabernet Sauvignon, enxertadas no porta-enxerto Paulsen 1103, foram plantadas com um espaçamento de 3,0 m (A1), 2,5 m (A2 e A3) entre fileiras e 1,0 m (A1, A2 e A3) entre plantas, controladas em um sistema de espaldeira e conduzidas por um único cordão Royat. A orientação predominante das fileiras de plantas era NE-SW (A1 e A2) e NO-SE (Figura 1).

Figura 1 – Distribuição geográfica das áreas de estudo localizadas na Vista da Mata (A1) e Vista do Vale (A2 e A3)



Fonte: O autor

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).

O Cambissolo Háplico Tb foi predominante no solo dos vinhedos, apresentando textura predominantemente argilosa, com teores médios de argila variando entre 41 e 54%, areia entre 39 e 49% e silte entre 6 e 9%, nas diferentes áreas avaliadas. Essa distribuição granulométrica caracteriza um solo de textura argilosa, com variações pontuais para franco-argilosa. A presença de óxidos de ferro, evidenciada pela coloração do solo e pelas características morfológicas observadas em campo, indica caráter férrico associado ao material de origem. Contudo, essa classificação oscilou entre eutrófico e distrófico epieutrófico (grande grupo) e entre típico, léptico ou petroplíntico (subgrupo) (Santos *et al.*, 2018). No entanto, amostras dessas duas últimas categorias foram menos comuns nos três vinhedos. Em todos os vinhedos, a sequência de horizontes Ap (removido) (0 a 0,20 m), seguida do horizonte subsuperficial B incipiente (Bi) (0,20 a 0,70 m) e C (0,70 a 1,00 m), este último composto por material ainda pouco consolidado, foi a mais prevalente na classificação dos horizontes diagnósticos. Ressalta-se que a categorização dos solos dos vinhedos foi conseguida através de uma amostragem feita em seis (A1 e A2) e quatro (A3) locais ao longo dos vinhedos, através de prospecções realizadas no perfil do solo com o uso de um trado holandês em intervalos regulares de 0,20 m de profundidade (Costa, 2021).

De acordo com a classificação de Koppen, o clima da área experimental foi classificado como Cwa, ou seja, subtropical úmido (C), com invernos secos (w) e verões quentes (a).

3.2 Fenologia e somatório térmico de cultivares de videira

A identificação e categorização das fases fenológicas das videiras foram feitas utilizando a escala BBCH ampliada, de acordo com o acordo sugerido por Lorenz *et al.* (1995). Esta escala fenológica estabelece uma padronização na descrição dos períodos de crescimento das plantas, possibilitando comparações entre diversas cultivares e condições ambientais. Durante os ciclos de produção, os avanços fenológicos foram documentados e categorizados em subperíodos ou intervalos, conforme apresentado na Tabela 1.

A classificação adotada permitiu a divisão do ciclo fenológico em dois períodos principais:

- P1: compreendido entre os intervalos ps0 e ps4 (BBCH 11 a 75), abrangendo desde a poda até o desenvolvimento dos frutos em tamanho "ervilha".
- P2: Correspondente ao intervalo PS5 (BBCH 81 a 89), caracterizando a fase de maturação, incluindo o estágio de *veraison* (mudança de coloração das bagas) e a maturação plena.

Tabela 1 – Estádios fenológicos da videira segundo o sistema BBCH e descrições dos principais eventos

Intervalo	Estágio ¹	Código ²	Estádio fenológico	Descrição
PS0	-	-	Poda de produção	Início do ciclo de produção
PS1	01	11	Emergência de folhas	Primeira folha expandida
PS2	06	65	Floração	Floração plena
PS3	07	73	Chumbinho	Bagas em tamanho "chumbinho"
PS4		75	Ervilha	Bagas em tamanho "ervilha"
PS5	08	81	Pintor ou <i>veraison</i>	Mudança de coloração das bagas
		89	Maturação plena	Frutos maduros para colheita

¹Estágios principais de crescimento: 01: desenvolvimento das folhas (BBCH 11 a 19); 06: floração (BBCH 60 a 69); 07: desenvolvimento dos frutos (BBCH 71 a 79); 08: maturação dos frutos (BBCH 81 a 89); ²Código BBCH (Lorenz *et al.*, 1995).

Fonte: Costa, 2021

3.3 Coleta e Processamento de Dados Proximais

Em todos os três vinhedos, a reflectância (ρ , adimensional) do dossel das videiras foi mensurada em três momentos distintos, denominados ocasiões de monitoramento (T_i , onde $i = 1, 2, 3$), no decorrer dos dois ciclos de produção de cada cultivar. Essas avaliações ocorreram durante o estágio fenológico proposto por Lorenz *et al.* (1995), onde o (T_1 , BBCH 79) representa o período de cacho fechado, bem como em ocasião imediatamente posterior ou próxima ao início da maturação (T_2 , BBCH 81) e em um último momento antes da colheita, no decorrer do estágio de amolecimento de bagas (T_3 , BBCH 85) conforme apresenta a Tabela 1.

Em cada ocasião de monitoramento mediu-se a ρ correspondente a três diferentes comprimentos de onda (λ , nm) equivalentes a 670 nm (ρ_R , vermelho), 730

nm (pRE, vermelho limítrofe) e 780 nm (pNIR, infravermelho próximo). Essas medidas foram obtidas por meio de sensoriamento proximal, com auxílio do sensor óptico ativo ACS-430 (Holland Scientific, Lincoln, NE, EUA), componente do sistema portátil Crop Circle. Além desse equipamento, utilizou-se conjuntamente o datalogger GeoSCOUT GLS-400 (Holland Scientific, Lincoln, NE, EUA) para armazenamento das medidas de ρ , as quais foram georreferenciadas durante a aquisição por meio de receptores GNSS (Global Navigation Satellite System) modelo HiPer GGD (Topcon, Pleasanton, CA, EUA), operando em modo autônomo, com precisão horizontal submétrica a métrica, conforme especificação do fabricante (Costa, 2021).

Com os dados coletados em cada ano pelo sensoriamento proximal, foram determinados os índices vegetativos NDVI (*Normalized Difference Vegetation Index*), RVI (*Ratio Vegetation Index*), MSR (*Modified Simple Ratio*), RDVI (*Renormalized Difference Vegetation Index*), IPVI (*Infrared Percentage Vegetation Index*) e SAVI (*Soil-Adjusted Vegetation Index*).

A utilização de múltiplos índices vegetativos teve como objetivo capturar diferentes aspectos do comportamento espectral do dossel das videiras. O NDVI foi empregado como indicador geral de vigor vegetativo e biomassa verde. O RVI e o MSR foram utilizados por apresentarem maior sensibilidade em áreas com alto índice de área foliar, reduzindo possíveis efeitos de saturação do NDVI. O RDVI foi incluído por combinar características lineares do RVI com a normalização do NDVI, proporcionando maior estabilidade em diferentes níveis de cobertura vegetal. O IPVI foi utilizado como medida proporcional da fração de vegetação ativa no dossel. Já o SAVI foi aplicado com o intuito de minimizar possíveis interferências do solo exposto, especialmente nas entrelinhas das fileiras, ajustando a resposta espectral à influência do fundo do solo. Dessa forma, a análise conjunta desses índices permite caracterizar com maior precisão e de maneira mais abrangente a variabilidade espacial do vigor vegetativo espectral nas áreas experimentais.

Foram considerados dois ciclos de produção (2018 e 2019) dos vinhedos A1, A2 e A3, cujas informações estão apresentadas na Tabela 2.

Tabela 2 – Datas e dias após a poda de produção (dap) do início de estádios de desenvolvimento fenológico dos vinhedos A1, A2 e A3 durante os ciclos de produção de 2018 e 2019

Evento	Intervalos entre estádios fenológicos								Total
	P0	PS0	PS1	PS2	PS3	PS4	PS5	H	
Área 1									
Datas (2018)	24/01	25/01	11/02	07/03	22/03	06/04	07/05	17/07	
Duração (dias)	1	17	24	15	15	31	71	1	174
Datas (2019)	17/01	18/01	29/01	22/02	06/03	21/03	05/05	03/07	
Duração (dias)	1	11	24	12	15	45	59	1	160
Área 2									
Datas (2018)	16/01	17/01	30/01	21/02	19/03	31/03	02/05	29/06	
Duração (dias)	1	13	22	23	15	32	58	1	164
Datas (2019)	22/01	23/01	04/02	06/03	14/03	25/03	17/05	01/07	
Duração (dias)	1	12	30	8	11	53	45	1	160
Área 3									
Datas (2018)	16/01	29/01	20/02	15/03	30/03	01/05	19/07	20/07	
Duração (dias)	1	13	22	23	15	32	79	1	185
Datas (2019)	22/01	03/02	05/03	15/03	19/03	09/05	30/07	31/07	
Duração (dias)	1	12	30	10	4	51	82	1	190

P0: poda de produção; PS0: intervalo entre a poda de produção e a emergência das folhas; PS1: intervalo entre a emergência das folhas e a floração plena; PS2: intervalo entre a floração plena e o estádio de bagas em tamanho “chumbinho”; PS3: intervalo entre o estádio de bagas em tamanho “chumbinho” até o tamanho “ervilha”; PS4: intervalo entre o estádio de bagas em tamanho “ervilha” até o início da maturação; PS5: intervalo entre o início da maturação e a maturação plena; H: colheita.

Fonte: Costa, 2021.

A seleção dos dados de coleta ou da fase da planta para a execução das análises foi fundamentada em pesquisas anteriores que apontam uma maior resposta e clareza entre as informações de satélites e sensores próximos durante o período em que a videira começa a amadurecer. Este período, denominado *veraison* (derivado do termo francês "*véraison*"), é um dos mais significativos no ciclo anual da videira; logo, a coleta de dados utilizada para a presente pesquisa foi no período T2 (BBCH 81) ou PS5. Esse período assinala o início do amadurecimento das uvas, caracterizado pela mudança de coloração das bagas (de verde para vermelho nas cultivares tintas), redução da clorofila nos frutos e início do acúmulo de açúcares e compostos fenólicos. Nessa fase, o dossel encontra-se plenamente desenvolvido e fisiologicamente ativo, apresentando estabilidade estrutural e máxima expressão da variabilidade espacial

do vigor vegetativo, o que a torna uma etapa recomendada para aquisição de dados espectrais em vinhedos (Anastasiou *et al.*, 2018).

No ciclo de 2018, o início do *veraison* na área A1 (Cabernet Franc) ocorreu em 07 de maio, enquanto a área A2 (Cabernet Franc) ocorreu em 02 de maio e a área A3 (Cabernet Sauvignon) ocorreu em 19 de julho. Em 2019, o início do *veraison* na área A1 ocorreu em 05 de maio, enquanto a área A2 em 17 de maio e a área A3 em 30 de julho, conforme ilustrado na Tabela 2.


Um passo crucial antes da análise foi a execução do pré-processamento dos dados, eliminando anomalias como pontos fora do intervalo geral do conjunto de dados, que são observações raras que se alteram estatisticamente e parecem inconsistentes com o restante (referidos como *outliers*), ou valores de dados que se diferenciam significativamente dos seus vizinhos, mas permanecem dentro do intervalo geral (referidos como *inliers*). Além disso, pontos sem valor registrado, decorrentes de falhas momentâneas de leitura do sensor ou inconsistências operacionais durante a aquisição, foram imputados com base na média dos valores espacialmente adjacentes. Essa estratégia foi adotada devido à baixa proporção de dados ausentes e teve como objetivo preservar a continuidade espacial do conjunto amostral, evitando lacunas que poderiam comprometer análises subsequentes, como a interpolação e a delimitação de zonas de manejo.

Resumindo, essas anomalias correspondem a observações que se afastam significativamente do comportamento estatístico predominante do conjunto de dados, podendo influenciar desproporcionalmente métricas como média, variância e padrões espaciais. Esses conjuntos de dados são bastante densos, com mais de 20.000 pontos obtidos por área, podendo causar grandes impactos no resultado final da análise. Por outro lado, a execução deste pré-processamento é crucial para garantir a qualidade e a confiabilidade das análises futuras, especialmente quando se trata de índices de vegetação. Foi aplicado um protocolo de corte de dados sugerido por Taylor *et al.* (1994), para garantir a solidez da análise e a obtenção de conclusões acuradas.

Há diversas estratégias para identificar anomalias, que englobam métodos estatísticos, algoritmos de aprendizagem supervisionados e não supervisionados, técnicas de processamento de sinais e estratégias fundamentadas em regras. O método do Z-score foi empregado na pesquisa devido à distribuição normal dos dados e à presença de poucos valores desproporcionais em relação ao total, garantindo assim sua eficácia. Caso contrário, poderia ocorrer uma alteração na média e no

desvio padrão. O Z-score nos diz quantos desvios padrão a amostra está longe da média, sendo assim uma regra estatística que nos diz que a porcentagem de valores que estão dentro de 1, 2, e 3 desvios padrão da média, os quais são 68, 95 e 99,7%, respectivamente (Figura 2); sendo considerados os outliers valores fora dessa faixa como mostrado por Hawkins (1980) em seu livro *"Identification of Outliers"*. Logo, estimar o Z-score é basicamente plotar os itens em um diagrama de dispersão, desvio padrão e média são indicados como 0 e 1 (Montgomery; Runger, 2011).

Figura 2 – Visualização da Distribuição Normal e do Z-Score



Fonte: Pascual, 2018

O cálculo do Z-score é dado pela seguinte expressão:

$$Z = \frac{(x_i - \mu)}{\sigma} \quad (7)$$

Z = Z-score

x_i = dados

μ = média

σ = desvio padrão

Entre os índices de vegetação, o RVI é o que evidencia de maneira mais clara a presença de dados que fogem consideravelmente do padrão previsto, conhecidos como *outliers*. Após o pré-processamento e a remoção dos valores discrepantes ($Z > 3$), proporcionou-se maior homogeneidade e estabilidade estatística do conjunto de

dados, com redução da assimetria, da curtose e da variabilidade extrema, atendendo aos pressupostos necessários para as análises estatísticas subsequentes.

Foram utilizados os dados adquiridos por meio de sensoriamento remoto proximal, já submetidos ao pré-processamento, para realizar a interpolação, com o objetivo de fornecer os valores dos índices de cultivo na área de investigação.

Em razão do grande volume de dados disponíveis (que ultrapassa 5.000 pontos amostrais) foi escolhida a utilização de um método de amostragem consultado ou aleatório com espaçamento sistemático de três metros entre os pontos. Essa distância foi estabelecida tendo como referência a grade amostral das imagens obtidas do satélite Planet, com o intuito de garantir a comparabilidade dos mapas interpolados gerados em relação aos produtos de sensoriamento orbital.

A fase subsequente envolveu a implementação da geoestatística por meio do procedimento de krigagem ordinária, realizada com a utilização do plugin SmartMap no software QGIS. Para cada índice de desenvolvimento avaliado, foi realizada, inicialmente, uma análise exploratória dos dados encontrados, abrangendo a verificação da distribuição estatística, a identificação de outliers e o cálculo de estatísticas descritivas.

Com os dados avaliados, foi identificada a dependência espacial entre os pontos amostrais do semivariograma. Na sequência, foi realizada a modelagem do semivariograma teórico, utilizando os modelos esférico, exponencial ou gaussiano, de acordo com a sua adequação aos dados observados. Os parâmetros calibrados abrangem o alcance (intervalo), o nível (peitoril) e o efeito pepita (pepita), essenciais para a interpolação.

A interpolação foi realizada por meio da krigagem ordinária, fundamentando-se no modelo de semivariograma ajustado, permitindo a estimativa dos valores dos índices de vegetação em regiões não amostradas. Embora a krigagem possa promover uma suavização espacial inerente ao processo de estimação, essa abordagem preserva a estrutura de dependência espacial identificada no semivariograma, possibilitando a geração de superfícies contínuas representativas da variabilidade espacial dos índices.

Ao término do procedimento, foram produzidas superfícies contínuas dos índices de vegetação com resolução espacial de três metros, compatível com as imagens do satélite Planet. Essas superfícies permitiram a análise detalhada dos

padrões espaciais da vegetação e subsidiaram a delimitação posterior das zonas de manejo.

3.4 Coleta e Processamento de Dados Orbitais

As imagens orbitais utilizadas foram adquiridas por meio de nanossatélites pertencentes à constelação PlanetScope, fornecidas pela RedeMAIS/MJSP, os quais dispõem de sensores que cobrem quatro bandas espectrais: azul, verde, vermelho e infravermelho próximo, apresentando resolução espacial de três metros por pixel. Essa constelação é capaz de realizar revisitas diárias, o que permite elevada frequência na aquisição de imagens e maior flexibilidade na seleção das cenas utilizadas no estudo.

Considerando que o período de maturação das uvas ocorre entre os meses de abril e maio, foram priorizadas imagens adquiridas nesse intervalo fenológico, por representarem fase de maior estabilidade vegetativa e proximidade com o momento de colheita. Para a seleção das cenas, adotou-se como critério a baixa cobertura de nuvens, conforme informações disponíveis nos metadados da plataforma Planet, garantindo maior qualidade radiométrica e confiabilidade no cálculo dos índices espectrais.

Foram selecionadas imagens referentes aos anos de 2018 e 2019 para o processamento dos índices de vegetação. Com base nesses dados, foram obtidos os mesmos índices espectrais utilizados para o sensoriamento proximal: NDVI (Normalized Difference Vegetation Index), RVI (Ratio Vegetation Index), MSR (Modified Simple Ratio), RDVI (Renormalized Difference Vegetation Index), IPVI (Infrared Percentage Vegetation Index) e SAVI (Soil-Adjusted Vegetation Index). Esses índices são amplamente utilizados na literatura científica por refletirem a densidade da vegetação, o vigor das plantas e a influência do solo nas respostas espectrais, sendo relevantes para estudos que correlacionam biomassa vegetal à produtividade agrícola.

O processamento das imagens e o cálculo dos índices foram realizados no software QGIS, versão 3.28.11, utilizando a ferramenta “Calculadora *Raster*”. As bandas espectrais foram previamente organizadas e atribuídas conforme a nomenclatura padronizada (ex.: B1_Azul, B2_Verde, B3_Vermelho, B4_NIR), garantindo que cada expressão matemática fosse aplicada corretamente às bandas

correspondentes. As fórmulas foram inseridas manualmente na calculadora *raster*, respeitando a organização dos arquivos e assegurando consistência nos procedimentos adotados.

Os produtos gerados foram salvos individualmente em formato GeoTIFF (.tif), mantendo a extensão espacial da área de estudo e adotando o sistema de referência SIRGAS 2000, projeção UTM, fuso 23S (EPSG:31983), compatível com os dados georreferenciados coletados em campo. Essa padronização assegurou a adequada sobreposição entre os dados orbitais e os dados provenientes do sensoriamento remoto proximal.

A verificação da compatibilidade geométrica foi realizada por meio da sobreposição das imagens orbitais com os pontos georreferenciados obtidos em campo, avaliando-se visualmente a coincidência espacial entre feições identificáveis, como linhas de plantio, limites de talhões e vias internas. Não foram observados deslocamentos espaciais relevantes que comprometessem as análises subsequentes.

Por fim, todo o processo foi documentado e validado por meio da inspeção visual das imagens e dos mapas gerados, bem como da análise estatística dos valores dos índices em pontos amostrais correspondentes, garantindo rigor metodológico e consistência nos resultados apresentados.

3.5 Zonas de Manejo a partir de Sensores Proxiais e Orbitais

Para a definição das áreas de zonas de manejo, utilizando informações obtidas por sensores proximais e orbitais, levou-se em conta a dinâmica temporal dos índices espectrais nos anos de 2018 e 2019. Os dados foram organizados em pares interanuais, especificamente: proximal 2018 × proximal 2019 e orbital 2018 × orbital 2019, possibilitando a análise da persistência espacial e a identificação de regiões com comportamento uniforme durante o período em avaliação.

A análise foi conduzida no ambiente R (versão 4.4.1), assegurando reprodutibilidade e transparência dos procedimentos adotados. Inicialmente, os dados foram organizados e estruturados em um fluxo de trabalho padronizado, com o carregamento de pacotes específicos para manipulação de dados (tidyverse), análises estatísticas (rstatix, nortest), agrupamento e visualização (cluster, factoextra) e análise de autocorrelação espacial (spdep).

Posteriormente, os dados referentes aos seis índices espectrais (NDVI, RVI, MSR, RDVI, IPVI e SAVI), obtidos por meio de sensores proximais e orbitais nos anos de 2018 e 2019, foram importados no formato CSV e estruturados em um único “*data frame*”. Para cada índice de vegetação, o processo de categorização das áreas de zonas de manejo fundamentou-se na utilização do algoritmo K-means em duas dimensões temporais (valores padronizados de 2018 e 2019), com o objetivo de evidenciar a dinâmica interanual do vigor vegetal. Primeiramente, as matrizes foram sujeitas à padronização por z-escore, eliminando distorções impostas por escalas divergentes e permitindo a utilização da distância euclidiana como categoria de similaridade.

O K-means é um algoritmo de agrupamento não supervisionado que divide um conjunto de dados em k grupos distintos, agrupando os pontos de modo que cada um fique associado ao centroide mais próximo. O algoritmo inicialmente define os centroides, seguido pela atribuição de cada ponto ao centroide mais próximo, com recálculos dos centroides até que as alterações nos agrupamentos se tornem mínimas. Esse método é bastante utilizado em planejamento de zonas de manejo devido à sua simplicidade, velocidade e eficácia em dados espaciais e espectrais. Esse método foi introduzido por MacQueen (1967), quando ele explicou o K-means como uma técnica eficaz para a classificação e exame de dados multivariados.

Sendo assim, determinou-se o número ideal de agrupamentos (k) com base em duas abordagens complementares:

- O método do cotovelo (*elbow*) consiste em calcular, para valores de k que variam de 1 a 10, a soma dos quadrados dentro do agrupamento (WSS). O ponto de inflexão na curva WSS sinaliza a situação em que os incrementos adicionais em homogeneidade interna se tornam irrelevantes.
- Avaliação da largura média da silhueta, calculada para valores de k variando entre 2 e 10, que mensura a coesão e a distinção dos agrupamentos. O valor ideal otimiza essa largura, revelando conFigurações de agrupamentos claramente delineadas.

O valor de k ideal correspondeu ao número que maximizou a silhueta; em caso de empates, a escolha recaiu sobre o k com menor WSS. A identificação visual desse ponto foi reforçada por duas curvas: o gráfico de *elbow* (WSS versus k) e o gráfico de silhueta (silhueta média versus k), cada um destacando o k selecionado com linha tracejada.

No método K-Means, a letra *k* representa a quantidade de grupos (ou agrupamentos) que se pretende identificar nos dados. Cada conjunto agrupa itens com semelhanças fundamentadas em características, sendo, neste caso, os valores dos índices espectrais referentes aos anos de 2018 e 2019. Entretanto, é necessário determinar-se a quantidade de agrupamentos ou de grupos para formar-se as zonas, e é nesse contexto que são introduzidos os métodos do cotovelo (*Elbow* - WSS) e da silhueta.

O valor de *k* vinculado ao “cotovelo” mais evidente e em maior largura média de silhueta foi considerado como parâmetro definitivo para cada índice. Visando garantir a solidez no agrupamento, foi realizado o K-Means final com 25 reinicializações solicitadas (`nstart = 25`) e com uma semente estabelecida (`set.seed(123)`), com a finalidade de atenuar o impacto de soluções locais e promover a reprodutibilidade dos resultados. Nas reinicializações solicitadas (`nstart = 25`), o algoritmo K-Means seleciona os centros dos agrupamentos de maneira consultada desde o início. A repetição da análise de diversas vezes pode resultar em diferentes estágios. Com o intuito de evitar a fixação em soluções insatisfatórias, utilizamos o argumento `nstart = 25`, solicitando que o R execute o algoritmo 25 vezes, empregando diferentes pontos de partida. Para que, em seguida, selecione automaticamente a melhor opção dentre as 25, com o menor WSS. Isto intensifica consideravelmente a solidez da análise. A semente pode ser concebida como a definição de um “ponto de partida” para qualquer forma de aleatoriedade. Sempre que uma função solicitada for utilizada (como a seleção de pontos iniciais), o computador produz números pseudoaleatórios. Ao utilizar `set.seed(123)`, garante-se que a aleatoriedade permaneça constante, possibilitando que um outro pesquisador reproduza o mesmo resultado por meio da aplicação do mesmo código e dos mesmos dados, o que se revela essencial para a reprodutibilidade científica.

Para cada par de índice e ano, elaboramos um modelo de análise de variância unidirecional (ANOVA) com o propósito de comparar as médias do índice entre os agrupamentos formados pelo algoritmo de agrupamento. A partir deste modelo, realizamos a remoção dos resíduos e, inicialmente, verificamos sua conformidade com a normalidade utilizando o teste de Anderson–Darling (`nortest::ad.test`). Na sequência, realizamos a verificação da homogeneidade das variâncias amostrais por meio do teste de Fligner-Killeen (`stats::fligner.test`), o que se apresenta como robusto em relação aos desvios de normalidade. Os dois testes foram realizados com um nível

de significância de 5% ($p\text{-valor} < 0,05$), o que implica na eliminação da hipótese nula referente à normalidade dos resíduos ou à homogeneidade das variâncias sempre que o p -valor se apresente abaixo desse patamar.

Se os resíduos demonstrassem uma distribuição compatível com a normalidade (p -valor de Anderson-Darling $> 0,05$) e as variâncias fossem estatisticamente equivalentes (p -valor de Fligner-Killeen $> 0,05$), utilizaríamos uma ANOVA clássica (`stats::aov`) para avaliar as diferenças globais entre as médias dos agrupamentos. Em seguida, realizamos o teste de comparações múltiplas de Tukey-HSD (`multcomp::TukeyHSD`), que administra o erro familiar ao comparar todos os pares de médias, proporcionando contribuições de confiança de 95% para a diferença entre os grupos. Quando apenas a normalidade foi satisfeita, porém as variâncias indicaram heterocedasticidade (p -valor do teste de Fligner-Killeen $\leq 0,05$), realizamos o teste de Welch (`stats::oneway.test` com `var.equal = FALSE`), seguido do teste pós-hoc de Games–Howell (`rstatix::games_howell_test`), o que não exige a condição de homogeneidade das variâncias e ajusta automaticamente os graus de liberdade de Welch.

Em situações nas quais a hipótese de normalidade dos resíduos foi refutada (p -valor de Anderson-Darling $\leq 0,05$), recorriamos ao teste não paramétrico de Kruskal-Wallis (`stats::kruskal.test`), adequado para distribuições assimétricas ou dados que apresentassem *outliers* importantes. Para identificar quais pares de agrupamentos apresentaram diferenças significativas, utilizamos o teste de Dunn (`rstatix::dunn_test`) com a correção de Bonferroni para comparações múltiplas, garantindo que o nível global de significância permaneça em 5%. Assim, cada fase inferencial foi cuidadosamente selecionada para atender aos pressupostos estatísticos do conjunto de dados, permitindo obter informações confiáveis sobre as disparidades entre as zonas de manejo.

Para melhorar a compreensão da distribuição espacial dos índices, foi determinado realizar uma análise de autocorrelação espacial em um contexto intragrupo, examinando especificamente o arranjo espacial dentro de cada zona de manejo previamente delineada por meio de agrupamento de k -means. Essa metodologia permite investigar se, apesar da demarcação das áreas em grupos distintos, os valores do índice preservam a dependência espacial interna, validando ou desafiando a coerência das zonas estabelecidas.

O procedimento começou com a identificação das coordenadas para cada local amostrado (X e Y) dentro das áreas dos vinhedos de inverno (A1, A2 e A3), que foram vinculadas aos valores dos índices proximal e orbital para os anos de 2018 e 2019, juntamente com a categorização dos grupos atribuídos por k-means. Para cada grupo e cada ano, foram consideradas apenas as observações válidas, garantindo um número adequado de pontos de dados para a execução do teste estatístico.

A estrutura espacial de vizinhança foi construída com base nas distâncias entre pontos e geradas no programa RStudio. O algoritmo `dnearneigh` especificou, para cada ponto, vizinhos situados dentro de um raio máximo de 100 unidades de medida, garantindo assim amplas interações espaciais. Posteriormente, a lista de vizinhanças foi convertida em uma matriz de pesos espaciais do tipo *W* (normalizada por linha), garantindo que os pesos cumulativos de cada ponto fossem iguais a um. A opção `zero.policy = TRUE` foi empregada para gerenciar instâncias de pontos isolados, atribuindo pesos zero para evitar erros computacionais.

Utilizando essa matriz de pesos, o teste intragrupo de Moran (`moran.test`) foi aplicado para cada zona e ano. A estatística de Moran *I* é uma ferramenta antiga que mede a autocorrelação espacial. Foi criada por Moran (1950) e diz quanto os valores de uma variável são parecidos ou diferentes em relação aos seus vizinhos. Ela analisa como as unidades se relacionam entre si e compara isso com a variância total, gerando um número que pode ir de -1 a +1. Quando os valores são positivos, isso mostra que as unidades próximas tendem a ser parecidas, formando grupos. Valores negativos indicam que as unidades estão espalhadas ou mudam de forma sistemática (aleatoriedade), enquanto valores perto de zero significam que não há uma estrutura espacial clara. A utilização do Moran *I* é muito importante nas análises de áreas de manejo, pois ajuda a ver se os grupos têm uma ligação espacial, ou seja, se realmente são áreas homogêneas em relação à variável que está sendo estudada. Essa verificação espacial torna a análise e a confiança nas áreas identificadas durante as classificações mais fortes.

Além da estatística *I* de Moran, a expectativa teórica $-1/(n-1)$, a variância e o escore *z* (*Z*-escore) foram calculados, derivados da padronização da diferença entre o valor observado e a expectativa teórica. O valor *p* correspondente foi utilizado para avaliar a significância estatística da autocorrelação. Um valor de *p* baixo (abaixo de 0,05) sugere que a probabilidade de observar tal padrão por acaso é mínima, afirmando assim a existência de uma estrutura espacial dentro da zona.

Assim, a análise intragrupo do Índice de Moran permite verificar se as zonas de manejo delineadas por k-means exibem consistência espacial interna em cada ano avaliado. A presença de valores de Moran I significativamente positivos, juntamente com escores z elevados e valores p baixos, indica que os pontos dentro de grupos específicos não são organizados aleatoriamente, mas sim estruturados de maneira espacialmente coerente. Se essa observação na geração dos resultados finais for verdadeira, acredita-se que a credibilidade das zonas de manejo geradas é positiva e confiável para a validação das mesmas.

Ressalta-se que a comparação entre as zonas de manejo delimitadas a partir dos sensores proximais e orbitais não teve como objetivo estabelecer correlação estatística direta entre os valores dos índices espectrais obtidos por cada plataforma. Não foram realizadas análises de regressão, coeficientes de correlação ou métricas de erro (como RMSE), uma vez que os sensores apresentam características distintas quanto à geometria de aquisição e à resposta espectral por diversos fatores como o ângulo do satélite, atmosfera, entre outros.

A abordagem adotada consistiu em uma análise descritiva e qualitativa da configuração espacial das zonas geradas em cada ano e por cada tipo de sensor, considerando a coerência dos padrões espaciais, a persistência temporal das áreas classificadas e a similaridade estrutural entre os agrupamentos obtidos. Essa estratégia permitiu avaliar a convergência dos padrões espaciais de vigor vegetativo sem assumir equivalência direta entre as magnitudes dos índices espectrais provenientes de diferentes plataformas.

Dessa forma, a ênfase do estudo concentrou-se na consistência espacial e na aplicabilidade das zonas de manejo para fins agronômicos, e não na equivalência numérica absoluta entre sensores.

4 RESULTADOS E DISCUSSÃO

Três vinhedos comerciais que são objeto deste estudo, áreas A1 e A2, correspondentes às cultivares de Cabernet Franc, enquanto que a área A3 é um vinhedo de Cabernet Sauvignon, passaram pelo processamento e desenvolvimento dos índices de vegetação dos sensores proximais e sensores orbitais.


4.1 Índices de Vegetação

Os mapas dos índices de vegetação (IV) resultantes do sensor proximal foram criados usando krigagem, que interpola valores entre os pontos amostrados, gerando superfícies contínuas que evidenciam variações locais. Já os mapas orbitais foram obtidos diretamente das imagens multiespectrais da constelação PlanetScope, cuja resolução espacial é de 3 m/pixel, ou seja, cada pixel representa uma área de 9 m² no terreno. Essas imagens são capturadas por sensores multiespectrais a bordo de satélites, que registram a refletância da vegetação em diferentes faixas do espectro eletromagnético. Essa diferença metodológica explica por que os mapas proximais mostram maior sensibilidade às microvariações do vinhedo, enquanto os orbitais apresentam padrões mais uniformes e abrangentes.

É importante destacar que os índices de vegetação obtidos representam o vigor vegetativo espectral, isto é, a resposta da cobertura foliar à radiação eletromagnética registrada pelos sensores. Esse vigor espectral não deve ser confundido com o vigor fisiológico da planta como um todo, que envolve processos metabólicos e fisiológicos mais amplos, como absorção de nutrientes, respiração e fotossíntese.


As Figuras 3 e 4 estabelecem uma comparação entre os seis mapas interpolados referentes aos índices de vegetação na área A1, no ano de 2018, obtidos por meio dos sensores proximais e orbitais durante a fase de veraison. Nos mapas proximais, observa-se maior nitidez das heterogeneidades entre plantas e ao seu redor, resultando em uma zonificação mais detalhada. Em oposição, os mapas orbitais demonstram áreas de intensidade de IV mais uniformes, uma vez que cada pixel da imagem PlanetScope corresponde a 3 m × 3 m no terreno, combinando sinais da vegetação, do solo e da atmosfera. Essa resolução espacial suaviza microvariações, fornecendo uma visão mais abrangente do vinhedo, em consonância com os estudos de Matese *et al.* (2015) e Zarco-Tejada *et al.* (2013).

Figura 3 – Índices de vegetação em A1 (2018), sensor proximal interpolado



Fonte: O autor.

Figura 4 – Índices de vegetação na área A1 no ano de 2018, sensor orbital



Fonte: O autor

A Tabela 3 sintetiza as estatísticas descritivas dos seis índices de vegetação pelo sensor proximal (Crop Circle) e pelo sensor orbital (PlanetScope) na parcela A1 em 2018.

Os índices próximos demonstram coeficientes de variação (CV) classificados como baixos ($CV < 10\%$), variando de 0,22% a 5,47%, o que reflete o fato de a

medição ter ocorrido próxima à cobertura vegetal e à saturação em níveis elevados de cobertura.

Os produtos orbitais apresentam variabilidade espacial superior à observada no sensor proximal, com coeficientes de variação variando de 1,56% a 7,42%, embora ainda sejam classificados como baixos. As amplitudes também são maiores (por exemplo, amplitude do NDVI de 0,150 em comparação com 0,040). Esse comportamento resulta da combinação entre a soma da resposta espectral do solo e da planta, influências atmosféricas e da geometria de aquisição das imagens orbitais, que tendem a suavizar as transições de vigor.

Tabela 3 – Estatísticas descritivas dos índices de vegetação na área A1 (Vista da Mata) com a cultivar Cabernet Franc, no ano de 2018

Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,869	0,886	0,846	0,040	0,007	0,787
RVI	15,932	18,200	12,909	5,291	0,871	5,466
MSR	0,481	0,484	0,478	0,006	0,001	0,224
RDVI	0,898	0,911	0,879	0,032	0,006	0,617
IPVI	0,934	0,943	0,923	0,020	0,003	0,366
SAVI	0,104	0,109	0,098	0,010	0,002	1,820
Sensor Orbital (Planet)						
NDVI	0,498	0,557	0,407	0,150	0,023	4,701
RVI	2,993	3,515	2,370	1,144	0,188	6,278
MSR	0,729	0,875	0,540	0,335	0,054	7,422
RDVI	1,017	1,133	0,848	0,285	0,039	3,814
IPVI	0,749	0,778	0,703	0,075	0,012	1,563
SAVI	0,667	0,743	0,547	0,196	0,030	4,426


SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor

As medidas do MSR e do RVI orbitais demonstram amplitudes relativas superiores, evidenciando maior sensibilidade às alterações na condição da vegetação e à exposição do solo em áreas com dossel menos denso.


As Figuras 5 e 6 apresentam os resultados dos índices para o ano de 2019, tanto para o proximal quanto para o orbital. Assim como no ano de 2018, em 2019 o padrão diferencial entre o proximal e orbital seguiu semelhante.

Figura 5 – Índices de vegetação em A1 (2019), sensor proximal interpolado



Fonte: O autor

Figura 6 – Índices de vegetação na área A1 no ano de 2019, sensor orbital



Fonte: O autor

Em 2018, as transições de vigor no sensor proximal formavam manchas maiores e mais homogêneas; em 2019, o padrão fragmentou-se em pequenos mosaicos, refletindo maior heterogeneidade microespacial. Já para o sensor orbital, o gradiente fenotípico de leste a oeste mostrou menor variação em 2019, sugerindo homogeneização do dossel, possivelmente associada a práticas de irrigação ou fertilização mais uniformes. A Tabela 4 sintetiza as estatísticas descritivas dos seis índices de vegetação.

Tabela 4 – Estatísticas descritivas dos índices de vegetação na área A1 (Vista da Mata) com a cultivar Cabernet Franc, no ano de 2019

Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,850	0,868	0,838	0,030	0,005	0,641
RVI	12,957	14,438	11,982	2,456	0,464	3,578
MSR	0,479	0,482	0,477	0,005	0,001	0,186
RDVI	0,883	0,897	0,873	0,024	0,004	0,504
IPVI	0,925	0,934	0,919	0,015	0,003	0,294
SAVI	0,093	0,097	0,090	0,007	0,001	1,522
Sensor Orbital (Planet)						
NDVI	0,526	0,581	0,483	0,098	0,017	3,297
RVI	3,223	3,776	2,869	0,907	0,155	4,818
MSR	0,795	0,943	0,694	0,249	0,043	5,430
RDVI	1,035	1,133	0,936	0,197	0,036	3,509
IPVI	0,763	0,791	0,742	0,049	0,009	1,136
SAVI	0,698	0,770	0,640	0,131	0,023	3,311

SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor

As amplitudes e os coeficientes de variação (CV) no sensor proximal permaneceram baixos, variando de 0,19% a 3,58%, o que corrobora sua habilidade de registrar microvariações do dossel. Em 2019, notou-se uma redução na amplitude do NDVI (0,030 em comparação a 0,040 em 2018) e do CV (0,64% em contraste com 0,79% em 2018), o que indica uma maior homogeneidade na cobertura vegetal.


No sensor orbital, a amplitude do NDVI também apresentou uma redução (de 0,098 em comparação a 0,150 em 2018), e o coeficiente de variação (CV) diminuiu

para 3,30%, em relação a 4,70%, proporcionando uma redução na heterogeneidade macroespacial. Essa atenuação ressalta que as imagens de satélite conectam o solo e a atmosfera, resultando em áreas de vigor menos dispersas.

As médias indicam tendências divergentes, pois o NDVI médio proximal diminuiu de 0,869 para 0,850, enquanto o orbital aumentou de 0,498 para 0,526, porém representam diferenças discretas, considerando a proximidade dos valores e o fato de que, na análise por sensor, há intercorrências ao longo do trato cultural e do estágio fisiológico da planta que podem interferir de forma sutil. Além disso, essas diferenças podem refletir variações na sensibilidade espectral e na influência da interação solo-planta, bem como possíveis mudanças climáticas ou práticas de manejo ocorridas.


A Figura 7 exibe as médias dos índices referentes aos anos de 2018 e 2019, fazendo uma comparação entre o sensor proximal (representado pelas barras azul-escuro) e o sensor orbital (indicado pelas barras azul-claras). Note-se que o RVI proximal atinge valores entre 16 e 13, enquanto o orbital apresenta apenas 3 a 4. Os índices normalizados, como NDVI, RDVI e IPVI, oscilam entre 0,8 e 0,9 no sensor proximal, caindo para uma faixa de 0,5 a 1,1 no orbital. O MSR, por sua vez, demonstra uma tendência inversa, apresentando uma média superior no sensor orbital (aproximadamente 0,8) em relação ao sensor proximal (cerca de 0,48). As variações entre 2018 e 2019 são discretas, com uma leve diminuição no NDVI proximal e um ligeiro aumento no NDVI orbital, sugestivas da uniformização do dossel resultante de práticas agronômicas.

Figura 7 – Comparação das médias dos índices de vegetação obtidos pelo proximal e orbital entre os anos de 2018 e 2019 na área A1




Fonte: O autor

Figura 8 – Índices de vegetação em A2 (2018), sensor proximal interpolado



Fonte: O autor

Figura 9 – Índices de vegetação na área A2 no ano de 2018, sensor orbital



Fonte: O autor

Na área A2, no ano de 2018, representadas nas Figuras 8 e 9, mantêm-se as mesmas observações que na área A1. O sensor proximal mostra visualmente de forma mais detalhada as mudanças do vigor vegetativo e o orbital de forma mais suave e generalista.

A Tabela 5 confirma esse padrão quantitativamente, visto que o NDVI proximal teve média de 0,860 e coeficiente de variação (CV) de 0,45 %, ao passo que o NDVI orbital registrou média de 0,514 e CV de 4,85 %. O RVI proximal variou em torno de 14,127 (CV 3,99 %) contra 3,124 (CV 6,88 %) no orbital; o MSR caiu de 2,729 (CV 2,53 %) para 0,766 (CV 7,89 %); e índices como RDVI, IPVI e SAVI também exibiram CV abaixo de 2,3 % no proximal versus acima de 1,6 % no orbital.

Tabela 5 – Estatísticas descritivas dos índices de vegetação na área A2 (Vista da Mata) com a cultivar Cabernet Franc, no ano de 2018


Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,860	0,869	0,850	0,019	0,004	0,448
RVI	14,127	15,500	13,056	2,444	0,564	3,994
MSR	2,729	2,888	2,573	0,315	0,069	2,528
RDVI	0,173	0,178	0,169	0,009	0,002	1,382
IPVI	0,930	0,935	0,925	0,010	0,002	0,207
SAVI	0,096	0,101	0,093	0,008	0,002	2,229
Sensor Orbital (Planet)						
NDVI	0,514	0,589	0,432	0,157	0,025	4,854
RVI	3,124	3,867	2,521	1,346	0,215	6,883
MSR	0,766	0,966	0,588	0,379	0,060	7,889
RDVI	0,998	1,234	0,865	0,369	0,044	4,379
IPVI	0,757	0,795	0,716	0,079	0,012	1,647
SAVI	0,680	0,793	0,576	0,216	0,031	4,565

SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor


As Figuras 10 e 11 da área A2 do ano de 2019 mantêm a mesma linha de raciocínio das anteriores a partir das análises visuais.

Figura 10 - Índices de vegetação na em A2 (2019), sensor proximal interpolado



Fonte: O autor

Figura 11 – Índices de vegetação na área A2 no ano de 2019, sensor orbital



Fonte: O autor

A Tabela 6 apresenta uma quantificação do padrão observado em 2019 na área A2, com o NDVI proximal apresentando média de 0,841 e coeficiente de variação (CV) de 0,80%, enquanto o NDVI orbital registrou média de 0,609 e CV de 3,90%. Para o RVI proximal, observou-se média de 12,065 com CV de 4,32%, ao passo que o RVI orbital apresentou valor consideravelmente menor, de 4,136, e CV de 7,30%. O MSR também apresentou redução entre as abordagens, passando de 2,456 (CV de 3,14%) no sensor proximal para 1,032 (CV de 7,26%) no orbital. Além disso, índices como RDVI, IPVI e SAVI apresentaram coeficientes de variação inferiores a 1,05% na análise proximal, enquanto na versão orbital esses valores ficaram acima de 1,48%, indicando diferenças na magnitude das variações entre as duas abordagens.

Tabela 6 – Estatísticas descritivas dos índices de vegetação na área A2 (Vista do Vale) com a cultivar Cabernet Franc, no ano de 2019


Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,841	0,853	0,824	0,029	0,007	0,797
RVI	12,065	13,214	10,778	2,436	0,521	4,321
MSR	2,456	2,623	2,259	0,364	0,077	3,137
RDVI	0,167	0,171	0,161	0,010	0,002	1,014
IPVI	0,920	0,927	0,912	0,014	0,003	0,364
SAVI	0,092	0,094	0,090	0,004	0,001	0,916
Sensor Orbital (Planet)						
NDVI	0,609	0,652	0,519	0,133	0,024	3,899
RVI	4,136	4,746	3,160	1,586	0,302	7,295
MSR	1,032	1,178	0,778	0,401	0,075	7,257
RDVI	1,167	1,285	0,991	0,294	0,060	5,136
IPVI	0,805	0,826	0,760	0,066	0,012	1,476
SAVI	0,804	0,866	0,685	0,182	0,033	4,123

SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor

Observe-se também na Figura 12 e nas Tabelas 5 e 6 que o NDVI proximal apresenta um valor aproximadamente 1,4 vezes superior ao NDVI orbital em ambos os anos analisados, evidenciando a saturação do sistema por satélite em dosséis florestais densos. Além disso, o NDVI e o IPVI do Crop Circle se aproximam do limite superior do referido eixo, o que sugere uma perda de sensibilidade além deste nível. O RVI obtido pelo sensor proximal destaca-se na função de seu amplo alcance sonoro e da elevada magnitude das barras, o que reafirma sua efetividade discriminatória em alta resolução. Por outro lado, o RDVI orbital apresenta uma alteração mais abrupta entre os anos de 2018 e 2019 em comparação ao RVI proximal, o que denota uma maior sensibilidade do sistema satélite a suas alterações fenológicas em larga escala. O SAVI do orbital demonstra um crescimento significativo em relação à faixa mais sutil do CropCircle, deixando que o satélite tenha uma capacidade superior de capturar as variações de umidade e cobertura do solo. Por fim, as barras mostram uma uniformidade maior, ilustrando a homogeneidade.


Figura 12 – Comparação das médias dos índices de vegetação obtidos pelo proximal e orbital entre os anos de 2018 e 2019 na área A2



Fonte: O autor


As Figuras 13 e 14 estão representando os índices gerados na área A3, para os sensores proximais e seguindo o mesmo raciocínio das outras áreas, porém de forma inversa quanto à homogeneidade.

Figura 13 – Índices de vegetação em A3 (2018), sensor proximal interpolado



Fonte: O autor

Figura 14 – Índices de vegetação na área A3 no ano de 2018, sensor orbital



Fonte: O autor

Na Área A3, no ano de 2018 foi identificada uma inversão no padrão que vinha de outras áreas com uma variabilidade significativa do índice orbital em relação ao proximal que pode ser atribuída à interação entre um relevo heterogêneo e uma estrutura de dossel irregular, os quais potencializam as discrepâncias espectrais

identificadas em escala macro. Neste contexto, o NDVI e o IPVI revelam uma sensibilidade superior a variações de sombreamento e ângulo solar em superfícies inclinadas, que é o mais provável de ter ocorrido, visto que a área A3 é subdividida em duas partes e bem próxima a uma mata nativa. Por outro lado, os sensores próximos, que se concentram na variabilidade entre plantas, apresentam uma tendência a atenuar esses efeitos locais como já mencionados por Silva e Oliveira (2019).

Além disso, a implementação de práticas de manejo específicas, como a irrigação localizada e a adubação em faixas, resulta na criação de mosaicos de vigor dentro da classe, os quais são mais eficazmente detectados por meio do sensoriamento orbital. Pesquisas evidenciam que solos caracterizados por uma textura argilosa, quando associados a regimes de irrigação não uniformes, potencializam a heterogeneidade espacial observada em imagens de satélite, segundo Campos e Almeida, 2018. Isso pode também explicar a razão pela qual o índice orbital pode exibir amplitudes superiores em comparação ao índice proximal, porém a irrigação local é bem homogênea e bem distribuída de forma local, o que leva a crer que esse não é o caso da área.

O sensor proximal apresentado na Tabela 7 registrou para NDVI uma média de 0,884, apresentando uma amplitude restrita de 0,023 e um coeficiente de variação (CV) de apenas 0,51%, o que evidencia um dossel extremamente homogêneo e uma cobertura foliar densa. O RVI proximal apresentou uma média de 17,190, com uma amplitude de 3,584 e um coeficiente de variação (CV) de 4,68%. Por sua vez, o MSR declarou uma média de 3,118, com uma amplitude de 0,453 e um CV de 2,95%. O RDVI proximal apresentou uma média de 0,181, com amplitude de 0,011 e coeficiente de variação (CV) de 1,22%. O IPVI registrou uma média de 0,942, com amplitude de 0,012 e CV de 0,24%. Por sua vez, o SAVI apresentou uma média de 0,103, com amplitude de 0,009 e CV de 1,89%. Esses valores indicam uma baixa dispersão e uma elevada fidelidade nas microvariações do dossel.

Em contrapartida, os produtos orbitais apresentaram uma heterogeneidade espacial mais acentuada com o NDVI médio que foi de 0,588, apresentando uma variação que alcançou uma amplitude de 0,176 (coeficiente de variação de 4,51%), o RVI médio registrado 3,879 (com amplitude de 2,085; coeficiente de variação de 7,99%) e o MSR médio situado em 0,968 (amplitude de 0,527; coeficiente de variação de 8,17%). O RDVI orbital apresentou uma média de 1,078, com uma

amplitude de 0,373 e um coeficiente de variação (CV) de 4,07%. O IPVI registrou uma média de 0,794, com uma amplitude de 0,088 e um CV de 1,67%. Por sua vez, o SAVI teve uma média de 0,768, com uma amplitude de 0,227 e um CV de 4,10%. Os resultados obtidos corroboram a premissa de que o sensoriamento proximal se mostra mais protetor para a detecção de suas variações de vigor entre plantas individuais.

Tabela 7 – Estatísticas descritivas dos índices de vegetação na área A3 (Vista do Vale) com a cultivar Cabernet Sauvignon, no ano de 2018


Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,884	0,894	0,871	0,023	0,005	0,514
RVI	17,190	18,676	15,092	3,584	0,805	4,681
MSR	3,118	3,316	2,864	0,453	0,092	2,949
RDVI	0,181	0,187	0,176	0,011	0,002	1,224
IPVI	0,942	0,947	0,935	0,012	0,002	0,241
SAVI	0,103	0,108	0,099	0,009	0,002	1,891
Sensor Orbital (Planet)						
NDVI	0,588	0,668	0,491	0,176	0,027	4,513
RVI	3,879	5,018	2,933	2,085	0,310	7,997
MSR	0,968	1,240	0,713	0,527	0,079	8,165
RDVI	1,078	1,300	0,928	0,373	0,044	4,072
IPVI	0,794	0,834	0,746	0,088	0,013	1,672
SAVI	0,768	0,874	0,646	0,227	0,031	4,099

SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor


No âmbito da área A3 (Figuras 15 e 16; Tabela 8), durante o ano de 2019, observou-se uma ligeira redução na média NDVI, que passou de 0,884 para 0,883. Entretanto, houve um aumento tanto na amplitude, que se elevou de 0,023 para 0,037, quanto no coeficiente de variação, que passou de 0,51% para 0,95%. Esses resultados sugerem que as microvariações de vigor entre as videiras foram mais pronunciadas. O índice de variabilidade do RVI proximal apresentou um aumento significativo, passando de uma média de 17,190 para 17,897, com uma amplitude elevando-se de 3,584 para 5,081. Além disso, o coeficiente de variação (CV) variou de 4,68% para 6,46%, o que corrobora o aumento na heterogeneidade observada.

Figura 15 – Índices de vegetação em A3 (2019), sensor proximal interpolado



Fonte: O autor

Figura 16 – Índices de vegetação na área A3 no ano de 2019, sensor orbital



Fonte: O autor

Os índices MSR e RDVI apresentaram um comportamento semelhante, evidenciado pelo aumento tanto nas respectivas amplitudes quanto nos coeficientes de variação (CV). No caso do MSR, observou-se uma elevação de 0,453 para 0,603, acompanhada de um incremento no CV de 2,95% para 4,35%. Para o RDVI, a

amplitude cresceu de 0,011 para 0,012, enquanto o coeficiente de variação passou de 1,22% para 1,51%. Os índices IPVI e o SAVI também apresentaram elevações sutis em sua amplitude e variação relativa. Em oposição a isso, o sensor orbital demonstrou uma maior sensibilidade às variações na cobertura global, tendo o NDVI um aumento de 0,588 para 0,655 (com uma amplitude reduzida de 0,176 para 0,144; e o coeficiente de variação (CV) fornecendo de 4,51% para 3,49%). Por outro lado, os índices RVI, MSR, RDVI, IPVI e SAVI obtidos por meio de sensores orbitais apresentaram amplitudes e coeficientes de variação menores em 2019, revelando que talvez as práticas de manejo e o preenchimento do dossel atenuaram os padrões macroespaciais. Esse comportamento distingue A3 de A1 e A2, onde tanta amplitude quanto CV proximal também reduziu de 2018 para 2019; aqui, as vinhas de Cabernet Sauvignon parecem ter desenvolvidas microzonas de vigor mais contrastantes, possivelmente em resposta a pequenas variações de solo, relevância ou manejo de irrigação, ao passo que a visão orbital captou a folha mais uniforme e abrangente.

Tabela 8 – Estatísticas descritivas dos índices de vegetação na área A3 (Vista do Vale) com a cultivar Cabernet Sauvignon, no ano de 2019

Variável	Média	Máximo	Mínimo	Amplitude	SD	CV%
Sensor Proximal (Crop Circle)						
NDVI	0,883	0,901	0,864	0,037	0,008	0,953
RVI	17,897	20,414	15,333	5,081	1,157	6,464
MSR	3,177	3,485	2,883	0,603	0,138	4,349
RDVI	0,181	0,187	0,175	0,012	0,003	1,512
IPVI	0,942	0,950	0,932	0,018	0,004	0,447
SAVI	0,103	0,108	0,098	0,010	0,002	2,017
Sensor Orbital (Planet)						
NDVI	0,655	0,705	0,562	0,144	0,023	3,492
RVI	4,814	5,782	3,561	2,220	0,377	7,822
MSR	1,192	1,405	0,887	0,517	0,086	7,236
RDVI	1,172	1,366	1,050	0,316	0,043	3,651
IPVI	0,827	0,853	0,781	0,072	0,011	1,381
SAVI	0,849	0,905	0,740	0,165	0,025	2,934

SD: desvio padrão; CV (%): coeficiente de variação.

Fonte: O autor


A avaliação integrada das médias dos seis índices referentes à área A3, conforme ilustrado na Figura 17, evidencia que o RVI obtido por meio do Crop Circle se sobressai, apresentando valores superiores a 15 em ambos os anos consolidados. Em contrapartida, a versão orbital desse índice não atinge a marca de 6, seguindo o mesmo padrão para as três áreas (A1, A2 e A3), o que sugere que o sensoriamento próximo fornece uma representação mais precisa da elevada biomassa das videiras maduras. Nota-se, igualmente, uma convergência parcial entre os índices NDVI e IPVI, de modo que o NDVI se apresenta estável em torno de 0,88, enquanto o índice orbital demonstra um incremento de 0,59 para 0,66 no período entre 2018 e 2019, proporcionando uma melhoria na uniformidade do dossel em uma escala mais abrangente. O alinhamento refletido no índice IPVI sugere que, apesar dos sensores próximos alcançarem rapidamente um limiar de saturação, as proximidades orbitais, que apresentam um menor grau de saturação, são mais eficazes na captação dos incrementos da cobertura vegetal. Isso é demonstrado pelo aumento anual observado no NDVI e no RDVI.

Ao se confrontar com a amplitude elevada bloqueada pelo sensor proximal, que indica uma maior heterogeneidade entre as plantas, com a estabilidade macroespacial das médias orbitais, que evidenciam áreas de vigor mais fluidas, torna-se patente a necessidade de um manejo zonal integrado. O sensoriamento proximal revela-se essencial para a identificação de variações sutis e para a delimitação de zonas de aplicação de insumos com alta resolução, enquanto o sensoriamento orbital fornece uma perspectiva abrangente e interanual das principais áreas de vigor, orientando disciplinas em larga escala e corroborando as estratégias de manejo adotadas.

A integração dos índices de vegetação proximal e orbital possibilita a delimitação precisa de áreas de manejo com base nos resultados obtidos. O sensoriamento proximal, através do RVI e do RDVI, é capaz de capturar a variabilidade da biomassa e fenologia com elevada sensibilidade. Por outro lado, o sensoriamento orbital, utilizando o NDVI e o IPVI, oferece uma perspectiva macroespacial menos saturada, apta a monitorar as mudanças interanuais e a uniformidade do dossel.

Ao utilizar percentis dos índices proximais para aprimorar as subzonas dentro das categorias condicionais pelos mapas orbitais, torna-se viável calibrar a utilização de insumos de acordo com as demandas específicas de cada área, harmonizando alta resolução espacial com tendências de vigor em uma escala mais ampla.

Figura 17 – Comparação das médias dos índices de vegetação obtidos pelo proximal e orbital entre os anos de 2018 e 2019 na área A3



Fonte: O autor

A validação estatística das fronteiras de manejo, por meio da aplicação de testes de variância e médias, confere uma robustez e confiabilidade substanciais ao plano zonal, o que, por sua vez, potencializa os ganhos em eficiência agronômica e sustentabilidade, conforme já apresentado por Martins (2017).

4.2 Definição do número de agrupamentos (k) para as áreas A1, A2 e A3

Acerca da aplicação da técnica de agrupamento k-means aos índices espectrais, a definição do número de agrupamentos (k) fundamentou-se em duas considerações complementares que, em conjunto, garantem uma segmentação de dados que se revela robusta. Foi observado que, à medida que o valor de k se eleva, a soma dos quadrados dentro do grupo (WSS) diminui de forma específica até alcançar um ponto em que a diminuição mais acentuada se torna menos significativa (**Figuras 20, 21, 24, 25, 28 e 29**). Esse ponto de inflexão, representado por uma linha pontilhada nos gráficos, sinaliza a quantidade de agrupamentos, além de que a segmentação dos dados não prevê avanços significativos em termos de coesão interna. A curva do cotovelo (Elbow) foi desenvolvida a partir da soma das distâncias ao quadrado dentro de cada agrupamento (WSS), considerando valores de k que variam de 1 a 10.

De maneira paralela, proceda ao design da silhueta média variando o valor de k de 2 a 10, com o objetivo de avaliar simultaneamente a coesão, que é definida como a distância média entre os pontos e seus respectivos centroides, e a separação, que

se refere à distância em relação ao agrupamento mais próximo. Cada valor de silhueta apresenta variação entre -1 e 1, e um aumento na silhueta média até chegar ao pico máximo, sugere que os agrupamentos realizados possuem, simultaneamente, características de compactação e um afastamento adequado entre si (**Figuras 18, 19, 22, 23, 26 e 27**). No gráfico, tal pico se apresenta ainda por meio de uma linha pontilhada, a qual está sincronizada com o ponto de “cotovelo”, evidenciando visualmente o valor de k que otimiza o equilíbrio entre agrupamentos diversos e a homogeneidade interna deles.

A representação visual em ambos os tipos de gráficos nas três áreas serve para corroborar a afirmação de que o valor de k selecionado não é fruto do acaso, mas sim sustentado por evidências relacionadas à qualidade do agrupamento. A linha pontilhada presente em ambos os gráficos evidencia que o método em questão não se fundamenta em um único indicador isolado, mas sim na convergência entre coesão e separação, o que resulta em uma diminuição do risco de sobreajuste. Dessa forma, a incorporação conjunta desses parâmetros fortalece a confiabilidade da segmentação, indicando que as áreas delimitadas apresentam coerência estrutural compatível com variações espaciais de vigor dos ecossistemas, contribuindo para subsidiar decisões agronômicas e para a gestão do ambiente.

A compatibilidade entre os dois métodos enfatiza a legitimidade dos agrupamentos identificados em que a curva do cotovelo indica o ponto em que o aumento da variância interna se torna insignificante; a análise da silhueta valida a qualidade estrutural da segmentação.

Na Figura 18, a análise dos valores de silhueta para o sensor proximal demonstra que, ao empregar os resultados de RVI com $k = 3$, cada ponto apresenta uma proximidade significativa em relação ao seu agrupamento específico, quando comparado a qualquer outro. Isso indica que as zonas de vigor baixo, médio e alto estão claramente delineadas, apresentando uma sobreposição mínima, ou seja, silhueta acima de 0,50 (RVI em $k = 3$) indica que, em média, cada ponto está muito mais próximo do seu próprio agrupamento do que do agrupamento vizinho. Para os índices NDVI, MSR, RDVI, IPVI e SAVI, a configuração que apresentou melhor desempenho foi $k = 2$. Nessa condição, os valores médios de silhueta variaram entre 0,30 e 0,50, indicando a presença de agrupamentos moderadamente coesos. Esses resultados sugerem uma segmentação consistente, embora com transições graduais

entre classes, possivelmente associadas a variações contínuas no vigor vegetativo ou à influência de ruídos espectrais.

Para o sensor orbital na área A1 (Figura 19), todos os índices apresentaram melhor desempenho para $k = 2$ agrupamentos. Destacaram-se os índices RVI e SAVI, com valores de silhueta variando entre 0,45 e 0,55, indicando melhor separação entre as classes de vigor baixo e alto. A diferença em relação aos resultados do sensor proximal pode estar associada à natureza da aquisição dos dados, à resolução espacial e à influência de efeitos atmosféricos e de mistura espectral, que impactam de forma distinta a definição dos agrupamentos.

A análise da curva do cotovelo evidenciou uma redução acentuada da WSS até $k = 2$, seguida por um decréscimo menos expressivo para valores superiores de k . Esse comportamento indica que a maior parte da variabilidade interna é explicada com dois agrupamentos, sendo que a inclusão de classes adicionais resulta em ganhos marginais na redução da variância intragrupo.

Nos primeiros pontos de análise na área A1 e nas Figuras 20 e 21, observa-se uma queda significativa na WSS na posição do $k = 2$, evidenciada pela rápida diminuição dos valores, que decaem de patamares superiores a 2.000 para aproximadamente 1.000. Esse fenômeno indica que a segmentação dos dados em duas ou três categorias é capaz de abranger uma porção considerável da variabilidade interna. A partir de um valor de k aproximadamente igual a 2 ou 3 que foi o caso do RVI do proximal da área A1, observa-se que a curva tende a se nivelar, implicando que cada novo agrupamento resulta em uma diminuição da soma dos erros quadráticos dentro do agrupamento (WSS) de maneira sutil, sem que se verifiquem ganhos significativos em termos de coesão. A linha tracejada que indica o número de agrupamentos assinala o ponto de inflexão em que a vantagem de incorporar mais grupos passa a não compensar a complexidade adicional. Em termos práticos, isso implica que $k = 2$ ou 3 proporciona o melhor equilíbrio entre a explicação das variações de vigor (reduzindo a dispersão interna) e a preservação da parcimônia do modelo, ao mesmo tempo em que evita subdivisões excessivas que trariam poucos benefícios para a identificação de zonas de manejo eficazes.

O mesmo método de análise pode ser seguido e repetido para os demais gráficos da silhueta e do *elbow*. E seguindo a análise para outras áreas, é importante se atentar para os resultados obtidos na área A2, principalmente para os dados do orbital (Figuras 23 e 25). Os gráficos apresentam agrupamentos exagerados e


distintos de índice para índice, contrariando um padrão que é mantido nas demais áreas e na própria área no caso do sensor proximal. Esse comportamento em que temos picos das médias de silhuetas muito próximas pode ser respondido por outras análises estatísticas como a de Moran.

Na área A3, o padrão de $k = 2$ agrupamentos voltaram e se mantiveram para todos os índices e sensores. Os valores do RVI e SAVI melhoraram, se destacando mais ainda, e os valores dos demais índices também melhoraram, aproximando-se de 0,50 para silhueta.

A consistência observada entre as curvas do cotovelo e os picos de silhueta fortalece a solidez da delimitação de agrupamentos em cada área específica. Nos casos de A1 e A3, tanto a abordagem de sensoriamento proximal quanto o orbital indicam valores de k bem definidos, que variam entre 2 ou 3 agrupamentos, de acordo com o índice utilizado, e refletem de forma clara zonas de vigor distintas. Em contrapartida, na área A2, a divergência e o maior número de agrupamentos identificados pelo sensoriamento orbital sugerem uma heterogeneidade espacial atípica, a qual pode ser atribuída a fatores como relevância irregular e práticas de manejo isoladas. Esta situação exige a complementação com análises adicionais, como o índice de Moran, para a validação dos padrões locais.


4.2.1 Largura média da Silhueta da área A1

Figura 18 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores proximais (A1)



Fonte: O autor


Figura 19 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores orbitais (A1)



Fonte: O autor


4.2.2 Curva Elbow (método do cotovelo) para área A1

Figura 20 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores proximais (A1)



Fonte: O autor


Figura 21 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores orbitais (A1)



Fonte: O autor


4.2.3 Largura média da Silhueta da área A2

Figura 22 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores proximais (A2)



Fonte: O autor


Figura 23 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores orbitais (A2)



Fonte: O autor


4.2.4 Curva Elbow (método do cotovelo) para área A2

Figura 24 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores proximais (A2)



Fonte: O autor


Figura 25 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores orbitais (A2)



Fonte: O autor


4.2.5 Largura média da Silhueta na área A3

Figura 26 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores proximais (A3)



Fonte: O autor


Figura 27 – Distribuição da silhueta por índice e qualidade dos agrupamentos para sensores orbitais (A3)



Fonte: O autor


4.2.6 Curva Elbow (método do cotovelo) para a área A3

Figura 28 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores proximais (A3)



Fonte: O autor

Figura 29 – Curva elbow (método do cotovelo) para seleção do número ótimo de agrupamentos em sensores orbitais (A3)



Fonte: O autor

4.3 Dispersão K-Means dos valores padronizados da área (A1, A2 e A3)

A análise dos gráficos de dispersão bidimensional dos agrupamentos gerados pelo algoritmo k-means foi realizada utilizando os valores de k previamente definidos pela convergência entre os métodos do cotovelo (WSS) e da silhueta média.


No conjunto proximal da área A1 (Figura 30), observam-se três grupos bem delimitados para o RVI, correspondendo a classes de baixo, médio e alto vigor, com elipses pouco sobrepostas, indicando boa coesão intragrupo e adequada separação intergrupo. Para os índices cuja definição ótima foi $k = 2$, a segmentação evidencia duas classes principais de vigor, com limites relativamente definidos. No conjunto orbital (Figura 31), os agrupamentos também refletem a configuração de k previamente definida, porém com distribuição mais compacta e ligeiramente achatada no espaço bidimensional. Esse comportamento pode estar associado à resolução espacial do sensor e ao efeito de mistura espectral, que tendem a suavizar contrastes locais quando comparados aos dados proximais. Ainda assim, a distinção entre as classes principais de vigor permanece identificável.

Na área A2 (Figuras 32 e 33), tanto para o sensor proximal quanto para o orbital, a definição de $k = 2$ resultou em dois agrupamentos densos e estruturalmente consistentes. No proximal, a separação apresenta maior nitidez, enquanto no orbital observa-se leve alongamento das nuvens de pontos, sugerindo maior variabilidade interna. Essa diferença pode estar relacionada à integração espacial dos pixels orbitais, que incorporam múltiplos alvos dentro de uma mesma unidade de análise.

Em A3 (Figuras 34 e 35), ambos os sensores indicaram $k = 2$ como configuração ideal. No proximal, os agrupamentos formam duas nuvens bem definidas e com mínima sobreposição. No orbital, os grupos mantêm separação discernível, embora com contornos menos definidos. A consistência entre os métodos de validação (silhueta e cotovelo) e a disposição espacial dos pontos reforça a adequação da segmentação adotada para cada área. A análise da dispersão evidencia as particularidades de cada plataforma de sensoriamento: enquanto o sensor proximal apresenta maior detalhamento e sensibilidade a variações locais, o sensor orbital tende a integrar respostas espectrais em escala mais ampla. Essa complementaridade deve ser considerada na interpretação dos padrões de vigor e na aplicação prática dos mapas de manejo.

4.3.1 Dispersão para os proximais (A1)


Figura 30 – Dispersão dos agrupamentos em 2D para os dados proximais (A1)



Fonte: O autor

4.3.2 Dispersão para os orbitais (A1)


Figura 31 – Dispersão dos agrupamentos em 2D para os dados orbitais (A1)



Fonte: O autor

4.3.3 Dispersão para os proximais (A2)


Figura 32 – Dispersão dos agrupamentos em 2D para os dados proximais (A2)



Fonte: O autor

4.3.4 Dispersão para os orbitais (A2)


Figura 33 – Dispersão dos agrupamentos em 2D para os dados orbitais (A2)



Fonte: O autor

4.3.5 Dispersão para os proximais (A3)


Figura 34 – Dispersão dos agrupamentos em 2D para os dados proximais (A3)



Fonte: O autor

4.3.6 Dispersão para os orbitais (A3)

Figura 35 – Dispersão dos agrupamentos em 2D para os dados orbitais (A3)




Fonte: O autor

Seguem nas Figuras 36, 37, 38, 39, 40 e 41 as distribuições espaciais das zonas de manejo geradas para cada índice, sensor, área e ano.


4.4 Mapa dos agrupamentos (zonas de manejo) para área A1

Figura 36 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor proximal na área A1.



Fonte: O autor


Figura 37 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor orbital na área A1.



Fonte: O autor


4.5 Mapa dos agrupamentos (zonas de manejo) para área A2

Figura 38 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor proximal na área A2.



Fonte: O autor


Figura 39 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor orbital na área A2.



Fonte: O autor


4.6 Mapa dos agrupamentos (zonas de manejo) para área A3

Figura 40 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor proximal na área A3



Fonte: O autor

Figura 41 – Agrupamento usando o método k-means entre os índices de vegetação de 2018 e 2019 do sensor orbital na área A3



Fonte: O autor

4.7 Validação estatística dos agrupamentos das áreas A1, A2 e A3

4.7.1 Testes de comparação de médias

Para verificar se os agrupamentos definidos pelo algoritmo k-means apresentavam diferenças estatisticamente significativas nos índices de vegetação, realizou-se a comparação de médias entre os grupos, respeitando a estrutura temporal e a plataforma de aquisição dos dados.

Inicialmente, para cada área, ano e sensor (proximal e orbital), testou-se a normalidade dos resíduos e a homogeneidade das variâncias. Quando atendidos os pressupostos, aplicou-se a análise de variância (ANOVA), seguida do teste de Tukey para comparações múltiplas. Nos casos de heterocedasticidade, utilizou-se a ANOVA de Welch, com pós-teste de Games-Howell. Quando os resíduos não apresentaram distribuição normal, empregou-se o teste não paramétrico de Kruskal-Wallis, seguido do teste de Dunn.

A validação foi conduzida separadamente para cada ano (2018 e 2019) e para cada sensor, evitando a mistura de dados provenientes de escalas espaciais e condições de aquisição distintas. Essa abordagem permitiu verificar se os agrupamentos mantiveram diferenças estatísticas consistentes ao longo do tempo dentro de cada plataforma.

Além dos testes estatísticos, foram construídos boxplots individuais para cada combinação de ano e sensor (proximal 2018, proximal 2019, orbital 2018 e orbital 2019). Esses gráficos possibilitaram avaliar a dispersão, a mediana e a sobreposição interquartílica dos grupos, complementando a interpretação inferencial.

A análise temporal comparativa foi realizada posteriormente, observando-se se as diferenças estatisticamente significativas entre os grupos se mantiveram em ambos os anos dentro do mesmo sensor. Dessa forma, foi possível distinguir padrões estruturais persistentes de variações associadas a condições sazonais ou operacionais específicas de cada ciclo agrícola.

Ressalta-se que a comparação entre sensores proximal e orbital foi conduzida de forma qualitativa e interpretativa, considerando as diferenças inerentes às plataformas quanto à resolução espacial, geometria de aquisição, abrangência de área e possíveis efeitos atmosféricos. Não foi realizada comparação quantitativa direta ou análise de correlação entre os valores absolutos dos índices, uma vez que os

sensores operam sob escalas distintas de captura e integração espectral. Assim, a análise concentrou-se na coerência estrutural dos agrupamentos, na manutenção das diferenças estatísticas em cada sensor ao longo do tempo e na correspondência geral dos padrões espaciais de vigor.

Realizar a validação ano a ano permite identificar possíveis alterações na dinâmica da área, como variações climáticas, mudanças nas práticas de manejo ou estágios fenológicos diferentes, que podem impactar a distribuição dos índices de vegetação. Se, em 2018, um grupo apresenta valores muito parecidos e altos, mas em 2019 sua variação aumenta ou sua mediana diminui, isso indica que aquela área pode ter reagido de maneira diferente a fatores externos, algo que só poderia ser notado com gráficos comparativos separados.

Na Figura 42 da área A1, no ano de 2018 para o sensor proximal, apresento a análise de exemplo para as demais áreas. No índice NDVI, existem dois boxplots: um vermelho representando o agrupamento 1 e outro azul representando o agrupamento 2. O eixo vertical varia entre 0,85 e 0,88. Nota-se que o grupo 2 apresenta uma mediana maior do que o grupo 1, o que indica um crescimento vegetal mais forte. A caixa azul está posicionada mais acima, com o intervalo interquartil (IQR) concentrado entre aproximadamente 0,865 e 0,875, enquanto o IQR vermelho se estende de cerca de 0,855 a 0,865.

As antenas foram projetadas apenas um pouco além das caixas em ambos os núcleos, o que indica que há poucos valores extremos e que a distribuição é bastante uniforme dentro de cada grupo. A uniformidade na amplitude dos IQRs mostra que cada área tem uma variabilidade interna que é bem controlada, confirmando, de forma visual, as diferenças estatísticas identificadas nos testes.

A comparação cuidadosa das médias em cada área, sensor e ano sempre vai seguindo o mesmo passo a passo. Primeiro, analisou-se se os resíduos seguiam uma distribuição normal (usando o teste de Anderson-Darling) e se as variâncias eram uniformes (com o teste de Fligner-Killeen), para então escolher o teste mais adequado. Quando ambos os pressupostos foram atendidos, utiliza-se a ANOVA seguida do teste Tukey HSD. Se apenas a normalidade se mantinha, mas havia heterocedasticidade, escolhemos a ANOVA de Welch com o método do Games-Howell. E se a distribuição não era normal, aplicamos o teste de Kruskal-Wallis com o pós-hoc (do latim “depois disso” e designa os testes aplicados depois que um teste global aponta diferenças significativas entre grupos) de Dunn.


Na área A1 (Figuras 42, 43, 44 e 45), a maioria dos índices mostrou alguma violação a essas suposições, por isso o método Kruskal-Wallis com o teste de Dunn foi o que mais se destacou nos quatro boxplots (proximal 2018/2019 e orbital 2018/2019). As abordagens destacam características específicas de cada índice, como em 2019, o MSR manteve resíduos normais, mas com variações diferentes, o que justifica a utilização do Welch e do teste do Games-Howell. No orbital de 2018, o IPVI apresentou um comportamento semelhante, também necessitando da via de Welch. No ano de 2018, os índices RDVI e SAVI atenderam às condições de normalidade e homocedasticidade, possibilitando a aplicação da ANOVA seguida do teste de Tukey. Em 2019, o SAVI confirmou novamente os critérios paramétricos, mantendo a concordância entre a ANOVA e o teste de Tukey.

A área A2 (Figuras 46, 47, 48 e 49) apresentou novamente o padrão comum de distribuições irregulares, onde os dados vindos de ambos os anos só corroboraram a utilização do teste de Kruskal-Wallis seguido pelo teste de Dunn, com exceção do RDVI de 2019, que, apesar de seguir uma distribuição normal, apresentou variações desiguais e, por isso, foi avaliado por meio do teste de Welch e Games-Howell. No orbital de A2, o teste de Kruskal-Wallis juntamente com o teste de Dunn também se mostrou predominante, sendo a única exceção o SAVI de 2019, em que a heterocedasticidade foi comprovada na aplicação do teste de Welch junto com o teste do Games.

Em A3 (Figuras 50, 51, 52 e 53), o sensor proximal de 2018 apresentou dois índices (NDVI e IPVI) com variações diferentes, mesmo em relação à normalidade. Isso levou à aplicação do teste Welch seguido por Games-Howell, enquanto os outros índices necessitaram do teste de Kruskal-Wallis com o ajuste de Dunn. No início de 2019, apenas o RDVI apresentou normalidade e variâncias homogêneas, o que permitiu a realização da ANOVA após o teste de Tukey. Todos os outros índices, por sua vez, mostraram uma queda no teste de Kruskal-Wallis. O orbital de A3, em ambos os anos analisados, apresentou claramente violações de normalidade ou homocedasticidade em todos os índices, confirmando a utilização do teste de Kruskal-Wallis seguido do teste de Dunn como a única opção adequada.


4.7.2 Comparação de médias do proximal (A1)

Figura 42 – Boxplot da comparação das médias no ano de 2018 do sensor proximal na área A1



Fonte: O autor


Figura 43 – Boxplot da comparação das médias no ano de 2019 do sensor proximal na área A1



Fonte: O autor


4.7.3 Comparação de médias dos orbitais (A1)

Figura 44 – Boxplot da comparação das médias no ano de 2018 do sensor orbital na área A1



Fonte: O autor


Figura 45 – Boxplot da comparação das médias no ano de 2019 do sensor orbital na área A1



Fonte: O autor


4.7.4 Comparação de médias dos proximal (A2)

Figura 46 – Boxplot da comparação das médias no ano de 2018 do sensor proximal na área A2



Fonte: O autor


Figura 47 – Boxplot da comparação das médias no ano de 2019 do sensor proximal na área A2



Fonte: O autor


4.7.5 Comparação de médias dos orbitais (A2)

Figura 48 – Boxplot da comparação das médias no ano de 2018 do sensor orbital na área A2



Fonte: O autor


Figura 49 – Boxplot da comparação das médias no ano de 2019 do sensor orbital na área A2



Fonte: O autor


4.7.6 Comparação de médias do proximal (A3)

Figura 50 – Boxplot da comparação das médias no ano de 2018 do sensor proximal na área A3



Fonte: O autor


Figura 51 – Boxplot da comparação das médias no ano de 2019 do sensor proximal na área A3



Fonte: O autor


4.7.7 Comparação de médias dos orbitais (A3)

Figura 52 – Boxplot da comparação das médias no ano de 2018 do sensor orbital na área A3



Fonte: O autor

Figura 53 – Boxplot da comparação das médias no ano de 2019 do sensor orbital na área A3



Fonte: O autor

Esses panoramas mostrados pelos bloxplots evidenciam que, em diferentes situações, os índices de vegetação não atenderam simultaneamente aos pressupostos de normalidade e homogeneidade de variâncias exigidos pela ANOVA clássica, com algumas exceções em momentos específicos como o RDVI e o SAVI demonstraram. Esse comportamento não é incomum em dados ambientais e espectrais. Conforme argumenta Zar (2010), variáveis biológicas e ecológicas frequentemente apresentam assimetria e variabilidade heterogênea em função da influência de múltiplos fatores naturais. De maneira semelhante, Montgomery (2019) destaca que, em experimentos aplicados e dados de campo, a heterocedasticidade tende a ser recorrente, exigindo abordagens estatísticas mais robustas.

Diante desse cenário, quando os pressupostos paramétricos não foram satisfeitos, optou-se pelo teste de Kruskal-Wallis. Segundo Conover (1999), esse teste representa uma extensão do procedimento de Wilcoxon para três ou mais grupos independentes e constitui alternativa apropriada quando não se pode assumir normalidade. Zar (2010) reforça que o método é particularmente indicado para dados com distribuição desconhecida ou quando a variabilidade entre grupos não é homogênea. Para a identificação das diferenças específicas entre pares de grupos, empregou-se o teste de Dunn com correção de Bonferroni. Conforme discutido por Field (2013), a aplicação de correções em comparações múltiplas é essencial para evitar o inflacionamento do erro do tipo I, garantindo maior confiabilidade às inferências realizadas.

Nas situações em que os resíduos apresentaram distribuição aproximadamente normal, mas com variâncias heterogêneas, como verificado no MSR proximal de 2019 e no IPVI orbital de 2018, a ANOVA de Welch mostrou-se uma alternativa robusta à ANOVA clássica. Segundo Frost (2019), esse método é apropriado quando a suposição de homogeneidade de variâncias é violada, pois mantém o controle do erro do tipo I mesmo sob condições de heterocedasticidade. Para as comparações pós-hoc, adotou-se o teste de Games-Howell, o qual, conforme destacado por Statistics by Jim (2020), é indicado em cenários com variâncias desiguais e tamanhos amostrais diferentes, promovendo ajustes conservadores dos valores de p e garantindo comparações confiáveis entre os grupos.

Assim, a escolha combinada desses procedimentos estatísticos não se restringe a uma decisão operacional, mas está alinhada às recomendações clássicas da literatura estatística para análise de dados ambientais e experimentais, assegurando

que a validação dos agrupamentos seja conduzida com rigor metodológico e coerência inferencial.

Por outro lado, quando ambos os pressupostos paramétricos foram atendidos, isto é, normalidade e homogeneidade das variâncias, como observado para o RDVI e SAVI orbital em 2018 e para o SAVI orbital em 2019, aplicou-se a ANOVA seguida do teste de Tukey HSD. De acordo com Trindade *et al.* (2021), esse procedimento é amplamente utilizado em pesquisas com dados de sensoriamento remoto para verificar diferenças entre classes de vegetação. Segundo os autores, o NDVI apresentou variações estatísticas significativas ao longo de diferentes meses do ano, evidenciando a sensibilidade do índice às mudanças sazonais na cobertura vegetal. Nesse sentido, a aplicação do teste de Tukey, como também destacado por Trindade *et al.* (2021), permite controlar adequadamente o erro tipo I e estabelecer intervalos de confiança consistentes, favorecendo interpretações mais seguras no contexto agrônomo.

De forma semelhante, Padilha *et al.* (2018), ao analisarem índices espectrais de vegetação com dados óptico-orbitais, utilizaram o teste de Kruskal-Wallis seguido de Dunn em situações de variâncias desiguais, bem como a ANOVA de Welch com Games-Howell quando identificada heterocedasticidade. Segundo esses autores, a adoção desses procedimentos estatísticos possibilitou validar a segmentação de áreas conforme os teores de carbono orgânico no solo, reforçando a importância da escolha criteriosa dos testes conforme o comportamento dos dados.

Nas Tabelas 9, 10, 11, 12, 13 e 14 estão organizados os valores numéricos utilizados na comparação das médias, considerando cada ano, tipo de sensor e zonas de manejo avaliadas. Esses mesmos valores fundamentaram a construção dos boxplots anteriormente apresentados, de modo que as representações gráficas derivam diretamente dos dados estatisticamente testados. Assim, as Tabelas não constituem informação isolada, mas complementam a análise visual ao explicitar as médias, variações e agrupamentos estatísticos que sustentam as diferenças observadas entre as áreas.

Essa organização sistemática dos dados não apenas facilita a interpretação dos resultados, como também reforça a robustez estatística das análises realizadas, permitindo identificar padrões espaço-temporais dos índices de vegetação e evidenciando a relevância da estratificação por ano, zona de manejo e tecnologia de sensoriamento empregada.

4.8 Comparação de médias

4.8.1 Sensor proximal área A1

As Tabelas 9 e 10 de testes estatísticos para o sensor proximal e orbital da área A1 apresentam uma visão bastante consistente e metodologicamente robusta. A maior parte dos índices, tanto em 2018 quanto em 2019, demonstraram diferenças estatísticas muito significativas entre os grupos estabelecidos pelo k-means, com valores de p inferiores a 0,001 em quase todas as comparações.

Tabela 9 – Resultados dos testes estatísticos por índice para o sensor proximal da área A1

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Kruskal–Wallis ($\chi^2 = 586,56$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 24,2; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 644,95$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 25,4; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 625,55$; gl = 2; $p < 0,001$)	1 vs 2 (Z = 10,2; ***); 1 vs 3 (Z = -19,1; ***); 2 vs 3 (Z = -24,9; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 795,4$; gl = 2; $p < 0,001$)	1 vs 2 (Z = 27,6; ***); 1 vs 3 (Z = 2,11; ns); 2 vs 3 (Z = -18,4; ***)
MSR	2018	Kruskal–Wallis ($\chi^2 = 603,85$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -24,6; ***)
MSR	2019	Welch ANOVA (F = 1069; gl = 1,0 / 1035,7; $p < 0,001$)	1 vs 2 (Dif = -0,00123; IC [-0,00130; -0,00116]; **)
RDVI	2018	Kruskal–Wallis ($\chi^2 = 591,83$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 24,3; ***)
RDVI	2019	Kruskal–Wallis ($\chi^2 = 641,08$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 25,3; ***)
IPVI	2018	Kruskal–Wallis ($\chi^2 = 586,56$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 24,2; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 644,96$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 25,4; ***)
SAVI	2018	Kruskal–Wallis ($\chi^2 = 575,99$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -24,0; ***)
SAVI	2019	Kruskal–Wallis ($\chi^2 = 732,19$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -27,1; ***)

Legenda: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ns ($p \geq 0,05$)

Z = valor do teste de Dunn; Dif = diferença estimada entre grupos; IC = intervalo de confiança de 95%

Fonte: Dados da pesquisa (2025)

Em consonância com o posicionamento dos centróides previamente observados, os resultados estatísticos reforçam que os agrupamentos não foram definidos de forma arbitrária e sim em concordância estatística.

No sensor proximal (Tabela 9), o índice RVI apresentou, em 2018, três agrupamentos definidos, com diferenças estatísticas observadas entre os pares de grupos. Em 2019, embora o teste global tenha indicado diferença entre os grupos, a comparação específica entre os grupos 1 e 3 não apresentou significância estatística (ns). Esse resultado pode indicar uma aproximação entre esses grupos naquele ano, possivelmente associada a fatores agronômicos ou climáticos que tenham contribuído para a redução da diferença entre eles. Outro aspecto relevante é o MSR de 2019, que foi o único índice analisado pelo teste de Welch ANOVA com o método de Games-Howell. Esse teste indicou a presença de variâncias desiguais entre os grupos, como já mencionado anteriormente nos boxplots, mas ainda demonstrou uma diferença estatística significativa (com intervalo de confiança não cruzando zero).

No sensor orbital (Tabela 10), os índices RDVI e SAVI destacam-se por atender a pressupostos paramétricos, o que possibilita a aplicação da ANOVA com o teste Tukey HSD. Isso proporciona um maior poder estatístico nas comparações realizadas. O RDVI de 2018, por sua vez, mostrou uma diferença estimada de 0,0429 entre os grupos, com um intervalo de confiança reduzido e completamente positivo, o que corroborou a distinção entre diferentes zonas de vigor. O SAVI também apresentou esse padrão em ambos os anos, com variações consistentes e significativas.

Por outro lado, o índice IPVI, apesar de ter sido analisado por meio da ANOVA de Welch em 2018, apresentou resultados menos significativos em relação à magnitude da diferença, o que pode sugerir uma menor sensibilidade desse índice para distinguir áreas de vigor na região A1. O valor de $p < 0,001$ indica que a distinção entre os grupos é estatisticamente significativa.

Os resultados apresentados nas Tabelas indicam que os métodos estatísticos foram utilizados de maneira cuidadosa, levando em consideração as particularidades dos dados em cada situação. A predominância do teste de Kruskal-Wallis com Dunn indica a característica não paramétrica da maioria dos índices, enquanto a utilização pontual da ANOVA de Welch e da ANOVA com Tukey demonstra que, quando os pressupostos são respeitados, os testes paramétricos proporcionam maior precisão, como observado nos boxplots. Os índices RVI, RDVI e SAVI se sobressaem, pois demonstraram uma maior capacidade de diferenciar áreas de vigor de maneira

consistente ao longo dos anos e entre os diferentes sensores. Os índices que apresentam um desempenho estatístico inferior, como o IPVI, ainda são úteis para a análise, porém requerem atenção cuidadosa na interpretação agrônômica.

4.8.2 Sensor orbital área A1

Tabela 10 – Resultados dos testes estatísticos por índice para o sensor orbital da área A1

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Welch ANOVA ($F = 1128$; $gl = 1,0 / 1297,1$; $p < 0,001$)	1 vs 2 (Dif = $-0,0318$; IC $[-0,0337; -0,0300]$; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 740,56$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 27,2$; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 663,31$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 25,8$; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 740,56$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -27,2$; ***)
MSR	2018	Kruskal–Wallis ($\chi^2 = 663,31$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -25,8$; ***)
MSR	2019	Kruskal–Wallis ($\chi^2 = 740,56$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 27,2$; ***)
RDVI	2018	ANOVA ($F = 576$; $gl = 1 / 1298$; $p < 0,001$)	1 vs 2 (Dif = $0,0429$; IC $[0,0394; 0,0464]$; ***)
RDVI	2019	Kruskal–Wallis ($\chi^2 = 801,92$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -28,3$; ***)
IPVI	2018	Welch ANOVA ($F = 1128$; $gl = 1,0 / 1297,1$; $p < 0,001$)	1 vs 2 (Dif = $0,0159$; IC $[0,0150; 0,0168]$; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 740,56$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -27,2$; ***)
SAVI	2018	ANOVA ($F = 1112$; $gl = 1 / 1298$; $p < 0,001$)	1 vs 2 (Dif = $0,03997$; IC $[0,03762; 0,04233]$; ***)
SAVI	2019	ANOVA ($F = 1482$; $gl = 1 / 1298$; $p < 0,001$)	1 vs 2 (Dif = $-0,03364$; IC $[-0,03535; -0,03192]$; ***)

Legenda: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ns ($p \geq 0,05$)

Z = valor do teste de Dunn; Dif = diferença estimada entre grupos; IC = intervalo de confiança de 95%

Fonte: Dados da pesquisa (2025)

Nos resultados do sensor proximal em A2 (Tabela 11), destaca-se a consistência no emprego do teste de Kruskal-Wallis, seguido do teste de Dunn, em quase todos os índices e anos. Isso indica que os resíduos frequentemente infringiram ao menos um dos pressupostos da ANOVA clássica, geralmente o da normalidade. A magnitude das estatísticas χ^2 , que varia de aproximadamente 119 no NDVI (2018) a 458 no NDVI

(2019), juntamente com os elevados valores absolutos de Z nas comparações pós-hoc (todos superiores a 10 em módulo), evidencia diferenças significativas entre os dois grupos em cada índice, mesmo quando as categorias foram definidas apenas em dois conjuntos. A única exceção refere-se ao RDVI em 2019, que, ao mostrar variâncias desiguais, mesmo com a normalidade dos resíduos, exigiu a utilização da ANOVA de Welch com o método do Games-Howell. Contudo, permaneceu com $p < 0,001$ e um intervalo de confiança para a diferença que não inclui o zero, confirmando a distinção entre as duas zonas de vigor naquele índice.

4.8.3 Sensor proximal área A2

Tabela 11 – Resultados dos testes estatísticos por índice para o sensor proximal da área A2.

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Kruskal–Wallis ($\chi^2 = 118,84$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 10,9; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 456,58$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 21,4; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 393,86$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -19,8; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 461,75$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,5; ***)
MSR	2018	Kruskal–Wallis ($\chi^2 = 331,97$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -18,2; ***)
MSR	2019	Kruskal–Wallis ($\chi^2 = 457,57$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,4; ***)
RDVI	2018	Kruskal–Wallis ($\chi^2 = 410,91$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -20,3; ***)
RDVI	2019	Welch ANOVA (F = 960,46; gl = 1,0 / 381,3; $p < 0,001$)	1 vs 2 (Dif = -0,00242; IC [-0,00258; -0,00227]; ***)
IPVI	2018	Kruskal–Wallis ($\chi^2 = 118,83$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 10,9; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 456,58$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 21,4; ***)
SAVI	2018	Kruskal–Wallis ($\chi^2 = 396,35$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -19,9; ***)
SAVI	2019	Kruskal–Wallis ($\chi^2 = 312,04$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -17,7; ***)

Legenda: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ns ($p \geq 0,05$)

Z = valor do teste de Dunn; Dif = diferença estimada entre grupos; IC = intervalo de confiança de 95%

Fonte: Dados da pesquisa (2025)

No sensor orbital A2 (Tabela 12), a complexidade se eleva com a testagem de cinco ou seis agrupamentos, o que resulta em uma rede ampla de comparações. Neste contexto, observa-se que o teste de Kruskal-Wallis se destaca, uma vez que as violações dos pressupostos se tornam mais frequentes à medida que aumenta o número de grupos analisados. A exceção do SAVI em 2019, que utilizou a ANOVA de Welch devido à presença de heterocedasticidade, indica que, mesmo em uma escala macro, algumas distribuições se comportam de maneira suficientemente "favorável" para a análise paramétrica. As dezenas de Z-scores apresentadas mostram que a grande maioria dos pares de agrupamentos apresenta diferenças estatisticamente significativas. No entanto, há exceções notáveis em que não se observa diferença (ns), como no caso de 1 vs. 5 em NDVI (2018) e 4 vs. 5 em RVI (2019). Isso sugere que alguns agrupamentos vizinhos são espectralmente muito semelhantes e poderiam, em uma análise hipotética, ser combinados sem comprometer a interpretação dos dados. Os pontos de "sobreposição" entre os agrupamentos orbitais indicam que, embora a divisão detalhada registre microzonas relevantes, é necessário ter cuidado para não fragmentar de forma artificial áreas de vigor contínuo.

Ainda no que diz respeito ao sensoriamento orbital, a grande quantidade de agrupamentos com cinco, seis ou até sete subdivisões por índice demonstra, em sua essência, a complexidade espectral que surge ao analisarmos toda a paisagem de maneira integral, sem o detalhamento proporcionado pelos sensores de proximidade. Ao invés de apresentar apenas duas zonas claramente definidas (vigor "alto" e "baixo"), a grade de pixels que abrange hectares de cultivo oferece uma variedade ampla de tonalidades intermediárias. Cada pixel incorporado contém diferentes tipos de solo, vegetação em diferentes estágios de crescimento, sombras geradas por árvores ou construções, áreas de cultivo que estão mais úmidas e regiões que estão mais expostas. Esse mosaico natural solicita ao algoritmo de agrupamento que "divida" o cenário em diferentes partes, cada uma delas capturando uma combinação singular de vigor, umidade e refletância de fundo.

Cabe ainda lembrar que a decisão de quantos agrupamentos empregar foi baseada em critérios estatísticos do método elbow e índice de silhueta, e que nem sempre a melhor separação biométrica coincide com o menor número de classes.

4.8.4 Sensor orbital área A2

Tabela 12 – Resultados dos testes estatísticos por índice para o sensor orbital da área A2

(continua)

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Kruskal–Wallis ($\chi^2 = 511,38$; gl = 4; p < 0,001)	1vs2 (Z = -14,1; ***); 1vs3 (Z = -12,8; ***); 1vs4 (Z = -7,20; ***); 1vs5 (Z = 0,55; ns); 2vs3 (Z = -2,57; **); 2vs4 (Z = 9,40; ***); 2vs5 (Z = 18,6; ***); 3vs4 (Z = 8,53; ***); 3vs5 (Z = 14,9; ***); 4vs5 (Z = 9,82; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 503,38$; gl = 4; p < 0,001)	1vs2 (Z = 9,22; ***); 1vs3 (Z = 7,77; ***); 1vs4 (Z = 17,8; ***); 1vs5 (Z = -0,60; ns); 2vs3 (Z = -2,51; *); 2vs4 (Z = 10,3; ***); 2vs5 (Z = -8,95; ***); 3vs4 (Z = 14,2; ***); 3vs5 (Z = -7,61; ***); 4vs5 (Z = -16,6; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 535,98$; gl = 5; p < 0,001)	1vs2 (Z = -16,5; ***); 1vs3 (Z = -8,34; ***); 1vs4 (Z = -15,0; ***); 1vs5 (Z = -1,96; *); 1vs6 (Z = 3,07; **); 2vs3 (Z = 8,53; ***); 2vs4 (Z = -3,13; **); 2vs5 (Z = 9,73; ***); 2vs6 (Z = 15,6; ***); 3vs4 (Z = -9,02; ***); 3vs5 (Z = 4,04; ***); 3vs6 (Z = 9,54; ***); 4vs5 (Z = 10,5; ***); 4vs6 (Z = 15,2; ***); 5vs6 (Z = 4,21; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 514,74$; gl = 5; p < 0,001)	1vs2 (Z = -3,53; ***); 1vs3 (Z = 8,40; ***); 1vs4 (Z = -10,4; ***); 1vs5 (Z = -9,34; ***); 1vs6 (Z = -7,12; ***); 2vs3 (Z = 13,3; ***); 2vs4 (Z = -8,35; ***); 2vs5 (Z = -7,37; ***); 2vs6 (Z = -4,93; ***); 3vs4 (Z = -17,5; ***); 3vs5 (Z = -15,8; ***); 3vs6 (Z = -13,8; ***); 4vs5 (Z = 0,234; ns); 4vs6 (Z = 2,52; *); 5vs6 (Z = 2,16; *)
MSR	2018	Kruskal–Wallis ($\chi^2 = 511,83$; gl = 4; p < 0,001)	1vs2 (Z = 8,88; ***); 1vs3 (Z = 15,4; ***); 1vs4 (Z = 13,1; ***); 1vs5 (Z = 2,83; **); 2vs3 (Z = 9,56; ***); 2vs4 (Z = 7,07; ***); 2vs5 (Z = -9,20; ***); 3vs4 (Z = -0,618; ns); 3vs5 (Z = -18,4; ***); 4vs5 (Z = -14,0; ***)
MSR	2019	Kruskal–Wallis ($\chi^2 = 507,96$; gl = 4; p < 0,001)	1vs2 (Z = 17,1; ***); 1vs3 (Z = 9,26; ***); 1vs4 (Z = 0,526; ns); 1vs5 (Z = 8,05; ***); 2vs3 (Z = -10,2; ***); 2vs4 (Z = -18,0; ***); 2vs5 (Z = -13,9; ***); 3vs4 (Z = -9,42; ***); 3vs5 (Z = -2,35; *); 4vs5 (Z = 8,14; ***)
RDVI	2018	Kruskal–Wallis ($\chi^2 = 473,38$; gl = 6; p < 0,001)	1vs2 (Z = -1,46; ns); 1vs3 (Z = 3,81; ***); 1vs4 (Z = -11,8; ***); 1vs5 (Z = -11,2; ***); 1vs6 (Z = -1,42; ns); 1vs7 (Z = 5,08; ***); 2vs3 (Z = 4,64; ***); 2vs4 (Z = -12,0; ***); 2vs5 (Z = -11,6; ***); 2vs6 (Z = 0,049; ns); 2vs7 (Z = 6,77; ***); 3vs4 (Z = -5,98; ***); 3vs5 (Z = -5,53; ***); 3vs6 (Z = 2,34; *); 3vs7 (Z = 1,13; ns); 4vs5 (Z = 0,56; ns); 4vs6 (Z = 4,22; ***); 4vs7 (Z = 7,78; ***); 5vs6 (Z = 1,36; ns); 5vs7 (Z = 6,06; ***); 6vs7 (Z = 9,89; ***)

Legenda: *p < 0,05; ** p < 0,01; *** p < 0,001; ns (p ≥ 0,05); Z = valor do teste de Dunn; Dif = diferença estimada entre grupos

Fonte: Dados da pesquisa (2025)

Tabela 12 – Resultados dos testes estatísticos por índice para o sensor orbital da área A2

(conclusão)

Índice	Ano	Teste estatístico global	Comparações pós-hoc
RDVI	2019	Kruskal–Wallis ($\chi^2 = 528,62$; gl = 6; p < 0,001)	1vs2 (Z = 19,8; ***); 1vs3 (Z = 5,96; ***); 1vs4 (Z = 3,46; ***); 1vs5 (Z = 13,2; ***); 1vs6 (Z = 8,18; ***); 1vs7 (Z = 5,68; ***); 2vs3 (Z = -3,30; **); 2vs4 (Z = -15,8; ***); 2vs5 (Z = -7,16; ***); 2vs6 (Z = -14,1; ***); 2vs7 (Z = -3,25; **); 3vs4 (Z = -6,41; ***); 3vs5 (Z = -5,75; ***); 3vs6 (Z = -2,11; *); 3vs7 (Z = -0,75; ns); 4vs5 (Z = 9,85; ***); 4vs6 (Z = 9,32; ***); 4vs7 (Z = 8,14; ***); 5vs6 (Z = 0,72; ns); 5vs7 (Z = -0,46; ns); 6vs7 (Z = 6,90; ***)
IPVI	2018	Kruskal–Wallis ($\chi^2 = 511,38$; gl = 4; p < 0,001)	1vs2 (Z = -9,82; ***); 1vs3 (Z = -14,9; ***); 1vs4 (Z = -18,6; ***); 1vs5 (Z = -0,55; ns); 2vs3 (Z = -8,53; ***); 2vs4 (Z = -9,40; ***); 2vs5 (Z = 7,20; ***); 3vs4 (Z = 2,57; *); 3vs5 (Z = 12,8; ***); 4vs5 (Z = 14,1; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 503,38$; gl = 4; p < 0,001)	1vs2 (Z = 10,3; ***); 1vs3 (Z = -8,95; ***); 1vs4 (Z = -2,51; *); 1vs5 (Z = -9,22; ***); 2vs3 (Z = -16,6; ***); 2vs4 (Z = -14,2; ***); 2vs5 (Z = -17,8; ***); 3vs4 (Z = 7,61; ***); 3vs5 (Z = 0,599; ns); 4vs5 (Z = -7,77; ***)
SAVI	2018	Kruskal–Wallis ($\chi^2 = 534,16$; gl = 6; p < 0,001)	1vs2 (Z = -3,32; **); 1vs3 (Z = -15,0; ***); 1vs4 (Z = -8,71; ***); 1vs5 (Z = -14,9; ***); 1vs6 (Z = 0,342; ns); 1vs7 (Z = -6,57; ***); 2vs3 (Z = -15,0; ***); 2vs4 (Z = -6,77; ***); 2vs5 (Z = -14,0; ***); 2vs6 (Z = 3,09; *); 2vs7 (Z = 6,16; ***); 3vs4 (Z = 6,29; ***); 3vs5 (Z = 14,0; ***); 3vs6 (Z = 5,14; ***); 3vs7 (Z = -1,12; ns); 4vs5 (Z = 6,44; ***); 4vs6 (Z = 3,49; ***); 4vs7 (Z = -14,1; ***); 5vs6 (Z = 1,28; ns); 5vs7 (Z = -12,8; ***); 6vs7 (Z = -9,02; ***)
SAVI	2019	Welch ANOVA (F = 389,19; df = 6,156; p < 0,001)	1vs2 (Dif = 0,0373; ***); 1vs3 (Dif = 0,0399; ***); 1vs4 (Dif = 0,0767; ***); 1vs5 (Dif = 0,000525; ns); 1vs6 (Dif = 0,0589; ***); 1vs7 (Dif = -0,0242; ***); 2vs3 (Dif = 0,00259; ns); 2vs4 (Dif = 0,0394; ***); 2vs5 (Dif = -0,0368; ***); 2vs6 (Dif = 0,0215; ***); 2vs7 (Dif = -0,0614; ***); 3vs4 (Dif = 0,0368; ***); 3vs5 (Dif = -0,0394; ***); 3vs6 (Dif = 0,0190; **); 3vs7 (Dif = -0,0641; ***); 4vs5 (Dif = -0,0762; ***); 4vs6 (Dif = -0,0178; *); 4vs7 (Dif = -0,1009; ***); 5vs6 (Dif = 0,0584; ***); 5vs7 (Dif = -0,0248; *); 6vs7 (Dif = -0,0620; ***)

Legenda: *p < 0,05; ** p < 0,01; *** p < 0,001; ns (p ≥ 0,05); Z = valor do teste de Dunn; Dif = diferença estimada entre grupo

Fonte: Dados da pesquisa (2025)

4.8.5 Sensor proximal área A3

Tabela 13 – Resultados dos testes estatísticos por índice para o sensor proximal da área A3

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Welch ANOVA ($F = 941,28$; $gl = 1,0 / 691,22$; $p < 0,001$)	1 vs 2 (Dif = 0,00677; IC [0,00634; 0,00721]; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 477,74$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 21,9$; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 497,70$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 22,3$; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 468,54$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 21,6$; ***)
MSR	2018	Kruskal–Wallis ($\chi^2 = 502,24$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 22,4$; ***)
MSR	2019	Kruskal–Wallis ($\chi^2 = 488,11$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 22,1$; ***)
RDVI	2018	Kruskal–Wallis ($\chi^2 = 516,11$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -22,7$; ***)
RDVI	2019	ANOVA ($F = 1\,261$; $gl = 1,0 / 807,0$; $p < 0,001$)	1 vs 2 (Dif = -0,00433; IC [-0,00457; -0,00409]; ***)
IPVI	2018	Welch ANOVA ($F = 941,27$; $gl = 1,0 / 691,23$; $p < 0,001$)	1 vs 2 (Dif = 0,00339; IC [0,00317; 0,00360]; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 477,74$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = 21,9$; ***)
SAVI	2018	Kruskal–Wallis ($\chi^2 = 502,68$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -22,4$; ***)
SAVI	2019	Kruskal–Wallis ($\chi^2 = 513,95$; $gl = 1$; $p < 0,001$)	1 vs 2 ($Z = -22,7$; ***)

Legenda: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ns ($p \geq 0,05$)

Z = valor do teste de Dunn; Dif = diferença estimada entre grupos; IC = intervalo de confiança de 95%

Fonte: Dados da pesquisa (2025)

Na área A3, tanto o sensoriamento próximo (Tabela 13) quanto o orbital (Tabela 14) confirmam a categorização em apenas dois grupos de vigor, apresentando diferenças estatisticamente significativas em todos os índices e anos analisados.

No ano de 2018, o NDVI e o IPVI mostraram-se apropriados em relação aos pressupostos de normalidade (mesmo com variâncias diferentes), o que permitiu a realização da ANOVA de Welch, seguida pelo teste do Games–Howell. Os resultados indicaram diferenças médias de 0,00677 (IC95% [0,00634; 0,00721]) para o NDVI e 0,00339 (IC95% [0,00317; 0,00360]) para o IPVI, ambas apresentando $p < 0,001$. Para o RDVI de 2019, que apresentou tanto normalidade quanto homocedasticidade, foi aplicada a ANOVA clássica juntamente com o teste de Tukey. Os resultados

indicaram uma redução média de - 0,00433 (IC95% [- 0,00457; - 0,00409]) entre os grupos analisados. Todos os outros índices naquele ano (NDVI, RVI, MSR, IPVI, SAVI) apresentaram uma diminuição na abordagem não paramétrica, sendo que o teste de Kruskal-Wallis revelou valores de χ^2 variando de 468 a 516 e Z-scores acima de |21|, indicando um $p < 0,001$. Isso demonstra que a divisão em duas classes é consistente, independentemente do padrão de distribuição observado.

4.8.6 Sensor orbital área A3

Tabela 14 – Resultados dos testes estatísticos por índice para o sensor orbital da área A3

Índice	Ano	Teste estatístico global	Comparações pós-hoc
NDVI	2018	Kruskal–Wallis ($\chi^2 = 474,89$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,8; ***)
NDVI	2019	Kruskal–Wallis ($\chi^2 = 473,69$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,8; ***)
RVI	2018	Kruskal–Wallis ($\chi^2 = 457,24$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 21,4; ***)
RVI	2019	Kruskal–Wallis ($\chi^2 = 508,19$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 22,5; ***)
MSR	2018	Kruskal–Wallis ($\chi^2 = 451,77$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,3; ***)
MSR	2019	Kruskal–Wallis ($\chi^2 = 507,66$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -22,5; ***)
RDVI	2018	Kruskal–Wallis ($\chi^2 = 217,39$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -14,7; ***)
RDVI	2019	Kruskal–Wallis ($\chi^2 = 246,52$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -15,7; ***)
IPVI	2018	Kruskal–Wallis ($\chi^2 = 474,89$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 21,8; ***)
IPVI	2019	Kruskal–Wallis ($\chi^2 = 473,69$; gl = 1; $p < 0,001$)	1 vs 2 (Z = 21,8; ***)
SAVI	2018	Kruskal–Wallis ($\chi^2 = 445,94$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -21,1; ***)
SAVI	2019	Kruskal–Wallis ($\chi^2 = 400,55$; gl = 1; $p < 0,001$)	1 vs 2 (Z = -20,0; ***)

Legenda: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ns ($p \geq 0,05$)

Z = valor do teste de Dunn; Dif = diferença estimada entre grupos; IC = intervalo de confiança de 95%

Fonte: Dados da pesquisa (2025)

No contexto orbital, a uniformidade foi ainda mais acentuada: nos anos de 2018 e 2019, todos os índices (NDVI, RVI, MSR, RDVI, IPVI e SAVI) infringiram algum pressuposto paramétrico, resultando na utilização exclusiva do teste de Kruskal-Wallis, seguido pelo teste de Dunn. Os valores de χ^2 variaram entre 217 e 508, enquanto os valores de Z oscilaram entre [14,7] e [22,5]. Esses resultados confirmam que cada pixel pertence de maneira inequívoca a um dos dois agrupamentos, sem exceções e como sempre $p < 0,001$.

A ocorrência de que, em diversas combinações de ano e índice, alguns índices apresentaram um comportamento “favorável” aos testes paramétricos (permitindo a realização da ANOVA de Welch ou clássica), enquanto a maior parte necessitou do teste de Kruskal-Wallis, indica a heterogeneidade intrínseca dos dados espectrais e a precisão na coleta de informações de cada sensor. Contudo, o resultado unânime, a falta de comparações que não são significativas e os intervalos de confiança que não incluem o zero nas raras análises paramétricas fortalecem a solidez da divisão em dois níveis de vigor na área A3.

4.9 Autocorrelação espacial (Moran I)

A estatística de Moran I exige uma consideração cuidadosa e diferenciada da distinção que existe entre a magnitude numérica da estatística e sua significância estatística associada, que é crucial para uma interpretação precisa. Embora a estrutura teórica de Moran I postule que seus valores podem oscilar entre -1 e 1, estudos desenvolvidos por Anseli (1995) e também por Yamamoto e Landim (2013) mostram que aplicações que envolvem um número elevado de pontos de amostra, ao lado de matrizes de peso espacial normalizadas, frequentemente produzem valores esperados mais próximos de zero do que de -1 ou 1. À luz dessas circunstâncias, fica melhor compreendido que mesmo pequenos desvios de um estado de aleatoriedade, como ilustrados por valores de Moran I tão modestos quanto 0,01 ou 0,02, podem levar ao surgimento de Z-escores notavelmente altos e estatisticamente significativos, o que pode ter implicações profundas na interpretação dos dados. Esse fenômeno pode ser atribuído ao fato de que a variância teórica associada à estatística de Moran I diminui à medida que o número de observações aumenta, resultando em pequenas correlações espaciais que se tornam estatisticamente indiscutíveis. Portanto, é importante que sejam compreendidas essas dinâmicas, pois elas ressaltam a

importância de reconhecer como mesmo pequenas variações estatísticas podem gerar implicações consideráveis na análise espacial. Por esses motivos, obter um entendimento abrangente da relação entre magnitude e significância no contexto de Moran I é essencial para garantir a robustez das conclusões analíticas em estatísticas espaciais, especialmente no contexto de zonas de manejo e áreas agrícolas.

Nos dados adquiridos por meio do sensoriamento proximal e até mesmo pelo sensor orbital, visto que os pontos de amostra no orbital foram correlacionados com os do proximal para nível de comparação, observou-se que a elevada densidade amostral e a diminuição das distâncias entre pontos impactaram significativamente as propriedades estatísticas do índice de Moran. Essa observação também se alinha às descobertas de Cressie (1993) e Isaaks e Srivastava (1989), que enfatizam que uma densidade grande de amostras normalmente diminui a variabilidade do estimador, potencialmente produzindo valores z elevados e valores p marcadamente baixos, mesmo em casos de autocorrelação espacial mínima. Consequentemente, apesar da magnitude relativamente pequena da autocorrelação detectada em algumas zonas geradas pelos índices de vegetação em alguns anos e outrora em alguns índices diferentes e até em sensores divergentes, a hipótese nula que afirma a ausência de dependência espacial pode ser descartada com um nível considerável de confiança. Um fenômeno comparável foi documentado por Cambardella *et al.* (1994) em estudos sobre a variabilidade das propriedades do solo e por Molin e Queiroz (2017) em aplicações geoestatísticas focadas na agricultura de precisão, destacando que, nesse contexto, a significância estatística deve ser interpretada como uma indicação da presença da estrutura espacial em vez de um marcador definitivo de forte dependência.

Além disso, observou-se que a magnitude do índice de Moran variou de acordo com a escala de análise e a resolução espacial dos dados com grupos maiores e grupos menores que influenciam na quantidade de amostras, comportamento similarmente observado por Anselin (1995) e Gavioli *et al.* (2016). Essa observação confirma a noção de que não existe uma referência universal para classificar o I de Moran como “bom” ou “ruim”, já que o valor absoluto do índice é significativamente influenciado pela matriz de peso espacial empregada e pelas características intrínsecas do conjunto de dados.

Do ponto de vista prático, a existência de valores de I de Moran baixos, mas estatisticamente significativos, sugere que, embora a autocorrelação esteja delimitada

a distâncias curtas, existe uma continuidade espacial adequada para garantir o estabelecimento de zonas de manejo. Descobertas semelhantes foram relatadas em vinhedos examinados por Matese *et al.* (2019), onde padrões espaciais sutis, porém consistentes, foram considerados pertinentes para o delineamento de zonas de vigor e o planejamento de práticas agronômicas diferenciadas. Portanto, a análise espacial conduzida nesta investigação ressalta que, mesmo em cenários em que o índice de Moran se aproxima de zero, a presença de significância estatística indica dependência espacial suficiente para defender estratégias de gestão localizadas.

Os valores do índice de Moran I calculados para os agrupamentos de cada zona de manejo foram organizados nas Tabelas 15 a 19, separadas por área (A1, A2, A3), sensor (proximal e orbital) e safra (2018-2019).

4.9.1 Sensor proximal área A1

Em uma análise abrangente dos resultados obtidos da Tabela 15, os resultados derivados do cálculo dos valores de Moran I do sensor proximal, dentro das zonas de manejo que foram delimitadas pelo k-means, demonstraram um nível consistentemente positivo e notavelmente significativo de autocorrelação espacial, com um limite de valor p inferior a 0,001, especificamente para os índices de NDVI, MSR, RDVI, IPVI e SAVI, que exibiram uma magnitude que variou entre 0,03 e 0,06. É particularmente digno de nota que mesmo aqueles valores que poderiam ser convencionalmente categorizados como baixos exibiram um alto Z-escore, afirmando assim a existência de dependência espacial, particularmente em distâncias curtas, o que é crucial para a compreensão dos padrões espaciais implícitos. Conforme articulado por Cressie (1993), em conjuntos de dados caracterizados por uma alta densidade de amostras, a variância associada ao estimador é significativamente reduzida ou menor, levando ao fenômeno em que mesmo autocorrelações fracas produzem valores p extremamente baixos, indicando assim uma forte significância estatística.

Tabela 15 – Estatística de Moran I Intragrupos obtida pelo Sensor Proximal na Área de Estudo A1

Índice	Ano	Agrupamentos		
		1	2	3
		(z; p; I; Exp.; Var.)		
NDVI	2018	50,70; p < 0,001; 0,032; -0,002; 4,50e-07	86,91; p < 0,001; 0,054; -0,001; 4,11e-07	—
	2019	86,06; p < 0,001; 0,056; -0,002; 4,50e-07	20,09; p < 0,001; 0,012; -0,001; 4,11e-07	—
RVI	2018	12,22; p < 0,001; 0,004; -0,001; 2,25e-07	39,80; p < 0,001; 0,028; -0,003; 5,77e-07	38,43; p < 0,001; 0,054; -0,005; 2,33e-06
	2019	-10,63; p = 1; -0,006; -0,001; 2,25e-07	52,22; p < 0,001; 0,037; -0,003; 5,77e-07	0,77; p = 0,221; - 0,004; -0,005; 2,32e-06
MSR	2018	49,19; p < 0,001; 0,031; -0,002; 4,34e-07	81,61; p < 0,001; 0,051; -0,001; 4,17e-07	—
	2019	78,71; p < 0,001; 0,050; -0,002; 4,34e-07	21,91; p < 0,001; 0,013; -0,001; 4,18e-07	—
RDVI	2018	84,25; p < 0,001; 0,053; -0,001; 4,09e-07	50,77; p < 0,001; 0,032; -0,002; 4,48e-07	—
	2019	20,71; p < 0,001; 0,012; -0,001; 4,10e-07	83,46; p < 0,001; 0,054; -0,002; 4,48e-07	—
IPVI	2018	50,70; p < 0,001; 0,032; -0,002; 4,50e-07	86,91; p < 0,001; 0,054; -0,001; 4,11e-07	—
	2019	86,06; p < 0,001; 0,056; -0,002; 4,50e-07	20,09; p < 0,001; 0,012; -0,001; 4,11e-07	—
SAVI	2018	87,74; p < 0,001; 0,034; -0,001; 1,61e-07	0,70; p = 0,242; - 0,002; -0,003; 5,28e-07	—
	2019	39,53; p < 0,001; 0,015; -0,001; 1,61e-07	76,27; p < 0,001; 0,053; -0,003; 5,29e-07	—

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025)

A significância estatística observada neste contexto fornece evidências convincentes de que as zonas de manejo exibem um grau de coerência interna, que reflete padrões espaciais consistentes em toda a área de estudo, uma descoberta que se alinha à pesquisa de zoneamento de vinhedos conduzida por Bramley e Hamilton (2004) na Austrália, que em sua pesquisa a variedade estudada incluía a Cabernet Sauvignon e o método usado também foi por K-means e que se alinha também com Molin *et al.* (2020). Em seus estudos, descobriu-se que dependências espaciais pequenas, mas significativas, são fundamentais para apoiar o delineamento de zonas caracterizadas por níveis variáveis de vigor.

Curiosamente, no ano de 2019, observou-se que apenas o índice RVI exibiu um valor negativo ($I = -0,006$), restrito a um dos três grupos categorizados. Esse resultado de Moran I para o RVI 2019 na área A1 repete ou confirma o mesmo que a estatística global de Kruskal-Wallis e Dunn já havia mostrado na tabela 9, em que o grupo 1 e o grupo 3 não apresentaram significância estatística quando comparados entre si, e assim também ocorreu com Moran I que apresentou problemas nos mesmos grupos apresentados na Tabela 15. Essa inversão de pontos não é atribuível a fatores topográficos, que normalmente são um dos principais fatores para que isso ocorra, que no caso da análise todos os índices estavam nas mesmas condições e na mesma área e resultaram de modo diferente; as mudanças climáticas ou de manejo podem interferir, mas a divergência está ligada às características inerentes ao RVI. O RVI, sendo uma razão direta das faixas do infravermelho próximo e do vermelho, demonstra maior sensibilidade às variações espectrais localizadas, bem como ao ruído presente em regiões caracterizadas pela baixa densidade foliar (Zhang *et al.*, 2021). Consequentemente, pequenas flutuações radiométricas podem interromper a continuidade espacial, resultando na falta de autocorrelação positiva dentro desse grupo específico, sem afetar adversamente a estrutura espacial geral do índice.

4.9.2 Sensor orbital área A1

Para o sensor orbital (Tabela16), a autocorrelação intragrupo permaneceu afirmativa, embora com maior variabilidade entre os agrupamentos. No ano de 2018, o NDVI e o MSR exibiram $I = 0,039$ ($p < 0,001$) no agrupamento 1, enquanto o agrupamento 2 apresentou uma autocorrelação marginalmente negativa ($I = -0,005$). No ano de 2019, o RDVI surgiu com destaque com $I = 0,089$ ($p < 0,001$).

Essa variabilidade nas magnitudes dos coeficientes significa a influência cumulativa da resolução espacial do sensor junto com a configuração das zonas criadas, pois pequenas alterações na escala de observação ou na matriz de peso espacial podem modificar a sensibilidade do I de Moran a padrões de curto alcance. Pesquisas conduzidas por Gavioli *et al.* (2016) ressaltam que a metodologia empregada para delinear as zonas de manejo e as dimensões das unidades de análise tem uma influência direta na identificação da autocorrelação espacial, mesmo nos casos em que o conjunto de dados é homogêneo.

Tabela 16 – Estatística de Moran I Intragrupos obtida pelo Sensor Orbital na Área de Estudo A1

Índice	Ano	Agrupamentos	
		1	2
		(z; p; I; Exp.; Var.)	
NDVI	2018	57,04; p < 0,001; 0,039; -0,002; 5,00e-07	-8,14; p = 1; -0,005; -0,002; 1,86e-07
	2019	34,10; p < 0,001; 0,023; -0,002; 5,01e-07	8,11; p < 0,001; 0,002; -0,002; 1,86e-07
RVI	2018	-7,14; p = 1; -0,005; -0,002; 1,86e-07	56,83; p < 0,001; 0,039; -0,002; 5,00e-07
	2019	8,26; p < 0,001; 0,002; -0,002; 1,86e-07	33,71; p < 0,001; 0,022; -0,002; 5,01e-07
MSR	2018	56,98; p < 0,001; 0,039; -0,002; 5,00e-07	-7,47; p = 1; -0,005; -0,002; 1,86e-07
	2019	33,85; p < 0,001; 0,022; -0,002; 5,01e-07	8,22; p < 0,001; 0,002; -0,002; 1,86e-07
RDVI	2018	129,69; p < 0,001; 0,089; -0,001; 4,82e-07	64,14; p < 0,001; 0,035; -0,002; 3,21e-07
	2019	0,62; p = 0,268; -0,001; -0,001; 4,83e-07	12,24; p < 0,001; 0,005; -0,002; 3,21e-07
IPVI	2018	57,04; p < 0,001; 0,039; -0,002; 5,00e-07	-8,14; p = 1; -0,005; -0,002; 1,86e-07
	2019	34,10; p < 0,001; 0,023; -0,002; 5,01e-07	8,11; p < 0,001; 0,002; -0,002; 1,86e-07
SAVI	2018	-8,14; p = 1; -0,005; -0,002; 2,03e-07	71,47; p < 0,001; 0,049; -0,002; 4,92e-07
	2019	4,20; p < 0,001; 0,000; -0,002; 2,03e-07	23,34; p < 0,001; 0,015; -0,002; 4,94e-07

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025)

Conforme afirmado por Zhang *et al.* (2021) e Matese *et al.* (2019), os sensores orbitais estão predispostos a discernir padrões espaciais mais amplos e mitigar as descontinuidades locais, diminuindo assim a magnitude do I de Moran em comparação com dados de alta resolução obtidos por meio de sensores proximais. Não obstante, as observações estatisticamente significativas denotam continuidade e coerência espacial pertinentes entre as zonas de manejo, ilustrando assim que os agrupamentos mantêm a uniformidade interna mesmo em escalas observacionais variáveis.

4.9.3 Sensor proximal área A2

Na área A2 do sensor proximal (Tabela 17), os resultados derivados do índice de Moran I intragrupo revelaram uma tendência distinta e comparativamente menos estável quando comparados às áreas A1 e A3. No ano de 2018, uma autocorrelação positiva e estatisticamente significativa foi observada para a maioria dos índices de vegetação, notadamente para SAVI ($I = 0,061$; $p < 0,001$) e NDVI ($I = 0,052$; $p < 0,001$), mas divergindo algumas vezes por grupos. No entanto, uma diminuição acentuada na magnitude do I de Moran e uma perda de significância estatística em certos grupos foram evidentes em 2019, particularmente para NDVI ($p = 0,927$) e RVI, que exibiram um valor negativo ($I = -0,011$; $p = 1$).

Esse comportamento observado pode ser elucidado pelos atributos estruturais e ambientais distintos na área. Primeiramente, constitui a menor parcela dentro do domínio experimental (0,82 ha), o que diminui o número de pares espaciais incorporados na matriz de peso e, conseqüentemente, reduz a sensibilidade do I de Moran aos padrões localizados. Além disso, o espaçamento de $2,5 \times 1,0$ m, que é mais denso em comparação com A1 ($3,0 \times 1,0$ m), provavelmente tornará o dossel uniforme e diminuirá o contraste espectral entre as linhas, mitigando assim a magnitude da autocorrelação espacial.

Um fator adicional que pode ter influenciado a variabilidade observada é o efeito de sombreamento periférico atribuído à proximidade da floresta e da vegetação de borda. As regiões sombreadas atenuam a irradiância incidente e impactam predominantemente a refletância do infravermelho próximo (NIR), levando a uma subestimação dos índices de vegetação e a uma interrupção na continuidade espacial entre os pixels vizinhos conforme Mielewicz *et al.* (2020). Esse fenômeno é

particularmente pronunciado em índices como o RVI, que representa uma razão direta entre NIR e RED e, portanto, é mais vulnerável a ruídos radiométricos e flutuações locais abruptas (Zhang *et al.*, 2021).

Tabela 17 – Estatística de Moran I Intragrupos obtida pelo Sensor Proximal na Área de Estudo A2

Índice	Ano	Agrupamentos	
		1	2
		(z; p; I; Exp.; Var.)	
NDVI	2018	-0,00; p = 0,5; -0,003; -0,003; 6,40e-17	42,29; p < 0,001; 0,052; -0,004; 1,75e-06
	2019	-0,00; p = 0,5; -0,003; -0,003; 6,39e-17	-1,45; p = 0,927; -0,006; -0,004; 1,75e-06
RVI	2018	26,99; p < 0,001; 0,033; -0,004; 1,88e-06	-0,00; p = 0,5; -0,003; -0,003; 4,12e-17
	2019	-5,29; p = 1; -0,011; -0,004; 1,88e-06	-0,00; p = 0,5; -0,003; -0,003; 4,11e-17
MSR	2018	39,85; p < 0,001; 0,050; -0,004; 1,85e-06	NaN; p = NA; -0,003; -0,003; -5,38e-17
	2019	-3,05; p = 0,999; -0,008; -0,004; 1,85e-06	NaN; p = NA; -0,003; -0,003; -5,37e-17
RDVI	2018	29,63; p < 0,001; 0,033; -0,004; 1,57e-06	20,80; p < 0,001; -0,001; -0,002; 8,10e-09
	2019	-19,65; p = 1; -0,029; -0,004; 1,57e-06	18,13; p < 0,001; -0,001; -0,002; 8,10e-09
IPVI	2018	42,29; p < 0,001; 0,052; -0,004; 1,75e-06	-0,00; p = 0,5; -0,003; -0,003; 6,40e-17
	2019	-1,45; p = 0,927; -0,006; -0,004; 1,75e-06	0,00; p = 0,5; -0,003; -0,003; 6,39e-17
SAVI	2018	47,80; p < 0,001; 0,061; -0,004; 1,89e-06	16,05; p < 0,001; -0,001; -0,002; 3,68e-09
	2019	-7,12; p = 1; -0,014; -0,004; 1,91e-06	3,88; p < 0,001; -0,002; -0,002; 3,68e-09

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025).

Portanto, os resultados derivados do sensor proximal em A2 indicam uma dependência espacial presente, porém enfraquecida, influenciada por fatores de escala, sombreamento e uniformidade estrutural. Não obstante a redução na magnitude, a identificação de aglomerados significativos comprova a existência de uma continuidade espacial relevante, adequada para garantir a implementação de

zonas de manejo dentro da área, condicionada à consideração das limitações decorrentes de sua menor extensão e do impacto das fronteiras.

4.9.4 Sensor orbital na área A2

As descobertas derivadas do sensor orbital (Tabela 18) pertencente à área A2 corroboram o comportamento aleatório identificado no sensor proximal e também já mencionado nas estatísticas de k-means. Em 2018, um número limitado de grupos exibiu autocorrelação positiva e estatisticamente significativa, como NDVI ($I = 0,202$; $p < 0,001$) e RVI ($I = 0,066$; $p < 0,001$), enquanto outros grupos manifestaram valores negativos ou estatisticamente não significativos. Em 2019, uma recorrência da instabilidade foi observada tanto na magnitude quanto no sinal do I de Moran, indicando um arranjo espacial desarticulado.

Essa inconsistência talvez esteja ligada à diminuição da escala física da região e à resolução do sensor orbital de 3 m. Com uma área de apenas 0,82 ha, o A2 é representado por uma quantidade limitada de pixels valiosos, o que prejudica a precisão estatística do I de Moran e amplifica o impacto de variações específicas (Matese *et al.*, 2019; Zhang *et al.*, 2021). Além disso, a presença de floresta na periferia pode ter causado os efeitos da sombra e da mistura espectral, levando a pixels de transição que prejudiquem obter sinais de videiras, solo e vegetação circundante, distorcendo assim o padrão de autocorrelação (Bégué *et al.*, 2018).

O alinhamento das linhas em relação ao ângulo solar e à direção da imagem pode ter influenciado a resposta espectral, particularmente em dias caracterizados por discrepâncias de iluminação entre as bordas do vinhedo e a área central (Tagarakis *et al.*, 2018).

Consequentemente, o comportamento do I de Moran em A2, conforme registrado pelo sensor orbital, ilustra a interação entre os efeitos de escala, sombra e resolução, que atenuam os padrões de autocorrelação espacial.

Tabela 18 – Estatística de Moran I Intragrupos obtida pelo Sensor Orbital na Área de Estudo A2

(Continua)

Índice	Ano	Agrupamentos					
		1	2	3	4	5	6
		(z; p; I; Exp.; Var.)					
NDVI	2018	-2.89; p = 0.998;	2.09; p = 0.018;	5.97; p < 0.001;	8.76; p < 0.001;	-2.28; p = 0.989;	—
		-0.008; -0.005;	-0.005; -0.007;	0.027; -0.015;	0.202; -0.020;	-0.009; -0.005;	
		9.58e-07	1.04e-06	4.96e-05	6.46e-04	3.65e-06	
	2019	-1.75; p = 0.960;	-10.31; p =	1.17; p = 0.120;	5.57; p < 0.001;	-3.81; p = 1.000;	—
-0.007; -0.005;		1.000; -0.018; -	-0.007; -0.015;	0.121; -0.020;	-0.012; -0.005;		
9.63e-07		0.007; 1.04e-06	4.87e-05	6.39e-04	3.66e-06		
RVI	2018	-0.89; p = 0.814;	-2.13; p = 0.984;	3.96; p < 0.001;	5.22; p < 0.001;	-1.02; p = 0.847;	-0.56; p = 0.712; -
		-0.020; -0.019;	-0.009; -0.005;	0.066; -0.017;	0.044; -0.021;	-0.007; -0.006;	0.0089; -0.0082;
		9.62e-07	3.50e-06	4.40e-04	1.57e-04	1.16e-06	1.61e-06
	2019	1.31; p = 0.096;	-2.67; p = 0.996;	9.38; p < 0.001;	1.12; p = 0.131; -	-4.48; p = 1.000;	-6.04; p = 1.000; -
-0.018; -0.019;		-0.010; -0.005;	0.180; -0.017;	0.0072; -0.0213;	-0.011; -0.006;	0.0159; -0.0082;	
9.75e-07		3.51e-06	4.41e-04	1.58e-04	1.17e-06	1.62e-06	
MSR	2018	-2.21; p = 0.987;	-2.30; p = 0.989;	2.23; p = 0.013;	5.16; p < 0.001;	7.24; p < 0.001;	—
		-0.008; -0.006;	-0.009; -0.005;	-0.005; -0.007;	0.022; -0.014;	0.150; -0.019;	
		8.86e-07	3.45e-06	1.09e-06	4.91e-05	5.39e-04	
	2019	-2.67; p = 0.996;	-2.66; p = 0.996;	-10.01; p =	0.48; p = 0.315; -	8.02; p < 0.001;	—
-0.008; -0.006;		-0.010; -0.005;	1.000; -0.018; -	0.011; -0.014;	0.168; -0.019;		
8.91e-07		3.46e-06	0.007; 1.09e-06	4.84e-05	5.38e-04		
IPVI	2018	8.76; p < 0.001;	5.97; p < 0.001;	-2.28; p = 0.989;	2.09; p = 0.018; -	-2.89; p = 0.998;	—
		0.202; -0.020;	0.027; -0.015;	-0.009; -0.005;	0.005; -0.007;	-0.008; -0.005;	
		6.46e-04	4.96e-05	3.65e-06	1.04e-06	9.58e-07	
	2019	5.57; p < 0.001;	1.17; p = 0.120;	-3.81; p = 1.000;	-10.31; p = 1.000;	-1.75; p = 0.960;	—
0.121; -0.020;		-0.007; -0.015;	-0.012; -0.005;	-0.018; -0.007;	-0.007; -0.005;		
6.39e-04		4.87e-05	3.66e-06	1.04e-06	9.63e-07		

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025).

Tabela 18 – Estatística de Moran I Intragrupos obtida pelo Sensor Orbital na Área de Estudo A2

		(Conclusão)						
Índice	Ano	Agrupamentos						
		1	2	3	4	5	6	7
		(z; p; I; Exp.; Var.)						
RDVI	2018	0.31; p =	6.75; p <	NaN; p = NA;	1.97; p =	6.06; p <	-2.88; p =	1.82; p =
		0.377; -0.025; -0.026; 2.44e- 05	0.001; 0.015; -0.008; 1.11e- 05	-0.083; - 0.083; -9.54e- 18	0.025; 0.006; -0.013; 9.09e- 05	0.001; 0.027; - 0.013; 4.30e- 05	0.998; -0.012; -0.006; 3.17e- 06	0.034; -0.002; -0.007; 5.65e- 06
	2019	-0.66; p =	9.04; p <	NaN; p = NA;	2.80; p =	-0.63; p =	-0.26; p =	9.41; p <
		0.747; -0.030; -0.026; 2.42e- 05	0.001; 0.022; -0.008; 1.12e- 05	-0.083; - 0.083; -8.67e- 18	0.003; 0.014; -0.013; 9.18e- 05	0.735; -0.017; -0.013; 4.29e- 05	0.601; -0.007; -0.006; 3.19e- 06	0.001; 0.016; - 0.007; 5.65e- 06
SAVI	2018	0.93; p =	1.33; p =	-2.29; p =	NaN; p = NA;	1.80; p =	-2.12; p =	7.96; p <
		0.175; -0.007; -0.009; 3.99e- 06	0.093; 0.015; -0.021; 7.11e- 04	0.989; -0.010; -0.005; 3.76e- 06	-0.020; - 0.020; -7.27e- 17	0.036; -0.022; -0.034; 4.63e- 05	0.983; -0.009; -0.006; 1.62e- 06	0.001; 0.115; - 0.023; 3.03e- 04
	2019	7.19; p <	2.37; p =	-2.49; p =	NaN; p = NA;	-2.47; p =	-1.11; p =	-0.10; p =
		0.001; 0.005; - 0.009; 3.99e- 06	0.009; 0.043; -0.021; 7.14e- 04	0.994; -0.010; -0.005; 3.78e- 06	-0.020; - 0.020; -7.26e- 17	0.993; -0.052; -0.034; 4.87e- 05	0.867; -0.007; -0.006; 1.63e- 06	0.541; -0.025; -0.023; 3.05e- 04

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025)

4.9.5 Sensor proximal área A3

É possível perceber que a área A3 se destaca por apresentar um padrão espacial muito consistente, que se manteve coerente tanto entre os diferentes agrupamentos quanto ao longo dos anos, quase como um espelho da área A1. Isso significa que, nos dois anos analisados, os dados mostraram uma clara 'vizinhança' ou autocorrelação positiva, um resultado estatisticamente muito forte.

Tivemos picos notáveis no sensor proximal em 2019 (Tabela 19), especialmente com os índices RVI e MSR, que ultrapassaram 0,08 ($p < 0,001$). Na prática, isso é uma ótima notícia, pois confirma que a forma como dividimos o vinhedo em zonas de manejo realmente reflete a realidade do vigor das plantas no campo. Não foi um resultado aleatório; é uma continuidade espacial bem definida que conseguimos capturar.

A consistência da A3 está relacionada à sua estrutura física equilibrada, com tamanho intermediário (0,97 ha) e espaçamento uniforme ($2,5 \times 1,0$ m), que favorecem a manutenção da continuidade espacial. Além disso, a A3 é composta pela cultivar Cabernet Sauvignon, que tende a apresentar dossel mais compacto e vigor mais uniforme em comparação à Cabernet Franc presente nas outras áreas, resultando em padrões espectrais mais estáveis (Matese *et al.*, 2019; Tardaguila *et al.*, 2017).

Em 2018, no sensor proximal, um índice chamou a atenção, o SAVI apresentou valor ligeiramente negativo ($I = -0,014$), provavelmente relacionado a microvariações de iluminação e sombreamento intraparcela, ou até mesmo pelo menor espaçamento em comparação com a área A1, pois o SAVI tem a correção do solo e como já mencionado anteriormente, o dossel da cultivar da área A3 tende a ser mais compacto, mas isso sem comprometer a estrutura espacial geral. Já em 2019, a melhora na magnitude do Moran I em todos os índices reforça a expressividade espacial do vigor, indicando estabilidade na estrutura das zonas de manejo e continuidade entre fileiras.

Portanto, no sensor proximal, na A3 mostrou dependência espacial bem definida, significativa e consistente, refletindo condições agronômicas equilibradas e uma segmentação eficiente para fins de manejo de precisão.

Tabela 19 – Estatística de Moran I Intragrupos obtida pelo Sensor Proximal na Área de Estudo A3

Índice	Ano	Agrupamentos	
		1	2
		(z; p; I; Exp.; Var.)	
NDVI	2018	26.07; p < 0.001; 0.044; -0.003; 3.27e-06	-27.36; p = 1; -0.040; -0.002; 1.89e-06
	2019	24.33; p < 0.001; 0.041; -0.003; 3.28e-06	65.42; p < 0.001; 0.088; -0.002; 1.89e-06
RVI	2018	13.13; p < 0.001; 0.014; -0.002; 1.55e-06	2.18; p = 0.015; 0.0005; -0.003; 3.09e-06
	2019	59.78; p < 0.001; 0.072; -0.002; 1.55e-06	65.30; p < 0.001; 0.111; -0.003; 3.09e-06
MSR	2018	-7.42; p = 1.000; -0.012; -0.002; 1.83e-06	6.71; p < 0.001; 0.008; -0.003; 2.80e-06
	2019	72.58; p < 0.001; 0.096; -0.002; 1.83e-06	51.77; p < 0.001; 0.084; -0.003; 2.80e-06
RDVI	2018	18.58; p < 0.001; 0.029; -0.003; 2.90e-06	-10.78; p = 1; -0.017; -0.002; 1.97e-06
	2019	22.89; p < 0.001; 0.036; -0.003; 2.90e-06	67.45; p < 0.001; 0.093; -0.002; 1.97e-06
IPVI	2018	26.07; p < 0.001; 0.044; -0.003; 3.27e-06	-27.36; p = 1; -0.040; -0.002; 1.89e-06
	2019	24.33; p < 0.001; 0.041; -0.003; 3.28e-06	65.42; p < 0.001; 0.088; -0.002; 1.89e-06
SAVI	2018	-7.73; p = 1.000; -0.014; -0.003; 1.93e-06	-11.70; p = 1; -0.018; -0.002; 1.77e-06
	2019	-10.66; p = 1.000; -0.018; -0.003; 1.93e-06	62.43; p < 0.001; 0.081; -0.002; 1.77e-06

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025)

4.9.6 Sensor orbital área A3

Os resultados do sensor orbital (Tabela 20) para a área A3 seguiram a mesma lógica dos dados coletados mais do proximal. A única diferença foi que os valores foram um pouco menores, algo totalmente esperado, já que a 'lente' do satélite é mais ampla e menos detalhada.

Em 2018, por exemplo, índices como MSR e RDVI mostraram uma conexão espacial positiva (I = 0,04; p < 0,001), embora em 2019 essa força tenha diminuído

levemente e perdido um pouco da significância em alguns pontos. Essa pequena diferença acontece porque a visão do satélite suaviza as microvariações de vigor que o sensor proximal consegue detectar em detalhes, como apontado por Zhang *et al.* (2021). Mesmo assim, a A3 continuou apresentando padrões espaciais consistentes e importantes, o que é ótimo, pois mostra que as nossas zonas de manejo são coerentes o suficiente para basear decisões no campo.

Tabela 20 – Estatística de Moran I Intragrupos obtida pelo Sensor Orbital na Área de Estudo A3

Índice	Ano	Agrupamentos	
		1	2
		(z; p; I; Exp.; Var.)	
NDVI	2018	16.72; p < 0.001; 0.0078; -0.0018; 3.33e-07	11.34; p < 0.001; 0.038; -0.0038; 1.37e-05
	2019	-8.86; p = 1.000; -0.0069; -0.0018; 3.33e-07	-0.45; p = 0.672; -0.0055; -0.0038; 1.35e-05
RVI	2018	19.37; p < 0.001; 0.0085; -0.0019; 2.93e-07	18.25; p < 0.001; 0.056; -0.0034; 1.04e-05
	2019	-8.13; p = 1.000; -0.0064; -0.0019; 2.94e-07	1.07; p = 0.143; 0.00003; -0.0034; 1.04e-05
MSR	2018	13.69; p < 0.001; 0.042; -0.0036; 1.11e-05	20.52; p < 0.001; 0.0094; -0.0019; 3.03e-07
	2019	0.80; p = 0.213; -0.0009; -0.0036; 1.10e-05	-11.55; p = 1.000; -0.0083; -0.0019; 3.04e-07
RDVI	2018	20.15; p < 0.001; 0.014; -0.0014; 6.24e-07	0.29; p = 0.386; -0.0071; -0.0089; 4.18e-05
	2019	30.98; p < 0.001; 0.023; -0.0014; 6.24e-07	18.11; p < 0.001; 0.108; -0.0089; 4.20e-05
IPVI	2018	11.34; p < 0.001; 0.038; -0.0038; 1.37e-05	16.72; p < 0.001; 0.0078; -0.0018; 3.33e-07
	2019	-0.45; p = 0.672; -0.0055; -0.0038; 1.35e-05	-8.86; p = 1.000; -0.0069; -0.0018; 3.33e-07
SAVI	2018	10.64; p < 0.001; 0.031; -0.0036; 1.09e-05	19.07; p < 0.001; 0.011; -0.0019; 4.26e-07
	2019	-1.30; p = 0.903; -0.0079; -0.0036; 1.08e-05	-2.14; p = 0.984; -0.0033; -0.0019; 4.27e-07

Legenda: (z = desvio padrão; p = significância; I = estatística de Moran I; Exp. = expectativa; Var. = variância).

Fonte: Dados da pesquisa (2025)

A avaliação dos resultados obtidos dos sensores proximais e orbitais nas áreas A1, A2 e A3 permitiu uma análise detalhada da eficácia das imagens orbitais de alta

resolução na criação de zonas de manejo em vinhedos envolvidos na viticultura de inverno. As análises estatísticas e espaciais realizadas, incluindo estatísticas descritivas, agrupamento de médias k , curvas de silhueta e cotovelo, boxplots interanuais e análise de autocorrelação espacial por meio do índice de Moran, contribuíram para uma interpretação coerente da dinâmica do vigor vegetativo.

Os sensores proximais mostraram sensibilidade elevada na identificação de microvariações no vigor da planta, conforme evidenciado pelos coeficientes de variação notavelmente baixos registrados (variando de 0,19% a 5,47%) e pelo distinto delineamento das zonas intraparcelsares. Índices como RVI e RDVI foram particularmente notáveis por sua captura precisa da variabilidade da biomassa e do dossel, além de exibirem valores de Moran I mais pronunciados, confirmando assim uma dependência espacial bem definida. Esses atributos ressaltam a adequação dos sensores proximais para diagnósticos mais detalhados, particularmente em regiões caracterizadas por variabilidade fina ou estratégias de manejo distintas.

Por outro lado, as imagens orbitais exibiram maior estabilidade macroespacial, conforme indicado por maiores amplitudes (com um CV atingindo até 7,99%) e pela diminuição da saturação observada nos índices normalizados, particularmente NDVI, IPVI e SAVI. Nas regiões A1 e A3, a consolidação de dois grupos foi observada de forma consistente em todos os índices orbitais, revelando padrões abrangentes de vigor claramente definidos. A região A2 apresentou maior heterogeneidade no sensoriamento orbital; no entanto, apesar de uma maior fragmentação dos grupos, a significância estatística de Moran I ainda consegue identificar algumas dependências espaciais adequadas para validar as zonas delineadas.

A comparação das duas plataformas indica que os sensores proximal e orbital não estão em competição, mas se complementam. A abordagem proximal oferece detalhes finos e capacidades de diagnóstico aprimoradas para variações sutis, enquanto o método orbital fornece uma perspectiva macroespacial, estabilidade temporal e saturação reduzida, ou seja, atributos essenciais para reconhecer padrões mais amplos e conduzir comparações agrícolas interanuais. Dentro dessa estrutura, os resultados afirmam que o sensor orbital funcionou de forma eficaz, cumprindo o objetivo do estudo, particularmente à luz de sua coerência ano a ano, capacidade de estabelecer grupos consistentes e sensibilidade às variações macroespaciais em vigor.

Entre os índices orbitais avaliados, NDVI, IPVI e SAVI foram destaque notáveis, exibindo maior estabilidade temporal, saturação reduzida e melhor alinhamento com os agrupamentos estabelecidos, especialmente em regiões com contrastes de vigor maiores. Destes, o NDVI demonstrou ser o índice mais apropriado para aplicações práticas em viticultura de precisão, devido à sua robustez estatística, estabilidade anual e ampla aplicação na literatura. O IPVI serve como uma alternativa eficiente em áreas significativamente influenciadas pelo solo, enquanto o SAVI provou ser particularmente adequado em contextos com presença substancial de solo exposto.

Os achados corroboram que as imagens de satélite de alta definição são recursos úteis e eficientes para a demarcação de áreas de manejo na viticultura de inverno, especialmente quando combinadas com técnicas de sensoriamento proximal. Seu uso aprimora a análise em diferentes escalas do vigor das plantas, possibilitando um planejamento mais preciso das ações agrônômicas, a adequação de práticas como irrigação e adubação, além de permitir a identificação de zonas críticas durante o ciclo de produção.

Para dar continuidade às investigações, é recomendado ampliar a avaliação para várias fases fenológicas, utilizando modelagens espaciais sofisticadas, como geoestatística multivariada e algoritmos de aprendizado automatizado. Além disso, é aconselhável integrar séries temporais de imagens de satélites ao longo de vários anos e correlacioná-las diretamente com dados sobre a produtividade e a qualidade das uvas, a fim de reforçar a relação entre variabilidade espectral e resposta agrônômica. A adição de sensores orbitais de alta resolução ou de informações coletadas por drones pode enriquecer a análise, aumentando a aptidão para identificar padrões sutis relacionados ao vigor das plantas.

5 CONCLUSÕES

Os seis índices de vegetação avaliados (NDVI, RVI, MSR, RDVI, IPVI e SAVI), obtidos por sensoriamento proximal e orbital nos ciclos produtivos de 2018 e 2019, demonstraram potencial para a delimitação de zonas de manejo nos vinhedos estudados. A aplicação de técnicas de agrupamento, análises estatísticas e avaliação da dependência espacial permitiu validar a coerência interna das zonas geradas para cada sensor.

Na comparação entre sensores, observou-se que o sensoriamento proximal apresentou maior sensibilidade na detecção de variações pontuais no vigor espectral das plantas, resultando em zonas com maior detalhamento espacial. Por outro lado, o sensoriamento orbital apresentou padrões mais contínuos e estáveis entre os ciclos produtivos, favorecendo a delimitação de zonas com maior uniformidade espacial.

A comparação foi realizada de forma qualitativa, considerando as diferenças de escala, resolução espacial e natureza dos dados obtidos por cada sensor. Assim, as zonas de manejo foram definidas separadamente para os dados proximais e orbitais, não sendo estabelecida correlação quantitativa direta entre os sensores.

Do ponto de vista prático, para a definição técnica de zonas de manejo para as áreas de estudo, recomenda-se considerar de forma integrada os dados provenientes do sensoriamento proximal e orbital. Observou-se que ambos os sensores apresentaram maior estabilidade quando estruturados em dois grupos (duas zonas de manejo), configuração que demonstrou melhor coerência estatística e espacial nos dois ciclos produtivos avaliados. Assim, a utilização combinada das duas abordagens pode proporcionar maior robustez na delimitação das zonas, associando detalhamento espacial e consistência temporal.

Dessa forma, conclui-se que ambos os sistemas de sensoriamento são complementares na viticultura de precisão, podendo ser utilizados de acordo com a escala de análise desejada, onde o sensor proximal é utilizado para maior refinamento para variabilidade espacial e o sensor orbital para analisar a estabilidade dessa variabilidade da área ao longo do tempo.

Para estudos futuros, recomenda-se incorporar variáveis produtivas às zonas delimitadas e aplicar abordagens complementares, como modelagem geoestatística e análise espacial multivariada, visando fortalecer a integração entre dados espectrais e desempenho agrônomo avaliando o vigor em esferas mais completas.

REFERÊNCIAS

- ANASTASIOU, E.; BALAFOUTIS, A.; DARRA, N.; PSIROUKIS, V.; BINIARI, A.; XANTHOPOULOS, G.; FOUNTAS, S. Satellite and proximal sensing to estimate the yield and quality of table grapes. **Agriculture**, v. 8, n. 7, p. 94, 2018. DOI: 10.3390/agriculture8070094.
- ANSELIN, L. Local indicators of spatial association - LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.
- BASSOI, L. H.; *et al.* Agricultura de precisão em fruticultura. In: BERNARDI, A. C. C.; *et al.* (org.). Agricultura de precisão: resultados de um novo olhar. São Carlos: **Embrapa Instrumentação**, 2014. p. 350-360.
- BÉGUÉ, A.; *et al.* Remote sensing and cropping practices: a review. **Agronomy for Sustainable Development**, v. 38, n. 3, p. 1–25, 2018.
- BRAGA, R. Viticultura de precisão. Lisboa: **Associação dos Jovens Agricultores de Portugal**, 2009. (Manual).
- BRAMLEY, R. G. V.; HAMILTON, R. P. Understanding variability in winegrape production systems — 1. Within vineyard variation in yield over several vintages. **Australian Journal of Grape and Wine Research**, v. 10, n. 1, p. 32–45, 2004.
- CALDERÓN, R.; NAVAS-CORTÉS, J. A.; LUCENA, C.; ZARCO-TEJADA, P. J. High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature, and narrow-band spectral indices. **Remote Sensing of Environment**, v. 139, p. 231–245, 2013.
- CAMARGO, U. A.; TONIETTO, J.; HOFFMANN, A. Progressos na viticultura brasileira. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 33, p. 144-149, out. 2011.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, v. 58, n. 5, p. 1501-1511, 1994.
- CAMPOS, T. L.; ALMEIDA, R. S. Variações de índices de vegetação em ambientes heterogêneos: implicações para zonas de manejo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 22, n. 4, p. 250–258, 2018.
- CARUSO, G.; *et al.* Estimating biophysical and geometrical parameters of grapevine canopies (“Sangiovese”) by an unmanned aerial vehicle (UAV) and VIS-NIR cameras. **Vitis**, v. 56, p. 63–70, 2017.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.
- CONOVER, W. J. Practical nonparametric statistics. 3. ed. New York: Wiley, 1999.

COSTA, B. R. S. Zonas de vigor vegetativo para colheita seletiva em viticultura irrigada com base em sensoriamento proximal. 2021. 220 f. Tese (Doutorado em Agronomia) - **Faculdade de Ciências Agrônomicas**, Universidade Estadual Paulista (UNESP), Botucatu, 2021.

CRESSIE, N. A. C. Statistics for spatial data. **Revised ed.** New York: Wiley, 1993.

DUCHÊNE, E.; SCHNEIDER, C. Grapevine and climatic changes: a glance at the situation in Alsace. *Agronomy for Sustainable Development*, v. 25, p. 93–99, 2005.

ENGESAT. Imagens de satélite PlanetScope. 2019. Disponível em: <http://www.engesat.com.br/imagem-de-satelite/planetscope/>. Acesso em: jan. 2024.

FARINASSI, L. G.; OLDONI, H.; BASSOI, L. H.; COSTA, B. R. S. Diferentes métodos de sensoriamento proximal do dossel de videiras promovem divergências no mapeamento de índices de vegetação. In: **Congresso Brasileiro de Agricultura de Precisão**, 2022, Campinas. Anais... Campinas: ConBAP, 2022.

FILHO, J. M. A era dos pequenos, micros e nanosatélites. Artigo - AEB - **Agência Espacial Brasileira**, 2013. Disponível em: <http://portal-antigo.aeb.gov.br/a-era-dos-pequenos-micros-e-nano-satelites-1/>. Acesso em: jan. 2024.

FLORENZANO, T. G. Iniciação em sensoriamento remoto. 3. ed. São Paulo: **Oficina de Textos**, 2007.

FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. São Paulo: **Oficina de Textos**, 2017.

FRANCISCO, W. de C. e. Revolução Verde. **Brasil Escola**, 2013. Disponível em: <https://brasilecola.uol.com.br/geografia/revolucao-verde.htm>. Acesso em: 25 jan. 2024.

FROST, J. ANOVA: When to use Welch's test, how to interpret the results. 2019. Disponível em: <https://statisticsbyjim.com/anova/welchs-anova/>. Acesso em: 6 ago. 2025.

GAVIOLI, A.; DE SOUZA, E. G.; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components of soil properties. **Computers & Electronics in Agriculture**, v. 127, p. (verificar número de páginas), 2016. DOI: 10.1016/j.compag.2016.06.029.

GIOVOS, R.; *et al.* Remote sensing vegetation indices in viticulture: a critical review. **Agriculture**, v. 11, n. 5, p. 457, 2021.

GRANSHAW, S. I. Photogrammetric terminology: third edition. **The Photogrammetric Record**, v. 31, n. 154, p. 210–252, jun. 2016.

HAWKINS, D. M. Identification of Outliers. London: Chapman and Hall, 1980.

HEIDT, H. *et al.* CubeSat: A new generation of picosatellite for education and industry low-cost space experimentation. In: Proceedings of the 14th Annual AIAA/USU Conference on Small Satellites. Logan: **Utah State University**, 2000.

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

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

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

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

JENSEN, J. R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. São José dos Campos: **Parêntese**, 2011.

JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663–666, 1969.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. 6. ed. **Hoboken**: John Wiley & Sons, 2008.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., 1967, Berkeley. Proceedings... Berkeley: **University of California Press**, 1967. p. 281–297.

MARTINS, R. C. Definição de zonas de manejo por índices de vegetação obtidos por sensoriamento remoto e mapas de produtividade. 2017. 149 f. **Dissertação (Mestrado em Agricultura de Precisão)** - Universidade Federal de Santa Maria, Santa Maria, 2017.

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENESIO, L.; VACCARI, F. P.; PRIMICERIO, J.; BELLI, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971–2990, 2015. DOI: 10.3390/rs70302971.

MATESE, A.; PANCHER, M.; PALO, M.; COLOMBO, R. Accurate in-field estimation of grapevine condition by integrating proximal and remote sensing. **Remote Sensing**, Basel, v. 11, n. 17, p. 2009, 2019.

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENNARI, G. P.; GIOLI, B. Methods to compare the spatial variability of UAV-based spectral and geometric information with ground autocorrelated data: a case for precision viticulture. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, p. 101–112, 2019.

MOLIN, J. P.; *et al.* Precision agriculture research in Brazil: evolution, current status, and future perspectives. **Computers and Electronics in Agriculture**, v. 170, p. 105247, 2020.

MOLIN, J. P.; QUEIROZ, D. M. Agricultura de precisão. 2. ed. São Paulo: Oficina de Textos, 2017.

MONTGOMERY, D. C. Design and analysis of experiments. 10. ed. New York: Wiley, 2019.

MONTGOMERY, D. C.; RUNGER, G. C. Estatística aplicada e probabilidade para engenheiros. 5. ed. Rio de Janeiro: LTC, 2011.

MORAN, P. A. P. Notes on continuous stochastic phenomena. **Biometrika**, v. 37, n. 1–2, p. 17–23, 1950.

PADILHA, J. G.; GEBLER, L.; MARTINS, J. A. Aplicação de índices espectrais de vegetação obtidos por sensores orbitais na identificação de áreas com diferentes teores de carbono orgânico no solo. **Embrapa Solos: Boletim de Pesquisa e Desenvolvimento**, n. 120, p. 1–38, 2018.

PEREIRA, L. D. S.; SILVA, D. O.; PAMBOUKIAN, S. V. D. Sensoriamento remoto aplicado à agricultura de precisão no cultivo de bambu. **Mackenzie de Engenharia e Computação**, v. 16, n. 1, 2016.

REGINA, M. de A.; *et al.* Implantação e manejo do vinhedo para produção de vinhos de qualidade. **Informe Agropecuário**, Belo Horizonte, v. 27, n. 234, p. 16–31, 2006.

RIBATSKI, E. O.; SANTOS, F. S.; NOGARA NETO, F. Revisão sobre utilizações de RPAs no cenário agrícola. **Brazilian Journal of Technology**, v. 1, n. 2, p. 313–333, 2018.

RODRIGUES, R. O que é vinicultura e viticultura? [online]. 2022. Disponível em: <https://www.cpt.com.br/cursos-treinamentoprofissional/artigos/o-que-e-vinicultura-eviticultura>. Acesso em: 26 jan. 2024.

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

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: **Earth Resources Technology Satellite-1 Symposium**, 3., 1973, Washington. Proceedings. Washington: NASA, 1974. v. 1, p. 309–317.

SAKAMOTO, T.; GITELSON, A. A.; NGUY-MINH, Y.; ITAGAKI, K. A method for estimating chlorophyll content using non-constant parameter transformed vegetation index (MSR). **Remote Sensing**, v. 6, n. 12, p. 12036–12060, 2014.

SILVA, J. C.; OLIVEIRA, P. M. Estrutura de dossel e saturação de índices de vegetação: comparativo proximal e orbital. **Ciência Rural**, Santa Maria, v. 49, n. 12, p. 1–8, 2019.

SILVA, J. R. da; *et al.* Metodologia para a implantação da viticultura de precisão na região de Santa Maria: fase de prospecção de campo. 2023. [s.l.]: [s.n.], 2023.

STATISTICS BY JIM. Games-Howell post hoc test: when and how to use it. 2020. Disponível em: <https://statisticsbyjim.com/hypothesis-testing/games-howell-test/>. Acesso em: 6 ago. 2025.

STATISTICS BY JIM. Welch's ANOVA compared to the classic one-way ANOVA. Disponível em: <https://statisticsbyjim.com/anova/welchs-anova-compared-to-classic-one-way-anova/>. Acesso em: abr. 2025.

TAGARAKIS, A. C.; GARCÍA-MORENO, R.; ROSSELL, J. R.; VELLIDIS, G. Site-specific management in vineyards using proximal sensors: variability of soil and canopy properties. **Precision Agriculture**, v. 19, p. 1031–1051, 2018.

TARDAGUILA, J.; *et al.* Mapping within-vineyard variability of soil and plant parameters to define management zones. **Australian Journal of Grape and Wine Research**, v. 23, p. 214–223, 2017.

TAYLOR, J. Geographic information systems – a step into the information age. **The Australian Grapegrower and Winemaker**, v. 435, p. 19–21, 2000.

THENKABAIL, P. S.; SMITH, B. B.; PAUW, E. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. **Remote Sensing of Environment**, v. 71, p. 158–182, 2000. DOI: 10.1016/S0034-4257(99)00067-X.

TRINDADE, L. C.; *et al.* Sensoriamento remoto aplicado à identificação de mudanças sazonais em áreas agrícolas: uma abordagem com NDVI. **Revista Brasileira de Agricultura de Precisão**, v. 12, n. 1, p. 45–57, 2021.

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

URRETAVIZCAYA, P.; MIALET, J.; *et al.* Real-time sensor-based irrigation management. **Precision Agriculture**, Dordrecht, v. 17, n. 4, p. 745–757, 2016.

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

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

YAMAMOTO, J. K.; LANDIM, P. M. B. Conceitos básicos. In: YAMAMOTO, J. K.; LANDIM, P. M. B. (org.). *Geoestatística, conceitos e aplicações*. São Paulo: Oficina de Textos, 2013. cap. 1, p. 19–32.

YANG, H.; LEE, Y.; JEON, S. Y.; LEE, D. Multi-rotor drone tutorial: 29 systems, mechanics, control, and state estimation. **Intelligent Service Robotics**, v. 10, n. 2, p. 79–93, abr. 2017. DOI: 10.1007/s11370-017-0224-y.

ZAR, J. H. Biostatistical analysis. 5. ed. **Upper Saddle River**: Pearson, 2010.

ZARCO-TEJADA, P. J.; DÍAZ-VARELA, R. A.; ANGLIDERI, V.; LOUDJANI, P. High-resolution satellite vs. UAV imagery for precision viticulture. **Remote Sensing of Environment**, v. 139, p. 213–232, 2013.

ZHANG, Y.; *et al.* Remote sensing-based analysis of spatial variation in vineyard canopy structure and vigor. **Remote Sensing of Environment**, v. 258, p. 112390, 2021.