

Universidade de São Paulo  
Escola Superior de Agricultura “Luiz de Queiroz”

**Avaliação de cultivos por meio de índices de vegetação obtidos por câmera  
multiespectral**

**Rubmara Ketzer Oliveira**

Tese apresentada para obtenção do título de Doutora em  
Ciências. Área de concentração: Engenharia de Sistemas  
Agrícolas

**Piracicaba  
2024**

Rubmara Ketzer Oliveira  
Engenheira Agrônoma

**Avaliação de cultivos por meio de índices de vegetação obtidos por câmera  
multiespectral**

versão revisada de acordo com a Resolução CoPGr 6018 de 2011

Orientador:  
Prof. Dr. **MARCOS VINÍCIUS FOLEGATTI**

Tese apresentada para obtenção do título de Doutora em  
Ciências. Área de concentração: Engenharia de Sistemas  
Agrícolas

Piracicaba  
2024

**Dados Internacionais de Catalogação na Publicação**  
**DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP**

Oliveira, Rubmara Ketzer

Avaliação de cultivos por meio de índices de vegetação obtidos por câmara multiespectral / Rubmara Ketzer Oliveira. - - versão revisada de acordo com a Resolução CoPGr 6018 de 2011. - - Piracicaba, 2024.

131 p.

Tese (Doutorado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Agricultura de precisão 2. Sensor multiespectral 3. Drones 4. Monitoramento agrícola 5. Sensoriamento remoto I. Título

## AGRADECIMENTOS

Muito obrigada a cada um que contribuiu para a realização deste trabalho e de toda minha vivência na ESALQ. Em especial, minha mãe Inês, minha querida Tia Ia, minha vó Neusa e minha Dinda Neca, pilares de tudo o que me tornei até hoje. Espero sempre ser motivo de orgulho pra vocês, assim como são pra mim! Obrigada por todo apoio SEMPRE!

Muitas pessoas contribuíram de uma forma essencial para que este Doutorado fosse finalizado, algumas já foram morar longe, outras ainda consigo ver por perto e outras que, mesmo à distância, sempre permaneceram me incentivando! Essa finalização de uma etapa tão difícil se dá pelo apoio de quem sempre me ajudou.

Trabalhar, estudar, fazer pesquisa, tudo ao mesmo tempo... é complicado. Mas fico muito feliz que deu certo! Termina esta etapa podendo afirmar com toda tranquilidade que fiz tudo e mais um pouco, vivi o que precisei e me qualifiquei o máximo que o tempo me permitiu.

Quero dedicar este resultado dos anos que vivi nesse doutorado a cada um que me ajudou. Foram dias de campo no sol e na chuva, foram experimentos destruídos e incansáveis horas montando equipamentos e aprendendo a pilotar drones e o processamento das imagens. Em todos os processos, sempre tive ajuda e a paciência de muitos!

Agradeço ao professor Folegatti pelo apoio, por ter estendido a mão para este doutorado e permitido que eu conseguisse partir para um plano B, C, D... a medida que as coisas iam acontecendo. Obrigada por ter me acolhido mesmo antes!

Ao professor Libardi, agradeço sua paciência, seu carinho e seu apoio sempre quando precisei! Deu uma aula prática de condutividade hidráulica INESQUECÍVEL para todos que assistiram. E eu nem consegui realizar as medidas! Muito obrigada por ter cuidado de mim esse tempo todo! Meu carinho pelo senhor é eterno.

À professora Rosebelly, que me ajudou a encontrar meu caminho, me ajudou a ver que eu realmente tinha algo pra oferecer e me ajudou a entender meu papel, deixo meu OBRIGADA. Já no finalzinho desse doutorado, fui me encontrar e me valorizar. Só tenho a te agradecer por todo teu apoio.

Aos meus cachorros, Alfredinho e Lupi, que sempre escolhiam a hora em que eu estava mais focada na escrita para latir pra qualquer sombra da rua, mas que sempre ficaram acordado me esperando desistir pelo sono. Amo vocês.

Neste agradecimento, deixo poucos nomes registados, pois não quero esquecer de ninguém, o agradecimento mais verdadeiro que posso dar é deixar esta tese como resultado de um trabalho coletivo.

Que venham os próximos passos!

## SUMÁRIO

RESUMO.....	6
ABSTRACT.....	7
1. APLICAÇÕES DO USO DE IMAGENS OBTIDAS COM VANT NOS ESTUDOS DE CARACTERÍSTICAS DA VEGETAÇÃO: UMA REVISÃO BIBLIOMÉTRICA.....	9
Resumo.....	9
Abstract.....	9
1.1. Introdução.....	9
1.2. Material e Métodos.....	12
1.3. Resultados e Discussão.....	15
1.4. Conclusões.....	24
Referências.....	25
2. AVALIAÇÃO POR MEIO DE ÍNDICES DE VEGETAÇÃO DA RESPOSTA PRODUTIVA DO ARROZ ( <i>Oryza sativa</i> L.) IRRIGADO COM DIFERENTES DOSES DE NaCl.....	31
Resumo.....	31
Abstract.....	31
2.1. Introdução.....	32
2.2. Material e Métodos.....	33
2.3. Resultados e Discussão.....	50
2.4. Conclusões.....	62
Referências.....	63
Anexos.....	66
3. MONITORAMENTO DAS CONDIÇÕES DO CULTIVO DE <i>Megathyrus maximus</i> (SYN. <i>Panicum maximum</i> JACQ.) CV. MOMBAÇA POR ÍNDICES MULTIESPECTRAIS.....	69
Resumo.....	69
Abstract.....	69
3.1. Introdução.....	70
3.2. Material e Métodos.....	73
3.3. Resultados e discussão.....	87
3.4. Conclusões.....	123
Referências.....	124

Anexo ..... 128

## RESUMO

### Avaliação de cultivos por meio de índices de vegetação obtidos por câmera multiespectral

Os três capítulos desta pesquisa abordam a aplicação de Veículos Aéreos Não Tripulados (VANTs) equipados com câmeras multiespectrais para avaliação de cultivos agrícolas, cada um focando em aspectos específicos. No primeiro capítulo, a pesquisa realiza uma análise bibliométrica de estudos relacionados à avaliação de cultivos por meio de índices de vegetação obtidos por imagens capturadas por VANTs. A análise bibliométrica oferece uma visão abrangente do panorama científico nessa área específica, contribuindo para a compreensão das tendências, lacunas e direções futuras de pesquisa. O segundo capítulo se concentra na avaliação da produção de arroz em condições de salinidade do solo. Utilizando VANT equipado com sensor multiespectral, o estudo destaca a eficácia dessa ferramenta para obter diferentes índices de vegetação que possibilitam a caracterização das plantas. A pesquisa investiga o cultivo de arroz em resposta a diferentes níveis de NaCl na água de irrigação, destacando a importância das bandas no espectro próximo ao infravermelho para uma detecção eficaz de características vegetais. O terceiro capítulo trata do monitoramento do cultivo de *Megathyrsus maximus* cv. Mombaça, utilizando índices multiespectrais obtidos por imagens de drones. O estudo destaca o comportamento dos índices de vegetação após o corte da vegetação, refletindo respostas fisiológicas e fenológicas das plantas. Destacam-se índices como GNDVI e NDRE como indicadores robustos, relacionados ao conteúdo de água no solo, e a influência da presença de biomassa remanescente e exposição do solo na variação dos índices. Os capítulos convergem na utilização de VANTs e índices multiespectrais para monitorar e avaliar cultivos agrícolas, evidenciando a relevância dessas tecnologias para a gestão eficiente e sustentável das práticas agrícolas, levando em consideração aspectos como resolução espacial, temporal e resposta fisiológica das plantas.

Palavras-chave: Agricultura de precisão, Sensor multiespectral, Drones, Monitoramento agrícola, Sensoriamento remoto

## ABSTRACT

### Crop assessment through vegetation indices obtained by multispectral camera

The three chapters of this research address the application of Unmanned Aerial Vehicles (UAVs) equipped with multispectral cameras for the assessment of agricultural crops, each focusing on specific aspects. In the first chapter, the research conducts a bibliometric analysis of studies related to crop assessment through vegetation indices obtained from images captured by UAVs. The bibliometric analysis provides a comprehensive view of the scientific landscape in this specific area, contributing to understanding trends, gaps, and future research directions. The second chapter focuses on the evaluation of rice production under soil salinity conditions. Utilizing a UAV equipped with a multispectral sensor, the study highlights the effectiveness of this tool in obtaining different vegetation indices that enable plant characterization. The research investigates rice cultivation in response to different levels of NaCl in irrigation water, emphasizing the importance of bands in the near-infrared spectrum for effective detection of vegetation features. The third chapter deals with the monitoring of *Megathyrsus maximus* cv. Mombaça cultivation using multispectral indices obtained from drone images. The study emphasizes the behavior of vegetation indices after vegetation cutting, reflecting physiological and phenological responses of the plants. Indices such as GNDVI and NDRE stand out as robust indicators related to soil water content, and the influence of residual biomass presence and soil exposure on index variation is highlighted. The chapters converge on the use of UAVs and multispectral indices to monitor and assess agricultural crops, highlighting the relevance of these technologies for efficient and sustainable management of agricultural practices, considering aspects such as spatial and temporal resolution, and physiological plant responses.

Keywords: Precision agriculture, Multispectral sensor, Drones, Agricultural monitoring, Remote sensing





# 1. APLICAÇÕES DO USO DE IMAGENS OBTIDAS COM VANT NOS ESTUDOS DE CARACTERÍSTICAS DA VEGETAÇÃO: UMA REVISÃO BIBLIOMÉTRICA

## Resumo

A utilização do Sistema de Informações Geográficas (SIG) como uma ferramenta de auxílio à gestão nas áreas agrícolas viabiliza os estudos com dados obtidos em maior resolução espacial, permitindo visualização e identificação de áreas críticas e potenciais. O uso de Veículos Aéreos Não tripulados (VANT, ou no inglês “UAV”), possibilitam a aquisição de imagens de alta precisão que permitem a estimativa de parâmetros de vegetação por meio de índices que auxiliam no monitoramento da saúde e cobertura vegetal. O objetivo deste trabalho é construir uma análise bibliométrica de estudos que englobam diferentes a avaliação de cultivos por índices de vegetação obtidos por imagens capturadas por VANT’s. Para análise bibliométrica, foi utilizado o software VosViewer® com intuito de demonstrar as principais conexões de publicações relacionada ao objetivo do trabalho. Foram analisados 393 artigos científicos quanto a autoria, países de publicação, número de publicações, citações e palavras-chave.

**Palavras-chave:** 1. Revisão Bibliométrica 2. Índices de Vegetação 3. Clusters 4. Drones.

## Abstract

### **Applications of unmanned aerial vehicle (UAV)-captured imagery in vegetation characteristics studies: a bibliometric review**

The utilization of Geographic Information Systems (GIS) as a management aid tool in agricultural areas enables studies with data obtained at higher spatial resolution, allowing for the visualization and identification of critical and potential areas. Unmanned Aerial Vehicles (UAVs), also known as Unmanned Aerial Systems (UAS) or drones, facilitate the acquisition of high-precision images, enabling the estimation of vegetation parameters through indices that assist in monitoring health and vegetative cover. The objective of this study is to construct a bibliometric analysis of research encompassing the evaluation of crops through vegetation indices obtained from images captured by UAVs. For bibliometric analysis, the VosViewer® software was employed to demonstrate the main connections among publications related to the study's objectives. A total of 393 scientific articles were analyzed for authorship, countries of publication, number of publications, citations, and keywords.

**Keywords:** 1. Bibliometric Review 2. Vegetation Indices 3. Clusters 4. Drones.

## 1.1. Introdução

O monitoramento de cultivos agrícolas com Veículos Aéreos Não tripulados (VANT) tem se tornado uma prática promissora e inovadora que visa aprimorar a eficiência e a produtividade

do setor agrícola. A utilização de drones equipados com sensores avançados oferece aos agricultores uma visão detalhada e em tempo real de suas plantações, permitindo o acompanhamento de parâmetros essenciais, como saúde das plantas, distribuição de nutrientes, detecção de pragas e doenças, e necessidades hídricas. Através da coleta de dados precisos e georreferenciados, os agricultores podem tomar decisões mais informadas, implementar práticas de manejo direcionadas e reduzir o uso excessivo de insumos, resultando em maior sustentabilidade e rentabilidade.

O monitoramento abrangente de cultivos agrícolas, essencial para controlar insetos, avaliar nutrientes, detectar doenças, gerenciar estresse hídrico e manter a saúde geral das plantas, tem evoluído com a incorporação de tecnologias avançadas. Tradicionalmente, as observações aéreas ou terrestres eram os métodos predominantes, porém, devido às limitações notáveis em termos de custo de operação e disponibilidade, novas abordagens têm ganhado destaque.

O monitoramento de cultivos agrícolas para controle de insetos, nutrientes, doenças, estresse hídrico e saúde geral das plantas é um aspecto importante das operações de agricultura de precisão. A utilização de imagens de satélite oferece uma perspectiva ampla e sistemática das áreas cultivadas, permitindo uma análise eficiente de extensas porções de terra. Simultaneamente, as medidas obtidas por sensores em campo proporcionam detalhes precisos sobre as condições específicas das plantações. Essa combinação de dados provenientes de diferentes fontes possibilita uma compreensão mais completa da dinâmica agrícola. Além disso, a introdução de Veículos Aéreos Não Tripulados (UAVs ou drones) elevou a eficácia do monitoramento. Os UAVs podem adquirir dados temporais e espaciais com resolução de centímetros, sobrevoando consistentemente com repetibilidade de rota e altitude. Isso viabiliza a cobertura contínua e sistemática dos campos agrícolas, enquanto a coleta de imagens por UAVs é gerenciável e menos suscetível à influência da cobertura de nuvens. A integração dessas tecnologias inovadoras, incluindo imagens de satélite, medidas com sensores em campo e o uso de UAVs, representa uma evolução significativa no monitoramento agrícola. Essa abordagem proporciona não apenas informações mais abrangentes e detalhadas para a tomada de decisões informadas, mas também acelera o processo de coleta de dados, aumentando a eficiência das operações agrícolas de precisão (Dutta & Goswami, 2020).

As áreas cultivadas com lavouras no mundo estão em torno dos 1,87 bilhão de hectares. Índia, Estados Unidos, China e Rússia totalizam 36% da área cultivada do Planeta. Em 2016, estima-se que o Brasil possuía uma área cultivada de mais de 60 milhões de hectares (de Miranda, 2018).

Visto a crescente necessidade, o conhecimento de como os ecossistemas respondem às pressões ambientais e decorrentes limitações é um elemento chave para a agricultura global. O sistema formado pelo conjunto do solo, da planta e da atmosfera atuando dinamicamente foi definido por Philip (1966) como “*The soil-plant-atmosphere continuum*”, ou o sistema solo-planta-

atmosfera (SPA). Este sistema é integrado, com diversos processos de fluxo que são interdependentes agindo em forma de cadeia.

O sensoriamento remoto (SR) é um conjunto de ferramentas que possibilitam o imageamento de uma área e obtenção de informações detalhadas das principais características espaciais e espectrais das mais diferentes áreas de estudo (Ben-Dor, 2002).

A utilização do Sistema de Informações Geográficas (SIG) como uma ferramenta de auxílio à gestão nas áreas agrícolas viabiliza os estudos com dados obtidos em maior resolução espacial, permitindo visualização e identificação de áreas críticas e potenciais. A obtenção de parâmetros importantes para o manejo dos agroecossistemas por meio de técnicas de sensoriamento remoto, permite identificar condições da superfície em alta resolução espacial. O uso de Veículos Aéreos Não tripulados (VANT), ou Sistemas Aéreos Não Tripulados possibilitam a aquisição de imagens de alta precisão que permitem a estimativa de parâmetros de vegetação (Ge et al., 2019).

O sensoriamento remoto associado ao uso de drones para aquisição de informações em alta resolução no meio agrícola é um elemento chave com crescente interesse econômico nos últimos anos para gerenciamento e aplicação de tecnologias no meio rural (Inoue, 2020).

Dentre as tecnologias ligadas ao sensoriamento remoto, o uso de VANT's acoplados com câmeras digitais de alta resolução na agricultura vem sendo um foco de pesquisas, com uma crescente intensa principalmente a partir de 2012, apresentando diferentes tópicos de estudo dentro das ciências agrárias e ambientais (Raparelli e Bajocco, 2019). Os drones são aeronaves pilotadas de forma remota, podendo ter diferentes denominações de acordo com o país, função ou área de utilização (Ahirwar et al., 2019). São comumente encontrados em trabalhos científicos os termos, em inglês, UAV (*Unmanned Aerial Vehicle*), UAS (*Unmanned Aerial Systems*) ou também RPAS (*Remotely Piloted Aircraft Systems*) (Granshaw, 2018; Restas, 2015).

O compartilhamento de informações por meio de estudos realizados nas diferentes partes do mundo é a forma de unir informações diversas sobre os ecossistemas terrestres e possibilita a criação de novos projetos, leis e ferramentas de gestão que busquem a conservação dos ecossistemas no mundo. A relação que existe entre a cooperação em pesquisas técnicas e científicas e diferentes variáveis próprias ao problema central desta, relacionada ao ambiente de estudo, pode ser analisada por meio do método bibliométrico de pesquisa (Subramanyam, 1983).

Tendo em vista a relevância dos estudos a respeito do monitoramento e avaliação das condições do solo e o uso de novas tecnologias como ferramentas essenciais de análises em escala espacial, o objetivo deste trabalho é construir uma análise bibliométrica de estudos que englobam a caracterização de cultivos por meio de imagens obtidas por VANT's.

## 1.2. Material e Métodos

### 1.2.1. Pesquisa e coleta de dados

Os dados deste trabalho foram pesquisados e coletados a partir das bases de dados da plataforma *Scopus*<sup>®</sup> ([www.scopus.com](http://www.scopus.com)) que abriga diversos índices de citações de periódicos do mundo todo. A plataforma é extensa, abrangente e multidisciplinar. As estratégias de pesquisa de dados a respeito do tema foram:

- ( TITLE-ABS-KEY ( *drone* ) OR TITLE-ABS-KEY ( *unmanned AND aerial AND vehicle* ) AND TITLE-ABS-KEY ( *vegetation AND indices* ) OR TITLE-ABS-KEY ( *plant AND indices* ) AND TITLE-ABS-KEY ( *agriculture* ) OR TITLE-ABS-KEY ( *agricultural AND applications* ) AND TITLE-ABS-KEY ( *crop AND analysis* ) ) AND ( LIMIT-TO ( DOCTYPE , "ar" ) ) AND ( LIMIT-TO ( PUBSTAGE , "final" ) ) AND ( LIMIT-TO ( SRCTYPE , "j" ) ) AND ( LIMIT-TO ( LANGUAGE , "English" ) )

Sendo:

1. (TITLE-ABS-KEY(drone) OR TITLE-ABS-KEY(uav))

Nesta parte, foram procurados artigos que continham a palavra "drone" OU a palavra "uav" (que é uma abreviação de "Unmanned Aerial Vehicle") no título ou no resumo.

2. AND TITLE-ABS-KEY(vegetation indices)

Em seguida, foram procurados artigos que tinham a expressão "vegetation indices" (índices de vegetação) no título ou no resumo. O "AND" indica que esta condição deve ser atendida juntamente com a pesquisa anterior.

3. OR TITLE-ABS-KEY(plant indices)

Aqui, foram artigos que continham a expressão "plant indices" (índices de plantas) no título ou no resumo. Novamente, o "OR" significa que procura-se encontrar artigos com qualquer uma das palavras-chave desta parte.

4. AND TITLE-ABS-KEY(agricultural)

Foram buscados artigos que continham a palavra "agricultural" no título ou no resumo. O "AND" indica que esta condição é adicional à pesquisa anterior.

5. AND ( LIMIT-TO ( PUBSTAGE , "final" ) )

Aqui, a consulta foi refinada para incluir apenas artigos que estão em estágio final de publicação, ou seja, aqueles que foram aceitos e estão prontos para publicação.

6. AND ( LIMIT-TO ( SRCTYPE , "j" ) )

Esta parte limita a busca para incluir apenas fontes de informação do tipo "j", que geralmente se refere a revistas acadêmicas.

7. AND ( LIMIT-TO ( LANGUAGE , "English" ) )

Essa cláusula restringe a pesquisa a artigos que estão escritos em inglês.

8. AND ( LIMIT-TO ( DOCTYPE , "ar" ) )

Por fim, a consulta é refinada para incluir apenas documentos do tipo "ar", que são artigos de periódicos.

Após a filtragem dos dados, foram obtidos 393 trabalhos na plataforma que se enquadram em todos os pré-requisitos. Para organização dos dados coletados foi utilizado o software Microsoft Excel® e para elaboração de produtos gráficos o software VOSviewer® (van Eck e Waltman, 2010).

O VOSviewer® é um software específico usado para visualização e análise de redes de coautoria científica e colaboração em pesquisa. O software trabalha com dados extraídos de bases bibliográficas. Em que é possível importar dados bibliográficos que incluem informações sobre autores, títulos de publicações, palavras-chave e afiliações. O software analisa a coocorrência de termos, autores ou afiliações em documentos científicos. Ele pode gerar uma matriz de coocorrência com base nas relações entre elementos, como termos ou autores. Uma vez que a matriz de coocorrência é gerada, o VOSviewer cria visualizações de rede para representar as relações entre os elementos. Por exemplo, os nós da rede podem representar autores ou termos, e as arestas entre eles indicam a coocorrência. O software é capaz de identificar grupos ou clusters de elementos que têm uma alta coocorrência entre si. Isso ajuda a identificar subáreas ou tópicos específicos dentro da rede.

A análise bibliométrica foi realizada para explorar padrões de estudos realizados a respeito do tema central do trabalho em relação aos parâmetros de quantidade de publicações ao longo dos anos, citações, países de publicação, frequência de palavras-chave e suas ligações com o tema central e autores.

A quantidade de publicações ao longo dos anos permite visualizar a evolução temporal das publicações sobre o tema central. Isso pode ajudar a identificar tendências, picos de interesse e flutuações na produção de conhecimento ao longo do tempo. Além disso, é útil para avaliar a relevância contínua do tema.

A quantidade de citações indica o impacto e a influência do trabalho na comunidade acadêmica. Um alto número de citações pode sugerir que o trabalho é considerado importante e

está sendo referenciado em outras pesquisas, contribuindo para o estabelecimento de uma base sólida para o tema em questão.

As métricas a respeito dos países de publicações ajudam a identificar a distribuição geográfica da pesquisa sobre o tema. Isso pode revelar se o interesse e o conhecimento sobre o assunto estão concentrados em determinadas regiões do mundo, fornecendo um panorama sobre a internacionalização do tema.

A análise da frequência de palavras-chave permite identificar as palavras-chave mais frequentes nos trabalhos relacionados ao tema central. Isso é valioso para entender os conceitos-chave associados ao tópico e pode ajudar na definição de áreas temáticas específicas que recebem mais atenção.

A avaliação das ligações com o tema central e autores permite examinar como as palavras-chave estão relacionadas ao tema central, proporcionando uma compreensão mais aprofundada das interconexões dentro do campo de estudo. Além disso, analisar os autores mais proeminentes fornece informações sobre as principais contribuições individuais e colaborações no campo.

A análise bibliométrica realizada com estes parâmetros, fornece uma visão abrangente e estruturada do panorama da pesquisa em um determinado tópico, auxiliando na identificação de lacunas no conhecimento, na compreensão da evolução temporal e na avaliação do impacto e influência das publicações.

### **1.2.2. Análise dos Resultados**

A partir da organização dos dados, estes foram inseridos em formato “csv” no software VOSviewer®, onde foi possível realizar as análises apresentadas na Tabela 1. Documentos com mais de 25 autores foram ignorados para análise. Para todas as pesquisas realizadas, foram gerados mapas de conexões (redes de ligação), de conexões por ano e de densidade (incidência).

**Tabela 1.** Dados limitantes utilizados para gerar mapas de conexões no software VOSviewer®.

Tipo de análise	Unidade de análise	Valor total	Limitantes	Nº de conexões restantes após limitantes
Coautoria	Autores	1745	Mínimo de 5 artigos por autor; Conexões entre os mesmos	35
Coautoria	Países	72	Mínimo de 4 artigos por país	30
Co-ocorrência	Todas palavras-chave por autor	1122	Mínimo de 6 ocorrências da palavra-chave Filtro de semelhança com o tema	40

Utilizando o software VOSviewer®, foram gerados mapas com base em uma matriz de coocorrência. O procedimento para a construção desses mapas envolve três etapas distintas. Na primeira fase, é calculada uma matriz de similaridade com base na matriz de coocorrência. Na segunda fase, a técnica de mapeamento é aplicada à matriz de similaridade para criar o mapa. Por fim, na terceira fase, o mapa é submetido a operações de tradução, rotação e reflexão.

A apresentação do panorama da estrutura intelectual e das tendências emergentes em um determinado campo de pesquisa demanda uma extensa coleta de dados bibliométricos. A abordagem metodológica adotada neste estudo emprega técnicas quantitativas, especificamente análise de dados bibliométricos.


Adicionalmente, foi conduzida uma análise descritiva dos principais dados relacionados às publicações examinadas no âmbito deste estudo.

### 1.3. Resultados e Discussão

A partir dos trabalhos selecionados, as métricas a respeito do ano de publicações são apresentadas na Figura 1. Entre os anos de 2009 e 2023 foram 393 publicações que se encaixam nos requisitos da pesquisa, com 57 trabalhos publicados em 2022 até o momento da pesquisa. No período anterior à 2013, foram publicados 2 trabalhos com a temática, no ano de 2009, tendo uma crescente de publicações a partir de 2014. O comportamento da curva de publicações mostra uma crescente de publicações ao longo dos anos, com crescimento mais acentuado a partir do ano de 2018. O crescimento no número de publicações a respeito do uso de drones para monitoramento de características de cultivos, acompanha o trabalho publicado por Raparelli & Bajocco (2019), que mostra uma crescente discussão a respeito do uso de drones nas pesquisas




científicas nas mais diversas áreas, possibilitando a compreensão do acompanhamento deste comportamento pelos estudos da ciência do solo.



**Figura 1.** Avaliação do número de trabalhos publicados ao longo dos anos.

Na Figura 2, são apresentadas as redes de conexões entre os autores com maior número de publicações. Entre os 34 autores selecionados, são ao todo 247 publicações e 8367 citações. Os 06 *clusters* formados (Figura 2), apresentam as conexões entre os autores e suas publicações. Os autores com maior número de publicações são “Feng H.”, com 13 publicações, “Yang G.”, “Zhang j.” e “Liu Y.” com 12 documentos publicados cada um.

Dentre os autores com maior número de citações, estão “Zhu Y.” com 690 citações em trabalhos e presente em 10 trabalhos do total analisado. O autor “Feng h.”, com 529 citações dentre os trabalhos listados, possui 13 trabalhos da lista total.



**Figura 2.** Rede de conexão entre os autores com maior número de trabalhos publicados a respeito da pesquisa bibliométrica.

Na Figura 3, são apresentadas as conexões formadas entre os países de publicação e são apresentados 6 *clusters* de conexões. A maior conexão formada entre as publicações dos países foi da China com os Estados Unidos, demonstrando grande colaboração entre os autores em publicações. A China possui o maior número de publicações na área estudada dentro da Plataforma Scopus® em relação ao tema do estudo, com um total de 236 trabalhos com 2858 citações. O país com maior número de citações é a Espanha, representando 14,7% do total e possuindo 6,5% de trabalhos publicados em relação ao total. Na Figura 4, são apresentados os 30 países com maiores números de publicações e seus respectivos totais de citações.

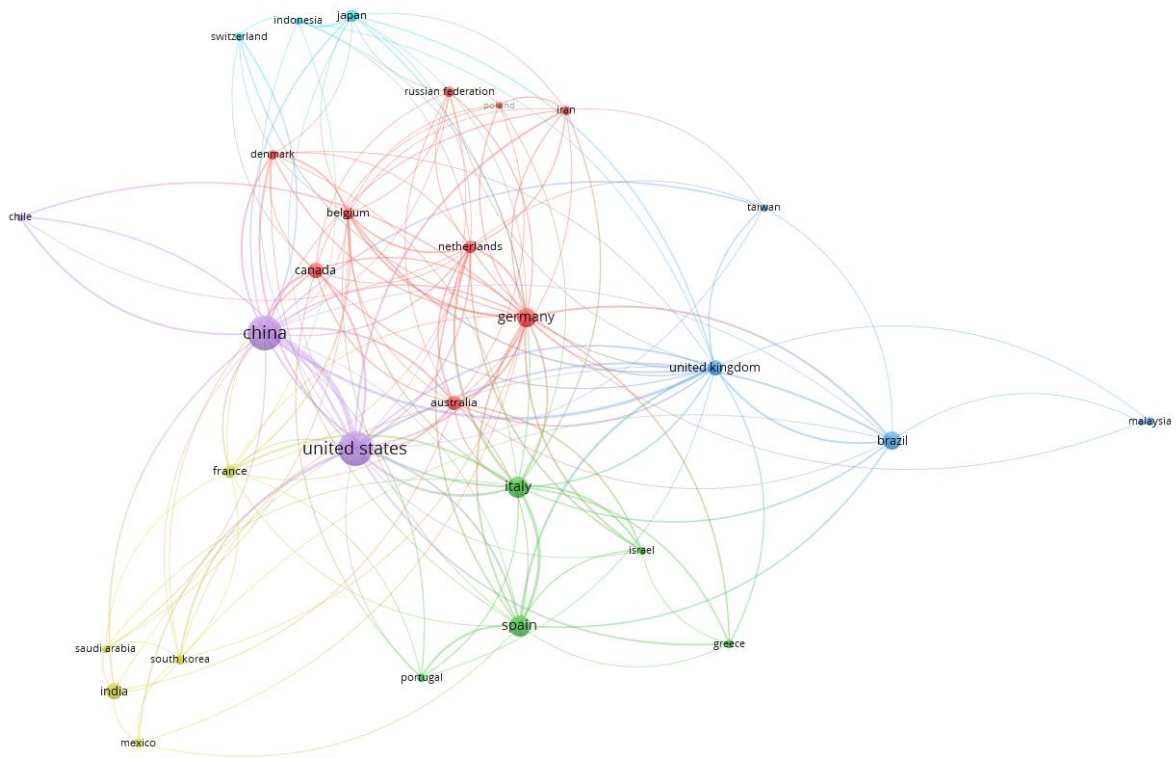


Figura 3. Rede de conexões de publicações por países.

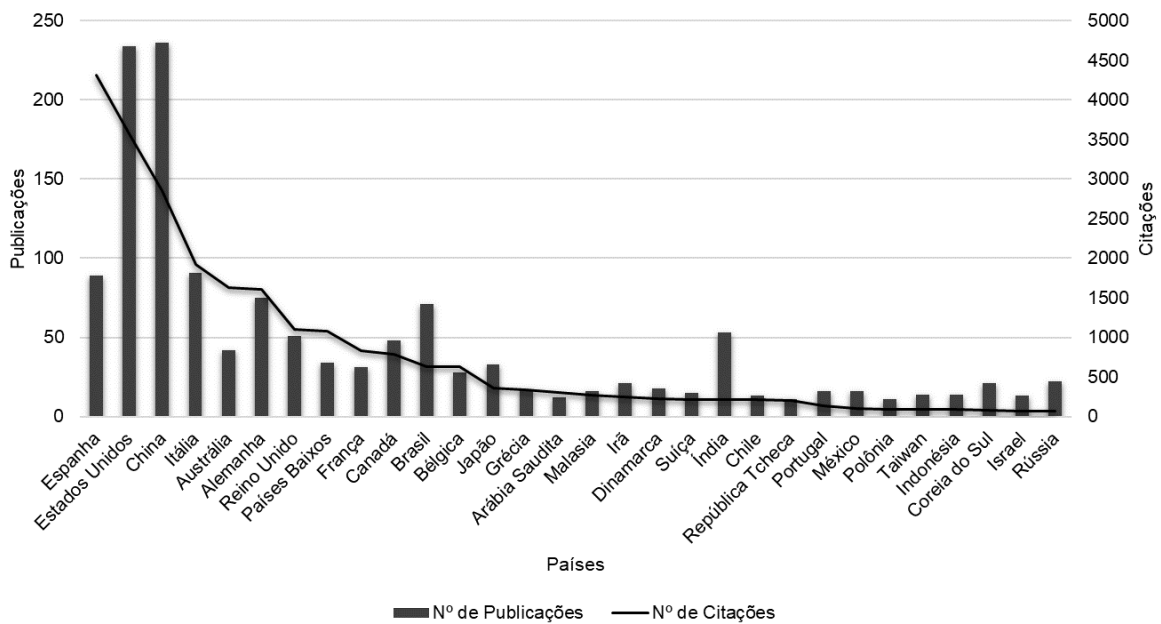
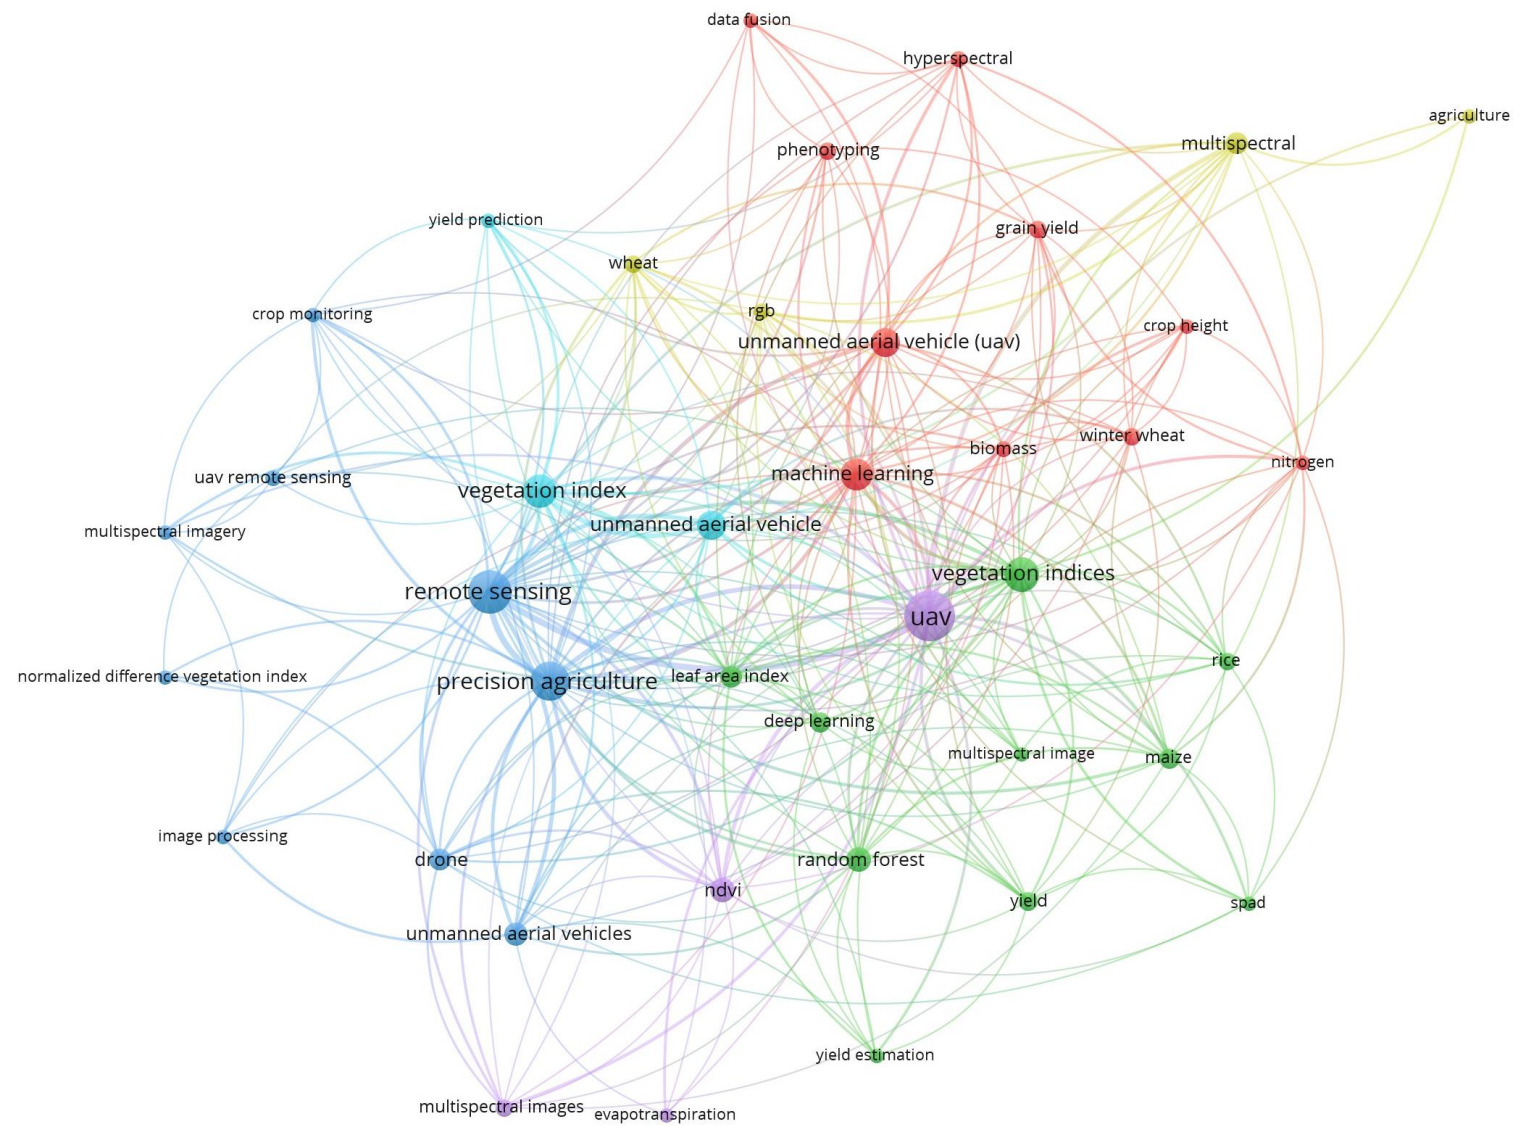


Figura 4. Dados referentes aos países de publicações e totais em relação ao número de trabalhos publicados e respectivos totais de citações.

Considerando as palavras-chave dos autores presentes nos estudos encontrados, foram selecionadas um total de 40 palavras com maior número de ocorrência que estão relacionadas com o tema central do trabalho. As conexões são apresentadas na Figura 5 e formam 6 clusters

representando os diferentes temas ligados ao termo central. A palavra-chave com maior número de ocorrências e conexões é “uav”, sigla para “unmanned aerial vehicle” com 88 ocorrências. Na Tabela 2, são apresentadas as palavras-chave com respectivo número de ocorrências encontradas. Dentre as métricas obtidas, os termos relacionados às palavras-chave englobam pesquisas com uso de drones para estimativa de índices de vegetação com auxílio de “machine learning”.



**Figura 5.** Rede de conexões de publicações por palavras-chave dos autores.

**Tabela 2.** Palavras-chave no título e resumo, relacionadas aos termos de pesquisa do trabalho.

<b>Palavras-chave</b>	<b>Ocorrências</b>
uav	88
remote sensing	64
precision agriculture	53
vegetation indices	40
vegetation index	36
machine learning	32
unmanned aerial vehicle	28
unmanned aerial vehicle (uav)	27
random forest	20
ndvi	19
unmanned aerial vehicles	18
drone	15
multispectral	15
leaf area index	14
deep learning	12
maize	12
yield	11
rice	10
wheat	10
winter wheat	10
grain yield	9
multispectral images	9
phenotyping	9
biomass	8
hyperspectral	8
rgb	8
uav remote sensing	8
multispectral imagery	7
nitrogen	7
yield prediction	7
agriculture	6
crop height	6
crop monitoring	6
data fusion	6
evapotranspiration	6
image processing	6
multispectral image	6
normalized difference vegetation index	6
yield estimation	6

De acordo com os trabalhos analisados, as 21 publicações com maior número de citações estão apresentadas na Tabela 3 com suas principais informações. O trabalho mais citado foi o de Berni et al. (2009a), que aborda o monitoramento da vegetação utilizando imagens obtidas por VANT, da revista “IEEE Transactions on geoscience and Remote Sensing”, sendo o estudo realizado na Espanha.

**Tabela 3.** Artigos publicados com maior número de citações na plataforma Scopus® de acordo com o tema do trabalho.

Trabalho	Ano	Citações
Berni et al., 2009b.	2009	998
Zhou et al., 2017	2017	369
Berni et al., 2009a.	2009	300
Sishodia et al., 2020	2020	241
Yue et al., 2017.	2017	238
Maimaitijiang et al., 2017.	2017	206
Li et al., 2016.	2016	203
Rasmussen et al., 2016.	2016	185
Yang et al., 2019.	2019	183
Santesteban et al., 2017.	2017	176
Li et al., 2020.	2020	166
Su et al., 2018.	2018	144
Jannoura et al., 2015.	2015	121
Maresma et al., 2016.	2016	116
Liu et al., 2018.	2018	112
Zha et al., 2020.	2020	111
Wan, et al., 2020.	2020	107
Ahmed et al., 2017.	2017	105
Feng et al., 2020.	2020	104
Jay et al., 2019.	2019	103
Maimaitijiang et al., 2020.	2020	101

A partir de uma filtragem de trabalhos por países, especificamente o Brasil, foram encontrados 22 trabalhos dentre a lista obtida na plataforma Scopus®. Os trabalhos publicados por autores brasileiros e realizados no Brasil, assim como suas principais informações estão na Tabela 3. Os trabalhos são mais recentes, mostrando uma maior atuação dos autores brasileiros no tema nos últimos anos. O trabalho com maior número de citações de acordo com a plataforma é o trabalho de Ramos et al. (2020), com 94 citações registradas pela plataforma e publicado na revista “Computers and Electronics in Agriculture”.

**Tabela 4.** Artigos brasileiros publicados presentes na plataforma Scopus® que abordam o tema central do trabalho.

Trabalho	Ano	Citações	Referência
Design of Vegetation Index for Identifying the Mosaic Virus in Sugarcane Plantation: A Brazilian Case Study	2023	0	Moriya et al. 2023.
Estimating Black Oat Biomass Using Digital Surface Models and a Vegetation Index Derived from RGB-Based Aerial Images	2023	1	Trevisan et al. 2023.
Digital mapping of coffee ripeness using UAV-based multispectral imagery	2023	0	Martins et al. 2023.
UAV Multispectral Data: A Reliable Approach for Managing Phosphate-Solubilizing Bacteria in Common Bean	2022	1	de Souza et al. 2022.
Carbon estimation in an integrated crop-livestock system with imaging sensors aboard unmanned aerial platforms	2022	0	de Lima et al. 2022.
Imputation of Missing Parts in UAV Orthomosaics Using PlanetScope and Sentinel-2 Data: A Case Study in a Grass-Dominated Area	2023	0	Pereira et al. 2023.
Predicting days to maturity, plant height, and grain yield in soybean: A machine and deep learning approach using multispectral data	2021	11	Teodoro et al. 2021.
Influence of flight hours on spectral behavior of rice ( <i>Oryza Sativa</i> L.) and soybean ( <i>Glycine Max</i> L.) cultivars in images obtained by remotely piloted aircraft system	2021	0	Eugenio et al. 2021.
Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data	2022	8	Pereira et al. 2022.
Biomass estimation of spring wheat with machine learning methods using UAV-based multispectral imaging	2022	3	Atkinson Amorim et al. 2022.
Unmanned aerial vehicle to evaluate frost damage in coffee plants	2021	3	Marin et al. 2021.
Predicting eucalyptus diameter at breast height and total height with uav-based spectral indices and machine learning	2021	8	da Silva et al. 2021.
Leaf nitrogen concentration and plant height prediction for maize using UAV-based multispectral imagery and machine learning techniques	2020	55	Osco et al. 2020.



Proposal for an embedded system architecture using a GNDVI algorithm to support UAV-based agrochemical spraying	2019	16	Basso et al. 2019.
Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee	2020	8	Parreiras et al. 2020.
Actual evapotranspiration and biomass of maize from a red-green-near-infrared (RGNIR) sensor on board an unmanned aerial vehicle (UAV)	2020	10	Argolo dos Santos et al. 2020.
Identification and quantification of potassium (K+) deficiency in maize plants using an unmanned aerial vehicle and visible / near-infrared semi-professional digital camera	2021	11	Furlanetto et al. 2021.
A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices	2020	94	Ramos et al. 2020.
Low-altitude, high-resolution aerial imaging for field crop phenotyping in summer squash ( <i>Cucurbita pepo</i> )	2020	1	Beloti et al. 2020.
Assessing the effects of dicamba and 2,4-Dichlorophenoxyacetic acid (2,4D) on soybean through vegetation indices derived from Unmanned Aerial Vehicle (UAV) based RGB imagery	2021	3	Abrantes et al. 2021.
The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields	2018	38	Sanches et al. 2018.
Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera	2019	16	Beniaich et al. 2019.

#### 1.4. Conclusões

A partir das bases de dados da plataforma *Scopus*<sup>®</sup>, foram selecionados 393 trabalhos que abordam o tema central deste estudo em seu conteúdo. A visualização das conexões formadas pelas métricas dos trabalhos facilita a compreensão a respeito das publicações e estado da arte. As palavras-chave e co-autorias dos trabalhos possuem fortes conexões entre si e a formação de poucos números de *clusters* ao longo das análises demonstra um agrupamento entre os termos pela semelhança ou correspondência.

Uma revisão bibliométrica possibilita conhecer métricas importantes a respeito de um tema de estudo. A partir deste trabalho, pode-se considerar que as pesquisas com uso de veículos aéreos não tripulados (ou drones), para estudo de características da vegetação, são recentes e ainda muito concentradas em poucos países. A China é o país com maior relevância em números a respeito do tema. O Brasil ainda possui poucos trabalhos relacionados ao objeto de estudo, por ser um tópico que vem ganhando investimento ao longo do tempo. Levando em consideração a crescente curva de publicações ao longo do ano, esta área possui grande potencial de crescimento.

A análise bibliométrica possui muita relevância por possibilitar elencar e classificar as conexões entre as publicações na área em estudo. Para melhor avaliação do tema em escala global, até mesmo comparativa, são necessárias análises em outras bases de dados.

## Referências

- Abrantes, T. C., Queiroz, A. R. S., Lucio, F. R., Mendes Junior, C. W., Kuplich, T. M., Bredemeier, C., & Merotto Junior, A. (2021). Assessing the effects of dicamba and 2, 4 Dichlorophenoxyacetic acid (2, 4D) on soybean through vegetation indices derived from Unmanned Aerial Vehicle (UAV) based RGB imagery. *International Journal of Remote Sensing*, 42(7), 2740-2758.
- Ahirwar, S., Swarnkar, R., Bhukya, S., & Namwade, G. (2019). Application of drone in agriculture. *International Journal of Current Microbiology and Applied Sciences*, 8(1), 2500-2505.
- Ahmed, O. S., Shemrock, A., Chabot, D., Dillon, C., Williams, G., Wasson, R., & Franklin, S. E. (2017). Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. *International journal of remote sensing*, 38(8-10), 2037-2052.
- Argolo dos Santos, R., Chartuni Mantovani, E., Filgueiras, R., Inácio Fernandes-Filho, E., Crislielle Barbosa da Silva, A., & Peroni Venancio, L. (2020). Actual evapotranspiration and biomass of maize from a red-green-near-infrared (RGNIR) sensor on board an unmanned aerial vehicle (UAV). *Water*, 12(9), 2359.
- Atkinson Amorim, J. G., Schreiber, L. V., de Souza, M. R. Q., Negreiros, M., Susin, A., Bredemeier, C., ... & Parraga, A. (2022). Biomass estimation of spring wheat with machine learning methods using UAV-based multispectral imaging. *International Journal of Remote Sensing*, 43(13), 4758-4773.
- Basso, M., Stocchero, D., Ventura Bayan Henriques, R., Vian, A. L., Bredemeier, C., Konzen, A. A., & Pignaton de Freitas, E. (2019). Proposal for an embedded system architecture using a GNDVI algorithm to support UAV-based agrochemical spraying. *Sensors*, 19(24), 5397.
- Beloti, I. F., Maciel, G. M., Gallis, R. B. A., Finzi, R. R., Clemente, A. A., Siquieroli, A. C. S., & Juliatti, F. C. (2020). Low-altitude, high-resolution aerial imaging for field crop phenotyping in summer squash (*Cucurbita pepo*). *Genetics and Molecular Research*, 19(3), 1-14.

- Ben-Dor, E. (2002). Quantitative remote sensing of soil properties. *Advances in Agronomy*, Volume 75.
- Beniaich, A., Naves Silva, M. L., Avalos, F. A. P., Menezes, M. D., & Candido, B. M. (2019). Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. *Semina-Ciencias Agrarias*, 40(1), 49-66.
- Berni, J. A. J., Zarco-Tejada, P. J., Sepulcre-Cantó, G., Fereres, E., & Villalobos, F. (2009a). Mapping canopy conductance and CWSI in olive orchards using high resolution thermal remote sensing imagery. *Remote Sensing of Environment*, 113(11), 2380-2388.
- Berni, J. A., Zarco-Tejada, P. J., Suárez, L., & Fereres, E. (2009b). Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on geoscience and Remote Sensing*, 47(3), 722-738.
- da Silva, A. K. V., Borges, M. V. V., Batista, T. S., da Silva Junior, C. A., Furuya, D. E. G., Prado Osco, L., ... & Pistori, H. (2021). Predicting eucalyptus diameter at breast height and total height with UAV-based spectral indices and machine learning. *Forests*, 12(5), 582.
- de Lima, G. S. A., Ferreira, M. E., Madari, B. E., & de Melo Carvalho, M. T. (2022). Carbon estimation in an integrated crop-livestock system with imaging sensors aboard unmanned aerial platforms. *Remote Sensing Applications: Society and Environment*, 28, 100867.
- de Miranda, E. E. (2018). Potência agrícola e ambiental: áreas cultivadas no Brasil e no mundo. *Agroanalysis*, São Paulo, SP, v. 38, n. 2, fev. p. 25-27.
- de Souza, A. E. S., Barbosa Júnior, M. R., de Almeida Moreira, B. R., da Silva, R. P., & Lemos, L. B. (2022). UAV Multispectral Data: A Reliable Approach for Managing Phosphate-Solubilizing Bacteria in Common Bean. *Agronomy*, 12(10), 2284.
- Dutta, G., & Goswami, P. (2020). Application of drone in agriculture: A review. *International Journal of Chemical Studies*, 8(5), 181-187.
- Eugenio, F. C., Grohs, M., Mallmann, C. L., Schons, C. T., Schuh, M. S., Fernandes, P., ... & Fantinel, R. A. (2021). Influence of flight hours on spectral behavior of rice (*Oryza Sativa* L.) and soybean (*Glycine Max* L.) cultivars in images obtained by remotely piloted aircraft system. *Journal of Applied Remote Sensing*, 15(4), 044505-044505.
- Feng, L., Zhang, Z., Ma, Y., Du, Q., Williams, P., Drewry, J., & Luck, B. (2020). Alfalfa yield prediction using UAV-based hyperspectral imagery and ensemble learning. *Remote Sensing*, 12(12), 2028.
- Furlanetto, R. H., Rafael Nanni, M., Guilherme Teixeira Crusiol, L., Silva, G. F. C., Junior, A. D. O., & Sibaldelli, R. N. R. (2021). Identification and quantification of potassium (K<sup>+</sup>) deficiency in maize plants using an unmanned aerial vehicle and visible/near-infrared semi-professional digital camera. *International Journal of Remote Sensing*, 42(23), 8783-8804.
- Ge, X., Wang, J., Ding, J., Cao, X., Zhang, Z., Liu, J., & Li, X. (2019). Combining UAV-based hyperspectral imagery and machine learning algorithms for soil moisture content monitoring. *PeerJ*, 7, e6926.

- Granshaw, S. I. (2018). rpv, uav, uas, rpa... or just drone?. *The Photogrammetric Record*, 33(162), 160-170.
- Inoue, Y. (2020). Satellite-and drone-based remote sensing of crops and soils for smart farming—a review. *Soil Science and Plant Nutrition*, 66(6), 798-810.
- Jannoura, R., Brinkmann, K., Uteau, D., Bruns, C., & Joergensen, R. G. (2015). Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. *Biosystems Engineering*, 129, 341-351.
- Jay, S., Baret, F., Dutartre, D., Malatesta, G., Héno, S., Comar, A., ... & Maupas, F. (2019). Exploiting the centimeter resolution of UAV multispectral imagery to improve remote-sensing estimates of canopy structure and biochemistry in sugar beet crops. *Remote Sensing of Environment*, 231, 110898.
- Li, B., Xu, X., Zhang, L., Han, J., Bian, C., Li, G., ... & Jin, L. (2020). Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 161-172.
- Li, W., Niu, Z., Chen, H., Li, D., Wu, M., & Zhao, W. (2016). Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. *Ecological indicators*, 67, 637-648.
- Liu, T., Li, R., Zhong, X., Jiang, M., Jin, X., Zhou, P., ... & Guo, W. (2018). Estimates of rice lodging using indices derived from UAV visible and thermal infrared images. *Agricultural and Forest Meteorology*, 252, 144-154.
- Maimaitijiang, M., Ghulam, A., Sidike, P., Hartling, S., Maimaitiyiming, M., Peterson, K., ... & Fritschi, F. (2017). Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134, 43-58.
- Maimaitijiang, M., Sagan, V., Sidike, P., Daloye, A. M., Erkbol, H., & Fritschi, F. B. (2020). Crop monitoring using satellite/UAV data fusion and machine learning. *Remote Sensing*, 12(9), 1357.
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J., & Martínez-Casasnovas, J. A. (2016). Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*Zea mays* L.) from a standard UAV service. *Remote Sensing*, 8(12), 973.
- Marin, D. B., Ferraz, G. A. E. S., Schwerz, F., Barata, R. A. P., de Oliveira Faria, R., & Dias, J. E. L. (2021). Unmanned aerial vehicle to evaluate frost damage in coffee plants. *Precision Agriculture*, 22(6), 1845-1860.
- Martins, R. N., de Carvalho Pinto, F. D. A., de Queiroz, D. M., Valente, D. S. M., Rosas, J. T. F., Portes, M. F., & Cerqueira, E. S. A. (2023). Digital mapping of coffee ripeness using UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, 204, 107499.
- Moriya, É. A. S., Imai, N. N., Tommaselli, A. M. G., Honkavaara, E., & Rosalen, D. L. (2023). Design of Vegetation Index for Identifying the Mosaic Virus in Sugarcane Plantation: A Brazilian Case Study. *Agronomy*, 13(6), 1542.

- Oscó, L. P., Junior, J. M., Ramos, A. P. M., Furuya, D. E. G., Santana, D. C., Teodoro, L. P. R., ... & Teodoro, P. E. (2020). Leaf nitrogen concentration and plant height prediction for maize using UAV-based multispectral imagery and machine learning techniques. *Remote Sensing*, *12*(19), 3237.
- Parreiras, T. C., Lense, G. H. E., Moreira, R. S., Santana, D. B., & Mincato, R. L. (2020). Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee.
- Pereira, F. D. S., de Lima, J. P., Freitas, R. G., Dos Reis, A. A., do Amaral, L. R., Figueiredo, G. K. D. A., ... & Magalhães, P. S. G. (2022). Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data. *Computers and Electronics in Agriculture*, *193*, 106645.
- Pereira, F. R. D. S., Dos Reis, A. A., Freitas, R. G., Oliveira, S. R. D. M., Amaral, L. R. D., Figueiredo, G. K., ... & Magalhães, P. S. (2023). Imputation of Missing Parts in UAV Orthomosaics Using PlanetScope and Sentinel-2 Data: a case study in a grass-dominated area. *ISPRS International Journal of Geo-Information*, *12*(2), 41.
- Philip, J. R. (1966). Plant water relations: some physical aspects. *Annual Review of Plant Physiology*, *17*(1), 245-268.
- Ramos, A. P. M., Oscó, L. P., Furuya, D. E. G., Gonçalves, W. N., Santana, D. C., Teodoro, L. P. R., ... & Pistori, H. (2020). A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. *Computers and Electronics in Agriculture*, *178*, 105791.
- Raparelli, E., & Bajocco, S. (2019). A bibliometric analysis on the use of unmanned aerial vehicles in agricultural and forestry studies. *International Journal of Remote Sensing*, *40*(24), 9070-9083.
- Rasmussen, J., Ntakos, G., Nielsen, J., Svendsgaard, J., Poulsen, R. N., & Christensen, S. (2016). Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, *74*, 75-92.
- Restas, A. (2015). Drone applications for supporting disaster management. *World Journal of Engineering and Technology*, *3*(03), 316.
- Sanches, G. M., Duft, D. G., Kölln, O. T., Luciano, A. C. D. S., De Castro, S. G. Q., Okuno, F. M., & Franco, H. C. J. (2018). The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields. *International journal of remote sensing*, *39*(15-16), 5402-5414.
- Santesteban, L. G., Di Gennaro, S. F., Herrero-Langreo, A., Miranda, C., Royo, J. B., & Matese, A. (2017). High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, *183*, 49-59.
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, *12*(19), 3136.
- Su, J., Liu, C., Coombes, M., Hu, X., Wang, C., Xu, X., ... & Chen, W. H. (2018). Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery. *Computers and Electronics in Agriculture*, *155*, 157-166.

- Subramanyam, K. (1983). Bibliometric studies of research collaboration: A review. *Journal of information Science*, 6(1), 33-38.
- Teodoro, P. E., Teodoro, L. P. R., Baio, F. H. R., da Silva Junior, C. A., dos Santos, R. G., Ramos, A. P. M., ... & Shiratsuchi, L. S. (2021). Predicting days to maturity, plant height, and grain yield in soybean: A machine and deep learning approach using multispectral data. *Remote Sensing*, 13(22), 4632.
- Trevisan, L. R., Brichi, L., Gomes, T. M., & Rossi, F. (2023). Estimating Black Oat Biomass Using Digital Surface Models and a Vegetation Index Derived from RGB-Based Aerial Images. *Remote Sensing*, 15(5), 1363.
- Wan, L., Cen, H., Zhu, J., Zhang, J., Zhu, Y., Sun, D., ... & He, Y. (2020). Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the South of China. *Agricultural and Forest Meteorology*, 291, 108096.
- Yang, Q., Shi, L., Han, J., Zha, Y., & Zhu, P. (2019). Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Research*, 235, 142-153.
- Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H., & Xu, B. (2017). Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models. *Remote Sensing*, 9(7), 708.
- Zha, H., Miao, Y., Wang, T., Li, Y., Zhang, J., Sun, W., ... & Kusnierek, K. (2020). Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning. *Remote sensing*, 12(2), 215.
- Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., ... & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255.



## 2. AVALIAÇÃO POR MEIO DE ÍNDICES DE VEGETAÇÃO DA RESPOSTA PRODUTIVA DO ARROZ (*Oryza sativa* L.) IRRIGADO COM DIFERENTES DOSES DE NaCl

### Resumo

A presente pesquisa aborda a avaliação da produção de arroz (*Oryza sativa* L.) em condições de salinidade do solo. A presença de íons de cloreto de sódio (NaCl) na água de irrigação impacta negativamente o desenvolvimento do arroz. A detecção da salinidade do solo em áreas vegetadas pode ser realizada por índices de vegetação, evidenciando a necessidade de dados com alta resolução temporal. O uso de Veículos Aéreos Não Tripulados (VANT) equipados com sensores multiespectrais oferece uma alternativa eficaz, com resolução espacial e temporal aprimorada a custos inferiores. O estudo investiga as características do cultivo de arroz em resposta a diferentes níveis de NaCl na água de irrigação, utilizando índices de vegetação obtidos por uma câmera multiespectral acoplada a um drone. A coleta de dados, realizada em novembro e dezembro de 2020, destaca a importância das bandas no espectro próximo ao infravermelho para a detecção eficaz de características vegetais. A análise quantitativa revela o desempenho de diversos índices de vegetação, destacando o DVI, GEMI, ExG e GRVI como os mais relevantes. A combinação de bandas no espectro próximo ao infravermelho e vermelho demonstra maior eficácia na detecção de características vegetais. A pesquisa ressalta desafios na coleta de dados, especialmente em plantas jovens e na formação de panículas. A fase vegetativa é identificada como mais propícia para coletas precisas, e estratégias de seleção de pontos são sugeridas para melhorar a consistência dos dados.

**Palavras-chave:** 1. Drone 2. Imagens Multiespectrais 3. Processamento de imagens 4. Experimento.

### Abstract

#### **Evaluation through vegetation indices of the productive response of rice (*Oryza sativa* L.) irrigated with different doses of NaCl**

This research addresses the evaluation of rice (*Oryza sativa* L.) production under soil salinity conditions. The presence of sodium chloride (NaCl) ions in irrigation water negatively impacts rice development. Soil salinity detection in vegetated areas can be performed using vegetation indices, emphasizing the need for data with high temporal resolution. Unmanned Aerial Vehicles (UAVs) equipped with multispectral sensors offer an effective alternative with enhanced spatial and temporal resolution at lower costs. The study investigates the characteristics of rice cultivation in response to different levels of NaCl in irrigation water, utilizing vegetation indices obtained by a multispectral camera mounted on a drone. Data collection, conducted in November and December 2020, highlights the importance of bands in the near-infrared spectrum for effective vegetation feature detection. Quantitative analysis reveals the performance of various vegetation indices, with DVI, GEMI, ExG, and GRVI identified as the most relevant. The combination of bands in the near-infrared and red spectrum demonstrates greater efficacy in detecting vegetation features. The research emphasizes challenges in data collection, especially in



young plants and panicle formation. The vegetative phase is identified as more conducive to precise data collection, and point selection strategies are suggested to enhance data consistency.

**Keywords:** 1. Drone 2. Multispectral Images 3. Image Processing 4. Experiment.

## 2.1 Introdução

A crescente demanda global por alimentos, em um cenário de mudanças climáticas e escassez de recursos hídricos, destaca a necessidade imediata de otimizar a produção agrícola. O arroz (*Oryza sativa* L.), como um dos principais alimentos básicos consumidos em todo o mundo, enfrenta desafios significativos quando exposto a condições de salinidade no solo. A presença de íons de cloreto de sódio (NaCl) na água de irrigação pode impactar negativamente o desenvolvimento e a produtividade das plantas de arroz (Pareek et al., 2020).

Em áreas não vegetadas de alta salinidade, a detecção da salinidade do solo pode ser realizada a partir da reflectância do solo nu. Contudo, ao detectar solos afetados pela salinidade em áreas vegetadas utilizando Índices de Vegetação, a condição da vegetação é empregada como referência, em vez de ser uma detecção direta da condição do solo. O crescimento deficiente da vegetação tem sido utilizado como um indicador para alta salinidade. Monitorar uma cultura de curta duração como a do arroz requer o uso de dados com alta resolução temporal para capturar o efeito da salinidade do solo (Paliwal et al., 2019).

Os índices de vegetação são métricas quantitativas que oferecem uma avaliação do vigor da vegetação, evidenciando uma sensibilidade mais aprimorada do que as bandas espectrais individuais na identificação de biomassa. O interesse primordial desses índices reside em sua aplicabilidade na interpretação de imagens provenientes de sistemas de sensoriamento remoto, destacando-se como uma abordagem viável para a detecção de mudanças no uso da terra (utilizando dados multitemporais), a estimativa da densidade da cobertura vegetal, a discriminação de culturas e a previsão de safras. No âmbito do mapeamento temático, a relevância predominante desses índices manifesta-se na otimização das classificações (Bannari et al., 1995).

As distintas coberturas vegetais podem ser discernidas com base em seu comportamento espectral singular em relação aos componentes do solo. A absorção da radiação visível na faixa do vermelho pela clorofila e a forte reflexão da radiação no infravermelho próximo pelas estruturas celulares das folhas são fenômenos determinantes. Ao analisar a curva geral de reflectância da vegetação, a disparidade entre as regiões do espectro vermelho e infravermelho próximo configura-se como uma variável sensível à presença de vegetação verde. Por sua vez, a resposta espectral da vegetação na faixa do vermelho correlaciona-se significativamente com a concentração de clorofila, enquanto a resposta espectral no

infravermelho próximo é governada pelo índice de área foliar e pela densidade de vegetação verde. A combinação entre esses dois domínios espectrais possibilita a diferenciação eficaz entre a vegetação e o solo, permitindo a determinação da biomassa fotossinteticamente ativa mediante a densidade da cobertura vegetal (Bannari et al., 1995).

Tradicionalmente, os meios primários empregados para aquisição de imagens remotas da superfície terrestre consistiam em satélites e aeronaves tripuladas; entretanto, esses instrumentos frequentemente carecem de resoluções espaciais e temporais adequadas. Atualmente, tais desafios podem ser mitigados mediante a utilização de plataformas não tripuladas de custo reduzido e elevada flexibilidade, como os Veículos Aéreos Não Tripulados (VANT). Plataformas de VANT equipadas com sensores de imagem, alcance e posicionamento, têm a capacidade de coletar imagens multiespectrais com resolução na ordem de centímetros, proporcionando amplas perspectivas nos domínios da agricultura de precisão, gestão agrícola e florestal, e geociências. Essas aeronaves não tripuladas possibilitam a realização de observações quantitativas e intrigantes com aprimorada resolução espacial e temporal, a custos de implementação inferiores em comparação com as plataformas aéreas ou satélites convencionais. Efetivamente, os levantamentos com VANT possibilitam o trabalho com imagens remotas em tamanhos de pixel muito reduzidos (Distância de Amostragem no Solo - DAS), frequentemente na ordem de centímetros, o que substancialmente aprimora a resolução normal de uma plataforma aérea ou satélite (Candiago, et al., 2015).

As informações derivadas desses levantamentos com VANT auxiliam os agricultores nos processos decisórios, contribuindo para o aprimoramento da produção agrícola e otimização do uso de recursos. Por meio de voos regulares rápidos e econômicos, os produtores podem tomar decisões confiáveis, resultando em economia de tempo e recursos financeiros. Os VANTs podem oferecer descrições confiáveis da situação no solo, superando os custos associados às avaliações em campo. O uso de plataformas VANT está experimentando crescimento acentuado devido ao alto grau de automação e à facilidade de operação (Candiago, et al., 2015).

O presente estudo teve como principal objetivo investigar as características do cultivo de arroz em resposta a diferentes níveis de NaCl (cloreto de sódio) presentes na água de irrigação, utilizando índices de vegetação obtidos por meio de câmera multiespectral. Com essa abordagem, é possível obter índices de vegetação que oferecem informações cruciais sobre o estado dos cultivos.

## **2.2 Material e Métodos**

### 2.2.1 Caracterização do estudo

O estudo foi conduzido em casa de vegetação, localizada no Departamento de Biosistemas localizado na Escola Superior de Agricultura “Luiz de Queiroz” – ESALQ/USP, em Piracicaba-SP (22° 42’ 30” Sul, 47° 38’ 00” Oeste, 546 m). O clima dessa região na classificação proposta por Köppen se caracteriza como tipo Cwa: tropical de altitude, com três meses mais secos (junho, julho e agosto), chuvas de verão e seca no inverno.

Para o estudo, utilizou-se a cultivar de arroz (*Oryza sativa* L.) “BRS SERRA DOURADA”, com densidade de semeadura de 5 sementes por vaso, os quais possuem uma capacidade de 2,0 L, com dimensões (0,16 m x 0,12 m) e características apresentadas na Figura 1, no qual foi inserida uma mistura de substrato de fibra de coco (Golden mix misto® Tipo 80), substrato de textura intermediária, com pH 6,2 ( $\pm 0,3$ ), CE 0,004 ( $\pm 0,6$ ) dS m<sup>-1</sup> e densidade de 90 kg m<sup>-3</sup> com areia fina; além disso, foi posto no fundo desse recipiente britas e manta bidin para facilitar a drenagem de água nessa região (Figura 1). Os vasos foram posicionados na superfície de caixas de 1 m<sup>2</sup> com solo.




**Figura 1.** Dimensões e composição do conteúdo do vaso de cultivo utilizado no estudo.

Com intuito de proporcionar condições adequadas de movimentação da água no substrato, foi efetuada uma relação proporcional para a quantidade de areia e fibra de coco existente nos recipientes, sendo inserido 95% de areia (1 kg) e 5% de fibra de coco (50 g).

Os dados de temperatura do ar e umidade relativa do ar foram coletados em estação meteorológica montada dentro da casa de vegetação. A semeadura do arroz foi realizada no dia 08 de novembro de 2020 e a emergência das plantas nos vasos ocorreu em 14 de novembro de 2020 (Figura 2). A irrigação foi realizada diariamente em todos os vasos cultivados com a saturação do substrato até a ocorrência de drenagem. Após 111 dias da semeadura, foi encerrada

a irrigação das plantas, sendo iniciado o processo de finalização do ciclo. Com colheita realizada com 115 dias após a semeadura. A irrigação foi realizada diariamente, com lâmina fixa para todos os tratamentos de 0,1m por vaso, totalizando 200 mL d<sup>-1</sup> vaso<sup>-1</sup>.



**Figura 2.** Períodos do ciclo produtivo do arroz cultivado no experimento.

A adubação foi realizada via aplicação de solução nutritiva ao longo do desenvolvimento das plantas. A primeira adubação foi realizada em 16 de novembro de 2020 com 45 mg vaso<sup>-1</sup> de Nitrato de amônio, 75 mg vaso<sup>-1</sup> de 0-52-34 e fórmula com os micronutrientes 3,6; 1,5; 5,0; 0,5 e 0,05 mg dm<sup>-3</sup> de Mn, Cu, Zn, B e Mo provenientes das fontes MnSO<sub>4</sub>.4H<sub>2</sub>O, CuSO<sub>4</sub>.5H<sub>2</sub>O; ZnSO<sub>4</sub>.7H<sub>2</sub>O; H<sub>3</sub>BO<sub>3</sub> e (NH<sub>4</sub>)<sub>6</sub>Mo<sub>7</sub>O<sub>24</sub>.4H<sub>2</sub>O.

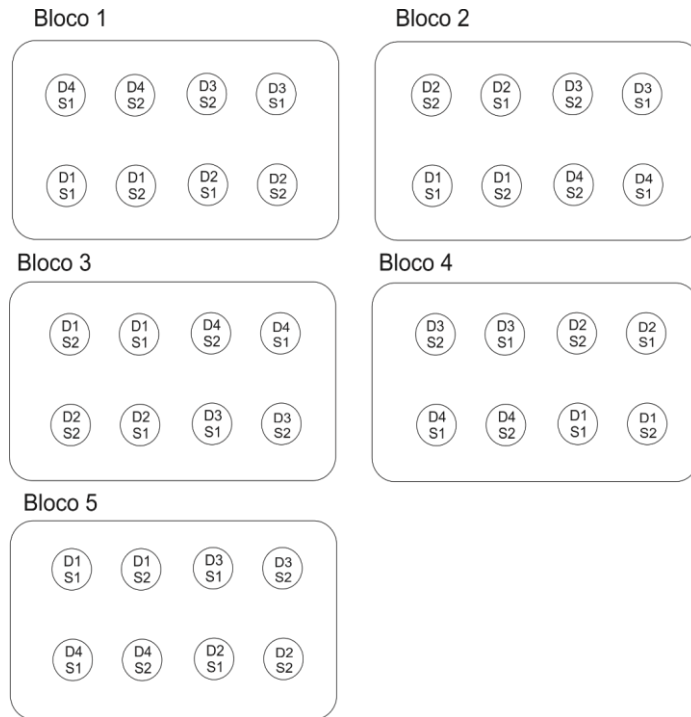
A segunda adubação foi realizada em 23 de novembro de 2020, com 200 ml/vaso de solução nutritiva (10ml L<sup>-1</sup>) diluída em água deionizada aplicada diretamente no substrato (Tabela 1) e 25 mg dm<sup>-3</sup> de Óxido de Cálcio (40% Ca). A terceira adubação foi realizada em 29 de novembro de 2020 com a solução nutritiva (10ml L<sup>-1</sup>) em um volume total de 50 mL vaso<sup>-1</sup> diluída em água deionizada. A quarta adubação foi realizada em 07 de dezembro de 2020 com solução nutritiva (10 mL L<sup>-1</sup>) em um volume total de 100 mL vaso<sup>-1</sup> diluída em água deionizada. As adubações subsequentes serão a cada 7 dias com a mesma característica da quarta adubação.

**Tabela 1.** Características da solução nutritiva utilizada nas unidades experimentais.

Nutriente ou Característica	Concentração (g L <sup>-1</sup> )
N	116,10
P <sub>2</sub> O <sub>5</sub>	25,80
K <sub>2</sub> O	12,90
B	0,516
Cu	1,29
Mn	1,29
Mo	1,29
Zn	1,29
Carbono Orgânico Total	77,4
Característica física	
Densidade	1,29 g cm <sup>-3</sup>
Salinidade	
CE em 10 ml L <sup>-1</sup> de água deionizada	7,2 mS cma

Em complementação, foi realizada em 23 de fevereiro de 2021 a adubação com N (fórmula 33-00-00) de K<sub>2</sub>O (fórmula 00-00-60) com 0,2 g por vaso de cada adubo, encerrando-se as adubações.

Para a avaliação do arroz quanto ao estresse salino, foi considerado um delineamento fatorial 4 x 2, com 5 repetições, apresentadas como blocos (Figura 3), adotando-se tratamentos com quatro níveis de salinidade da água de irrigação, denominados de D1, D2, D3 e D4, com CE de 0,7, 1,5, 2,0 e 3,0 dS m<sup>-1</sup>, respectivamente, que foram aplicados diariamente ao longo do cultivo pela irrigação.



**Figura 3.** Delineamento experimental, com as doses aplicadas (D1 a D4), sem o pré-tratamento (S1) e o pré-tratamento com elevada condutividade elétrica (S2).

Antes da semeadura, os vasos com substrato foram separados em duas condições, sendo a primeira sem pré-tratamento do substrato por meio de água salina, denominado de S1 e com o pré-tratamento, pela irrigação com água de elevada CE, denominado de S2. Para o pré-tratamento do substrato foi utilizada água salina de condutividade elétrica (CE) de 2 dS m<sup>-1</sup>. Após a semeadura, cada parcela foi irrigada com uso de água com condutividade elétrica correspondente ao respectivo tratamento. Para o preparo dos tratamentos referentes a CE da água, foi utilizado Cloreto de Sódio (NaCl) de modo a alcançar cada condutividade elétrica proposta no trabalho.

### 2.2.2 Coleta de imagens e processamento


Para obtenção de imagens do cultivo, foi utilizada uma câmera multiespectral modelo MicaSense Altum (MicaSense, Seattle, WA, USA). Esta câmera possui 5 bandas multiespectrais, vermelha, verde, azul, Red Edge e NIR (infravermelho-próximo) e um sensor de imagem termal, sendo possível capturar imagens multiespectrais e termais em cada captura. A câmera estava acoplada em um drone modelo MATRICE 600PRO (DJI®).

Em cada coleta foram capturadas de três a cinco imagens de cada bloco, sendo selecionada a imagem com melhor enquadramento dos vasos cultivados para avaliação. A banda


termal possui resolução de 160x120 pixels e um tamanho de pixel de 12  $\mu\text{m}$ . A captura de imagens de cada bloco foi realizada a partir do posicionamento da câmera a 1m de altura da planta. As coletas foram realizadas em 20 e 30 de novembro de 2020 e 08, 18 e 30 de dezembro de 2020, antes da emissão de panículas. Para avaliação do cultivo, foram utilizadas as imagens dos dias 8, 18 e 30 de dezembro de 2020 devido a maior quantidade de folhas por planta.

Cada imagem capturada possui 6 arquivos do tipo GeoTIFF, representando diferentes bandas. Essas imagens foram selecionadas para cada bloco do estudo e, em seguida, inseridas individualmente no software ArcGIS® para a extração dos valores dos pixels (Figura 4). Para cada vaso, foram escolhidos 05 pontos distribuídos ao longo de uma folha. Utilizando a ferramenta de extração de valores correspondentes a cada ponto no software, calculou-se uma média dos valores próximos a cada ponto, resultando 5 amostras médias por planta. Ao realizar essa coleta para todos os tratamentos, obteve-se um total de 200 pontos para cada banda. Na Figura 7, estão apresentadas as imagens base para processamento de coleta de cada banda.

As imagens dos dias 20 (Figura 5) e 30 (Figura 6) de novembro de 2020 não foram utilizadas devido à menor área foliar nos vasos, tornando difícil a coleta dos pixels ao longo das folhas. Datas posteriores a 30 de dezembro de 2020 também não foram capturadas pela alta densidade das folhas causando sobreposição, assim como surgimento das panículas, gerando uma menor confiabilidade nos dados. As coletas de dados na banda termal foram descartadas devido à baixa confiabilidade nos dados pela sobreposição de folhas e sobreposição, causando grande dificuldade (Figuras 5-B, 6-B e 7-F).




**Figura 4.** Processo de coleta e processamento das imagens.




**Figura 5.** Exemplos de imagens capturadas na data de 20 de novembro de 2020.





**Figura 6.** Exemplos de imagens capturadas na data de 30 de novembro de 2020.



**Figura 7.** Imagens de um vaso para as bandas vermelha (A), verde (B), azul (C), Red Edge (D), NIR (E) e termal (F).

### 2.2.3 Análises do cultivo

Na colheita, foram medidos o número de perfilhos por vaso, peso seco das panículas, número de panículas por vaso, tamanho de panículas, número de grãos abortados por vaso e matéria seca, obtida pelas pesagens em massa seca (60° por 48h) das folhas e caule. Os grãos foram separados das panículas, contados e pesados.

As folhas bandeiras das panículas foram coletadas (separadas e pesadas) e enviadas para análise foliar. As amostras da parte aérea foram lavadas com solução de água e ácido clorídrico, numa diluição de 0,1%, visando retirar as impurezas e secas em estufa com circulação forçada até 65°C. Posteriormente, foram processadas em moinho e encaminhadas para análises de diagnose nutricional, conforme Malavolta et al. (1997), pelo Laboratório de Ciências Agrárias/Solos da

FZEA/USP. Os teores de nutrientes obtidos foram comparados com valores sugeridos por Raij (2011).

Cada substrato, ao final do ciclo, foi inserido em um copo de béquer, ao qual foi adicionada água deionizada até a saturação. A pasta resultante foi filtrada a vácuo, utilizando-se um funil de Büchner, com a aplicação da sucção até obter um volume adequado de extrato (Warncke, 1986). Com isto, obteve-se a condutividade elétrica final do substrato de cada unidade experimental.

Todos os resultados obtidos foram submetidos à análise de variância e comparação de médias a 5% utilizando o pacote agricolae no software RStudio®.

#### **2.2.4 Índices de vegetação**

Quando a iluminação incide sobre uma superfície, uma parte significativa é refletida, outra é transmitida, e a porção remanescente é absorvida. As proporções relativas de luz refletida, transmitida e absorvida são intrinsecamente dependentes da natureza da superfície, apresentando variações conforme o comprimento de onda da luz. No ambiente terrestre, a luz que atinge o solo é predominantemente refletida ou absorvida, com uma fração mínima sendo transmitida, e as alterações relativas em função do comprimento de onda são relativamente pequenas. No entanto, no contexto vegetal, especialmente nas proximidades do infravermelho próximo (NIR), observa-se que a maior parte da luz é transmitida e refletida, com absorção mínima, ao contrário dos comprimentos de onda visíveis, onde a absorção prevalece, acompanhada por baixa refletância e transmissão. Esses fenômenos ópticos são distintivos e fundamentais na interação luz-vegetação, destacando-se como elementos essenciais na interpretação de dados espectrais (Jackson e Huete, 1991).

De maneira geral, as bandas de comprimento de onda escolhidas para calcular os Índices de Vegetação (IV) são selecionadas de tal forma que uma diminua e a outra aumente com o aumento da cobertura vegetal. Em áreas de vegetação densa, a quantidade de luz vermelha refletida pelo dossel é bastante reduzida. Foram calculados diferentes índices de vegetação, a fim de avaliar as características de cada tratamento. Sendo eles DVI, GEMI, ExG, GRVI, MSAVI2, OSAVI, RGBVI, RVI, NDVI, VARI, ExGR, MGVRI, GLI e SAVI, descritos a seguir:

GNDVI (Green Normalized Difference Vegetation Index) ou Índice de Vegetação de Diferença Normalizada Verde é um índice utilizado para avaliar a saúde e a densidade de vegetação em uma determinada área. O índice GNDVI varia de -1 a 1. Quanto maior o valor do

índice, mais vegetação saudável e densa é presente na área. Um valor próximo de 1 indica vegetação exuberante, enquanto valores próximos de -1 sugerem ausência ou pouca vegetação.

O GNDVI é amplamente utilizado em estudos ambientais, agrícolas e florestais para monitorar a saúde das plantas, avaliar mudanças na cobertura vegetal ao longo do tempo e auxiliar no manejo de culturas e ecossistemas. Ao comparar imagens de satélite ou dados de diferentes épocas, os especialistas podem detectar mudanças na vegetação, identificar áreas afetadas por estresse hídrico, doenças ou outros problemas relacionados às plantas. O GNDVI representa efetivamente as propriedades da clorofila em plantas verdes (Lee et al., 2021).

GRVI (Green-Red Vegetation Index) ou Índice de Vegetação Verde-Vermelho é outro índice utilizado para avaliar a saúde e a densidade da vegetação em uma área específica. Assim como o GNDVI, o índice GRVI também varia de -1 a 1. Valores maiores indicam uma vegetação mais saudável e densa, enquanto valores menores podem sugerir áreas com vegetação menos desenvolvida ou sob estresse.

O GRVI é um indicador eficaz, especialmente para a coloração das folhas. O GRVI é, em princípio, sensível à mudança nas cores visíveis do dossel. O GRVI pode não ser efetivo em representar áreas com baixa cobertura vegetal (Motohka et al., 2010).

O índice MSAVI2 (Modified Soil-Adjusted Vegetation Index 2) ou Índice de Vegetação Ajustado ao Solo Modificado 2 é um índice de vegetação ajustado para o solo modificado que busca resolver algumas das limitações do NDVI quando aplicado a áreas com alto grau de superfície de solo exposta. O MSAVI2 é aplicado em áreas onde ocorre escassez de vegetação ou à ausência de clorofila, especialmente durante estágios fenológicos de emergência. Este índice desempenha um papel crucial na minimização do efeito do solo exposto, contribuindo para a maior identificação da vegetação. É um índice recomendado para estágios iniciais do desenvolvimento da cultura, permitindo a observação precisa das mudas emergentes.

O índice NDRE (Normalized Difference Red Edge) ou Índice de Diferença Normalizada de Borda Vermelha é um índice de vegetação que é usado para avaliar a saúde e o vigor das plantas, especialmente culturas agrícolas. O NDRE é particularmente sensível à quantidade de clorofila nas folhas das plantas e é especialmente útil para estimar a quantidade de biomassa e o conteúdo de clorofila em culturas. O índice NDRE varia de -1 a 1, e valores mais altos indicam uma vegetação mais saudável e vigorosa. Como o NDRE é mais sensível às mudanças na clorofila das plantas, ele pode fornecer informações mais detalhadas sobre a saúde das culturas em comparação com outros índices mais gerais. Devido à reflectância diferencial da luz em diferentes comprimentos de onda pelas plantas, índices de vegetação, como o NDRE,

têm sido empregados na quantificação do crescimento e desenvolvimento de culturas (Thompson et al., 2019).

O índice OSAVI (Optimized Soil-Adjusted Vegetation Index) ou Índice de Vegetação Otimizado Ajustado ao Solo é um índice de vegetação utilizado para avaliar a saúde e a densidade da vegetação em uma determinada área, especialmente em regiões com solo exposto ou superfícies brilhantes. O OSAVI é uma variação do índice SAVI (Soil-Adjusted Vegetation Index) e foi projetado para superar algumas de suas limitações, especialmente relacionadas à sensibilidade ao brilho do solo e ao problema de oscilação do índice quando a cobertura vegetal é baixa. Assim como outros índices de vegetação, o OSAVI varia de -1 a 1, com valores maiores indicando uma vegetação mais saudável e densa. O fator de ajuste L é utilizado para controlar a influência do brilho do solo no cálculo do índice. O índice OSAVI é recomendado para aplicações na agricultura (Rondeaux et al., 1996).

O índice RGBVI (Red-Green Vegetation Index) é um índice de vegetação que utiliza as bandas espectrais vermelha (Red) e verde (Green) para avaliar a saúde e a densidade da vegetação em uma área. É uma combinação simples de duas bandas espectrais, tornando-o fácil de calcular e interpretar. Diferentemente de outros índices de vegetação mais populares, como o NDVI (Índice de Vegetação por Diferença Normalizada), o RGBVI utiliza a banda verde em vez da banda vermelha. O índice explora a diferença entre a reflectância do infravermelho próximo e a reflectância na banda verde para fornecer uma estimativa da vegetação. O RGBVI pode ser útil em determinadas situações, especialmente em áreas com solo exposto ou com grande quantidade de material não vegetado que pode afetar os índices de vegetação mais sensíveis ao brilho do solo, sendo muito útil para identificação e classificação de vegetação (Lee et al., 2021).

O índice RI (Redness Index) é um índice que usa a banda vermelha do espectro eletromagnético para avaliar a quantidade de "vermelhidão" presente na cena. É menos específico em relação à vegetação e é mais focado na análise da composição espectral da superfície. A "vermelhidão" refere-se à intensidade da cor vermelha na área analisada, que pode ser influenciada por vários fatores, incluindo a quantidade de vegetação, o tipo de solo e a presença de outros materiais ou superfícies. No entanto, vale ressaltar que o índice não é tão amplamente utilizado ou estabelecido como outros índices de vegetação, e sua interpretação e aplicação podem variar dependendo do contexto e do objetivo do estudo. O RI permite identificar áreas com solo exposto, que têm uma tonalidade comumente avermelhada (Pilaš et al., 2020).

O RVI (Ratio Vegetation Index) ou Índice de Razão de Vegetação é um índice de vegetação utilizado para avaliar a saúde e a densidade da vegetação em uma área específica com base em dados espectrais obtidos por sensores remotos, como imagens de satélite ou drones. O

RVI é um índice relativamente simples e eficaz que usa duas bandas espectrais: a banda do infravermelho próximo (NIR - Near-Infrared) e a banda vermelha. A razão entre essas duas bandas é usada para quantificar a quantidade de luz refletida pelas plantas, o que é relacionado à presença de clorofila e, portanto, à saúde e à densidade da vegetação. O índice RVI varia de acordo com as características da vegetação presente na área e geralmente é usado para identificar áreas com vegetação densa e saudável, como florestas, culturas agrícolas bem desenvolvidas e áreas vegetadas em geral. Se a banda vermelha for medida com precisão suficiente, o RVI é bastante sensível a mudanças na vegetação durante o período de crescimento máximo. Ele não é muito sensível quando a cobertura vegetal é esparsa (Jackson e Huete, 1991).

O índice NDVI (Normalized Difference Vegetation Index) ou Índice de Vegetação de Diferença Normalizada é um dos índices de vegetação mais amplamente utilizados em sensoriamento remoto e geoprocessamento para avaliar a saúde e a densidade da vegetação em uma determinada área. Valores próximos de -1 indicam que a área é coberta principalmente por superfícies não vegetadas, como água ou solo exposto. Valores próximos de 1 indicam alta densidade e saúde da vegetação, como florestas densas ou culturas exuberantes. A base teórica para o NDVI está na diferença de contraste entre as assinaturas espectrais de reflectância vegetal no vermelho e NIR. À medida que a quantidade de vegetação verde viva aumenta em um pixel, a reflectância vermelha diminuirá devido à absorção de clorofila, enquanto a região espectral NIR não absorvente geralmente aumentará, especialmente a estrutura foliar e a quantidade (Ahmad, 2012). Em áreas com baixa cobertura vegetal e superfície do solo exposta, a reflectância da luz nos espectros vermelho e infravermelho próximo pode influenciar os valores dos índices de vegetação. Isso é especialmente problemático quando são feitas comparações entre diferentes tipos de solo que podem refletir diferentes quantidades de luz nas faixas de comprimento de onda vermelho e infravermelho próximo (Ahmad, 2012).

O Índice de Vegetação Aprimorado (EVI - Enhanced Vegetation Index) tem sido mostrado como bem correlacionado com a Área Foliar (LAI), biomassa, cobertura do dossel e a fração de radiação fotossinteticamente ativa absorvida sendo, portanto, útil para monitorar variações sazonais, interanuais e de longo prazo na estrutura da vegetação. Além disso, o EVI corrige distorções devido a aerossóis usando a faixa azul, emprega um ajuste para o solo usando a faixa L e não satura tão facilmente quanto o NDVI. Dadas essas características, os modeladores começaram a utilizar dados de EVI para prever a produção primária líquida em aplicações de modelagem de ecossistemas (Gurung et al., 2009).

O índice VARI (Visible Atmospherically Resistant Index) ou Índice de Vegetação Atmosfericamente Resistente Visível é um índice de vegetação desenvolvido para reduzir a

influência de fatores atmosféricos na estimativa da vegetação em imagens de satélite ou outras imagens adquiridas por sensores remotos. O VARI é uma variação do NDVI (Normalized Difference Vegetation Index) e foi projetado para minimizar os efeitos da atmosfera na estimativa da vegetação. A inclusão da banda azul no denominador do cálculo permite que o VARI seja menos sensível a influências atmosféricas, uma vez que a reflectância atmosférica é mais forte na banda azul do que nas bandas vermelha e infravermelha próxima. O VARI é considerado útil em áreas onde a presença de aerossóis atmosféricos pode afetar negativamente a precisão de índices de vegetação tradicionais, como o NDVI. Ao minimizar os efeitos da atmosfera, o VARI pode fornecer estimativas mais precisas da vegetação, especialmente em regiões urbanas e outras áreas com altos níveis de aerossóis.

O Índice ExG (Excess Green Index) ou Índice de Excesso de Verde é um índice de vegetação que utiliza as bandas espectrais verde e vermelha para avaliar a presença e a saúde da vegetação em uma determinada área. Ao contrário dos índices de vegetação tradicionais, o ExG não inclui a banda do infravermelho próximo (NIR - Near-Infrared) em sua fórmula. O resultado do cálculo do ExG é uma imagem em tons de cinza, na qual as áreas de vegetação geralmente são realçadas em tons mais claros, enquanto outras superfícies podem aparecer em tons mais escuros, ou seja, o ExG tem sido amplamente utilizado para segmentar culturas do plano de fundo (Zhang et al., 2021).

O índice ExB (Excess Blue Index) ou Índice de Excesso de Azul é um índice de vegetação que utiliza as bandas espectrais azul e vermelha para avaliar a vegetação em uma determinada área. Assim como o Índice ExG (Excess Green Index), o ExB também é usado para realçar a vegetação em uma imagem. O índice ExB pode ser útil para destacar áreas com vegetação saudável e densa, pois é sensível à presença de clorofila nas plantas. A principal diferença entre o ExB e o ExG é que o ExB enfatiza a banda azul, enquanto o ExG enfatiza a banda verde. Em ambos os casos, a ideia é realçar a vegetação, mas a escolha entre os índices pode depender do tipo de vegetação predominante na área de interesse e do objetivo específico da análise. É importante notar que o ExB é considerado um índice de vegetação "clorofila-sensível", assim como o ExG, o que significa que ele é sensível à presença de clorofila nas plantas. No entanto, como o ExB não inclui a banda do infravermelho próximo, ele pode ser menos sensível a variações na densidade de vegetação em comparação com índices como o NDVI ou o EVI. Portanto, o ExB pode ser mais adequado para aplicações que priorizam a detecção de vegetação densa e saudável (Mahmud et al., 2023).

O índice ExR (Excess Red Index) ou Índice de Excesso de Vermelho é um índice de vegetação utilizado em sensoriamento remoto para avaliar a presença e a saúde da vegetação em

uma determinada área. Ele faz parte da família de índices de vegetação "Excess", que combinam diferentes bandas espectrais para realçar a vegetação em uma imagem. O resultado do cálculo do ExR é uma imagem em tons de cinza, na qual as áreas de vegetação geralmente são realçadas em tons mais contrastantes. Assim como outros índices "Excess", o ExR enfatiza uma das bandas espectrais, neste caso, a banda vermelha, para realçar a vegetação. Ele é sensível à presença de clorofila nas plantas, o que permite identificar áreas com vegetação saudável e densa. O índice ExR é especialmente útil em áreas urbanas ou em culturas com vegetação predominante, onde a resposta na banda vermelha pode ser mais relevante (Das et al., 2016).

O índice ExGR (Excess Green-Red Index) é um índice de vegetação que utiliza as bandas espectrais verde e vermelha para avaliar a vegetação em uma determinada área. Ele é uma extensão do índice ExG (Excess Green Index) e ExR (Excess Red Index), combinando esses dois índices para fornecer uma estimativa mais precisa da vegetação. Assim como os índices ExG e ExR, o ExGR também é projetado para realçar a vegetação em uma imagem. Ele pode ser usado para identificar áreas com vegetação saudável e densa, assim como para detectar mudanças na cobertura vegetal e em outras aplicações relacionadas ao monitoramento da vegetação. O índice ExGR é especialmente útil quando a vegetação predominante na área analisada tem uma resposta significativa nas bandas verde e vermelha. Ele pode ser usado em conjunto com outros índices de vegetação para obter informações mais detalhadas sobre a saúde e a densidade da vegetação em diferentes contextos. É importante mencionar que o ExGR, assim como o ExG e o ExR, é considerado um índice de vegetação "clorofila-sensível", o que significa que ele é sensível à presença de clorofila nas plantas (Meyer e Neto, 2008).

O índice GLI (Green Leaf Index) ou Índice de Folhas Verdes é um índice de vegetação que foi desenvolvido para avaliar especificamente a quantidade e a saúde das folhas verdes em uma determinada área, fornecendo informações sobre a atividade fotossintética das plantas. O índice GLI é sensível à quantidade de clorofila presente nas folhas das plantas e é projetado para medir diretamente o teor de folhas verdes. Portanto, ele pode ser mais específico na avaliação da saúde da vegetação do que outros índices de vegetação que podem ser influenciados por diferentes fatores, como a quantidade de vegetação total ou a presença de outras superfícies não vegetadas. De acordo com o trabalho de Barbosa et al. (2019), o GLI foi eficaz na identificação de solo exposto (coloração vermelha), não sendo eficiente na identificação do vigor da vegetação (*Zoysia japonica*), principalmente por influência de sombras na imagem.

O índice SAVI (Soil-Adjusted Vegetation Index) ou Índice de Vegetação Ajustado ao Solo é um índice de vegetação utilizado em sensoriamento remoto para avaliar a saúde e a densidade da vegetação, levando em consideração a presença do solo e reduzindo os efeitos de



fundo ou cobertura do solo na estimativa da vegetação. Ao introduzir o fator de correção "L" na fórmula do SAVI, o índice é ajustado para levar em conta a reflectância do solo, reduzindo os efeitos do brilho do solo na estimativa da vegetação. Quando o solo está completamente exposto, "L" é definido como -1 para neutralizar os efeitos do solo. Quando a área é completamente coberta por vegetação, "L" é definido como 0, e o SAVI se torna equivalente ao NDVI. "L" pode ser determinado empiricamente com base nas características do solo e da vegetação da área de interesse (Ahmad, 2012).

O índice MTCI (MERIS Terrestrial Chlorophyll Index) é um índice de vegetação desenvolvido para estimar o teor de clorofila nas folhas das plantas em ecossistemas terrestres. Ele foi especialmente projetado para uso com os dados do sensor MERIS (Medium Resolution Imaging Spectrometer) a bordo dos satélites da série Envisat da Agência Espacial Europeia (ESA). O MTCI utiliza três bandas espectrais, duas no infravermelho e uma no vermelho, para quantificar a clorofila presente na vegetação. O MTCI é particularmente sensível à clorofila e ao estado fisiológico das folhas, o que o torna útil para monitorar a saúde das plantas, detectar estresses hídricos e estudar mudanças sazonais na vegetação. Devido à sua sensibilidade à clorofila, o MTCI pode ser mais adequado para estudos que visam analisar o conteúdo de clorofila em vegetação densa ou em áreas onde a quantidade de clorofila nas folhas é um fator importante (Dash e Curran, 2007).

O índice GEMI (Global Environment Monitoring Index) é um índice de vegetação utilizado em sensoriamento remoto para monitorar o ambiente global, particularmente a vegetação, em escala global ou regional. O objetivo do GEMI é fornecer uma estimativa da saúde e densidade da vegetação, levando em conta fatores como a presença de clorofila nas plantas e a correção para efeitos atmosféricos. O índice GEMI foi desenvolvido para superar algumas limitações de outros índices de vegetação, como o NDVI (Normalized Difference Vegetation Index), que podem ser influenciados por efeitos atmosféricos e por superfícies de solo brilhantes. O índice GEMI possui uma correção para reduzir a influência de superfícies brilhantes, como solos desnudos ou superfícies urbanas, além de considerar correções atmosféricas para melhorar a precisão das estimativas de vegetação. O GEMI é usado em várias aplicações, incluindo monitoramento de ecossistemas naturais, detecção de mudanças na cobertura vegetal, avaliação da saúde de culturas agrícolas e estudos de uso da terra em escalas regionais e globais (González et al., 2021).

O índice TVI (Triangular Vegetation Index) ou Índice de Vegetação Triangular é um índice de vegetação utilizado em sensoriamento remoto para avaliar a saúde e a densidade da vegetação em uma determinada área. Ele faz parte da categoria de índices de vegetação que

combinam múltiplas bandas espectrais para fornecer uma estimativa mais precisa da vegetação. O índice TVI utiliza uma combinação ponderada das três bandas espectrais para realçar a vegetação, permitindo avaliar a saúde da vegetação e detectar áreas com maior cobertura de plantas verdes. O TVI é particularmente útil em ambientes com vegetação densa e saudável, onde a resposta nas bandas utilizadas é relevante para identificar áreas verdes. No entanto, como a maioria dos índices de vegetação, o TVI também pode ser afetado por fatores como a presença de sombras, nuvens e cobertura do solo, o que pode limitar sua precisão em algumas condições (Xing et al., 2019).

O índice MGVRI (Modified Green Vegetation Ratio Index) ou Índice de Razão de Vegetação Verde Modificada é um índice de vegetação utilizado em sensoriamento remoto para avaliar a saúde e a densidade da vegetação em uma determinada área. Ele é uma modificação de índices de vegetação tradicionais, como o NDVI (Normalized Difference Vegetation Index), com o objetivo de melhorar a sensibilidade em relação à vegetação e reduzir a influência de fundos não vegetados. Ao contrário do NDVI, o MGVRI não subtrai a reflectância na banda vermelha da reflectância no infravermelho próximo. Em vez disso, ele apenas divide o valor do infravermelho próximo pelo valor da banda verde e subtrai 1 do resultado. Essa modificação é feita para tornar o índice menos sensível a condições do solo e aumentar a sensibilidade à vegetação, melhorando a capacidade de detectar variações na saúde da vegetação. De acordo com Barbosa et al. (2019), MGRVI forneceu os melhores resultados em uma avaliação qualitativa da discriminação entre vegetação e solo, mas seu uso em imagens contendo regiões afetadas por sombras deve ser avaliado cuidadosamente.


O MGVRI é particularmente útil em áreas com vegetação densa e saudável, onde a resposta nas bandas utilizadas é relevante para identificar áreas verdes. No entanto, como qualquer índice de vegetação, o MGVRI também pode ser afetado por fatores como a presença de sombras, nuvens e cobertura do solo, o que pode limitar sua precisão em algumas condições.

O Índice de Vegetação de Diferença (DVI - Difference Vegetation Index) é um índice de vegetação usado em sensoriamento remoto para avaliar a saúde e a densidade da vegetação em uma área específica. O índice DVI representa a diferença entre a reflectância da vegetação na banda do infravermelho próximo e a reflectância na banda vermelha. Isso é útil porque a vegetação reflete mais luz no NIR devido à presença de clorofila nas folhas, enquanto a reflectância na banda vermelha é afetada por outros fatores além da vegetação. O DVI pode variar de -1 a +1, onde: Valores positivos indicam maior quantidade e saúde da vegetação. Valores negativos indicam menor quantidade de vegetação, como áreas com solo exposto ou superfícies não vegetadas. O índice DVI é utilizado em diversas aplicações, como monitoramento

da saúde de culturas agrícolas, detecção de desmatamento, avaliação da cobertura vegetal em ecossistemas naturais e estudos de mudanças no uso da terra (Lyon et al., 1998; Naji, 2018).

### 2.3 Resultados e Discussão

Os dados meteorológicos da estufa em que o experimento foi montado estão apresentados na Figura 8. Para temperatura, durante o período de estudo, a média foi de 27,74°C com um desvio padrão de 2,08°C. A temperatura mínima foi de 22,20°C e máxima de 31,00°C. Para umidade relativa do ar, foi obtida uma média de 67,36%, mínima de 58,65% e máxima de 85,81%. Os dados de umidade apresentam uma variação significativa ao longo do período analisado. Em contraste, a temperatura mostra uma variação mais estável. Isso sugere consistência nas condições térmicas ao longo do tempo.



**Figura 8.** Condições de temperatura e umidade do ar dentro da estufa.

Na Tabela 2, são apresentados os dados nutricionais das plantas de arroz após colheita. Os dados representam a concentração de vários nutrientes nas plantas dos diferentes tratamentos. O Fósforo (P), varia de 0,54 a 1,13 g.kg<sup>-1</sup>, com uma média de aproximadamente 0,90 g.kg<sup>-1</sup>. Mostra variabilidade entre os tratamentos, mas a média é relativamente consistente. Potássio (K) apresenta uma variação entre 5,45 e 10,34 g.kg<sup>-1</sup>, média em torno de 8,75 g.kg<sup>-1</sup>.

Com maior variação entre tratamentos. Cálcio (Ca) e Magnésio (Mg) apresentam variação, sendo Ca em torno de 4,14 a 6,99 g.kg<sup>-1</sup> e Mg de 2,46 a 4,05 g.kg<sup>-1</sup>.

Enxofre (S) varia entre 1,05 e 1,71 g.kg<sup>-1</sup>, com média em torno de 1,45 g.kg<sup>-1</sup>. Pouca variação entre os tratamentos. Boro (B), Cobre (Cu), Ferro (Fe), Manganês (Mn) e Zinco (Zn) apresentam valores específicos para cada tratamento, sem uma variação significativa aparente.

**Tabela 2.** Condições nutricionais das plantas após colheita.

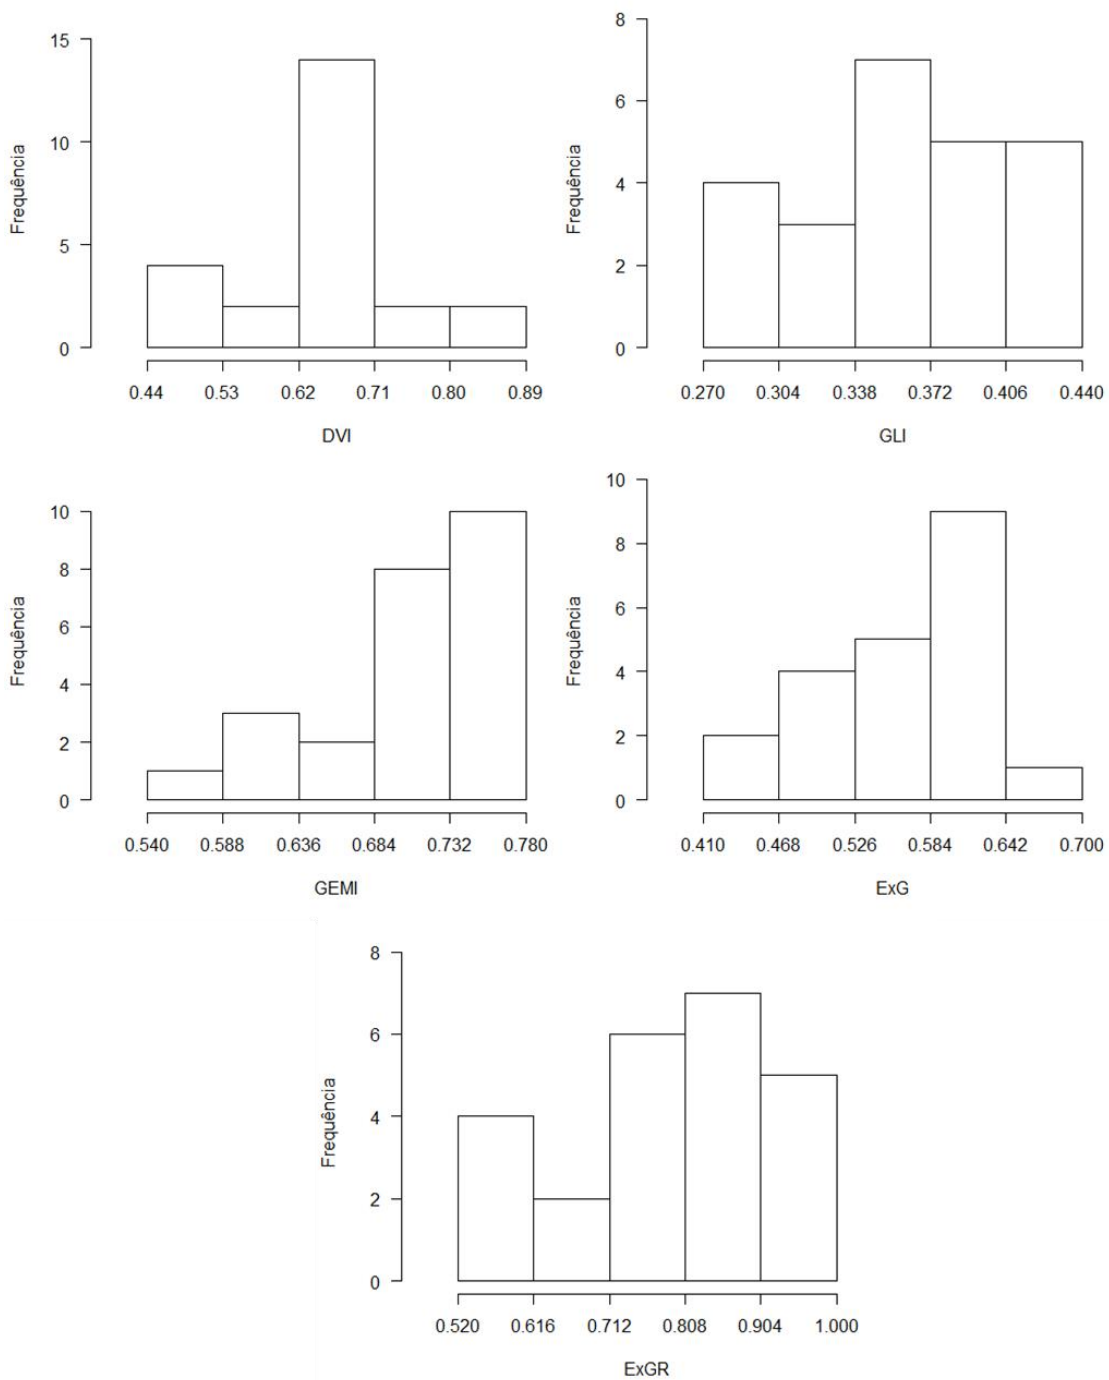
Tratamento	g.kg-1							mg.kg-1						
	N	P	K	Na	Ca	Mg	S	B	Cu	Fe	Mn	Zn	Mo*	Si*
D1S1	20,79	0,81	9,36	1,00	6,92	2,94	1,60	131,66	11,90	151,50	191,40	39,70	ns	ns
D1S2	19,61	0,99	9,36	1,00	6,64	2,46	1,45	138,26	17,40	119,00	218,20	37,60	ns	ns
D2S1	22,69	0,54	5,45	1,00	4,14	2,73	1,27	140,51	10,80	140,60	69,40	17,20	ns	ns
D2S2	17,20	0,95	8,38	1,00	6,99	3,21	1,38	119,93	18,20	164,40	154,50	39,10	ns	ns
D3S1	22,24	1,13	10,34	1,00	6,14	4,05	1,05	100,95	29,50	132,50	139,30	35,40	ns	ns
D3S2	24,57	1,04	8,38	1,00	5,44	2,62	1,71	91,47	16,20	125,20	126,00	38,50	ns	ns
D4S1	30,84	1,09	8,38	1,00	5,51	2,87	1,71	86,16	16,90	151,10	193,70	38,80	ns	ns
D4S2	26,86	1,10	10,34	0,00	4,98	2,50	1,52	74,58	16,30	169,50	213,00	38,70	ns	ns

\*Nota: Elementos com valores constantes "ns", indicando que não foram detectados ou estão abaixo do limite de detecção do método utilizado.

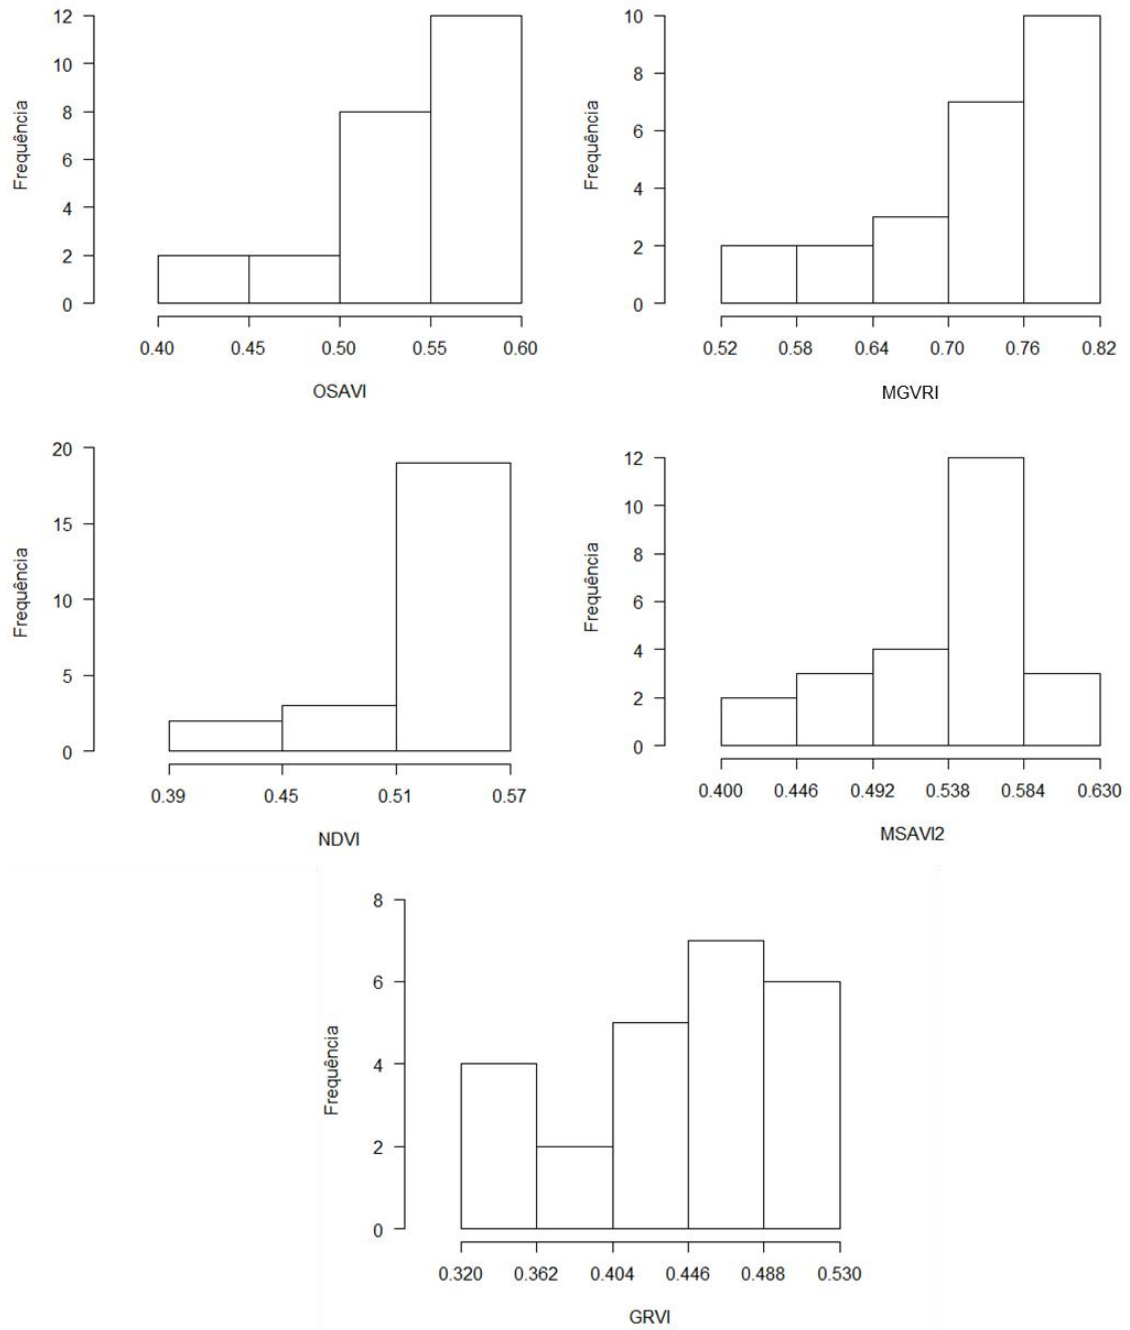
De acordo com os dados médios obtidos para cada tratamento, para os índices considerados com melhor desempenho neste estudo foram elaborados histogramas (Figuras 9, 10 e 11) para análise da faixa predominante de cada índice, independente dos tratamentos analisados, por não ocorrer diferença estatística entre os mesmos. Na análise dos diferentes índices de vegetação, foram obtidas médias e desvios padrão para cada parâmetro considerado. O DVI (Índice de Vegetação Diferencial) apresentou uma média de 0,65, com um desvio padrão de  $\pm 0,11$ . O GEMI (Índice de Vegetação Melhorado Global) registrou uma média de 0,71, com um desvio padrão de  $\pm 0,06$ . O ExG (Índice de Vegetação Excesso de Verde) exibiu uma média de 0,55, acompanhada de um desvio padrão de  $\pm 0,08$ . O GRVI (Índice de Vegetação Razão Verde-Vermelho) revelou uma média de 0,44, com um desvio padrão de  $\pm 0,06$ . Os valores médios de cada tratamento estão apresentados no Anexo A.

Analisando outros índices, o MSAVI2 (Índice de Vegetação Ajustado para Sombra Modificado) apresentou média de 0,54 e desvio padrão de  $\pm 0,06$ , enquanto o OSAVI (Índice de Vegetação Ajustado para Sombra Ótimo) registrou média de 0,53 e desvio padrão de  $\pm 0,05$ . O RGBVI (Índice de Vegetação Baseado em Cores RGB) teve média de 0,64 e desvio padrão de  $\pm 0,07$ , ao passo que o RVI (Índice de Vegetação Razão de Vermelho-Infravermelho) exibiu média de 0,33 e desvio padrão de  $\pm 0,06$ .

O NDVI (Índice de Vegetação da Diferença Normalizada) demonstrou média de 0,52 e desvio padrão de  $\pm 0,04$ , enquanto o VARI (Índice de Vegetação de Vermelho-Azul) apresentou média de 0,74 e desvio padrão de  $\pm 0,12$ . O ExGR (Índice de Vegetação Excesso de Verde-Vermelho) revelou uma média de 0,79, com um desvio padrão de  $\pm 0,13$ , e o MGVRI (Índice de Vegetação Modificado por Razão de Gradiente) teve média de 0,72, com um desvio padrão de  $\pm 0,08$ . Finalmente, o GLI (Índice de Iluminação Global) exibiu média de 0,36, com um desvio padrão de  $\pm 0,05$ , e o SAVI (Índice de Vegetação Ajustado para Sombra) registrou média de 0,55, com um desvio padrão de  $\pm 0,06$ . Esses resultados proporcionam uma visão detalhada das características espectrais nas áreas estudadas, refletindo a complexidade das condições ambientais e agrícolas.

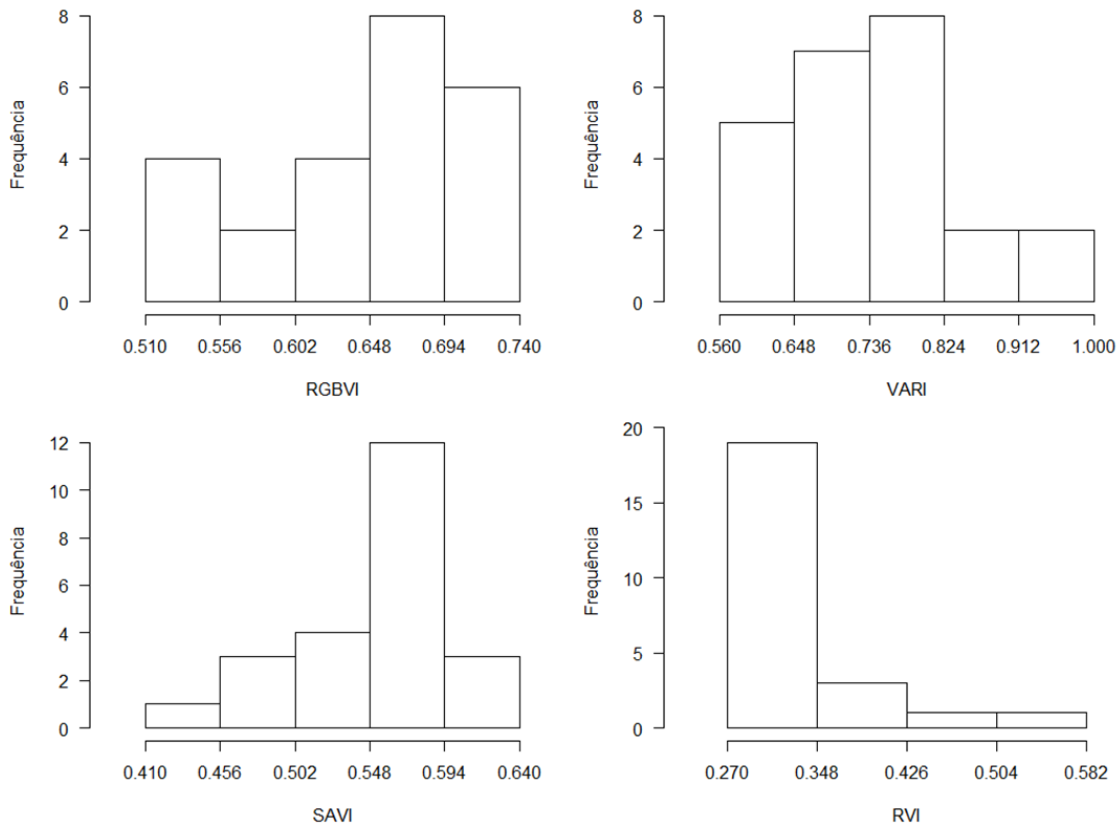


**Figura 9.** Histograma de frequências para os índices DVI, GLI, GEMI, ExG e ExGR.



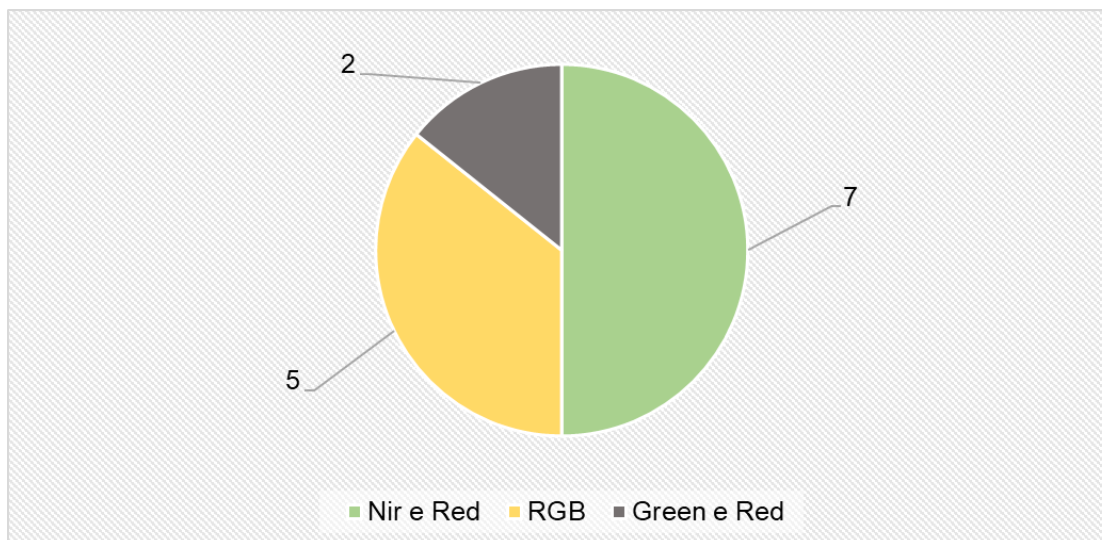
**Figura 10.** Histogramas de frequência para os índices OSAVI, MGARI, NDVI, MSAVI2 e GRVI.





**Figura 11.** Histogramas de frequência para os índices RGBVI, VARI, SAVI e RVI.

Com base em uma análise qualitativa (Figura 12), observamos que a combinação de bandas que utiliza as informações no espectro próximo ao infravermelho (NIR) e vermelho (Red) apresenta o maior número de índices com bom desempenho. Essa preferência destaca a importância dessas bandas na detecção de características específicas em imagens, como na análise de vegetação. A utilização dessas bandas, conhecidas por fornecer informações sobre a saúde e vigor vegetal, destaca-se pela capacidade de distinguir diferenças sutis no espectro eletromagnético. Em contraste, índices que dependem exclusivamente das bandas RGB, compostas por vermelho (Red), verde (Green) e azul (Blue), ou apenas das bandas Green e Red, apresentam um número menor, indicando uma menor relevância ou capacidade de discriminação para as características em questão. Isso sugere que, para a aplicação específica considerada, a inclusão do espectro próximo ao infravermelho contribui significativamente para o desempenho dos índices.



**Figura 12.** Análise qualitativa dos índices de vegetação com bom desempenho e suas respectivas bandas.

Observando os índices que não alcançaram o desempenho esperado, podemos identificar padrões nas bandas utilizadas em sua composição. Os valores médios dos índices para cada tratamento estão apresentados no Anexo B. O GNDVI, que emprega as bandas Green e Nir, e o NDRE, que utiliza as bandas Nir e Red Edge, podem ter enfrentado limitações na capacidade de discriminação devido à dependência de informações específicas desses espectros. Similarmente, o RI, construído a partir das bandas Green e Red, e o TVI, que utiliza as bandas Nir e Red Edge, podem ter sido afetados pela escolha dessas bandas, indicando uma possível limitação na distinção de características. O EVI, com a combinação de bandas Blue, Red, e Nir, também não alcançou o desempenho desejado, sugerindo que tal configuração espectral pode não ser a mais adequada para a aplicação considerada. Além disso, os índices ExB, ExR e MTCI, que incorporam as bandas Blue, Red, e Nir, Red e Green, e Red, respectivamente, podem ter sido impactados pela combinação específica desses espectros, evidenciando a sensibilidade do desempenho dos índices à escolha das bandas utilizadas em sua formulação. Essa análise ressalta a importância de considerar a interação entre bandas espectrais na concepção de índices de vegetação para garantir resultados mais robustos.

O índice EVI obteve uma média de 0,24 no presente estudo, abaixo do que foi obtido no estudo de Gurung et al. (2009), mostra uma média de valores máximos anuais do EVI em torno de 0,7, com variação aproximada de 0,42 a 0,82 para arroz.

Para o trabalho de Jackson e Huete (1991), os valores de NDVI para os dados são 0,86, 0,09 e 0,14 para trigo, solo seco e solo úmido, respectivamente. Para o algodão, os valores de

NDVI são 0,18 e 0,96 para Dias do Ano 130 e 225, respectivamente. O índice NDVI, analisado no estudo de Bhandari et al. (2020), alcançou valores médios, mínimos e máximos de 0,57, 0,39 e 0,7, respectivamente, para o cultivo de trigo.

O trabalho de Bhandari et al. (2020), mostra valores do índice GLI para folhas saudáveis e infectadas. A quantidade de luz refletida na região visível é significativamente diferente entre folhas infectadas por ferrugem e folhas saudáveis. Quando o teor de clorofila é reduzido na folha doente, a refletância é maior na região vermelha e menor na região verde do espectro. Essa variação pode ser capturada por câmeras RGB e posteriormente processada para desenvolver índices de vegetação. Um índice de vegetação comumente usado derivado de sensores RGB é o índice GLI. Os valores do GLI variam de -1 a +1. Valores de GLI negativos representam objetos não vivos, enquanto os valores positivos representam folhas e caules verdes. A refletância observada na banda vermelha, um dos principais componentes do GLI, pode desempenhar um papel vital na separação entre o dossel de trigo saudável e o infectado por ferrugem. O trabalho obteve os valores médios, mínimos e máximos de 0,14, 0,01 e 0,25, respectivamente, para o índice GLI.

O trabalho de Mahmud et al. (2023), em experimentos preliminares, apresentou valores para os índices ExB, NDVI e GNDVI, que demonstraram ser mais sensíveis à doença de fogo bacteriano. Esses índices foram projetados para avaliar a verdura da vegetação, na qual a infecção pela doença altera a quantidade de verdura nas copas das árvores. As relações entre os índices de vegetação e a infecção por fogo bacteriano foram únicas, especialmente nos índices calculados usando o canal azul. Seis índices foram calculados a partir das copas saudáveis e infectadas. O valor do NDVI e GNDVI variou de 0 a 1. O valor do índice ExB variou de 0 a 2 porque o índice foi calculado usando o canal azul multiplicado por 2. Os índices mostraram uma diferença significativa entre as copas saudáveis e as infectadas por fogo bacteriano.

A média de ExB para a vegetação saudável ficou na faixa de 0,7 e vegetação infectada de 1,6. Para NDVI, foi de 0,67 para vegetação sadia e 0,45 para vegetação infectada. O índice GNDVI apresentou valores de 0,63 para vegetação sadia e 0,4 para vegetação infectada.

O estudo conduzido por Boiarskii e Hasegawa (2019) tem como foco a comparação entre os índices NDVI (Normalized Difference Vegetation Index) e NDRE (Normalized Difference Red Edge) na detecção de variações na vegetação e no teor de clorofila. Na análise da imagem com o índice NDRE, os pesquisadores identificaram leituras mais baixas em áreas onde a aplicação de nitrogênio foi menor. O NDRE possibilitou a detecção de um canteiro de mudas de

cedro com baixo teor de clorofila, indicando limitação de nitrogênio nas folhas, enquanto o NDVI não apresentou tal indicação.

O estudo propõe que diferentes índices, como NDVI e NDRE, podem ser mais adequados para diferentes culturas, densidades de plantio, taxas de semeadura e estágios de crescimento. Na imagem NDRE, as leituras mais baixas associadas à menor aplicação de nitrogênio são explicadas pela limitação da penetração da luz vermelha além de algumas camadas de células foliares. Destaca-se que as folhas são mais translúcidas à luz do rededge do que à luz vermelha, sendo que o comprimento de onda red edge penetra mais profundamente nas folhas em comparação com as faixas de luz vermelha.

Ainda com base no estudo de Boiarskii e Hasegawa (2019), NDRE se mostra mais apropriado para estágios médios e tardios de crescimento das culturas, quando estas acumulam concentrações mais elevadas de clorofila nas folhas e a luz vermelha penetra de forma menos eficiente. A pesquisa destaca a sensibilidade diferenciada dos índices NDVI e NDRE na detecção de variações na vegetação e no teor de clorofila, proporcionando informações precisas para a escolha e interpretação adequada desses índices em contextos específicos. No caso do presente estudo, o NDRE não conseguiu representar bem as condições analisadas.

Para análise em plantas com pouca área de cobertura das folhas, ou seja, menor densidade de área foliar, o método de coleta no presente estudo mostrou-se eficiente, mas existem algumas ressalvas, como por exemplo:

- Plantas jovens com folhas finas apresentam desafios significativos na coleta de dados, devido à delicadeza das folhas. Isso ressalta a importância de técnicas não invasivas e métodos adaptados para minimizar danos durante a coleta de dados em plantas em estágios iniciais de crescimento.
- O comportamento das folhas em resposta ao estresse hídrico é um fenômeno natural, mas que complica a coleta de dados. O fechamento das folhas durante o estresse hídrico destaca a necessidade de considerar o estado fisiológico da planta ao planejar a coleta de dados, especialmente em estudos relacionados ao status hídrico das plantas.
- Durante a fase de formação de panículas, a densidade foliar aumenta, levando a sombreamento e sobreposição de folhas. Esse desafio destaca a importância de considerar a arquitetura da planta ao planejar a coleta de dados, bem como a possibilidade de utilizar técnicas de processamento de imagem para mitigar os efeitos de sobreposição.

- A fase vegetativa é identificada como o período mais propício para a coleta de dados precisos. A transição para a fase reprodutiva torna a coleta de dados significativamente mais difícil. Isso ressalta a necessidade de realizar coletas de dados sensíveis ao tempo para garantir a precisão e relevância dos resultados.
- A estratégia de selecionar menos pontos e concentrar a coleta em uma mesma folha da planta é uma abordagem prática para melhorar a qualidade dos dados. Esse enfoque pode minimizar a variabilidade intra-planta e fornecer dados mais consistentes e confiáveis.
- A variação na coleta de dados da banda térmica, dependendo da fase do ciclo de vida da planta, destaca a importância de considerar as condições sazonais e as características específicas da planta ao planejar estudos que envolvem dados térmicos.

A arquitetura do dossel alvo influencia na qualidade dos índices de vegetação. No caso do cultivo de arroz, a escolha por selecionar pixels dentro de uma folha e não da área de visada, foi devido à quantidade de sombra, dobras de folhas e sobreposições que ocorrem na planta. A partir da formação de perfilhos e após, as panículas, aumentou ainda mais a sobreposição na planta e dificuldade de captura de valores para os índices.

A arquitetura de um dossel vegetal determina as direções em que a radiação será refletida pelas superfícies das plantas. Os elementos verticais de um dossel erectófilo retêm a radiação refletida dentro do dossel, com uma redução correspondente na quantidade refletida verticalmente em direção a um radiômetro orientado para o nadir. O oposto é verdadeiro para um dossel planófilo. As folhas horizontais refletem mais na direção vertical e menos é retido dentro do dossel. Um sensor apontado para o nadir pode receber 20-30% mais radiação refletida de um dossel planófilo do que de um dossel erectófilo (Jackson e Huete, 1991).

Dentro de uma cena que contém quantidades semelhantes de vegetação, mas geometrias diferentes, diferentes índices de vegetação (IV) responderão de maneira diferente à arquitetura do dossel. À primeira vista, esse recurso complicador diminuiria o valor do (IV). Na verdade, ele adiciona uma nova perspectiva que poderia ser explorada para fornecer informações de outra forma inacessíveis sobre características arquitetônicas do dossel dentro de uma cena (Jackson e Huete, 1991).

Considerando os dados de grãos abortados (Tabela 3), os resultados da análise de variância revelam diferenças significativas entre os tratamentos, com um valor de  $F_c$  de 14.6735 e um  $p$ -valor de 0.000, indicando que pelo menos um dos tratamentos tem uma média significativamente diferente dos outros. O teste de blocos não mostrou diferenças significativas,

sugerindo que a variabilidade observada pode ser atribuída principalmente aos tratamentos. O coeficiente de variação (CV) de 68.14% indica uma considerável variabilidade nos dados.

**Tabela 3.** Resultados dos testes de comparação de médias LSD, Bonferroni, Tukey e Duncan para a quantidade de grãos abortados por tratamento.

Tratamentos	Médias
D1S1	1,4a
D1S2	3,8a
D2S1	5,4b
D2S2	17,4b
D3S1	13,4b
D3S2	24,8b
D4S1	80,8b
D4S2	76,5b

Nota: Grupos com a mesma letra indicam que as médias correspondentes não são significativamente diferentes entre si. Grupos com letras diferentes, apresentam médias significativamente diferentes entre si.

Os testes de normalidade dos resíduos indicam que, a um nível de significância de 5%, os resíduos não seguem uma distribuição normal. No entanto, o teste de homogeneidade de variância sugere que as variações são homogêneas entre os tratamentos, conforme indicado pelo valor-p de 0.2832155.

Esses resultados indicam uma relação significativa entre a quantidade de sal na água de irrigação e a ocorrência de grãos de arroz abortados. A interpretação prática é que doses mais altas de sal podem estar contribuindo para um aumento na taxa de aborto de grãos de arroz. Isso pode ter implicações importantes para a prática agrícola, destacando a sensibilidade do desenvolvimento dos grãos de arroz à concentração de sal na água de irrigação e sugerindo que a redução da dose de sal pode ser benéfica para minimizar a ocorrência de grãos abortados.

Os resultados da análise estatística da condutividade elétrica da solução do substrato em diferentes tratamentos (Tabela 4), indicam diferenças significativas entre os grupos, conforme evidenciado pelo valor de Fc significativo (4.8966) no quadro da análise de variância (ANOVA). A significância do tratamento é reforçada pelo teste de bloco, que revela diferenças entre os blocos, além da variabilidade observada nos tratamentos. O coeficiente de variação (CV) de 36.84% indica uma moderada variabilidade nos dados.

**Tabela 4.** Resultados dos testes de comparação de médias LSD, Bonferroni, Tukey e Duncan para a condutividade elétrica da solução obtida do substrato de casa vaso com os tratamentos.

Tratamentos	Médias (Bonferroni e Tukey)	Médias (LSD e Duncan)
D1S1	0,4072(b)	0,4072(d)
D1S2	0,4388(b)	0,4388(d)
D2S1	0,6810(ab)	0,6810(cd)
D2S2	0,6924(ab)	0,6924(bcd)
D3S1	0,6192(ab)	0,6192(cd)
D3S2	0,8256(ab)	0,8256(abc)
D4S1	1,1714(a)	1,1714(a)
D4S2	1,0326(a)	1,0326(ab)

Nota: Grupos com a mesma letra indicam que as médias correspondentes não são significativamente diferentes entre si. Grupos com letras diferentes, apresentam médias significativamente diferentes entre si.

Os testes de normalidade dos resíduos e homogeneidade de variância atestam que os pressupostos da ANOVA são atendidos, pois os resíduos podem ser considerados normais, e as variâncias são homogêneas entre os tratamentos. Isso fortalece a confiabilidade das conclusões extraídas dos testes de comparação de médias.

Os testes t de LSD, Bonferroni, Tukey e Duncan identificam grupos de tratamentos com médias estatisticamente diferentes. Por exemplo, no teste de Tukey, os tratamentos D4S1 e D4S2 são agrupados como "a", indicando que suas médias não são estatisticamente diferentes entre si, mas são diferentes dos demais tratamentos agrupados como "ab".

## 2.4 Conclusões

Com base na análise dos dados apresentados, pode-se concluir que diferentes índices de vegetação respondem de maneira distinta às condições ambientais e agrícolas, refletindo a complexidade das características espectrais das áreas estudadas. Os índices que combinam informações do espectro próximo ao infravermelho (NIR) e vermelho (Red) apresentam um desempenho superior, destacando a importância dessas bandas na detecção de características específicas da vegetação, como saúde e vigor vegetal. Por exemplo, o VARI (Índice de Vegetação de Vermelho-Azul) registrou uma média significativamente alta de 0,74, com um desvio padrão de  $\pm 0,12$ , indicando sua eficácia na avaliação da saúde da vegetação. Em contraste, índices que dependem exclusivamente das bandas RGB ou de combinações específicas dessas bandas, como o RI (Índice de Vegetação Razão de Vermelho-Infravermelho) com média de 0,33,

demonstraram um desempenho inferior. Essa diferença sugere que a inclusão do espectro próximo ao infravermelho contribui significativamente para o desempenho dos índices de vegetação, fornecendo informações mais precisas e abrangentes sobre as condições da vegetação analisada.

Além disso, os resultados destacam a sensibilidade dos índices de vegetação à escolha das bandas espectrais utilizadas em sua formulação, com alguns índices mostrando desempenho abaixo do esperado devido à dependência de informações específicas desses espectros. Isso ressalta a importância de considerar a interação entre as bandas espectrais na concepção de índices de vegetação para garantir resultados mais robustos e precisos.

A análise estatística dos dados relacionados à quantidade de grãos abortados e à condutividade elétrica da solução do substrato sugere uma relação significativa entre a concentração de sal na água de irrigação e a ocorrência de grãos abortados, bem como diferenças significativas entre os tratamentos em relação à condutividade elétrica. Esses resultados têm implicações importantes para a prática agrícola, indicando que a redução da dose de sal na água de irrigação pode ser benéfica para minimizar a ocorrência de grãos abortados e melhorar a qualidade das plantas cultivadas.

Em suma, os dados analisados permitem uma compreensão sobre a resposta dos índices de vegetação a diferentes condições e destacam a importância de considerar uma variedade de fatores, incluindo a escolha das bandas espectrais e as práticas de manejo agrícola, para interpretar com precisão as informações obtidas por meio de sensoriamento remoto e promover uma agricultura mais eficiente e sustentável.

## Referências

- Ahmad, F. (2012). Spectral vegetation indices performance evaluated for Cholistan Desert. *J. Geogr. Res. Plan*, 5(6), 165-172.
- Bannari, A., Morin, D., Bonn, F., & Huete, A. (1995). A review of vegetation indices. *Remote sensing reviews*, 13(1-2), 95-120.
- Barbosa, B. D. S., Ferraz, G. A. S., Gonçalves, L. M., Marin, D. B., Maciel, D. T., Ferraz, P. F. P., & Rossi, G. (2019). RGB vegetation indices applied to grass monitoring: A qualitative analysis.
- Bhandari, M., Ibrahim, A. M., Xue, Q., Jung, J., Chang, A., Rudd, J. C., ... & Landivar, J. (2020). Assessing winter wheat foliage disease severity using aerial imagery acquired from small Unmanned Aerial Vehicle (UAV). *Computers and Electronics in Agriculture*, 176, 105665.



- Boiarskii, B., & Hasegawa, H. (2019). Comparison of NDVI and NDRE indices to detect differences in vegetation and chlorophyll content. *J. Mech. Contin. Math. Sci*, 4, 20-29.
- Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote sensing*, 7(4), 4026-4047.
- Das, B., Sahoo, R. N., Pargal, S., Krishna, G., Gupta, V. K., Verma, R., & Viswanathan, C. (2016). Measuring leaf area index from colour digital image of wheat crop. *Journal of Agrometeorology*, 18(1), 22-28.
- Dash, J., & Curran, P. J. (2007). Evaluation of the MERIS terrestrial chlorophyll index (MTCI). *Advances in Space Research*, 39(1), 100-104.
- González, E., Núñez, C., Salinas, J., Rodas, J., Rodas, M., Paiva, E., ... & Rodríguez-Piñeiro, J. (2021). Analysis and Application of Multispectral Image Processing Techniques Applied to Soybean Crops from Drones Vision System. In *ICINCO* (pp. 707-715).
- Gurung, R. B., Breidt, F. J., Dutin, A., & Ogle, S. M. (2009). Predicting Enhanced Vegetation Index (EVI) curves for ecosystem modeling applications. *Remote Sensing of Environment*, 113(10), 2186-2193.
- Jackson, R. D., & Huete, A. R. (1991). Interpreting vegetation indices. *Preventive Veterinary Medicine*, 11(3-4), 185-200.
- Lee, G., Hwang, J., & Cho, S. (2021). A novel index to detect vegetation in urban areas using UAV-based multispectral images. *Applied Sciences*, 11(8), 3472.
- Lyon, J. G., Yuan, D., Lunetta, R. S., & Elvidge, C. D. (1998). A change detection experiment using vegetation indices. *Photogrammetric engineering and remote sensing*, 64(2), 143-150.
- Mahmud, M. S., He, L., Zahid, A., Heinemann, P., Choi, D., Krawczyk, G., & Zhu, H. (2023). Detection and infected area segmentation of apple fire blight using image processing and deep transfer learning for site-specific management. *Computers and Electronics in Agriculture*, 209, 107862.
- Malavolta, E., Vitti, G. C., & Oliveira, S. A. D. (1997). Avaliação do estado nutricional das plantas: princípios e aplicações.
- Meyer, G. E., & Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and electronics in agriculture*, 63(2), 282-293.
- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of green-red vegetation index for remote sensing of vegetation phenology. *Remote Sensing*, 2(10), 2369-2387.
- Naji, T. A. (2018). Study of vegetation cover distribution using DVI, PVI, WDVI indices with 2D-space plot. In *Journal of physics: conference series* (Vol. 1003, p. 012083). IOP Publishing.

- Paliwal, A., Laborte, A., Nelson, A., & Singh, R. K. (2019). Salinity stress detection in rice crops using time series MODIS VI data. *International journal of remote sensing*, 40(21), 8186-8202.
- Pareek, A., Dhankher, O. P., & Foyer, C. H. (2020). Mitigating the impact of climate change on plant productivity and ecosystem sustainability. *Journal of Experimental Botany*, 71(2), 451-456.
- Pilaš, I., Gašparović, M., Novkinić, A., & Klobučar, D. (2020). Mapping of the canopy openings in mixed beech–fir forest at Sentinel-2 subpixel level using UAV and machine learning approach. *Remote Sensing*, 12(23), 3925.
- Raij, B. V. (2011). Soil Fertility and Nutrient Management= Fertilidade do Solo e Manejo de Nutrientes. *International Plant Nutrition Institute, Piracicaba, SP, Brazil (in Portuguese)*.
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote sensing of environment*, 55(2), 95-107.
- Thompson, C. N., Guo, W., Sharma, B., & Ritchie, G. L. (2019). Using normalized difference red edge index to assess maturity in cotton. *Crop Science*, 59(5), 2167-2177.
- Warncke, D. D. (1986). Analyzing greenhouse growth media by the saturation extraction method. *HortScience*, 21(2), 223-225.
- Xing, N., Huang, W., Xie, Q., Shi, Y., Ye, H., Dong, Y., ... & Jiao, Q. (2019). A transformed triangular vegetation index for estimating winter wheat leaf area index. *Remote Sensing*, 12(1), 16.
- Zhang, L., Zhang, H., Han, W., Niu, Y., Chávez, J. L., & Ma, W. (2021). The mean value of gaussian distribution of excess green index: A new crop water stress indicator. *Agricultural Water Management*, 251, 106866.

**Anexo A. Valores médios de cada tratamento para os índices de vegetação considerados com bom desempenho no trabalho**

Data de coleta	Tratamento	DVI	GEMI	ExG	GRVI	MSAVI2	OSAVI	RGBVI	RVI	NDVI	VARI	ExGR	MGVRI	GLI	RGBVI	SAVI
30/dez	D1S1	0,7	0,63	0,62	0,47	0,55	0,53	0,69	0,32	0,51	0,75	0,88	0,76	0,4	0,69	0,55
	D1S2	0,65	0,73	0,51	0,43	0,55	0,54	0,59	0,31	0,53	0,71	0,74	0,71	0,33	0,59	0,56
	S2S1	0,5	0,71	0,41	0,36	0,48	0,48	0,52	0,36	0,48	0,67	0,57	0,62	0,27	0,52	0,48
	D2S2	0,63	0,68	0,55	0,43	0,52	0,52	0,64	0,33	0,51	0,71	0,79	0,71	0,36	0,64	0,53
	D3S1	0,54	0,7	0,46	0,42	0,49	0,49	0,58	0,35	0,48	0,8	0,67	0,71	0,31	0,58	0,49
	D3S2	0,47	0,7	0,41	0,32	0,4	0,4	0,51	0,58	0,39	0,59	0,52	0,52	0,27	0,51	0,42
	D4S1	0,66	0,76	0,55	0,44	0,57	0,55	0,65	0,3	0,54	0,76	0,79	0,74	0,36	0,65	0,57
	D4S2	0,59	0,74	0,56	0,45	0,53	0,52	0,65	0,32	0,51	0,78	0,8	0,75	0,37	0,65	0,54
18/dez	D1S1	0,63	0,77	0,62	0,47	0,56	0,55	0,69	0,3	0,54	0,75	0,89	0,77	0,4	0,69	0,56
	D1S2	0,64	0,69	0,6	0,45	0,53	0,53	0,67	0,32	0,52	0,69	0,85	0,73	0,39	0,67	0,54
	S2S1	0,69	0,76	0,64	0,47	0,58	0,57	0,71	0,29	0,55	0,72	0,91	0,77	0,41	0,71	0,59
	D2S2	0,63	0,78	0,59	0,41	0,56	0,55	0,65	0,3	0,54	0,63	0,81	0,69	0,38	0,65	0,57
	D3S1	0,76	0,75	0,63	0,49	0,61	0,59	0,7	0,27	0,57	0,79	0,92	0,78	0,41	0,7	0,62
	D3S2	0,68	0,74	0,64	0,48	0,57	0,56	0,7	0,29	0,55	0,76	0,92	0,77	0,41	0,7	0,58
	D4S1	0,68	0,64	0,64	0,46	0,52	0,51	0,7	0,35	0,5	0,69	0,9	0,75	0,41	0,7	0,54
	D4S2	0,7	0,74	0,7	0,5	0,58	0,56	0,74	0,29	0,55	0,74	1	0,79	0,44	0,74	0,59
08/dez	D1S1	0,47	0,78	0,41	0,33	0,49	0,50	0,52	0,33	0,51	0,56	0,55	0,59	0,28	0,52	0,49
	D1S2	0,63	0,74	0,52	0,39	0,55	0,54	0,61	0,30	0,53	0,62	0,72	0,67	0,34	0,61	0,56
	S2S1	0,67	0,73	0,50	0,39	0,56	0,55	0,61	0,31	0,53	0,65	0,70	0,68	0,33	0,61	0,57
	D2S2	0,89	0,62	0,56	0,51	0,63	0,60	0,67	0,28	0,57	0,95	0,84	0,80	0,37	0,67	0,64
	D3S1	0,82	0,59	0,61	0,53	0,59	0,56	0,71	0,30	0,54	0,91	0,92	0,82	0,40	0,71	0,60
	D3S2	0,70	0,73	0,51	0,50	0,57	0,55	0,64	0,31	0,53	1,00	0,78	0,79	0,34	0,64	0,58
	D4S1	0,71	0,71	0,55	0,49	0,57	0,55	0,66	0,30	0,54	0,90	0,82	0,79	0,36	0,66	0,58
	D4S2	0,44	0,54	0,45	0,34	0,41	0,41	0,54	0,45	0,41	0,57	0,59	0,55	0,30	0,54	0,41

**Anexo B. Médias dos índices com baixo desempenho ou valores fora da faixa normal -1 A 1.**

Tratamento	Data	Índices							
		GNDVI	NDRE	RI	TVI	EVI	ExB	ExR	MTCI
D1S1	08/12/2022	0,12	-0,16	-0,44	1,02	0,24	-0,09	-0,23	-0,35
	18/12/2022	0,08	-0,16	-0,47	1,02	0,25	-0,17	-0,27	-0,35
	30/12/2022	0,06	-0,12	-0,47	1,01	0,24	-0,17	-0,26	-0,28
D1S2	08/12/2022	0,10	-0,18	-0,46	1,02	0,24	-0,11	-0,25	-0,38
	18/12/2022	0,09	-0,15	-0,45	1,01	0,24	-0,16	-0,25	-0,33
	30/12/2022	0,11	-0,16	-0,43	1,01	0,23	-0,08	-0,23	-0,34
D2S1	08/12/2022	0,10	-0,14	-0,48	1,03	0,25	-0,11	-0,27	-0,29
	18/12/2022	0,11	-0,17	-0,47	1,03	0,27	-0,19	-0,27	-0,35
	30/12/2022	0,14	-0,15	-0,36	0,99	0,21	-0,03	-0,16	-0,34
D2S2	08/12/2022	0,09	-0,18	-0,39	0,98	0,20	-0,06	-0,18	-0,43
	18/12/2022	0,16	-0,14	-0,41	1,02	0,28	-0,17	-0,22	-0,29
	30/12/2022	0,09	-0,17	-0,43	1,01	0,23	-0,13	-0,23	-0,34
D3S1	08/12/2022	0,11	-0,18	-0,46	1,02	0,24	-0,08	-0,24	-0,37
	18/12/2022	0,11	-0,16	-0,49	1,04	0,28	-0,16	-0,28	-0,33
	30/12/2022	0,08	-0,17	-0,42	0,99	0,20	-0,05	-0,21	-0,38
D3S2	08/12/2022	0,11	-0,17	-0,42	1,01	0,22	-0,09	-0,22	-0,36
	18/12/2022	0,09	-0,16	-0,48	1,02	0,26	-0,18	-0,28	-0,35
	30/12/2022	0,10	-0,18	-0,32	0,92	0,18	-0,08	-0,12	-0,58
D4S1	08/12/2022	0,10	-0,18	-0,37	0,97	0,20	-0,09	-0,17	-0,43
	18/12/2022	0,06	-0,20	-0,46	1,00	0,24	-0,19	-0,26	-0,40
	30/12/2022	0,13	-0,14	-0,44	1,02	0,25	-0,12	-0,24	-0,32
D4S2	08/12/2022	0,12	-0,19	-0,46	1,02	0,24	-0,09	-0,24	-0,38
	18/12/2022	0,07	-0,18	-0,50	1,02	0,27	-0,22	-0,30	-0,37
	30/12/2022	0,08	-0,16	-0,45	1,01	0,23	-0,12	-0,25	-0,35



### 3. MONITORAMENTO DAS CONDIÇÕES DO CULTIVO DE *Megathyrsus maximus* (SYN. *Panicum maximum* JACQ.) CV. MOMBAÇA POR ÍNDICES MULTIESPECTRAIS

#### Resumo

O presente estudo aborda o monitoramento do cultivo de *Megathyrsus maximus* cv. Mombaça, por meio de índices multiespectrais obtidos por imagens de drones. O estudo utilizou um drone equipado com câmera multiespectral para capturar imagens da área de cultivo. Os resultados mostram comportamento dos índices após o corte da vegetação, refletindo respostas fisiológicas e fenológicas das plantas. Após o corte da vegetação, houve uma diminuição significativa nos valores dos índices de vegetação, refletindo a resposta fisiológica das plantas ao estresse mecânico e à perda de biomassa. Os índices de vegetação apresentaram uma recuperação gradual à medida que a vegetação se regenerou ou novas plantas cresceram após o corte. Alguns índices, como GNDVI e NDRE, destacaram-se como indicadores robustos, mostrando forte relação com o conteúdo de água no solo. A presença de biomassa remanescente e a exposição do solo influenciaram a variação nos índices de vegetação, especialmente aqueles sensíveis à presença do solo. Índices como ExG, ExGR, GNDVI, NDRE, TVI, NDVI e a Temperatura do Dossel mostraram correlações consistentemente elevadas com a altura das plantas. Os índices de vegetação variaram ao longo do tempo, refletindo diferentes fases do ciclo de crescimento das plantas, como a fase de senescência pós-corte, regeneração ativa e aumento na área foliar e atividade fotossintética.

**Palavras-chave:** 1. Índice de vegetação 2. Imagens Multiespectrais 3. Altum Micasense 4. Drone.

#### Abstract

#### **Monitoring of *Megathyrsus maximus* (Syn. *Panicum maximum* Jacq.) cv. Mombaça crop conditions through multispectral indices**

This study addresses the monitoring of *Megathyrsus maximus* cv. Mombaça cultivation using multispectral indices obtained from drone imagery. A drone equipped with a multispectral camera was employed to capture images of the cultivation area. The results illustrate the behavior of indices post-vegetation cutting, reflecting physiological and phenological responses of the plants. Following vegetation cutting, there was a significant decrease in vegetation index values, reflecting the physiological response of plants to mechanical stress and biomass loss. Vegetation indices exhibited a gradual recovery as vegetation regenerated or new plants grew after cutting. Certain indices, such as GNDVI and NDRE, stood out as robust indicators, showing a strong relationship with soil water

content. The presence of residual biomass and soil exposure influenced the variation in vegetation indices, particularly those sensitive to soil presence. Indices like ExG, ExGR, GNDVI, NDRE, TVI, NDVI, and Canopy Temperature consistently demonstrated high correlations with plant height. Vegetation indices varied over time, reflecting different phases of the plant growth cycle, such as post-cut senescence, active regeneration, and increases in leaf area and photosynthetic activity.

**Keywords:** 1. Vegetation Index 2. Multispectral Images 3. Altum Micasense 4. Drone.

### **3.1 Introdução**

O monitoramento das condições do cultivo de pastagens por índices multiespectrais é uma prática valiosa e eficaz para avaliar o estado de saúde e desenvolvimento dessa espécie forrageira. O uso de índices multiespectrais, obtidos a partir de imagens de satélite ou drones, permite a análise precisa e contínua de diversos parâmetros, como a densidade vegetal, a cobertura do solo e a distribuição de biomassa. Além disso, esses índices possibilitam a detecção precoce de estresses hídricos, deficiências nutricionais e ataques de pragas, permitindo a tomada de medidas corretivas de forma rápida e direcionada. Com base nessa abordagem, os produtores podem otimizar o manejo do cultivo de pastagens, garantindo maior produtividade, sustentabilidade e rentabilidade ao sistema agropecuário.

O estudo de Bayaraa et al. (2022) ressalta que a aplicação da tecnologia de sensoriamento remoto na estimativa da biomassa de pastagens representa um avanço significativo no campo da agropecuária de precisão. Ao fornecer informações detalhadas em alta resolução espacial e temporal, esses métodos permitem uma análise mais abrangente e precisa do estado de saúde das pastagens, contribuindo para o aprimoramento do manejo agrícola. Com a utilização de imagens de satélite, drones e medições em solo, os pesquisadores podem obter dados em diferentes escalas, possibilitando uma compreensão mais completa das variações espaciais e temporais da biomassa vegetal. Os índices de vegetação, por sua vez, desempenham um papel crucial nesse processo, pois fornecem métricas sensíveis e confiáveis para avaliar a cobertura vegetal e identificar possíveis áreas de degradação ou crescimento excedente. Assim, a aplicação conjunta de tecnologias de sensoriamento remoto e índices de vegetação representa uma abordagem promissora para aprimorar o monitoramento e a gestão sustentável de pastagens em diferentes contextos ambientais.

A agricultura de precisão é um sistema de gerenciamento agrícola baseado em informações e tecnologia, que visa melhorar a eficiência da produção de culturas ajustando insumos agrícolas, como sementes, fertilizantes e pesticidas, às condições específicas de cada área do campo. Essa tecnologia tem algumas décadas e recebeu diferentes denominações, tais como agricultura por tipo de solo, agricultura prescritiva espacial, agricultura assistida por computador, agricultura por satélite, agricultura sustentável de alta tecnologia, tecnologia de taxa variável, manejo de culturas específico para o local e manejo preciso de culturas. A agricultura de precisão oferece oportunidades para explorar os sítios de acordo com suas capacidades específicas (Metternicht, 2003).

A avaliação das condições de vegetação em paisagens agrícolas pode auxiliar na correção de condições de estresse ou degradação precoce nas plantas, reduzindo assim o impacto nas perdas de rendimento e qualidade das colheitas. Áreas problemáticas (como deficiência de fertilizantes, presença de ervas daninhas, variações nas propriedades do solo) podem ser facilmente identificadas e localizadas nas imagens de vídeo aprimoradas ou por meio de análises multi-temporais. Em seguida, os locais podem ser visitados para identificar as causas da variabilidade do local, permitindo a adoção de decisões oportunas sobre as práticas de manejo adequadas para corrigir o problema (Metternicht, 2003).

Segundo o estudo conduzido por Tong et al. (2019), o sensoriamento remoto hiperespectral é amplamente reconhecido como uma ferramenta robusta e versátil para a amostragem contínua e a seleção de bandas espectrais em diversas áreas específicas, incluindo extração de produtos agrícolas, monitoramento de nutrientes, segurança alimentar, avaliação do ecossistema e orientação de práticas agrícolas. As vantagens dessa técnica incluem a alta correlação entre as características de reflectância espectral e os parâmetros da vegetação, além da coleta ágil e repetível de dados sem prejudicar a vegetação, o que a torna uma abordagem promissora para a estimativa da biomassa acima do solo (AGB). A quantificação da AGB e a análise da sua distribuição espacial durante o período de pico fornecem informações valiosas para subsidiar o manejo da colheita de pastagens. É importante destacar que mesmo em escalas reduzidas, a variação espacial da AGB ainda se manifesta e é perceptível em biomas de pastagem. Dado o desafio decorrente da complexa relação entre a reflectância espectral e a AGB, é essencial utilizar plenamente os dados hiperespectrais, incluindo os índices de vegetação e derivados obtidos por meio de sensores hiperespectrais.



A resposta espectral das pastagens é difícil de compreender devido à sua dependência de diversos fatores, como a combinação de espécies, tipo de solo ou precipitação, o que torna extremamente complexo classificar a degradação das pastagens usando índices de vegetação. No entanto, vários autores têm utilizado sensores orbitais para analisar e mapear variações espaciais e temporais em campos de pastagens utilizando esses indicadores. O Índice de Vegetação por Diferença Normalizada (NDVI) foi o indicador mais amplamente utilizado. Outros índices frequentemente utilizados incluem o Índice de Vegetação Melhorado (EVI), o Índice de Vegetação Ajustado ao Solo (SAVI), o Índice de Área Foliar (LAI), a Eficiência do Uso de Água (WUE), a Produtividade Primária Líquida (NPP), entre outros. Muitos autores também têm aplicado sensores de espectro visível (RGB) para quantificar e mapear indicadores do estado biofísico das plantas, como a biomassa acima do solo, o vigor das plantas, a produtividade e o LAI. Outros estudos indicaram o uso do índice de vegetação baseado nas cores do espectro visível e o índice de excesso de verde para diagnosticar a cobertura vegetal. Por outro lado, o índice de folhas verdes mostrou-se eficiente para contar plantas, distinguir a biomassa vegetal do solo e dos resíduos, monitorar a fração de vegetação e estimar o LAI, bem como indicadores-chave de crescimento do arroz. O uso de índices de vegetação na faixa do espectro visível poderia impulsionar o uso de equipamentos de monitoramento de baixo custo, como veículos aéreos não tripulados (UAVs) em nível de dossel e até smartphones em nível de folha, que possuem câmeras RGB, mas raramente câmeras NIR (da Silva Quinaia et al., 2021).

O objetivo desta pesquisa é realizar o monitoramento das condições do cultivo de *Megathyrsus maximus* (Syn. *Panicum maximum* Jacq.) cv. Mombaça por meio da utilização de índices multiespectrais. Pretende-se analisar a resposta espectral das pastagens com o intuito de avaliar o estado de saúde e o desenvolvimento dessa espécie forrageira. A pesquisa buscará identificar e selecionar índices multiespectrais relevantes, obtidos a partir de imagens de drones. O estudo visa contribuir para o aprimoramento do manejo do cultivo de pastagens, buscando maior produtividade, sustentabilidade e rentabilidade no sistema agropecuário.

## 3.2 Material e Métodos


### 3.2.1 Caracterização do estudo

O trabalho foi realizado em uma área experimental da Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP), localizada no município de Piracicaba – SP. Localizada nas coordenadas 22°42'15.04"S e 47°37'24.78"O em altitude de 569 m. Os dados meteorológicos foram obtidos da série de dados climatológicos do “Campus Luiz de Queiroz” de Piracicaba, SP (LEB - ESALQ – USP), disponibilizados em escala temporal de 15 minutos de intervalo de registro, obtidos por estação meteorológica automática (Figura 1).



**Figura 1.** Localização da área experimental e estação meteorológica.

O clima do município de Piracicaba é caracterizado como Cwa (Clima subtropical, com verão quente), apresentando invernos secos e verões chuvosos (Peel et al., 2007). A média histórica (1917 a 2019) da precipitação acumulada anual é de 1278,7 mm e a temperatura média anual é de 21,7 °C, sendo julho e agosto os meses mais secos e os meses de dezembro e janeiro os mais chuvosos, historicamente (Figura 2).




**Figura 2.** Temperatura e Precipitação média mensal de Piracicaba-SP considerando uma média histórica de 1917 a 2019.

A área de estudo possuía com um sistema de canteiros instalados, com cultivo de *Megathyrus maximus* (*Panicum maximum* cv. Mombaça) já estabelecido. A semeadura do Capim Mombaça foi realizada a lanço em março de 2019 e com densidade de sementes de  $15 \text{ kg ha}^{-1}$ . Inicialmente, o cultivo passou por uma adubação com dose de  $125 \text{ kg ha}^{-1}$  de N e um corte de uniformização após 60 dias do início do cultivo com altura residual de 60 dias, para iniciar o primeiro ciclo produtivo.

A irrigação do local foi realizada por um sistema de gotejamento subsuperficial, instalado a uma profundidade de 0,2 m da superfície do solo, composto por tubos de polietileno (DN 32 mm PN80) e tubo gotejador adequado para irrigação por gotejamento subsuperficial Modelo PCAS (autocompensante e antisifão) que previne a sucção de impurezas durante drenagem (Topdrip PC AS 16 mm – NaanDanJain®). A vazão dos gotejadores é de  $1,0 \text{ L h}^{-1}$  e espaçamento entre gotejadores de 0,5 m.

Neste trabalho, foi analisado o 7º ciclo produtivo (Ciclo de primavera, de 24/09/20 a 21/10/20) dos canteiros de aproximadamente  $130 \text{ m}^2$  de área com cultivo de Capim Mombaça. As características da área são apresentadas na Figura 3.



**Figura 3.** Canteiros de cultivo do local de estudo.

### 3.2.2 Desenvolvimento do cultivo: altura de plantas

Foram realizadas medidas de altura de planta em cada um dos quatro canteiros de cultivo em três datas diferentes: 24/09, 06/10 e 20/10 de 2020. É importante ressaltar que o corte do cultivo ocorreu no dia 24/09, após a captura da primeira imagem da área. Para analisar o comportamento do crescimento das plantas ao longo do ciclo, foram aplicadas regressões polinomiais com  $R^2=1$  em cada conjunto de dados, gerando equações de ajuste específicas para cada dia do ciclo. As equações resultantes foram:

Para o canteiro 1:

$$y = -0,1177x^2 + 6,2484x + 35 \quad \text{equação 1.}$$

Para o canteiro 2:

$$y = -0,1313x^2 + 7,1258x + 35 \quad \text{equação 2.}$$

Para o canteiro 3:

$$y = -0,1461x^2 + 7,3313x + 35 \quad \text{equação 3.}$$

Para o canteiro 4:

$$y = -0,1329x^2 + 7,1582x + 35 \quad \text{equação 4.}$$

Sendo x o dia do ciclo de cultivo e y a altura de planta.

A partir dessas equações, foi possível gerar curvas de crescimento do cultivo para cada canteiro, proporcionando uma avaliação mais detalhada e precisa dos dados, permitindo compreender o desenvolvimento das plantas ao longo do período estudado. Essa abordagem fornece informações importantes para a compreensão dos fatores que influenciam o crescimento das plantas em relação ao comportamento dos índices de vegetação.

### 3.2.3 Características do solo

O solo do local de estudo é classificado como Nitossolo Vermelho eutroférrico latossólico (Santos et al., 2013). Na Tabela 1, estão apresentados os parâmetros físicos de caracterização do solo. Com textura predominantemente argilosa, o solo de estudo possui teor de argila aumentando em profundidade, com mudança brusca de textura a partir de, aproximadamente 0,9 m de profundidade, com diminuição drástica no teor de argila.

**Tabela 1.** Parâmetros de caracterização física do solo em estudo.

Camada (m)	Porosidade Total (cm <sup>-3</sup> cm <sup>-3</sup> )	K <sub>0</sub> (cm h <sup>-1</sup> )	Densidade do Solo (g cm <sup>-3</sup> )	Areia (%)	Argila (%)	Silte (%)
0-0,1	0,50	1,30	1,39	33,38	46,20	20,43
0,1-0,2	0,48	1,20	1,55	30,21	51,07	18,72
0,2-0,3	0,45	1,07	1,62	29,77	54,75	15,48
0,3-0,4	0,45	1,13	1,60	25,53	58,79	15,68
0,4-0,5	0,48	1,04	1,49	25,59	60,88	13,53
0,5-0,6	0,50	0,96	1,48	25,69	61,13	13,19
0,6-0,7	0,53	0,93	1,25	28,83	60,42	10,75
0,7-0,8	0,54	0,44	1,27	27,2	59,64	13,16
0,8-0,9	0,54	0,17	1,3	26,63	13,69	59,69

Fonte: Adaptado de Prudente Junior, 2019.

Na Tabela 2, estão apresentados os parâmetros do solo obtidos através do software RETC e descritos pelo sistema de equações de van Genuchten-Mualem, sendo o modelo mais utilizado para caracterizar propriedades hidráulicas de diferentes tipos de solos (van Genuchten, 1980).

**Tabela 2.** Parâmetros hidráulicos do solo (van Genuchten-Mualem).

Parâmetro	Camada de solo (m)								
	0-0,1	0,1-0,2	0,2-0,3	0,3-0,4	0,4-0,5	0,5-0,6	0,6-0,7	0,7-0,8	0,8-0,9
ThetaR	0,29	0,28	0,24	0,26	0,32	0,34	0,34	0,32	0,35
ThetaS	0,55	0,45	0,44	0,48	0,50	0,52	0,54	0,54	0,53
Alpha	0,09	0,09	0,13	0,19	0,10	0,08	0,09	0,10	0,05
n	1,48	1,27	1,16	1,25	1,37	1,33	1,41	1,39	1,47

### 3.2.4 Conteúdo de água no solo

Para estimativa do conteúdo de água no solo, foi utilizada uma sonda FDR (“*frequency domain reflectometry*” ou reflectometria no domínio da frequência), modelo Diviner 2000® (Sentek, Stepney South, Australia) com um *datalogger* ligado a sonda por um cabo, proporcionando leituras a cada 0,1 m. As leituras da sonda são realizadas pela inserção da mesma dentro de um tubo de PVC com diâmetro específico. Para obter a leitura do solo, o

tubo deve ser inserido perpendicularmente à superfície do solo, com vedação no extremo inferior e tampa plástica no extremo superior para impedir entrada de umidade.

A saída gerada pelas leituras da sonda e armazenada no *datalogger* é em forma de frequência em escala (“*scaled frequency*” – SF), sendo gerada pela equação 5:

$$SF = \frac{(F_a - F_s)}{(F_a - F_w)} \quad \text{equação 5}$$

sendo  $F_a$  a leitura de frequência no tubo PVC suspenso no ar,  $F_w$  a leitura de frequência em tubo PVC imerso em água e  $F_s$  a leitura de frequência no tubo PVC instalado no solo. Para realização das leituras na área cultivada, foram utilizados os tubos de acesso previamente instalados, na profundidade de 0,8m.

A umidade volumétrica ( $\theta$ ) do solo é obtida pela equação 6:

$$\theta = a SF^b \quad \text{equação 6}$$


sendo  $a$  e  $b$  parâmetros de regressão de potência obtidos via calibração prévia que, para o solo de estudo, foi conduzida por Prudente Júnior et al. (2019). As equações de calibração para o solo de estudo estão apresentadas na Tabela 3.

**Tabela 3.** Equações de calibração da sonda capacitiva para obtenção do conteúdo de água no solo ( $\theta_v$ ) a partir da frequência relativa (FR) por camada de solo.

Camada (m)	$\theta_{CC}$ (cm <sup>3</sup> cm <sup>-3</sup> )	$\theta_{PP}$ (cm <sup>3</sup> cm <sup>-3</sup> )	Equação de Calibração	R <sup>2</sup>
0,0 - 0,1	0,35	0,29	$\theta_v = 0,4665 * FR^{1,4377}$	0,8605
0,1 - 0,2	0,35	0,30	$\theta_v = 0,4542 * FR^{1,1693}$	0,9772
0,2 - 0,3	0,36	0,30	$\theta_v = 0,4564 * FR^{0,9467}$	0,9895
0,3 - 0,4	0,34	0,29	$\theta_v = 0,4718 * FR^{1,1062}$	0,8890
0,4 - 0,5	0,37	0,33	$\theta_v = 0,5509 * FR^{1,1363}$	0,9585
0,5 - 0,6	0,41	0,36	$\theta_v = 0,5794 * FR^{1,3256}$	0,9381
0,6 - 0,7	0,39	0,35	$\theta_v = 0,6397 * FR^{2,1974}$	0,8838
0,7 - 0,8	0,38	0,32	$\theta_v = 0,5597 * FR^{2,0009}$	0,9628

$\theta_{CC}$ : umidade na capacidade de campo;  $\theta_{PP}$ : umidade no ponto de murcha;  $\theta_v$ : conteúdo de água no solo; FR: frequência relativa.

Na Figura 4, são apresentados os valores de conteúdo de água no solo para cada profundidade no período analisado para o Canteiro 2.



**Figura 4.** Conteúdo de água no solo para diferentes profundidades no Canteiro 2.

### 3.2.5 Coleta e processamento de imagens

Para realização da captura de imagens na área, foram realizados 9 voos sobre a área de estudo, utilizando um Drone (Figura 5) modelo MATRICE 600PRO (DJI®) com uma câmera multispectral modelo MicaSense Altum (MicaSense, Seattle, WA, USA). Esta câmera possui 5 bandas multispectrais, vermelha, verde, azul, Red Edge e NIR (infravermelho-próximo) e um sensor de imagem termal, sendo possível capturar imagens multispectrais e termais em cada captura.





**Figura 5.** Drone modelo MATRICE 600PRO (DJI®) utilizado no estudo.

As características da câmera estão apresentadas na Tabela 4. O sistema formado pelo drone equipado com a câmera possui um painel de calibração de reflectância e um sensor de radiação, para obter a radiação solar incidente em cada momento de captura, também sendo equipado por um GPS que permite gerar as imagens georreferenciadas.

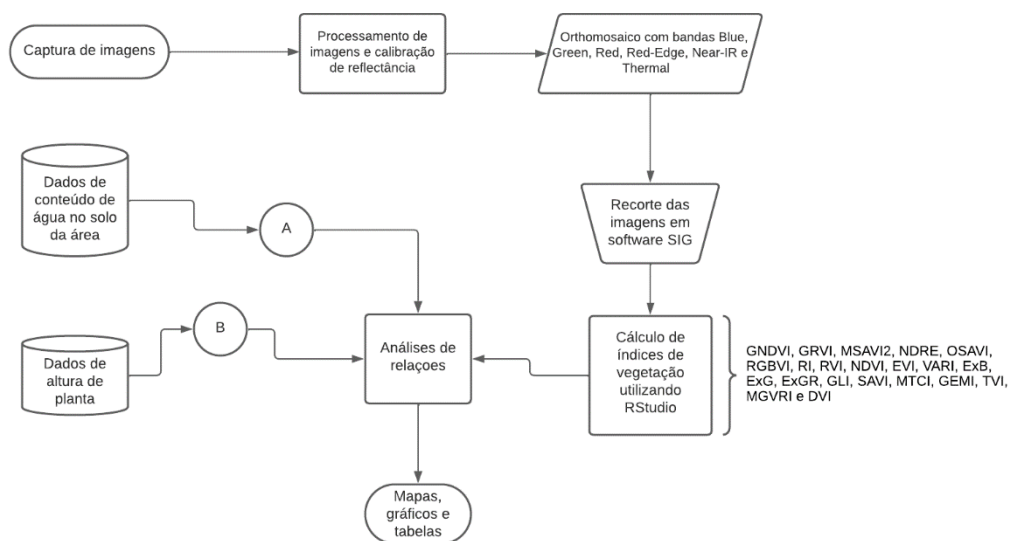
**Tabela 4.** Características da câmera multiespectral Altum (Micasense) utilizada no estudo.

Característica	Bandas Multiespectrais	Banda termal
Tamanho de pixel	3,5 $\mu\text{m}$	12 $\mu\text{m}$
Resolução	2064 x 1544 pixels	160 x 120 pixels
Proporção	4:3	4:3
Tamanho do sensor	7,2 x 5,33 mm (8,9 mm diagonal)	1,92 x 1,44 mm
Lente focal	8 mm	1,68 mm
Campo de visão	48° x 36,8°	57° x 44,3°
Sensitividade termal	--	< 50 mK
Profundidade de bits de saída	12-bit	14-bit
Distância da amostra do solo (GSD) 120m	5,2 cm	81 cm
Distância da amostra do solo (GSD) 60m	2,1 cm	41cm

Cada captura de imagens foi realizada em uma fase do ciclo de cultivo, nas datas 23, 25, 28 e 30 de setembro de 2020 e 2, 6, 13, 17 e 21 de outubro de 2020, sempre no

período da manhã. Cada voo foi realizado mediante a plano de voo criado no software DJI PILOT®, com 30m de altura, 2,3 m/s de velocidade

O processamento das imagens foi realizado pelo programa *Agisoft Metashape*, sendo possível unir as capturas de um vôo formando um Ortomosaico da área e gerar um mapa de elevação do terreno (DEM) (Figura 6). A partir disto, foi utilizado o software *ArcGis* para recorte e composição de imagens.



**Figura 6.** Fluxo de processamento das imagens capturadas em cada voo no software Agisoft Metashape.

Após a criação do Orthomosaico, os valores presentes nas bandas de saída mantêm-se como valores inteiros de 16 bits, assim como os valores das bandas de entrada. Uma refletância de 100% em cada banda corresponderia ao valor médio da faixa disponível, ou seja, o valor 32768. A fim de facilitar os cálculos de índices de vegetação e gerar as imagens em escala semelhante, ou seja, exportar a refletância normalizada para a faixa de 0 a 1, foi necessário criar bandas de saída e aplicar a fórmula de normalização para cada uma delas. A fórmula consiste em dividir o valor da fonte pelo fator de normalização:  $B1/32768$ ;  $B2/32768$ ;  $B3/32768$ ;  $B4/32768$ ;  $B5/32768$ . A banda térmica "LWIR" não faz parte do processo de calibração de refletância, não sendo necessário aplicar a normalização para essa banda. Este processo foi realizado utilizando o software Rstudio®.

No software Rstudio® foram calculados, por meio de um *script* construído, os índices de vegetação utilizando as bandas separadas para cada data de captura. Cada imagem gerada (GeoTIFF) foi analisada no software Arcgis® para extração dos valores das médias dos pixels correspondentes a cada canteiro de cultivo.

### 3.2.6 Características das imagens e índices de vegetação

Recentemente, os Veículos Aéreos Não Tripulados (VANTs), equipados com câmeras de alta resolução, têm desempenhado um papel crescente no monitoramento ambiental, apresentando-se como um complemento crucial aos sistemas convencionais de sensoriamento remoto via satélite.

As imagens de satélite demonstram eficácia na análise da vegetação em extensas áreas. Entretanto, devido ao movimento orbital fixo dos satélites, a obtenção de imagens no momento desejado torna-se desafiadora. Adicionalmente, a resolução das imagens multiespectrais provenientes de satélites, como as do Landsat ETM+, apresenta limitações em estudos que demandam análises altamente precisas. Portanto, para regiões urbanas de menor escala, as pesquisas envolvendo VANTs, capazes de capturar rapidamente imagens no momento desejado, ganham destaque. Especificamente, o emprego de VANTs equipados com sensores multiespectrais facilita a condução de diversas pesquisas relacionadas à vegetação (Lee et al.,2021).

Cada imagem capturada no voo origina um Ortmosaico composto de 6 bandas multiespectrais com diferentes características (Tabela 5).

**Tabela 5.** Características das bandas da câmera Altum (Micasense).

Nome da banda	Comprimento de onda central (nm)	Largura de banda (nm)
Blue (Azul)	475	20
Green (Verde)	560	20
Red (Vermelho)	668	10
RedEdge	717	10
NIR	840	40
LWIR (Termal)	11 $\mu$ m	6 $\mu$ m

Nota: A largura de banda é definida como a largura do filtro que deixa passar a luz de um determinado comprimento de onda. Por exemplo, o sensor Blue tem uma largura de 20 nm que permite a passagem da luz de um comprimento de onda central de 475 nm.

A unidade dos valores de saída da banda termal (LWIR) é na unidade de centi-Kelvin. Para converter os valores de temperatura de centi-Kelvin para Celsius, foi aplicada a equação 7:

$$Temperatura (^{\circ}C) = \frac{LWIR}{100} - 273,15 \quad \text{equação 7.}$$

Os índices de vegetação são ferramentas poderosas que permitem obter informações valiosas sobre o estado de saúde e desenvolvimento das plantas de forma não invasiva e em grande escala. Esses índices são derivados de dados obtidos por sensores remotos, como imagens de satélite ou drones, e são capazes de quantificar a quantidade e a qualidade da vegetação presente em uma área específica. Através dessa abordagem, é possível monitorar o crescimento das culturas, detectar doenças e estresses hídricos precocemente, além de otimizar o manejo agrícola, contribuindo assim para o aumento da produtividade e a sustentabilidade do setor agrícola.

Com base nisto, foram calculados para cada Orthomosaico os seguintes índices de vegetação:

GNDVI - Green Normalized Difference Vegetation Index (equação 8, Änäkälä et al., 2022)

$$GNDVI = \frac{NIR-green}{NIR+green} \quad \text{equação 8.}$$

GRVI - Green-Red Vegetation Index (equação 9, Chen & Meron, 2018; García-Fernández et al., 2021)

$$GRVI = \frac{green-red}{green+red} \quad \text{equação 9.}$$

MSAVI2 - Modified Soil-Adjusted Vegetation Index 2 (equação 10, Änäkälä et al., 2022; Orsini et al., 2019)

$$MSAVI_2 = \frac{(2*NIR+1-\sqrt{(2*NIR+1)^2-8*(NIR-red)})}{2} \quad \text{equação 10.}$$

NDRE - Normalized Difference Red Edge (equação 11, Änäckälä et al., 2022; Torino et al., 2014)

$$NDRE = \frac{NIR-RedEdge}{NIR+RedEdge} \quad \text{equação 11.}$$

OSAVI - Optimized Soil-Adjusted Vegetation Index (equação 12, Änäckälä et al., 2022)

$$OSAVI = 1,16 * \frac{(NIR-red)}{(NIR+red+0,16)} \quad \text{equação 12.}$$

RGBVI - Red-Green Vegetation Index (equação 13, Barbosa et al., 2019; Lu et al., 2019)

$$RGBVI = \frac{green^2-(blue*red)}{green^2+(blue*red)} \quad \text{equação 13.}$$

RI - Redness Index (equação 14, Änäckälä et al., 2022)

$$RI = \frac{red-green}{red+green} \quad \text{equação 14.}$$

RVI - Ratio Vegetation Index (equação 15, Änäckälä et al., 2022)

$$RVI = \frac{red}{NIR} \quad \text{equação 15.}$$

NDVI - Normalized Difference Vegetation Index (equação 16, Änäckälä et al., 2022)

$$NDVI = \frac{NIR-red}{NIR+red} \quad \text{equação 16.}$$

EVI - Enhanced Vegetation Index (equação 17, Ali & Salman, 2015)

$$EVI = 2,5 * \frac{(NIR-red)}{(NIR+6*red-7,5*blue+1)} \quad \text{equação 17.}$$

VARI - Visible Atmospherically Resistant Index (equação 18, Abdollahnejad et al., 2017; Abrahão et al., 2009)

$$VARI = \frac{g-r}{g+r-b} \quad \text{equação 14.}$$

Sendo r, g e b obtidos pelas equações 19, 20 e 21 (Guijarro et al., 2011), respectivamente.

$$r = \frac{red}{red+green+blue} \quad \text{equação 19.}$$

$$g = \frac{green}{red+green+blue} \quad \text{equação 20.}$$

$$b = \frac{blue}{red+green+blue} \quad \text{equação 21.}$$

ExG - Excess Green Index (equação 22, Guijarro et al., 2011; Lu et al., 2019)

$$ExG = 2 * g - r - b \quad \text{equação 22.}$$

ExB - Excess Blue Index (equação 23, Guijarro et al., 2011; Lu et al., 2019)

$$ExB = 1,4 * b - g \quad \text{equação 23.}$$

ExR - Excess Red Index (equação 24, Guijarro et al., 2011; Lu et al., 2019)

$$ExR = 1,4 * r - g \quad \text{equação 24.}$$

ExGR - Excess Green-Red Index (equação 25, Guijarro et al., 2011; Lu et al., 2019)

$$ExGR = ExG - ExR \quad \text{equação 25.}$$

GLI - Green Leaf Index (equação 26, Freire-Silva et al., 2019; Lu et al., 2019)

$$GLI = \frac{2*green-red-blue}{2*green+red+blue} \quad \text{equação 26.}$$

SAVI - Soil-Adjusted Vegetation Index (equação 27, Palaś & Zawadzki, 2020)

$$SAVI = \frac{(NIR-red)}{(NIR+red+L)*(1+L)} \quad \text{equação 27.}$$

MTCI - MERIS Terrestrial Chlorophyll Index (equação 28, Palaś & Zawadzki, 2020; Torino et al., 2014)

$$MTCI = \frac{NIR-RedEdge}{RedEdge-red} \quad \text{equação 28.}$$

GEMI - Global Environment Monitoring Index (equação 29, Gorgan et al., 2010)

$$GEMI = n * (1 - 0,25 * n) - \frac{red-0,125}{1-red} \quad \text{equação 29.}$$

Sendo n obtido pela equação 30:

$$n = \frac{2*(NIR^2-red^2)+1,5*NIR+0,5*red}{NIR+red+0,5} \quad \text{equação 30.}$$

TVI - Triangular Vegetation Index (equação 31, Änäkälä et al., 2022)

$$TVI = \sqrt{NDVI + 0,5} \quad \text{equação 31.}$$

MGVRI - Modified Green Vegetation Ratio Index (equação 32, Barbosa et al., 2019)

$$MGVRI = \frac{green^2-red^2}{green^2+red^2} \quad \text{equação 32.}$$

DVI - Difference Vegetation Index (equação 33, Änäkälä et al., 2022)

$$DVI = NIR - red \quad \text{equação 33.}$$

Cada índice calculado passou por uma análise das médias dos canteiros ao longo do tempo, com relação à altura do dossel e umidade do solo.

### 3.3 Resultados e Discussão

Os dados meteorológicos apresentados na Figura 7, fornecem uma visão detalhada das condições do local de estudo durante o período de 22 de setembro a 22 de outubro de 2020.

A temperatura média durante o período foi de 24,8°C, com sua variação apresentando um mínimo de 17,4°C e um máximo de 32,1°C. As temperaturas mais altas foram registradas no final de setembro e início de outubro.

A umidade relativa do ar variou de 37,2% a 86,2%. A média da umidade foi de 60,7%, indicando um ambiente relativamente úmido durante o período. A velocidade média do vento foi de 2,0 m/s. As variações na velocidade do vento observadas apresentaram valores mínimos de 1,4 m s<sup>-1</sup> e máximos de 3,3 m s<sup>-1</sup>.

A radiação solar incidente, representada por Q<sub>g</sub>, variou de 9441,8 W m<sup>-2</sup> a 29887,3 W m<sup>-2</sup>. A radiação solar média foi de 21831,2 W m<sup>-2</sup>, indicando uma quantidade significativa de energia solar disponível na área de estudo. A quantidade de PAR variou de 7148,8 umol s<sup>-1</sup> m<sup>-2</sup> a 33722,7 umol s<sup>-1</sup> m<sup>-2</sup>. A média da PAR foi de 25423,6 umol s<sup>-1</sup> m<sup>-2</sup>, representando a energia luminosa disponível para a fotossíntese das plantas.

O saldo de radiação (R<sub>n</sub>) variou de 64,6 W m<sup>-2</sup> a 14565,8 W m<sup>-2</sup>. A média de R<sub>n</sub> foi de 10590,4 W m<sup>-2</sup>, indicando grande quantidade de calor transferido. Houve um total de 19,1 mm de chuva durante o período de estudo. A maioria dos dias não teve precipitação significativa, indicando condições predominantemente secas durante esse período.



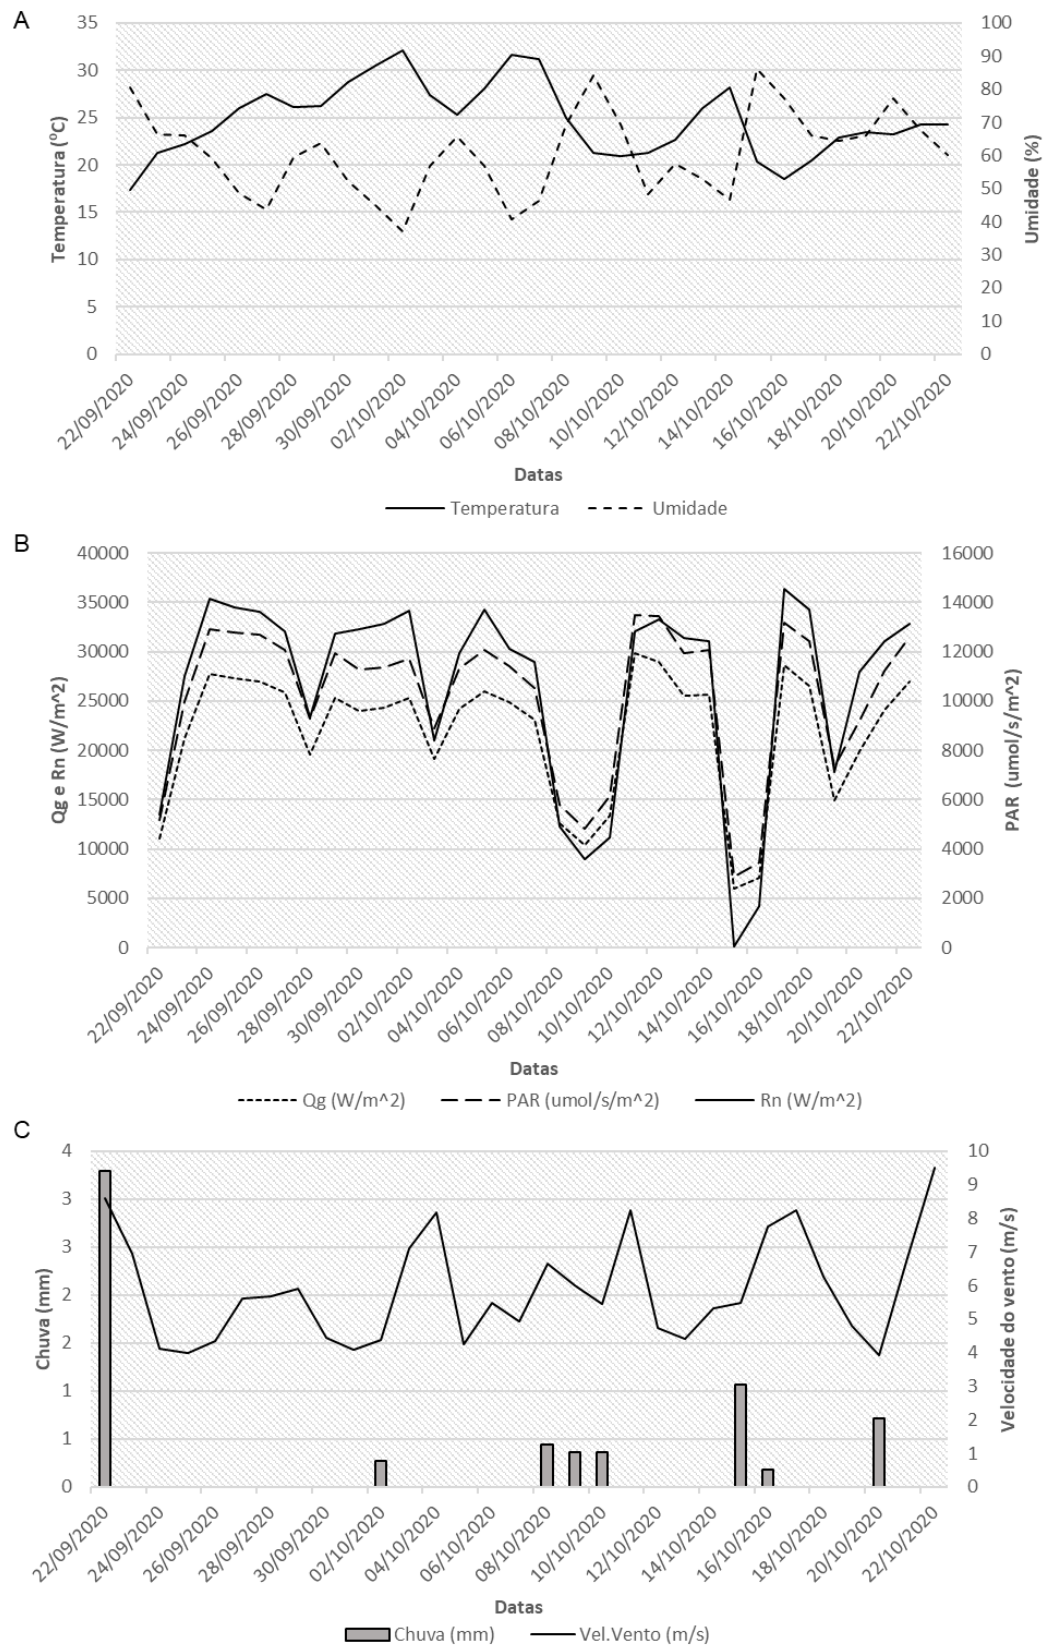


Figura 7. Dados meteorológicos do local de estudo no período de análise.

Os valores médios para os diferentes índices de vegetação analisados (DVI, EVI, ExB, ExG, ExR, ExGR, GEMI, GLI, GNDVI, GRVI, MGVRI, MSAVI2, NDRE, OSAVI, RGBVI, RI, SAVI, TVI e NDVI) e a Temperatura do dossel nos quatro canteiros (1, 2, 3 e 4) em diferentes datas de medição, começando em 23 de setembro de 2020 e indo até 21 de outubro de 2020, estão apresentados no ANEXO A. Os dados estão apresentados na forma de médias e desvios padrão ( $\pm$ ) para cada índice de vegetação em cada canteiro e data específicos. O desvio padrão é uma medida da variação ou dispersão dos valores em torno da média. Quanto maior o desvio padrão, maior é a variabilidade dos dados em relação à média.

Os índices de vegetação são utilizados para avaliar a saúde e o vigor das plantas, sendo calculados a partir de dados de reflectância obtidos por sensores remotos. Cada índice tem suas próprias características e aplicabilidades, mas todos eles ajudam a monitorar o estado das plantas e podem ser usados em estudos de agricultura, ecologia e monitoramento ambiental.

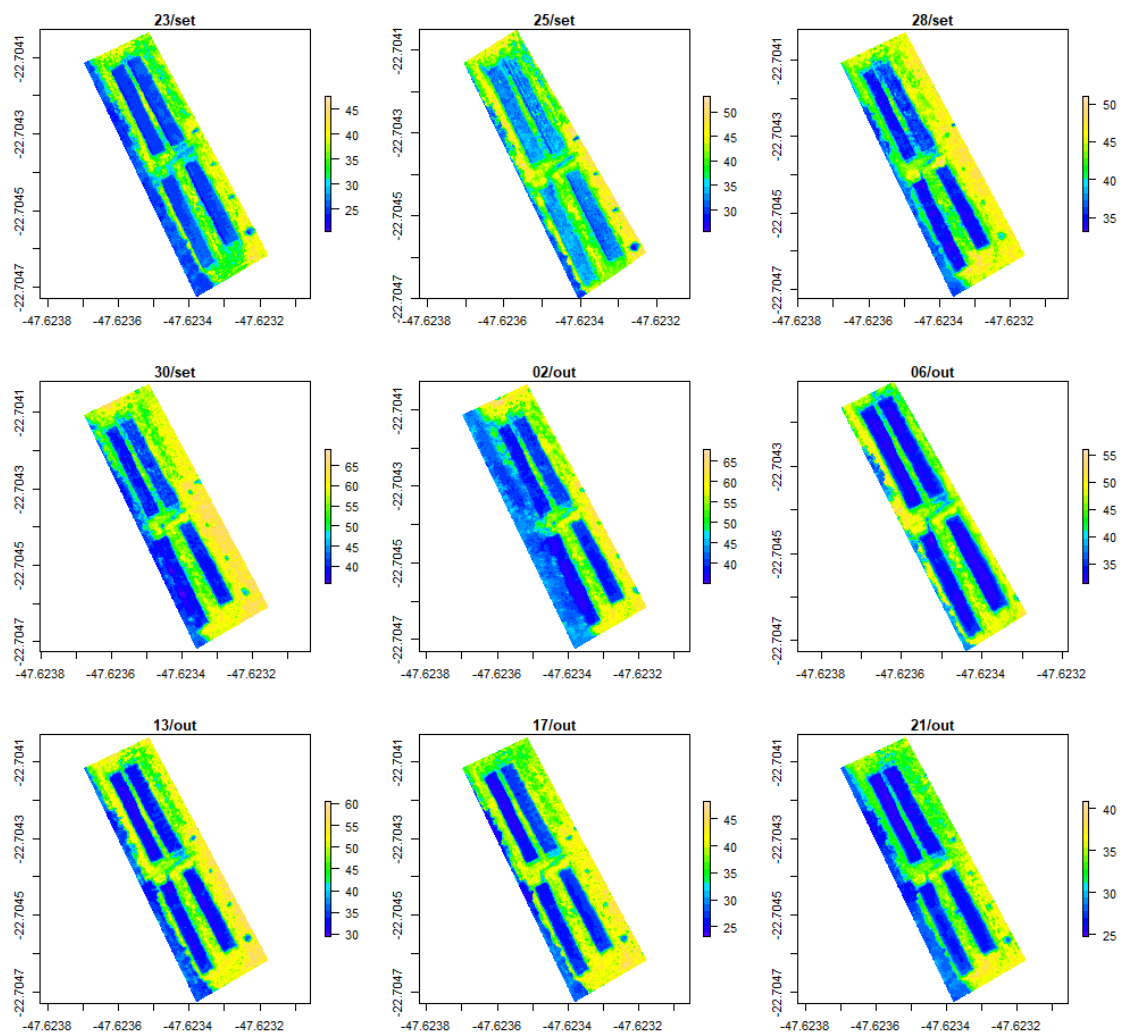
A maioria dos índices de vegetação mostra variações nas datas de coleta de imagens. Os valores tendem a flutuar em uma pequena escala ao longo do tempo, indicando poucas mudanças na saúde e produtividade da vegetação. Em geral, os valores dos índices de vegetação são mais altos nas datas que representam o final do ciclo, o que pode indicar o crescimento e desenvolvimento contínuos das plantas ao longo das semanas.

Os índices RVI (Índice de Vegetação por Reflexão) e MTCI (Índice Triangular de Clorofila Modificado) não apresentaram valores adequados para essa área específica, levando à decisão de não utilizá-los na análise. Esses índices podem ser sensíveis a determinadas condições ambientais e coberturas vegetais, e seus valores podem variar de acordo com as características da vegetação e do solo. No contexto dessa área em particular, esses índices demonstraram um comportamento pouco consistente e pouco representativo das condições de vegetação, tornando-os inadequados para a avaliação precisa do desenvolvimento vegetativo e dos processos biológicos nesse ambiente. Portanto, optou-se por priorizar outros índices que demonstraram melhor desempenho e maior consistência nos resultados para uma análise mais confiável das condições da vegetação.

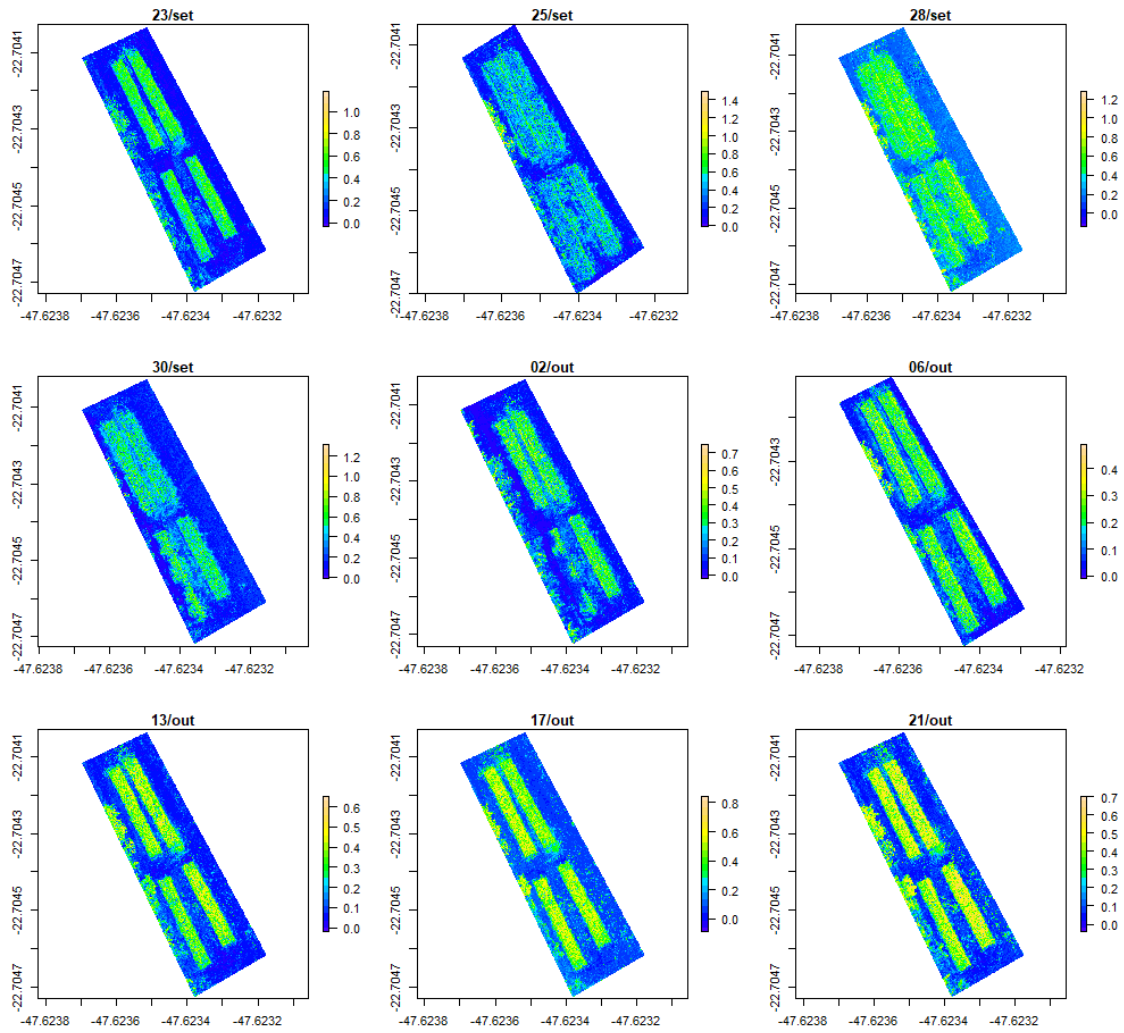
As incertezas associadas aos valores dos índices de vegetação indicadas pelo desvio padrão das medidas, apresentam baixa variabilidade nos dados e a confiabilidade das medições. Quanto menor a incerteza, maior a confiabilidade dos valores relatados.

Em geral, a análise dos dados dos índices de vegetação pode fornecer informações valiosas sobre a saúde e a produtividade da vegetação ao longo do tempo e entre diferentes canteiros. Essas informações podem ser úteis para monitorar o crescimento das plantas, identificar problemas de saúde, avaliar a eficácia de práticas agrícolas e monitorar mudanças no uso da terra. Entretanto, é importante lembrar que a interpretação precisa dos dados requer conhecimento detalhado sobre os índices de vegetação específicos utilizados e as características da área estudada.

As Figuras 8 a 24 apresentam os mapas gerados para a área de estudo em cada data de coleta para a temperatura do dossel, e os índices DVI, ExG, ExGR, GEMI, GLI, GNDVI, GRVI, MGVRI, MSAVI2, NDRE, OSAVI, RGBVI, RI, SAVI, TVI e NDVI.



**Figura 8.** Mapas de captura de imagens para a Temperatura do Dossel, em °C.



**Figura 9.** Mapas dos dias de captura de imagens para o Índice de Vegetação de Diferença (DVI).

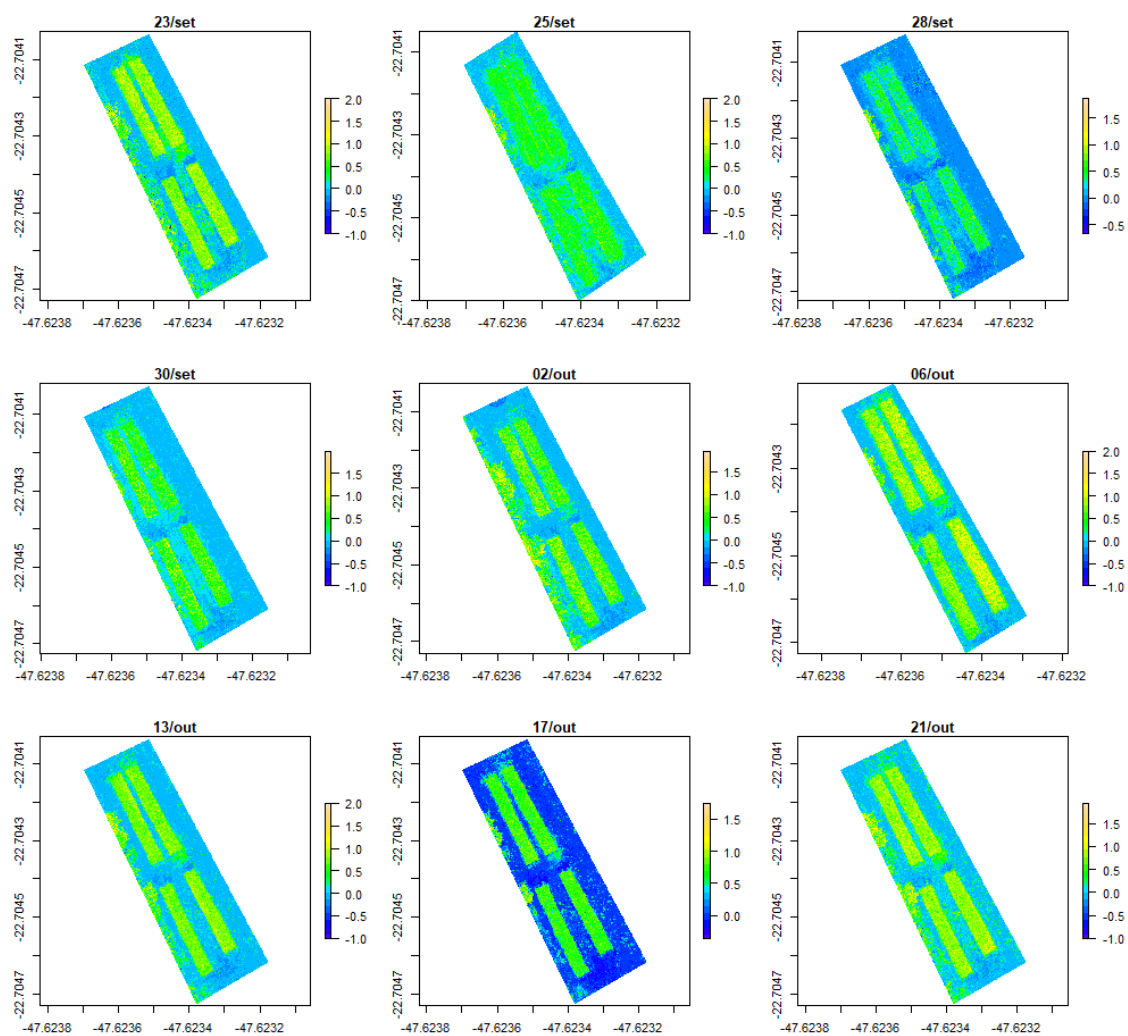
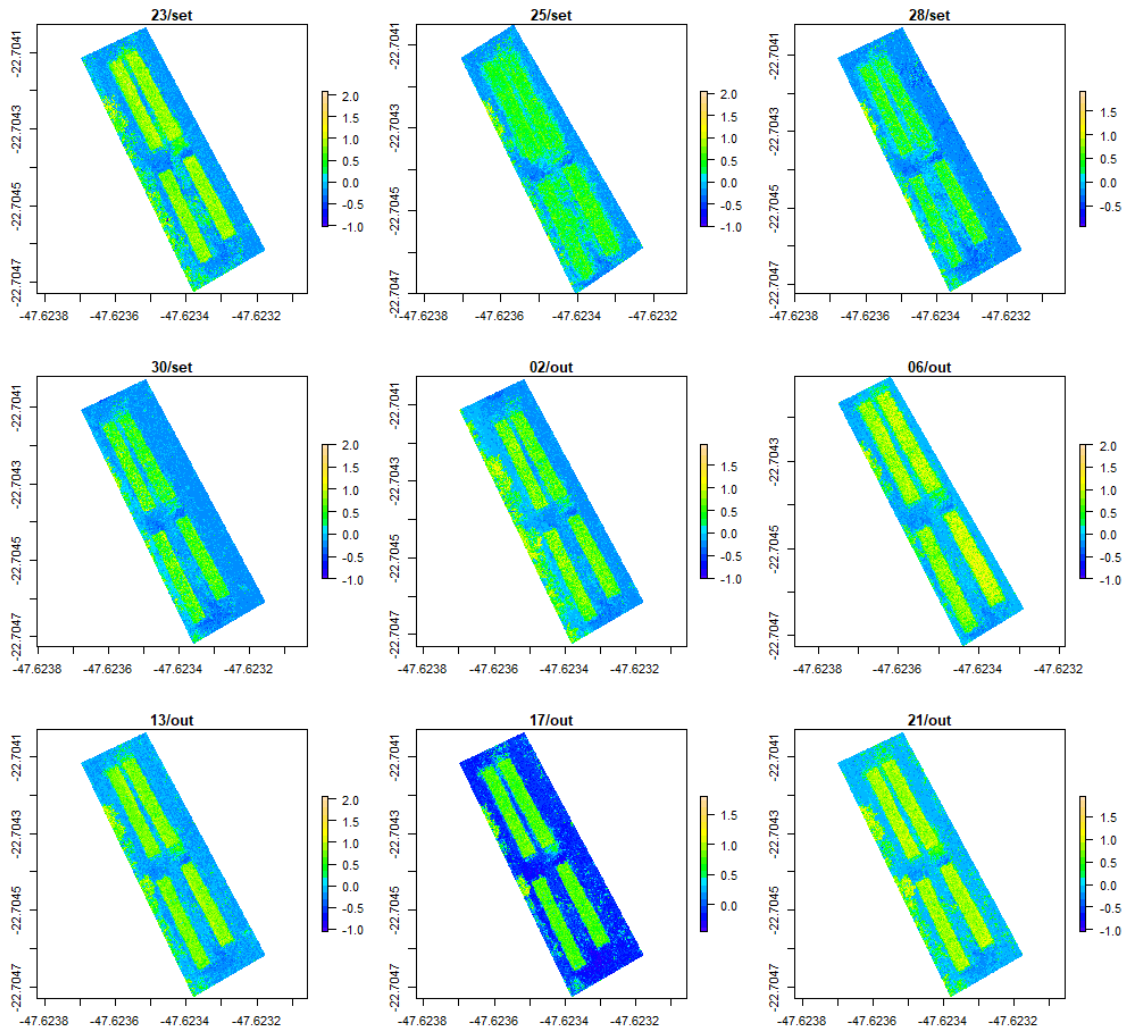


Figura 10. Mapas dos dias de captura de imagens para o Índice de Excesso de Verde (ExG).



**Figura 11.** Mapas dos dias de captura de imagens para o Índice de Excesso de Verde-Vermelho (ExGR).

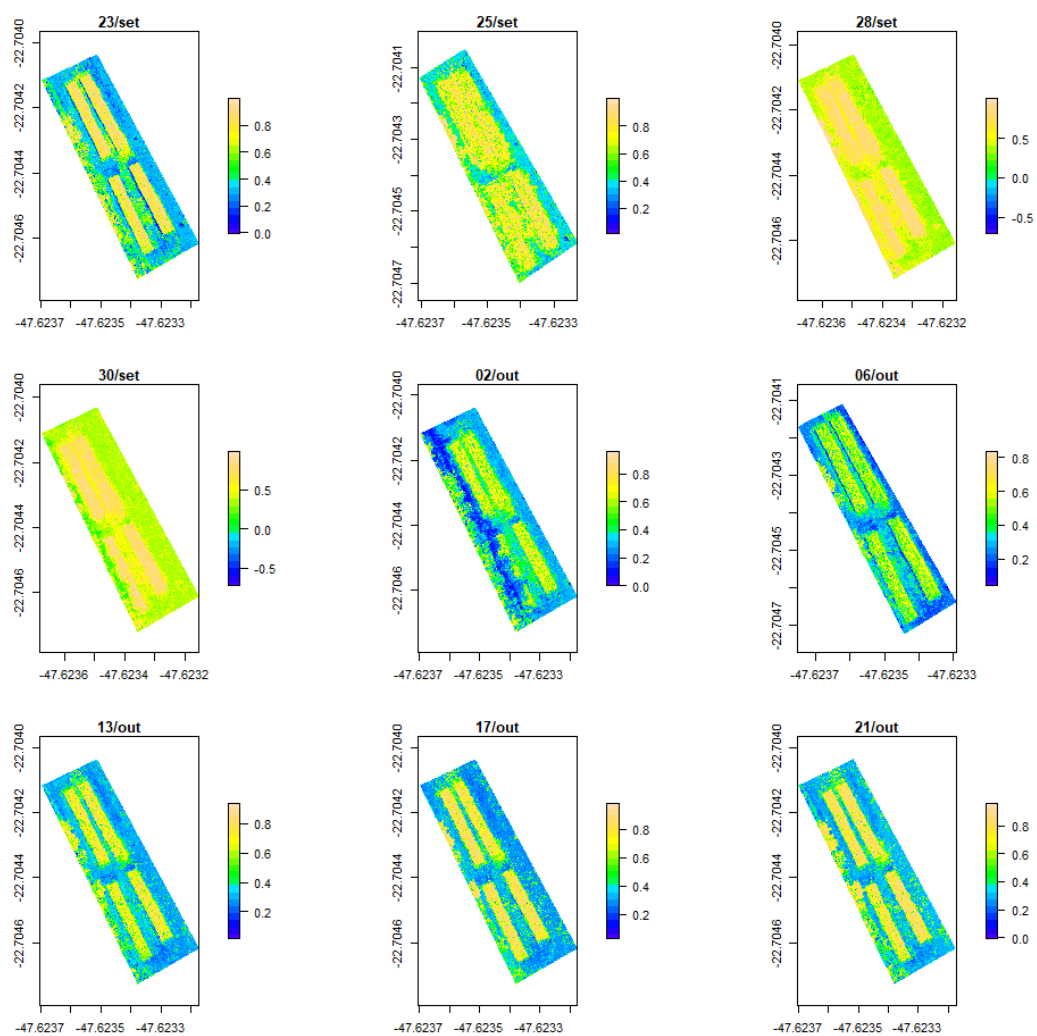
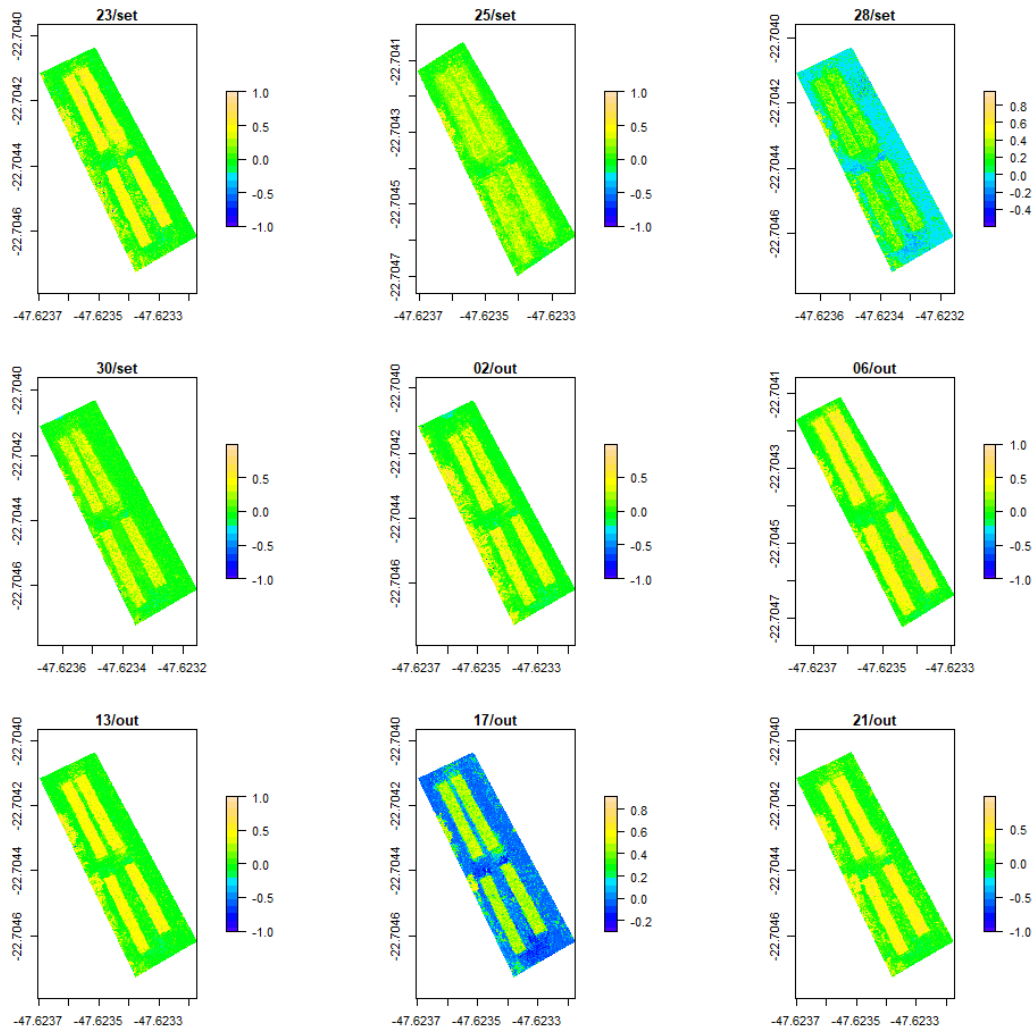
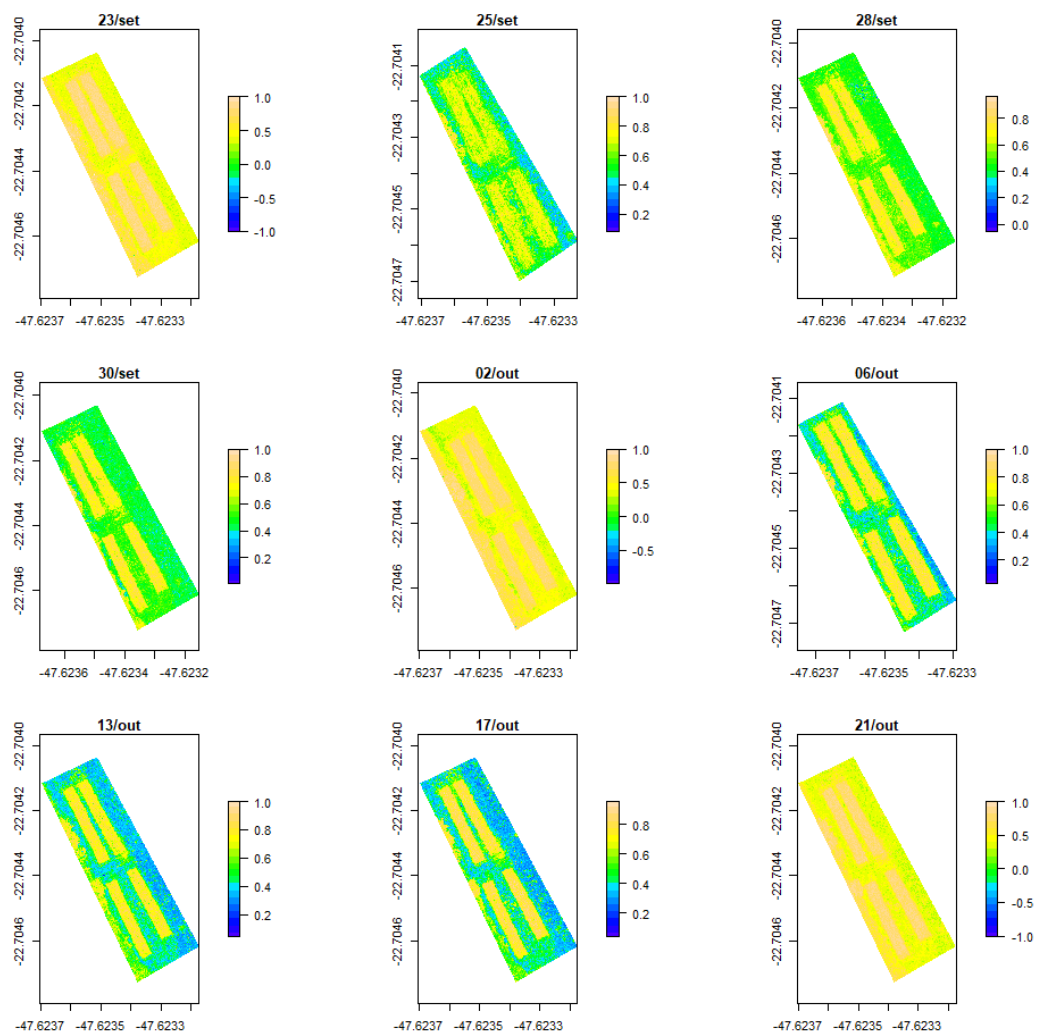


Figura 12. Mapas dos dias de captura de imagens para o Índice de Monitoramento Global (GMI).

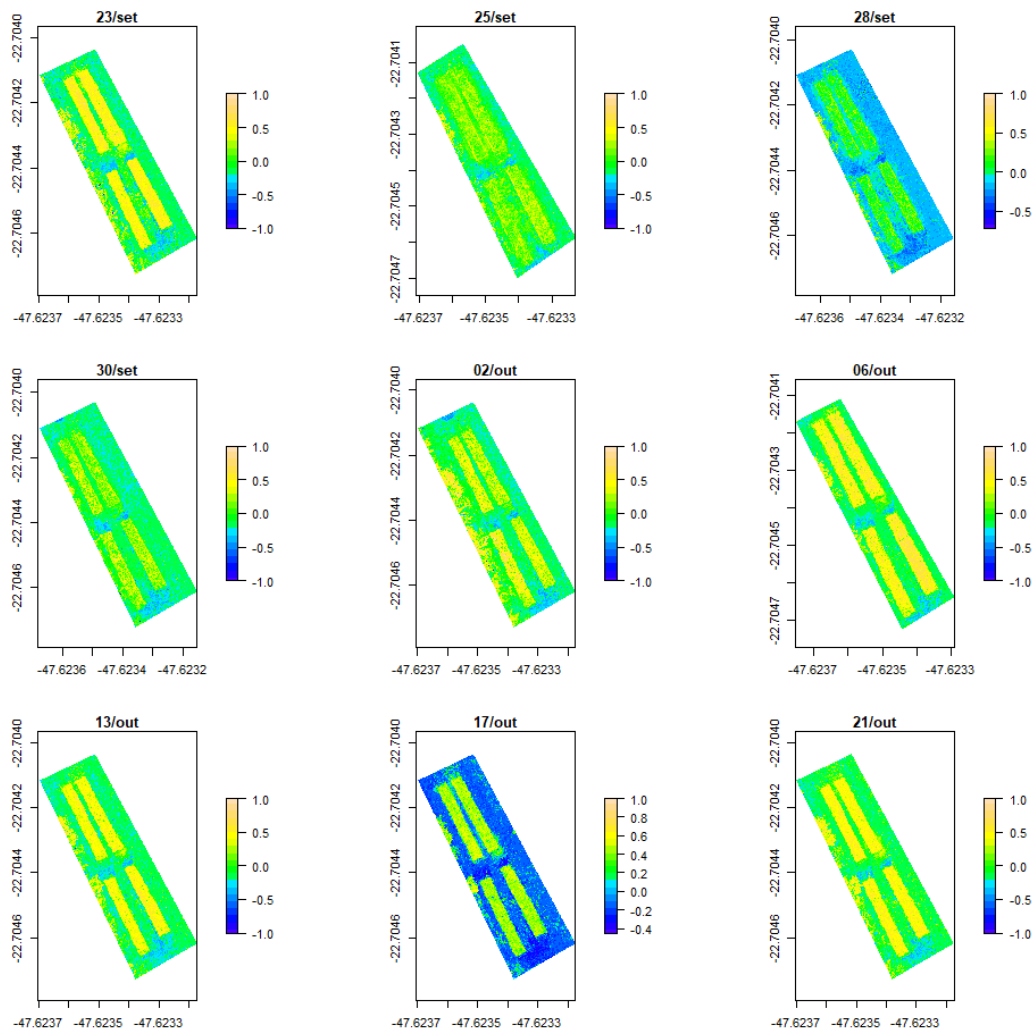




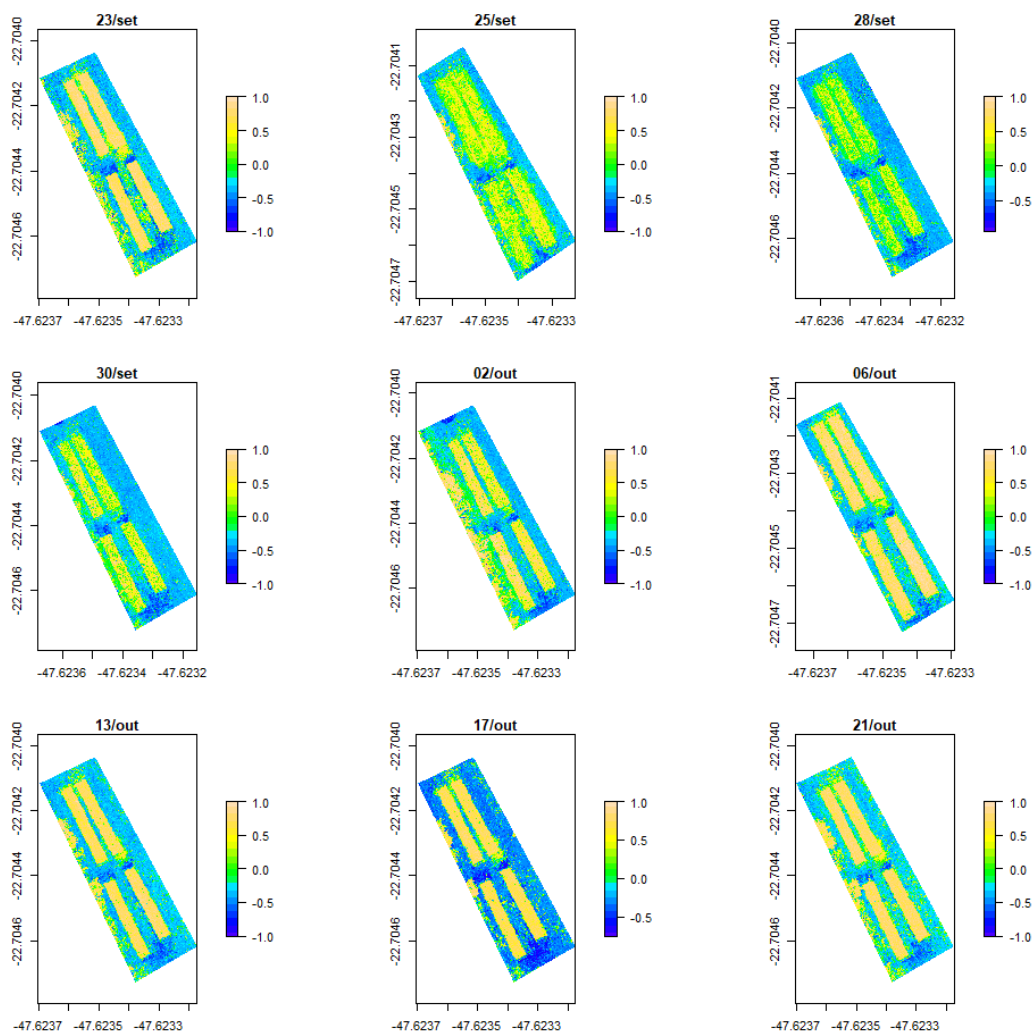
**Figura 13.** Mapas dos dias de captura de imagens para o Índice de Folhas Verdes (GLI).



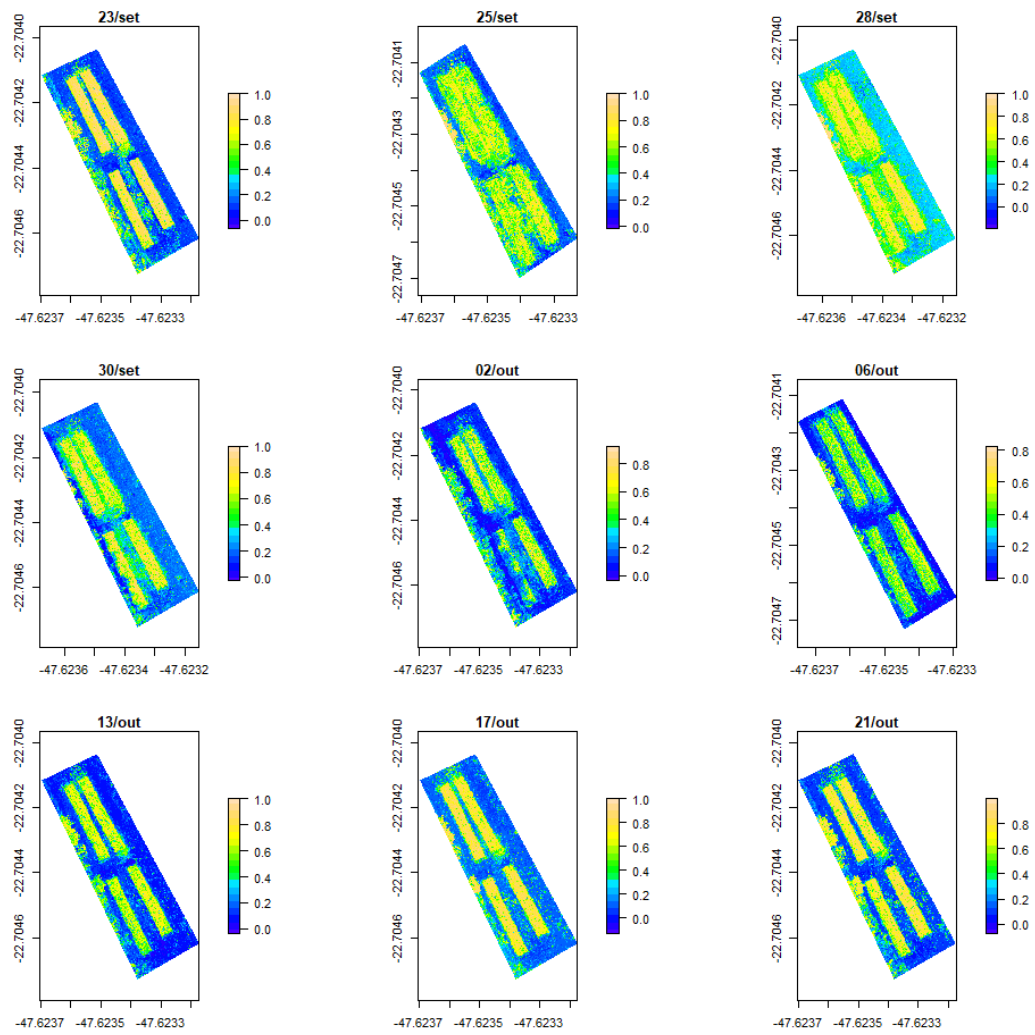
**Figura 14.** Mapas dos dias de captura de imagens para o Índice de Vegetação de Diferença Normalizada Verde (GNDVI).



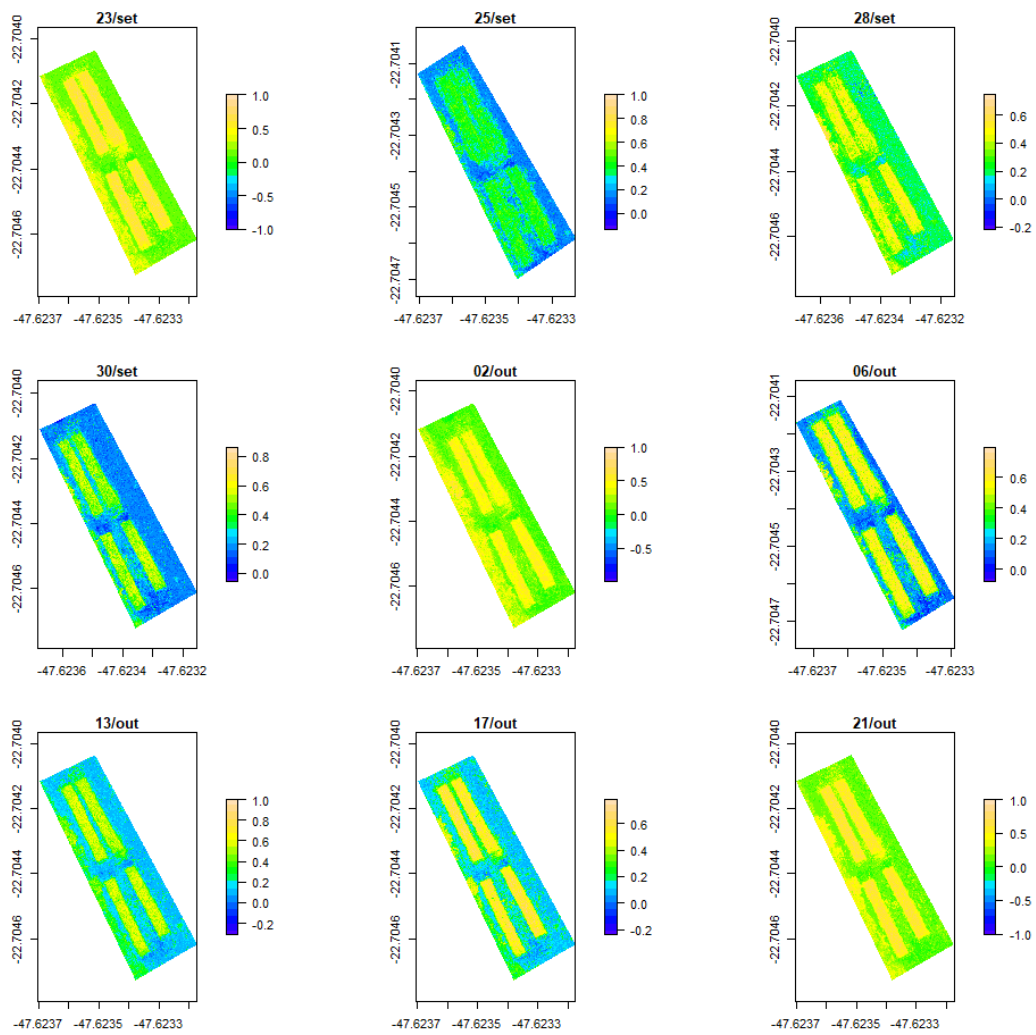
**Figura 15.** Mapas dos dias de captura de imagens para o Índice de Vegetação Verde-Vermelho (GRVI).



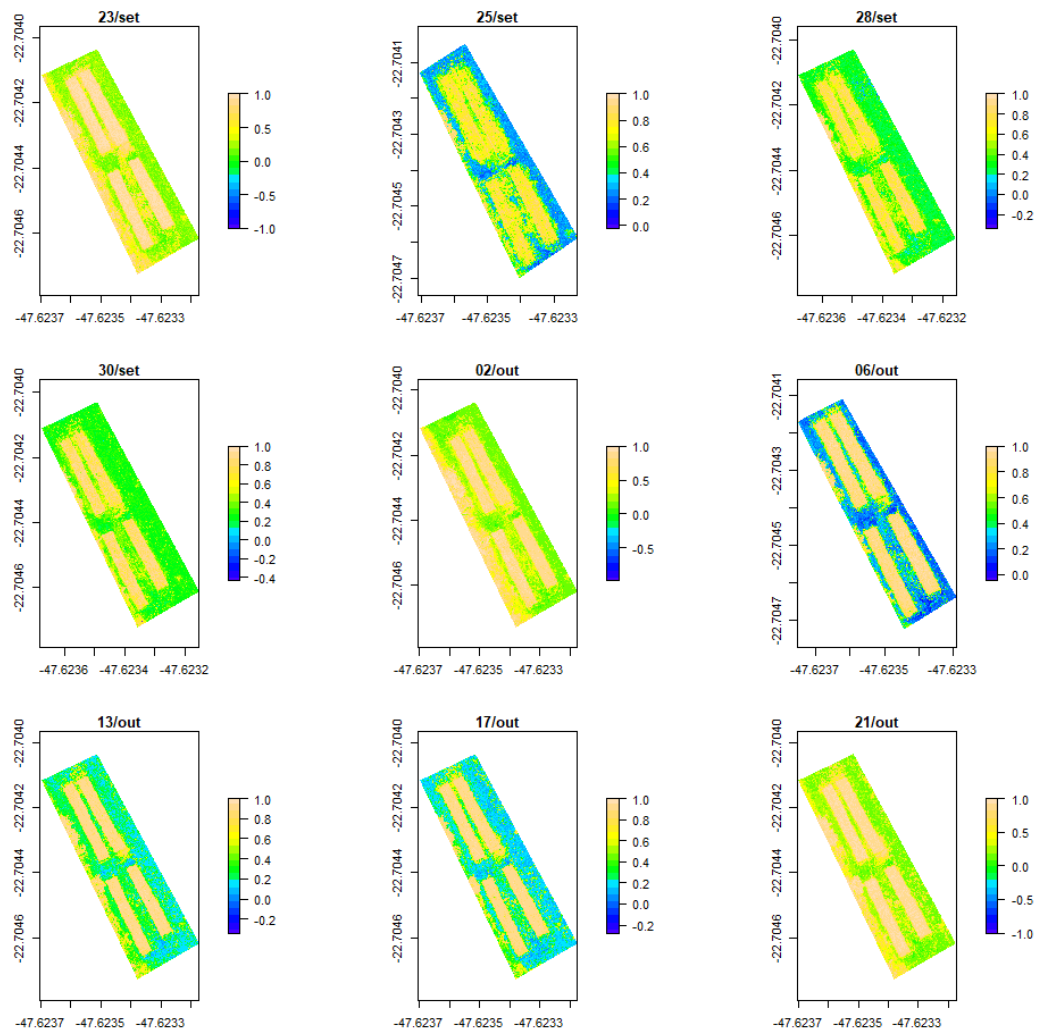
**Figura 16.** Mapas dos dias de captura de imagens para o Índice de Vegetação Modificado por Raios Infravermelhos (MGVRI).



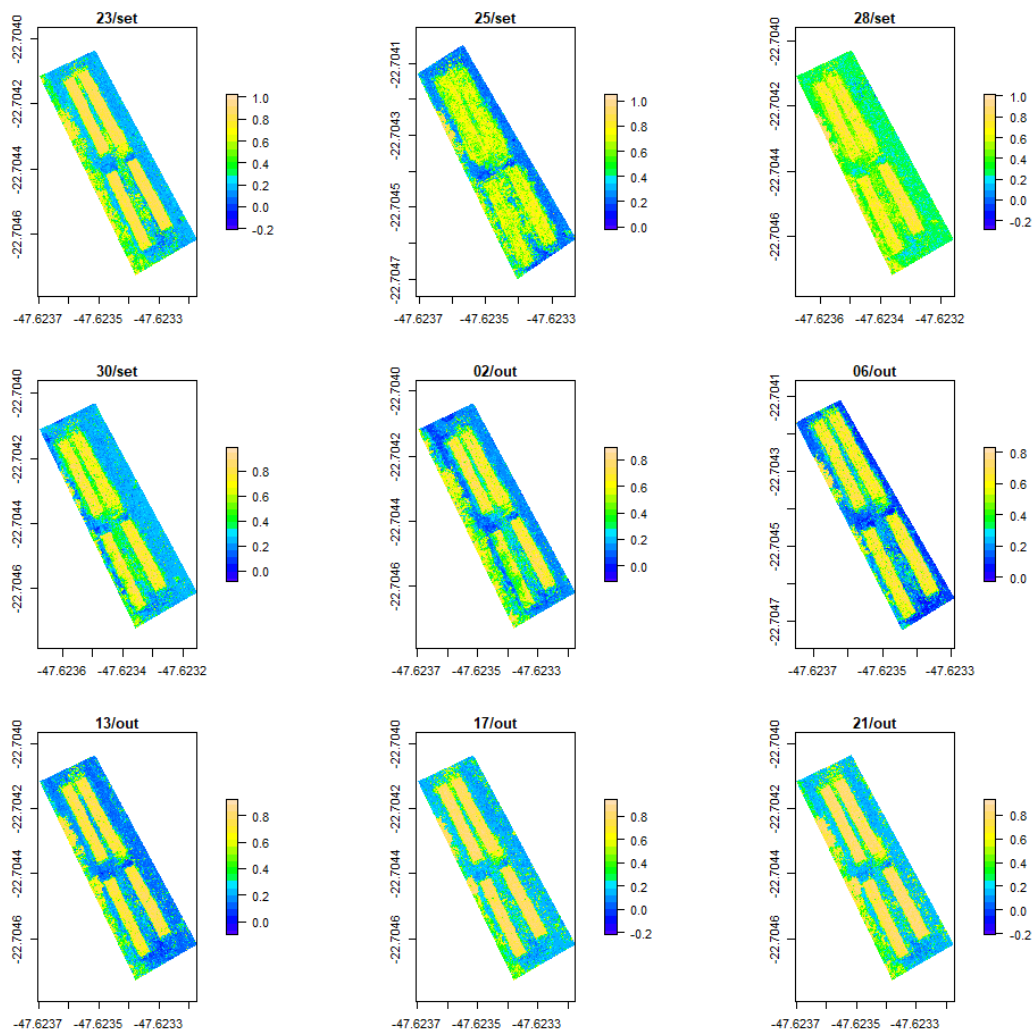
**Figura 17.** Mapas dos dias de captura de imagens para o Índice de Vegetação Ajustado ao Solo Modificado 2 (MSAVI2).



**Figura 18.** Mapas dos dias de captura de imagens para o Índice de Diferença Normalizada de Borda Vermelha (NDRE).

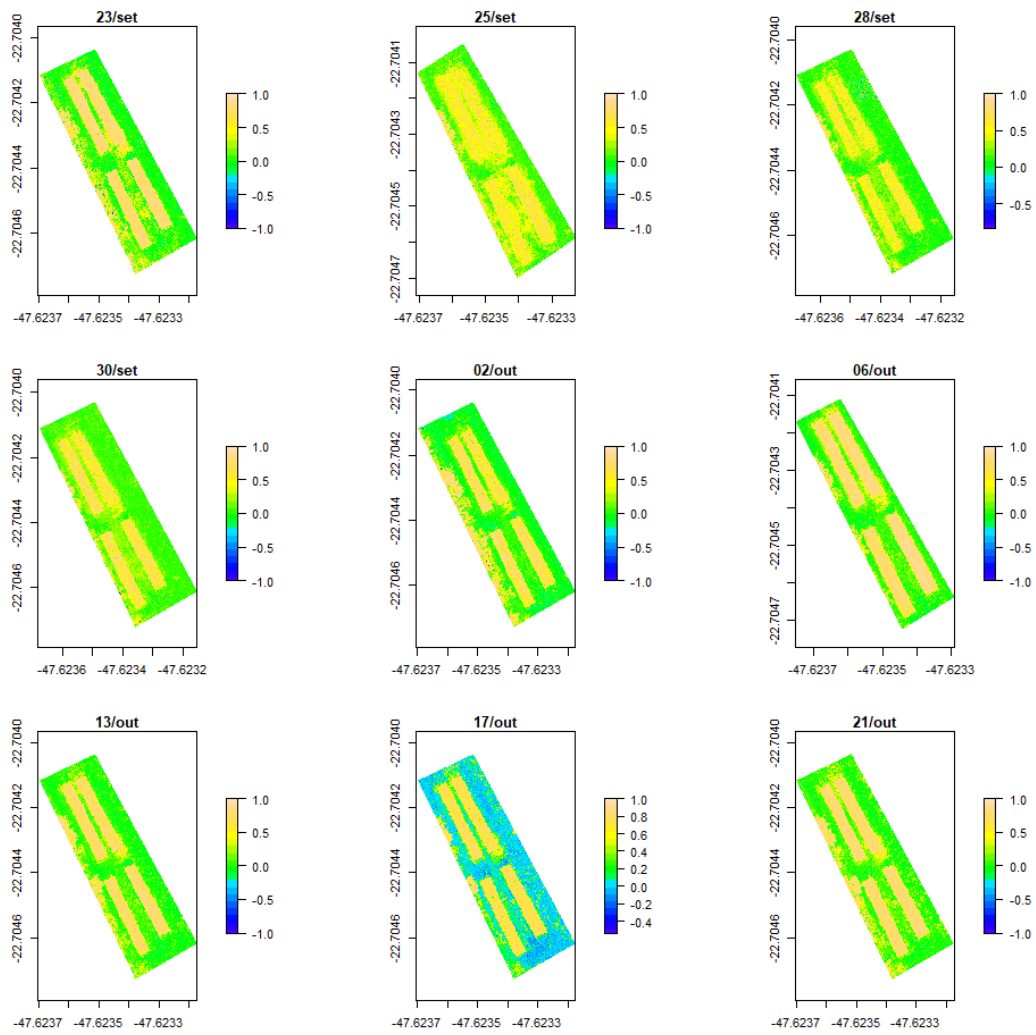


**Figura 19.** Mapas dos dias de captura de imagens para o ou Índice de Vegetação de Diferença Normalizada (NDVI).



**Figura 20.** Mapas dos dias de captura de imagens para o Índice de Vegetação Otimizado Ajustado ao Solo (OSAVI).





**Figura 21.** Mapas dos dias de captura de imagens para o Índice de Vegetação Vermelho-Verde (RGBVI).

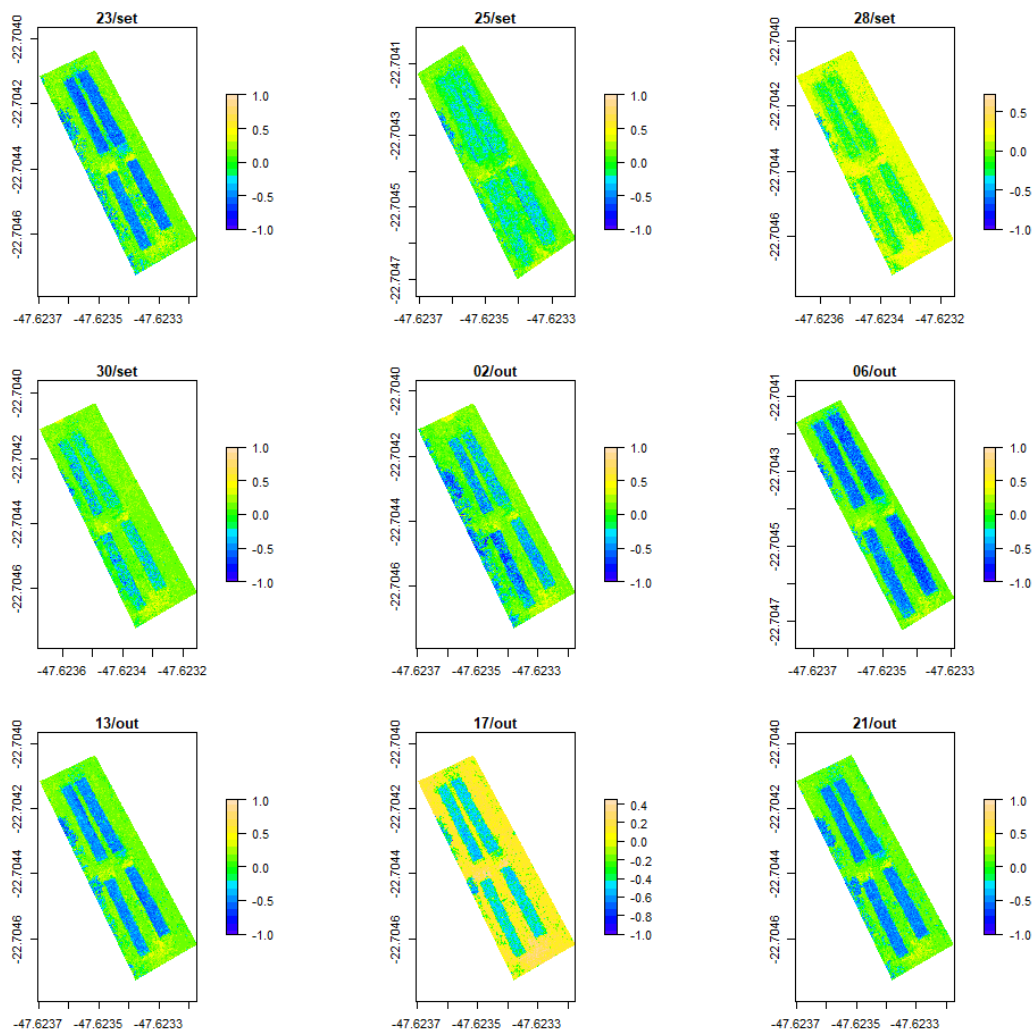
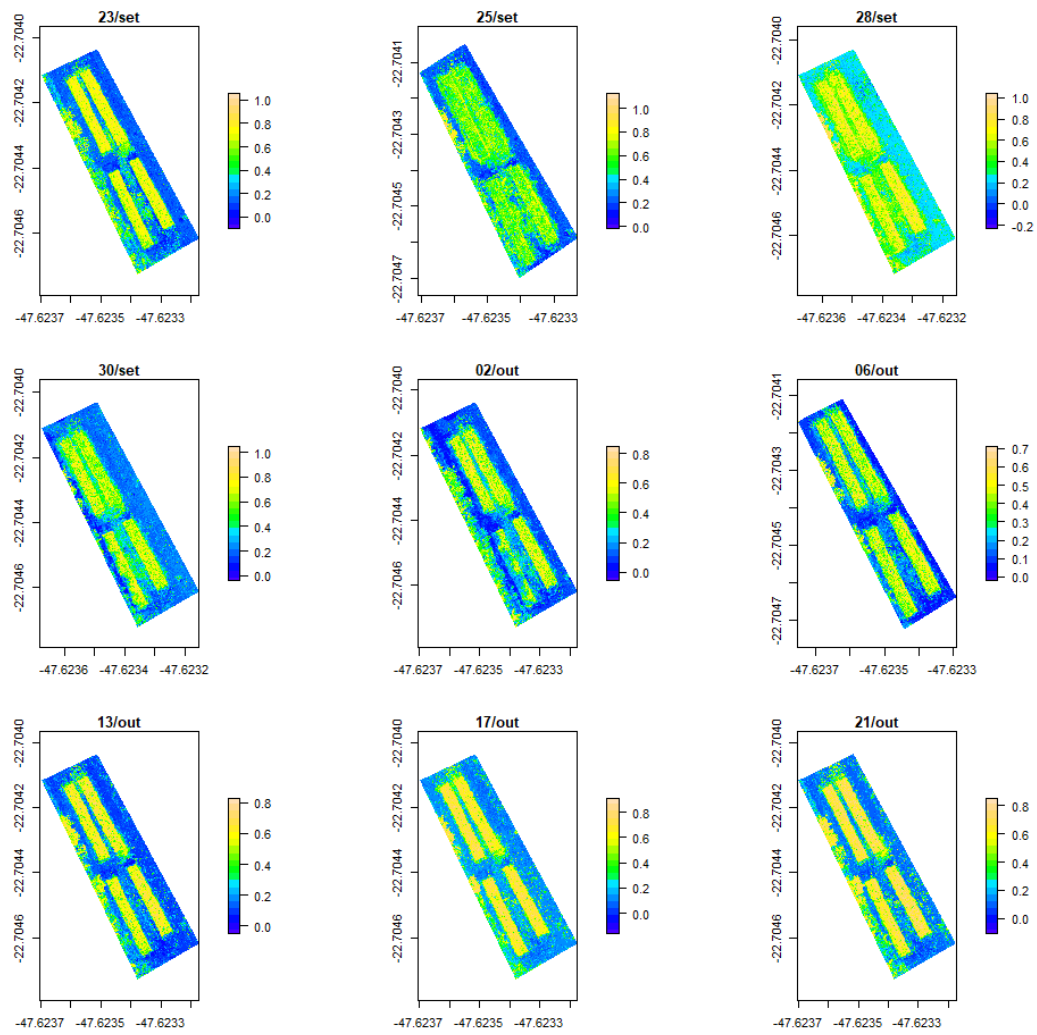
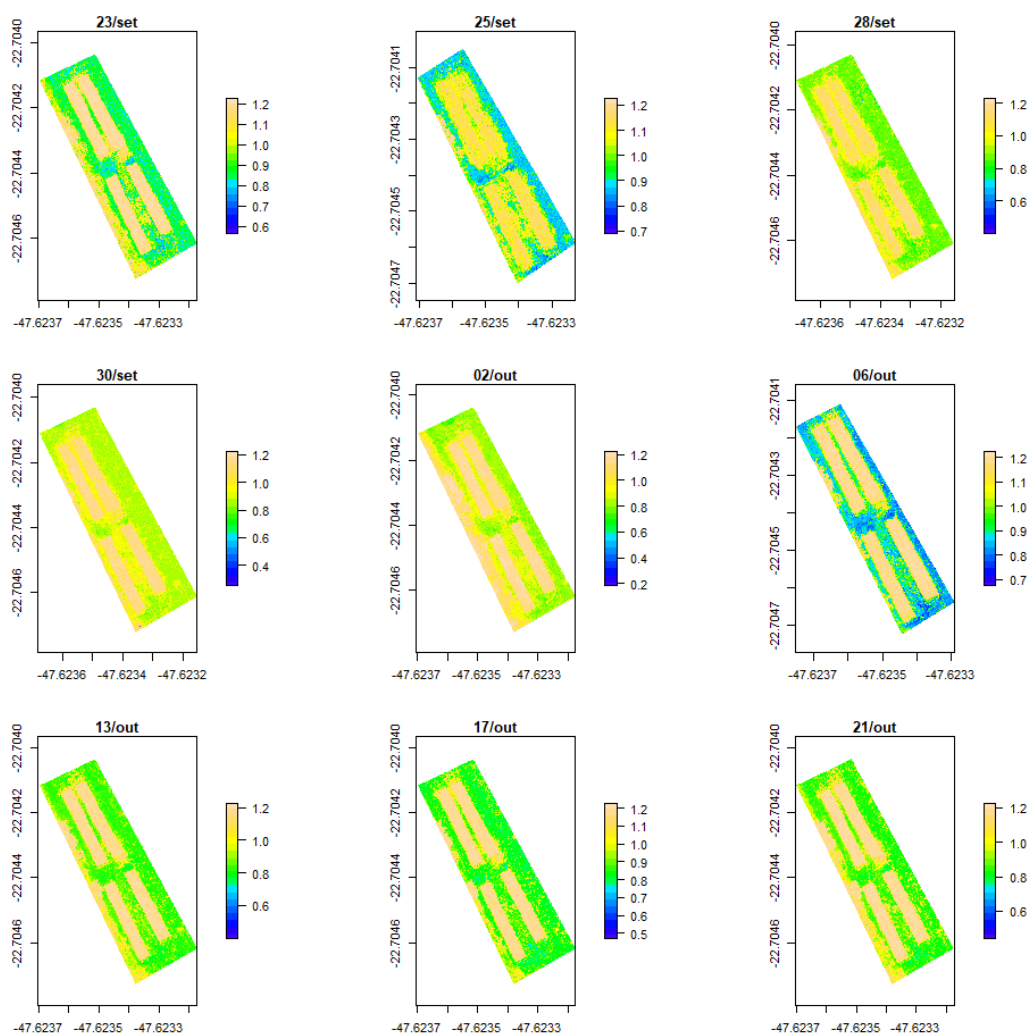


Figura 22. Mapas dos dias de captura de imagens para o Índice de Vermelhidão (RI).



**Figura 23.** Mapas dos dias de captura de imagens para o Índice de Vegetação Ajustado ao Solo (SAVI).



**Figura 24.** Mapas dos dias de captura de imagens para o Índice de Vegetação Transformado (TVI).

Os índices de vegetação podem ser usados para medir a saúde, a cobertura e o vigor das plantas. De acordo com as Figuras 25 e 26, que apresentam os índices NDRE, RGBVI, TVI, NDVI, ExG, ExGR, GLI, GNDVI, GRVI e MGVRI, assim como seu comportamento ao longo do tempo, entende-se que após o corte do cultivo (em 25 de setembro) e com o desenvolvimento da biomassa do cultivo, ou seja, crescimento do dossel, os índices vão aumentando o valor médio, chegando próximo ao máximo, que representa maior biomassa, estabilizando após a cobertura total do solo pelo dossel, que no caso, ocorreu próximo ao dia 6 de outubro.

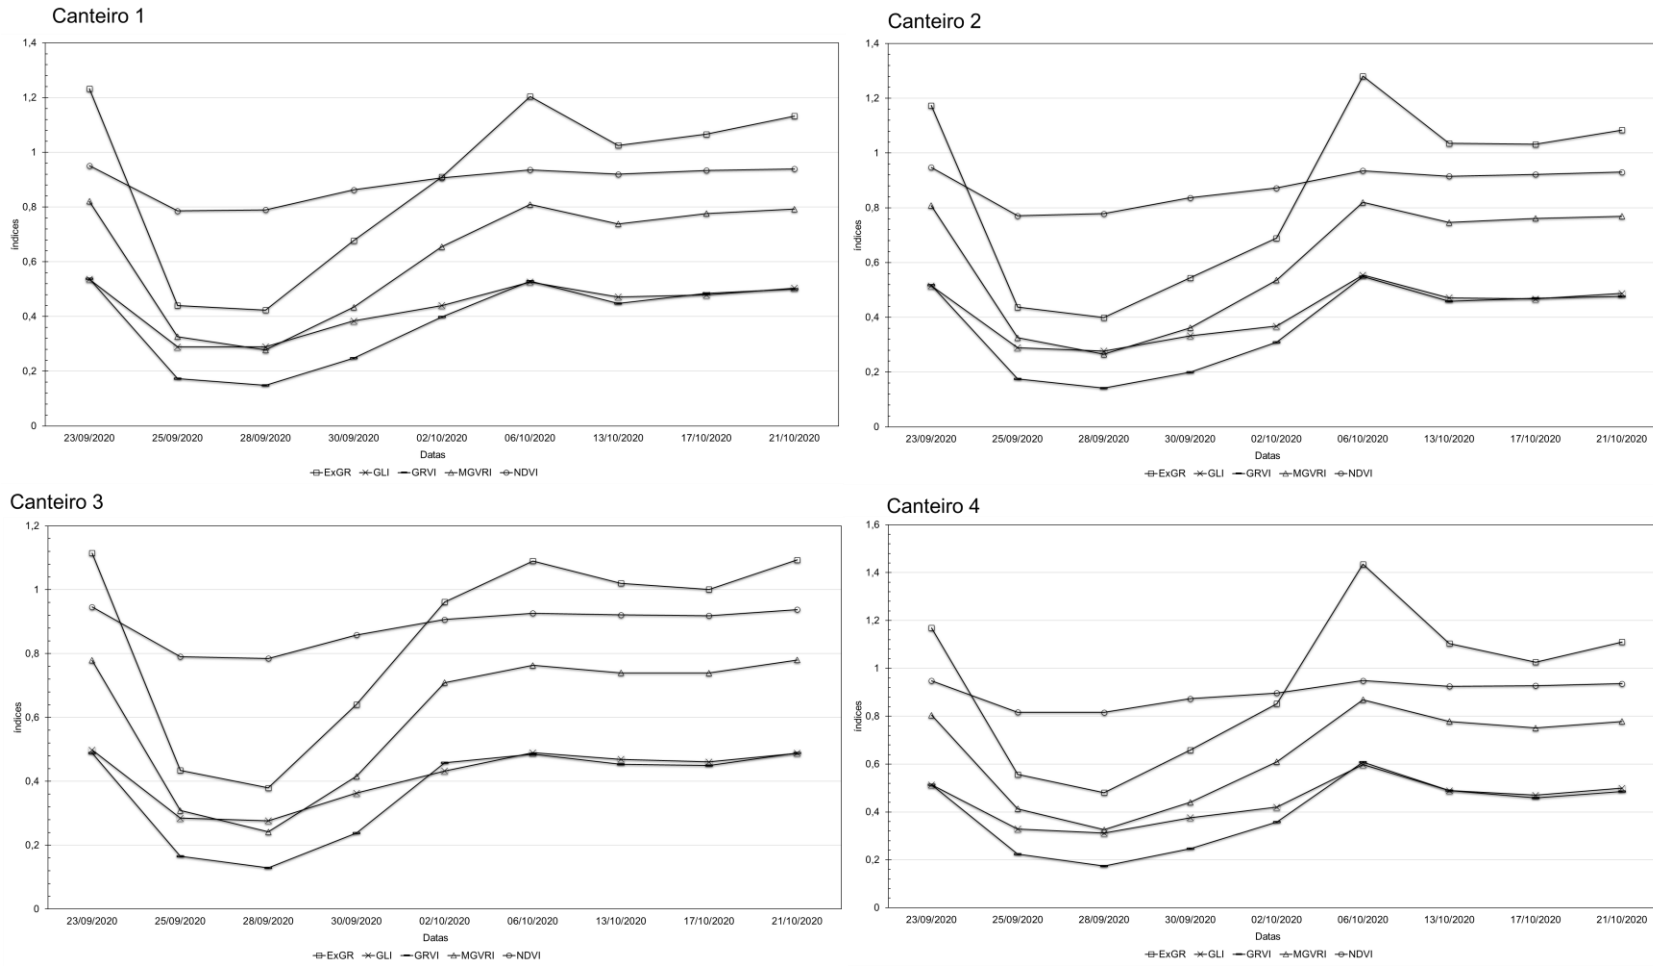


Figura 25. Valores médios dos índices ExR, GLI, GRVI, MGVRT e NDVI para cada canteiro de cultivo.

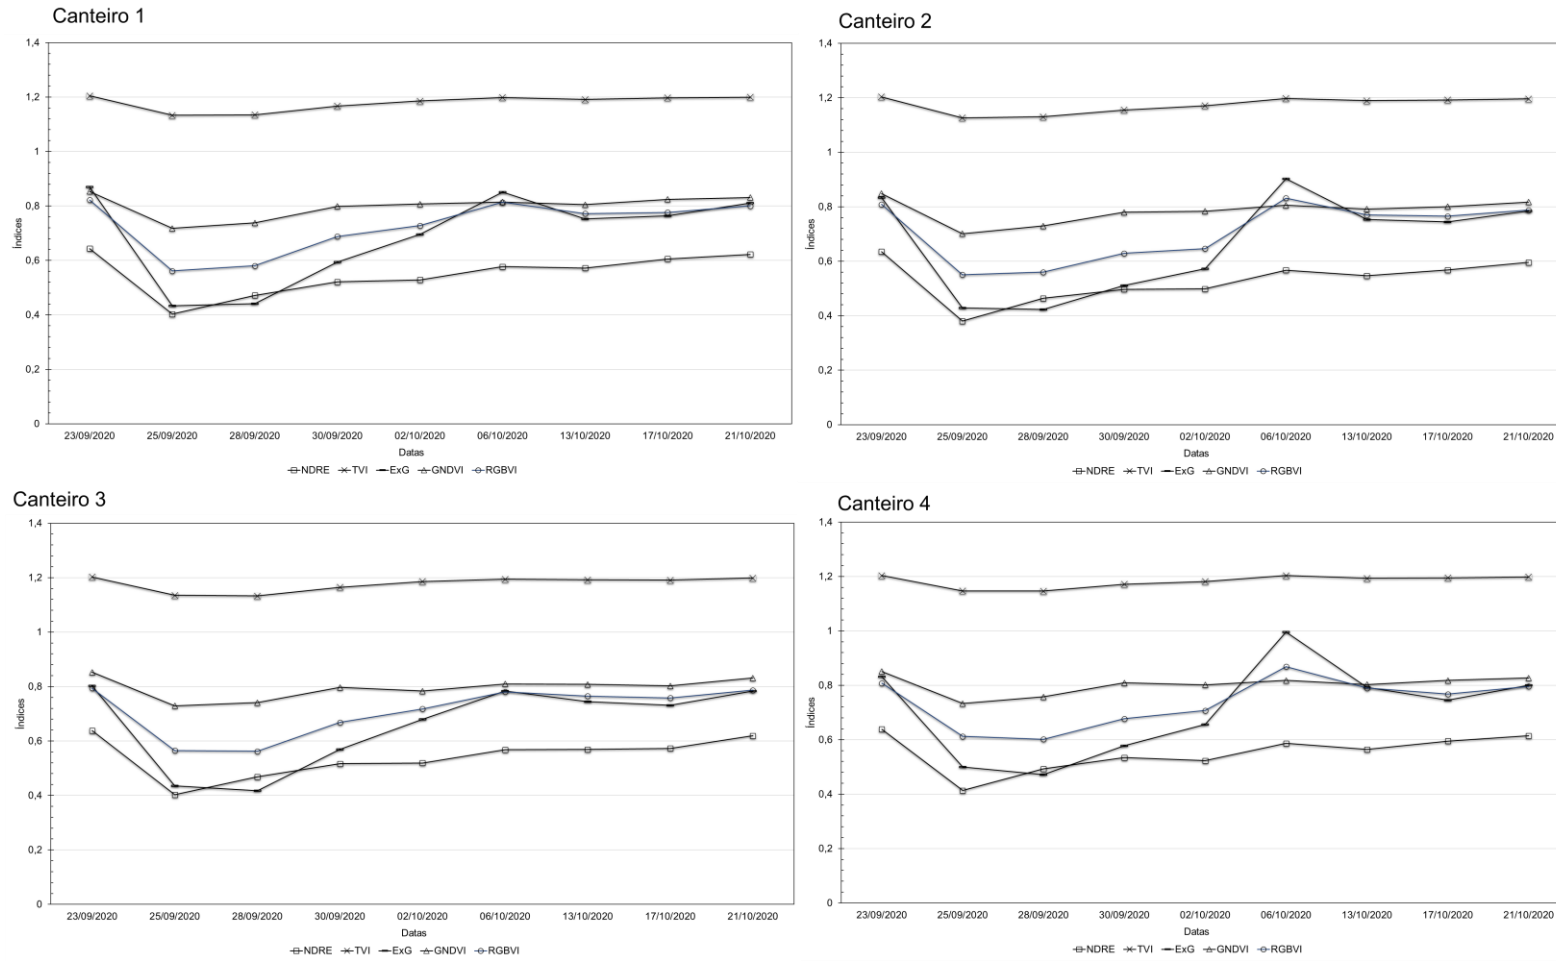


Figura 26. Valores médios dos índices NDRE, TVI, ExG, GNDVI e RGBVI para cada canteiro de cultivo.

O índice DVI apresentou valores na faixa de 0,18 a 0,57 nos canteiros avaliados, apresentando uma menor média no dia 6 de outubro, 11 dias após o corte do cultivo. Alguns apresentaram valores negativos, em uma faixa de -0,21 a -0,44 para ExB, 0,04 a -0,44 para ExR e -0,13 a -0,61 para o índice RI. O índice TVI apresentou valores na faixa de 1,13 a 1,20 que acompanharam muito bem o desenvolvimento do dossel.

O ExG é um índice que mede o excesso de energia verde em relação ao vermelho e azul nas imagens. É frequentemente usado em análises de imagens de satélite ou drones para avaliar a saúde e a densidade vegetal. Os valores do ExG variam de 0,42 a 1 no presente estudo. Quanto maior o valor, mais vegetação densa ou saudável geralmente é indicada. Os menores valores são atribuídos ao período do corte dos canteiros e início de um novo ciclo, aumentando à medida que ocorre um maior desenvolvimento do dossel.

O ExGR é um índice de vegetação que mede o excesso de energia na faixa verde em relação à faixa vermelha nas imagens. É uma medida útil para avaliar a saúde e o vigor das plantas, especialmente para detectar a densidade e a quantidade de vegetação verde. Os valores de ExGR variam de 0,38 a 1,44. Valores mais altos indicam uma maior quantidade de vegetação saudável ou densa. No caso desta pesquisa, os dados de ExGR ultrapassaram 1, devido ao índice ExR ter valores negativos que, a partir da fórmula de cálculo ( $ExG - ExR$ ) proporcionar a soma dos dois valores, não a subtração.

No estudo de Meyer e Neto (2008), o índice ExGR proporcionou a melhor identificação de plantas (qualidade média do índice de 0,80 a 0,93). Os resultados de ExGR tiveram desvios padrão menores e foram menos sensíveis a diferentes fundos de solo-resíduo durante o período de teste.

O GLI é um índice de vegetação que mede a densidade de folhas verdes em relação a outros elementos (como solo e galhos) na vegetação. É um indicador útil para monitorar a quantidade e a saúde das folhas verdes nas plantas. Os valores de GLI variam de 0,28 a 0,60. Valores mais altos indicam uma maior densidade de folhas verdes nas plantas. O estudo de Bhandari et al. (2020), apresenta valores máximos na faixa de 0,42 para o índice GLI no cultivo de trigo, representando as plantas mais saudáveis do estudo.

Semelhantemente ao NDVI, o Índice de Vegetação Melhorado (EVI) evidencia uma correlação substancial com o Índice de Área Foliar (LAI), biomassa, cobertura do dossel e fração de radiação fotossinteticamente ativa absorvida, estabelecendo-se como um indicador valioso para monitoramento das variações sazonais, interanuais e de longo prazo na arquitetura da vegetação. O EVI atenua distorções provenientes de aerossóis por meio da incorporação da

banda azul, realiza uma correção de influência do solo por meio da banda L e apresenta uma menor propensão à saturação em comparação ao NDVI. Devido a essas propriedades, pesquisadores e modeladores têm adotado dados de EVI como componente essencial na previsão da produção primária líquida em contextos de modelagem de ecossistemas. Essa adoção destaca-se como uma resposta às limitações percebidas do NDVI e destaca o papel do EVI como uma ferramenta promissora na análise e prognóstico de dinâmicas ecossistêmicas (Gurung et al., 2009).

No presente estudo, os valores do índice EVI variaram de 0,32 a 0,76. As definições de coeficientes utilizadas no presente estudo foram as utilizadas para o sensor MODIS, em que os coeficientes C1 e C2 são termos de resistência a aerossóis que dependem da faixa azul para eliminar parcialmente a influência atmosférica na faixa vermelha. Porém, não se espera as mesmas influências atmosféricas nas imagens de VANT e nas de satélite. Em termos de valores médios de EVI para os canteiros de cultivo não são baixos, estando numa faixa intermediária, mas provavelmente isto explica o comportamento aleatório das médias sem acompanhar o desenvolvimento do dossel. Neste caso, como teste, não se mostra um índice que pode ser adaptado para imagens obtidas por VANT.

O estudo conduzido por Almeida et al. (2008) aborda a aplicação do Enhanced Vegetation Index (EVI) na avaliação do vigor da vegetação, destacando sua relação direta com as variações na cobertura vegetal. O EVI é empregado para minimizar os efeitos indesejados provenientes do solo e da atmosfera, apresentando, adicionalmente, uma elevada sensibilidade a mudanças fenológicas.

A análise dos dados revela um comportamento aparentemente aleatório nos valores médios do EVI ao longo do tempo. Esse dinamismo observado na série temporal é atribuído à resposta fenológica do dossel florestal analisado. Tal resposta é temporalmente variável devido ao espectro de reflexão da cobertura vegetal, que incide nos sensores remotos. As diferentes fenofases, como desenvolvimento, descoloração, senescência das folhas e floração, variam anualmente, dependendo das condições climáticas. No entanto, essas fenofases geralmente exibem um comportamento sazonal, caracterizado por repetição e/ou periodicidade anual.

A análise dos resultados destaca picos no EVI que ocorrem nas mesmas épocas do ano, com valores máximos (0,6098) no verão e mínimos (0,4009) no inverno, indicando claramente um padrão sazonal. Este comportamento sazonal sugere uma forte relação entre o vigor da vegetação e a pluviosidade na região estudada, onde os valores de EVI são mais elevados durante o período chuvoso. A pesquisa destaca a capacidade do EVI em fornecer informações sobre a



dinâmica sazonal da vegetação e sua resposta às condições ambientais, destacando a influência significativa das condições climáticas, especialmente a pluviosidade, no comportamento do EVI na região de estudo.

De acordo com o trabalho de Gurung et al. (2009), para pastagem, a média de valores máximos anuais de EVI foi por volta de 0,6, com grande variação dos dados, próxima dos extremos 0 a 1.

O Índice de Vegetação Aprimorado (EVI) é um 'índice otimizado' projetado para aprimorar o sinal da vegetação com maior sensibilidade em regiões de alta biomassa e melhor monitoramento da vegetação, desacoplando o sinal de fundo do dossel e reduzindo as influências atmosféricas (Ahmad, 2012).

O GRVI é um índice de vegetação que mede a diferença entre a reflectância do infravermelho próximo (NIR) e a reflectância da faixa verde nas imagens. É usado para avaliar a densidade e a saúde das plantas, sendo particularmente útil para monitorar o crescimento da vegetação. Os valores de GRVI variam na faixa de 0,13 a 0,61. Valores mais altos indicam uma maior densidade e saúde das plantas. Lee et al. (2021), ressalta o uso do índice para relação com a biomassa vegetal em diferentes estudos e apresenta valores de GRVI para grama de médio porte de 0,11 e grama de pequeno porte de -0,01. A faixa de valores possui uma diferença com o presente estudo, mas apresenta a mesma tendência de aumento do valor do índice à medida que a planta se desenvolve.

O MGVRI é uma versão modificada do índice de vegetação Green Ratio Vegetation Index (GRVI), e é utilizado para medir a saúde e a densidade das plantas, especialmente para detectar a quantidade de vegetação verde. Os valores de MGVRI variam de 0,24 a 0,87. Valores mais altos indicam uma maior densidade e saúde das plantas. Este índice apresenta sensibilidade em demonstrar a mudança de dossel do cultivo.

O NDRE é um índice de vegetação que utiliza a região do espectro conhecida como "red edge" (borda vermelha) para avaliar a saúde e o vigor das plantas. É particularmente útil para estimar a quantidade de biomassa nas plantas e identificar o estresse hídrico. Os valores de NDRE variam de 0,38 a 0,64. Valores mais altos indicam uma maior quantidade de biomassa e saúde das plantas. O estudo realizado por Li et al. (2014) mostra que nos estádios V6 e V7 do cultivo de milho analisado, o solo teve uma forte influência no índice. Nos estádios de crescimento mais avançados, (V10-V12), a influência do solo foi melhor e o desempenho do NDRE foi melhor.

Para Thompson et al. (2019), os valores máximos de NDRE ocorreram com o fechamento do dossel, em vez de quando a cultura completou seu crescimento.

O OSAVI é um índice de vegetação que leva em consideração a correção do solo, o que o torna mais adequado para áreas com solo exposto. Ele é usado para avaliar a quantidade de vegetação saudável em áreas com vegetação densa ou parcialmente coberta. Os valores de OSAVI variam de 0,54 a 0,85. Valores mais altos indicam uma maior densidade e saúde das plantas.

O RGBVI é um índice de vegetação que combina informações de diferentes canais de cores (vermelho, verde e azul) para avaliar a saúde e a densidade das plantas. Os valores de RGBVI variam de 0,36 a 0,75. Valores mais altos indicam uma maior densidade e saúde das plantas. Lee et al. (2021), apresenta valores de RGBVI para grama de médio porte de 0,33 e grama de pequeno porte de 0,17.

O índice SAVI leva em consideração a correção do solo para reduzir o efeito do solo nos valores de reflectância e melhorar a detecção da vegetação. Os valores de SAVI variam de 0,55 a 0,87. Valores mais altos indicam uma maior densidade e saúde das plantas.

A linearidade entre as reflectâncias no infravermelho próximo e visível de solos nus motivou o desenvolvimento de diversos índices de vegetação, utilizando os coeficientes dessa relação para mitigar a influência do solo. Exemplos incluem o Índice de Vegetação Ajustado ao Solo (SAVI). Esses índices demonstram eficácia notável na redução da influência do solo, especialmente em contextos agrícolas ou em dosséis de plantas homogêneos. Contudo, a não universalidade da linha do solo demanda uma abordagem caso a caso (Rondeaux et al., 1996).

O Índice de Vegetação Ajustado para o Solo Modificado 2 (MSAVI2) é uma modificação dos índices de vegetação ajustados para o solo que busca resolver algumas limitações do NDVI quando aplicado em áreas com uma grande exposição da superfície do solo (Ahmad, 2012). No presente estudo, os valores ficaram na faixa de 0,34 a 0,85 e um comportamento muito parecido ao índice GEMI no canteiro 3 com valor menor de média, porém no dia 2 de outubro.

O índice GEMI alcançou valores na faixa de 0,41 a 0,87 nos diferentes dias de coleta de imagens, com uma diferença no canteiro 3 no dia 2 de outubro, possivelmente sendo influenciado por sombreamento.

Visando mitigar a dependência do NDVI em relação às propriedades atmosféricas, foi concebido o Índice Global de Vegetação por Diferença Normalizada (GEMI), projetado especificamente para reduzir os efeitos do solo e da atmosfera nos dados de satélite. O GEMI preserva informações biológicas das plantas de maneira comparável ao NDVI, mas com

transparência em relação à atmosfera. Entretanto, a complexidade da formulação do GEMI implica em desafios na sua aplicação e interpretação (Rondeaux et al., 1996).

O GNDVI, para o presente estudo, apresentou valores na faixa de 0,7 a 0,85, apresentando uma queda a partir do corte do cultivo e aumento à medida que o dossel desenvolvia. De acordo com o trabalho de Li et al. (2014), o GNDVI foi considerado mais sensível do que o NDVI na diferenciação da variabilidade do dossel de milho à medida que a vegetação aumentava durante a estação de crescimento. O GNDVI teve um desempenho significativamente melhor do que o NDVI na estimativa da concentração de N ou absorção pela planta em ambos os estágios, especialmente nos estágios V6 e V7. Ele teve um desempenho semelhante ou ligeiramente pior do que o NDRE. Esses resultados corroboram as descobertas de que as reflectâncias na região verde e de red edge são sensíveis a uma faixa mais ampla de níveis de clorofila do que a reflectância vermelha. Além disso, a banda de red edge pode ser influenciada pelo aumento do estresse de fluorescência, sendo assim mais sensível às alterações de clorofila induzidas pelo estresse do que a banda verde.

O NDVI é um índice comumente utilizado para monitorar a vegetação e sua saúde. Ele fornece informações sobre a quantidade de vegetação verde e pode indicar a condição geral da vegetação, a cobertura vegetal e a produtividade da vegetação em uma determinada área. Ao longo do tempo, o NDVI varia, mostrando mudanças na quantidade de vegetação verde nas datas em questão. É possível notar que o NDVI tende a aumentar em algumas datas, o que pode indicar o crescimento ou o aumento da vegetação. Os valores de NDVI variam de 0,77 a 0,95.

As técnicas de sensoriamento remoto oferecem uma solução eficaz para estimar com precisão a biomassa verde acima do solo em pastagens. Índices de vegetação calculados a partir das bandas vermelha e infravermelha próxima (NIR) são bons indicadores da atividade fotossintética da planta e estão bem correlacionados com a biomassa verde acima do solo em pastagens. O índice de vegetação bem conhecido, amplamente utilizado para estimativa de biomassa verde acima do solo em pastagens, é o NDVI. No entanto, o índice perde sua utilidade para estimar a biomassa verde acima do solo em situações de vegetação esparsa devido à contribuição proeminente do fundo do solo (Ren e Zhou, 2014).

Ao longo do tempo, o NDVI varia, mostrando mudanças na quantidade de vegetação verde nas datas em questão. É possível notar que o NDVI tende a aumentar em algumas datas, o que pode indicar o crescimento ou o aumento da vegetação. Comparando os diferentes canteiros, é evidente que o NDVI pode variar entre eles em determinadas datas. Alguns canteiros

podem apresentar valores mais altos ou mais baixos de NDVI em comparação com outros, o que pode refletir diferenças na cobertura vegetal ou na saúde das plantas em cada grupo.

Em geral, os valores do NDVI estão relativamente altos, o que indica uma presença significativa de vegetação verde nas áreas estudadas. Os valores do NDVI para cada canteiro apresentam valores relativamente estáveis ao longo do período observado, com pequenas flutuações.

De acordo com Rondeaux et al. (1996), o Índice de Vegetação por Diferença Normalizada (NDVI) mantém uma relação direta com a quantidade de vegetação até atingir a saturação na cobertura total do dossel, estando, portanto, intrinsecamente vinculado às propriedades biofísicas dos dosséis vegetais, incluindo a radiação ativa fotossinteticamente absorvida, eficiências fotossintéticas e produtividade. Contudo, índices intrínsecos, exemplificados pelo NDVI, são altamente sensíveis às propriedades ópticas do solo, apresentando desafios interpretativos em áreas com baixa cobertura vegetal quando as características do solo são desconhecidas.

O trabalho de Lee et al. (2021), apresenta valores para grama de porte médio, o trabalho apresenta uma média de 0,52 para NDVI, 0,43 para GNDVI, 0,33 para RGBVI, 0,11 para GRVI e 0,78 para SAVI. Para grama de porte pequeno, os valores de NDVI, GNDVI, RGBVI, GRVI e SAVI são, respectivamente, 0,29, 0,30, 0,17, -0,01 e 0,43.

A temperatura do dossel é uma medida da temperatura da superfície vegetada ou da parte superior das plantas. Essa medida é útil para monitorar a temperatura da vegetação ao longo do tempo e pode fornecer informações sobre a saúde e o estado da vegetação. Ao longo do tempo, a temperatura do dossel pode variar de forma significativa, indicando diferentes condições climáticas e alterações sazonais. No presente trabalho, a faixa de temperatura foi de 24,6 a 41,4°C.

Alguns índices apresentaram valores fora da escala normal de cultivos saudáveis, valores maiores que 1 e valores negativos, podendo ocorrer devido à necessidade maior de ajustes na calibração dos dados de reflectância e conversão das bandas, assim como sombreamento nos canteiros de cultivo ou captura de imagens em horário de sol intenso. O trabalho de Candiago et al. (2015), apresenta valores registrados para GNDVI e SAVI que ultrapassaram as faixas convencionalmente estabelecidas em algumas áreas do mapa gerado, sendo atribuído esse fenômeno a fatores como a presença de sombras entre as linhas do vinhedo, impactando negativamente nos resultados desses índices, assim também como ao emprego de Números Digitais em substituição aos correspondentes valores de reflectância. Essas considerações

apontam para a necessidade de cautela na interpretação desses índices em contextos com características específicas, destacando a relevância de ajustes metodológicos para otimizar a precisão das análises em cenários agronômicos.

Os índices de vegetação são métricas importantes que utilizam informações espectrais de diferentes comprimentos de onda do espectro eletromagnético para avaliar a saúde, cobertura e produtividade da vegetação. Cada índice possui uma fórmula específica que responde a diferentes características das plantas, como o teor de clorofila, a quantidade de folhas verdes e a quantidade de vegetação total. A partir dos dados obtidos, é possível notar que a data de corte da vegetação (início do ciclo) em 24/09/2020 pode ter influenciado o comportamento dos índices de vegetação nas datas subsequentes. O corte da vegetação acompanha a diminuição significativa nos valores dos índices de vegetação, uma vez que a vegetação foi removida. Isso pode ter resultado em uma redução temporária na presença de vegetação verde nas áreas estudadas.

Após o corte da vegetação, é normal que ocorram mudanças na estrutura da vegetação, na quantidade de folhas verdes e na produtividade das plantas, o que influencia diretamente nos valores dos índices de vegetação nas datas seguintes. Os índices de vegetação mostraram uma recuperação gradual à medida que a vegetação se regenerou ou que novas plantas tenham crescido após o corte.

Os índices de vegetação que apresentam os maiores valores médios para cada canteiro são ExG, ExGR, GEMI, GNDVI, MGVRI, OSAVI, RGBVI, TVI e NDVI, nas datas 23/9 e 21/10 de 2020, o que condiz com o máximo desenvolvimento do cultivo nas datas. Em conjunto destes, os índices NDRE, GLI, GRVI e a temperatura, apresentam melhor comportamento em relação ao desenvolvimento do dossel, com um índice com valor mais elevado na primeira data, diminuindo imediatamente após o corte e com aumento novamente ao longo do crescimento do cultivo. Os índices ExR e RI, possuem um padrão que, apesar dos valores negativos desses índices, eles capturam de maneira sensível as variações associadas ao crescimento e manejo do cultivo em questão.

O comportamento observado nos índices de vegetação, que diminuem após o corte da pastagem e aumentam ao longo do seu subsequente desenvolvimento, pode ser atribuído a várias interações fisiológicas e fenológicas das plantas, podendo ser devido à:

- Reflexo da Senescência e Estresse Inicial: O corte da pastagem resulta em um período inicial de senescência, onde as plantas respondem ao estresse mecânico e à perda de biomassa. Isso se reflete nos índices de vegetação, que diminuem devido à redução da atividade fotossintética e à resposta fisiológica ao estresse.

- Alterações na Estrutura do Dossel: O corte altera a estrutura do dossel, diminuindo temporariamente a área foliar disponível para a captação de luz. Isso impacta negativamente nos índices de vegetação, que são sensíveis à quantidade e qualidade da vegetação presente.
- Regeneração Ativa: Após o corte, as plantas iniciam um processo de regeneração ativa, envolvendo a produção de novos brotos e folhas. À medida que essa regeneração ocorre, os índices de vegetação começam a aumentar, indicando uma recuperação nas atividades fotossintéticas.
- Aumento na Área Foliar e Atividade Fotossintética: O desenvolvimento subsequente da pastagem é caracterizado pelo aumento na área foliar e na atividade fotossintética. Os índices de vegetação respondem positivamente a esses processos, refletindo a recuperação da saúde e vitalidade da vegetação.
- Resposta ao Ciclo de Crescimento: Índices de vegetação, como NDVI, são sensíveis às mudanças no ciclo de crescimento das plantas. O aumento gradual ao longo do tempo pode ser associado ao retorno das condições ideais de crescimento, incluindo a fase de crescimento vegetativo e a entrada na fase de maturação.
- Indicação da Resiliência do Ecossistema: O aumento dos índices de vegetação após o corte e durante o subsequente desenvolvimento sugere a resiliência da vegetação e sua capacidade de se recuperar de distúrbios, como o corte para pastejo ou colheita.

A variação nas médias dos índices DVI, EVI, ExB, GEMI, MSAVI2, OSAVI e SAVI, em contraste com os padrões anteriormente discutidos, pode também ser explicada por fatores específicos relacionados ao manejo pós-corte e à presença de biomassa remanescente na área.


Tais fatores podem ser:

- Decomposição e Alteração Espectral: A presença de biomassa cortada, deixada na área após o corte, pode passar por processos de decomposição ao longo do tempo. Essa decomposição pode alterar as propriedades espectrais da área, afetando os índices de vegetação, especialmente aqueles sensíveis à presença de material orgânico.
- Influência na Reflectância do Solo: A abertura do dossel vegetal pós-corte pode aumentar a exposição do solo à radiação solar, influenciando a reflectância espectral. Índices que são sensíveis à presença do solo, como SAVI e OSAVI, podem refletir variações mais pronunciadas devido à maior exposição do solo.

- **Efeito na Captura de Sinal pelo Sensor:** A presença de biomassa remanescente e a maior exposição do solo podem interferir na captura do sinal espectral pelo sensor, afetando a qualidade das imagens. Isso, por sua vez, pode impactar os valores dos índices de vegetação calculados a partir dessas imagens.
- **Mudanças Dinâmicas Após o Manejo:** A dinâmica pós-corte, incluindo a decomposição da biomassa e a resposta do solo à abertura do dossel, pode variar ao longo dos dias, gerando uma maior variação nas médias dos índices. Essas variações temporais podem ser particularmente marcadas em índices sensíveis a essas mudanças.
- **Sensibilidade dos Índices:** Cada índice de vegetação responde de maneira única a diferentes características do dossel e condições ambientais. A sensibilidade específica de cada índice pode explicar as variações diferenciadas observadas.

Essas considerações destacam a complexidade da dinâmica pós-corte e a importância de levar em conta fatores específicos do manejo e da composição do dossel ao interpretar as variações nos índices de vegetação. Essa compreensão mais profunda permite uma análise mais precisa e contextualizada das mudanças observadas nos índices ao longo do tempo.

Um ponto importante a ser destacado é a presença de sombra sob o canteiro 3 analisado, em que para a mesma imagem capturada, os índices possuem diferente comportamento em destacar ou não a mesma na imagem. Na Figura 27, estão apresentados exemplos em que no mesmo dia e mesma imagem capturada, dois índices (GEMI e NDVI) demonstram diferentes comportamentos em relação a identificação da sombra na imagem. De acordo com o trabalho de Barbosa et al. (2019), a presença de sombra na imagem coletada influencia o comportamento de índices de vegetação, podendo ocasionar erro na distinção de vegetação e solo.



**Figura 27.** Identificação de sombra pelo índice GEMI (A) e não identificação de sombra pelo índice NDVI (B) no dia 2 de outubro.

A Tabela 6 apresenta as equações lineares e os coeficientes de determinação ( $R^2$ ) para a relação entre índices de vegetação (x) e o conteúdo de água no solo (y) em diferentes profundidades no canteiro 2. Cada linha representa um índice de vegetação específico, relacionado à análise da vegetação no canteiro.



**Tabela 6.** Equação linear e coeficiente de determinação ( $R^2$ ) para a relação índice de vegetação (x) e conteúdo de água no solo (y) no canteiro 2 analisado.

Índice	Profundidade	Equação	$R^2$
DVI	0,3	$y = 0,0463x + 0,3559$	0,2765
ExB	0,2	$y = 0,2247x + 0,3839$	0,6726
	0,4	$y = 0,033x + 0,3636$	0,4677
ExG	0,2	$y = -0,0684x + 0,3641$	0,7082
	0,4	$y = -0,0097x + 0,3605$	0,4639
ExGR	0,2	$y = -0,0364x + 0,35$	0,7014
	0,4	$y = -0,0051x + 0,3584$	0,4443
ExR	0,2	$y = 0,0773x + 0,3338$	0,6816
	0,4	$0,0107x + 0,3562$	0,4248
GLI	0,2	$y = -0,1194x + 0,3688$	0,7015
	0,4	$y = -0,017x + 0,3612$	0,458
GNDVI	0,2	$y = -0,3298x + 0,5763$	0,8198
	0,4	$y = -0,0559x + 0,3976$	0,7583
GRVI	0,2	$y = -0,0751x + 0,3464$	0,6804
	0,4	$y = -0,0105x + 0,3579$	0,4286
MGVRI	0,2	$y = -0,053x + 0,3507$	0,6888
	0,4	$y = -0,0073x + 0,3585$	0,4238
NDRE	0,2	$y = -0,2019x + 0,4242$	0,9357
	0,4	$y = -0,0312x + 0,3703$	0,7205
RGBVI	0,2	$y = -0,1191x + 0,4028$	0,7934
	0,4	$y = -0,0167x + 0,3658$	0,5002
RI	0,2	$y = 0,0751x + 0,3464$	0,6804
	0,4	$y = 0,0105x + 0,3579$	0,4286
TVI	0,2	$y = -0,4439x + 0,8397$	0,7933
	0,4	$y = -0,0672x + 0,4329$	0,5857
NDVI	0,2	$y = -0,2418x + 0,5362$	0,755
	0,4	$y = -0,0378x + 0,388$	0,5938

Nota: A profundidade de 0,2m corresponde à camada de 0,1 a 0,2m de profundidade do solo, a camada de 0,2 a 0,3m corresponde a profundidade indicada de 0,3 e a camada de 0,3 a 0,4m corresponde a profundidade indicada de 0,4m.

O índice DVI Apresenta baixo coeficiente de determinação ( $R^2 = 0,2765$ ) indicando uma relação limitada com o conteúdo de água no solo. O índice Exb mostra aumento na correlação com a profundidade, sendo mais significativo em 0,4m ( $R^2 = 0,4677$ ). OS índices ExG, ExGR, ExR, GLI, GRVI e MGVRI demonstram coeficientes de determinação consistentes, indicando boa capacidade de explicar variações no conteúdo de água no solo. O

índice GNDVI apresenta elevado  $R^2$  em ambas as profundidades (0,2m: 0,8198; 0,4m: 0,7583), sugerindo forte relação com o conteúdo de água no solo. O índice NDRE destaca-se com altos coeficientes de determinação em ambas as profundidades (0,2m: 0,9357; 0,4m: 0,7205), indicando sensibilidade significativa ao conteúdo de água no solo. Os índices RGBVI, TVI e NDVI mostram valores moderados de  $R^2$ , indicando uma correlação razoável com o conteúdo de água.

A partir dos dados apresentados na Tabela 6, pode-se considerar que a profundidade do solo influencia a capacidade dos IV em refletir variações no conteúdo de água; alguns índices de vegetação, como GNDVI e NDRE, destacam-se como indicadores robustos, enquanto outros apresentam correlações mais moderadas; e o entendimento dessas relações é crucial para o desenvolvimento de estratégias de monitoramento e manejo adequado da irrigação em práticas agrícolas.

A Tabela 7 apresenta equações polinomiais e coeficientes de determinação ( $R^2$ ) que descrevem a relação entre diferentes índices de vegetação (IV) e a altura das plantas nos quatro canteiros de cultivo. Esses resultados são cruciais para a compreensão do desempenho dos IV na estimativa da altura das plantas, fornecendo informações relevantes para o monitoramento do crescimento vegetativo em ambientes agrícolas:

- ExG: O coeficiente de determinação ( $R^2$ ) é alto em todos os canteiros, indicando uma relação forte com a altura das plantas.
- ExGR: Apresenta correlação significativa, com  $R^2$  consistentemente acima de 0,65.
- GNDVI: Demonstra alta correlação em todos os canteiros, com  $R^2$  superior a 0,84.
- NDRE: Destaca-se com  $R^2$  alto, indicando forte sensibilidade à altura das plantas ( $R^2$  variando de 0,7369 a 0,9656).
- TVI e NDVI: Mostram correlações consistentemente elevadas em todos os canteiros.
- Temperatura do Dossel: Apresenta relações polinomiais bem definidas com a altura das plantas.  $R^2$  varia de 0,8519 a 0,8845, indicando uma boa capacidade de explicar as variações na altura das plantas.

Diferentes índices de vegetação exibem variabilidade em sua capacidade de prever a altura das plantas. A escolha do índice apropriado pode depender do canteiro específico, sugerindo uma abordagem personalizada para a seleção do IV em estudos de monitoramento do crescimento vegetativo.

**Tabela 7.** Equação polinomial e coeficiente de determinação ( $R^2$ ) para a relação índice de vegetação (x) e altura de plantas (y) para cada canteiro de cultivo.

Índice	Canteiro	Equação	$R^2$
ExG	1	$y = -7E-05x^2 + 0,0167x - 0,1894$	0,8528
	2	$y = -3E-05x^2 + 0,0107x - 0,0276$	0,7446
	3	$y = -4E-05x^2 + 0,0109x - 0,011$	0,8568
	4	$y = -5E-05x^2 + 0,0138x - 0,0695$	0,635
ExGR	1	$y = -0,0001x^2 + 0,0277x - 0,6275$	0,8417
	2	$y = -5E-05x^2 + 0,0171x - 0,3266$	0,7547
	3	$y = -7E-05x^2 + 0,0215x - 0,4509$	0,8272
	4	$y = -9E-05x^2 + 0,0233x - 0,4278$	0,6543
ExR	1	$y = 4E-05x^2 - 0,0113x + 0,4471$	0,8242
	2	$y = 2E-05x^2 - 0,0068x + 0,3121$	0,7666
	3	$y = 4E-05x^2 - 0,0103x + 0,4306$	0,7885
	4	$y = 3E-05x^2 - 0,0093x + 0,3532$	0,6732
GLI	1	$y = -4E-05x^2 + 0,0096x - 0,0699$	0,8508
	2	$y = -2E-05x^2 + 0,0058x + 0,036$	0,7419
	3	$y = -2E-05x^2 + 0,0066x + 0,0171$	0,8629
	4	$y = -3E-05x^2 + 0,0076x + 0,0168$	0,6582
GNDVI	1	$y = -2E-05x^2 + 0,0052x + 0,5394$	0,8926
	2	$y = -2E-05x^2 + 0,0044x + 0,5463$	0,9259
	3	$y = -1E-05x^2 + 0,003x + 0,6186$	0,8485
	4	$y = -2E-05x^2 + 0,0038x + 0,5997$	0,8756
GRVI	1	$y = -4E-05x^2 + 0,0116x - 0,2928$	0,8231
	2	$y = -2E-05x^2 + 0,007x - 0,1551$	0,7792
	3	$y = -4E-05x^2 + 0,0108x - 0,2839$	0,7827
	4	$y = -3E-05x^2 + 0,0089x - 0,1734$	0,6897
MGVRI	1	$y = -5E-05x^2 + 0,0156x - 0,3122$	0,8393
	2	$y = -1E-05x^2 + 0,0088x - 0,1053$	0,8222
	3	$y = -4E-05x^2 + 0,014x - 0,293$	0,8061
	4	$y = -2E-05x^2 + 0,0098x - 0,0488$	0,7557
NDRE	1	$y = -2E-05x^2 + 0,0064x + 0,1815$	0,9656
	2	$y = -2E-05x^2 + 0,0065x + 0,2805$	0,8227

	3	$y = -3E-05x^2 + 0,0071x + 0,2809$	0,8855
	4	$y = -3E-05x^2 + 0,0072x + 0,3171$	0,7369
TVI	1	$y = -1E-05x^2 + 0,0029x + 1,0268$	0,892
	2	$y = -8E-06x^2 + 0,0022x + 1,0397$	0,9084
	3	$y = -8E-06x^2 + 0,0022x + 1,0489$	0,8646
	4	$y = -8E-06x^2 + 0,0022x + 1,047$	0,8659
NDVI	1	$y = -3E-05x^2 + 0,0067x + 0,5402$	0,8921
	2	$y = -2E-05x^2 + 0,005x + 0,5724$	0,9069
	3	$y = -2E-05x^2 + 0,005x + 0,5913$	0,8648
	4	$y = -8E-06x^2 + 0,0022x + 1,047$	0,8659
Temperatura do dossel	1	$y = -0,0058x^2 + 0,8391x + 7,8184$	0,8845
	2	$y = -0,0044x^2 + 0,6849x + 12,221$	0,8519
	3	$y = -0,0038x^2 + 0,5841x + 15,239$	0,8572
	4	$y = -0,0041x^2 + 0,656x + 11,891$	0,8557

### 3.4 Conclusões

Os resultados apresentados neste capítulo fornecem uma análise abrangente dos índices de vegetação e da temperatura do dossel em quatro canteiros de cultivo, no período de 23 de setembro a 21 de outubro de 2020. A avaliação dos valores médios e desvios padrão para os diversos índices de vegetação, juntamente com a temperatura do dossel, revela padrões distintos ao longo do tempo e entre os canteiros.

Inicialmente, destaca-se a exclusão dos índices RVI e MTCI devido à sua inadequação para a área específica, evidenciando a importância de uma cuidadosa seleção de índices de vegetação de acordo com as condições ambientais e características da vegetação estudada. A preferência por índices como NDRE, GLI, GRVI, e outros, que demonstraram consistência e desempenho superior, é essencial para garantir resultados mais confiáveis na avaliação do desenvolvimento vegetativo e processos biológicos.

A análise das incertezas associadas aos índices de vegetação, indicadas pelos desvios padrão, revela baixa variabilidade nos dados, destacando a confiabilidade das medições. A relação inversa entre a incerteza e a confiabilidade dos valores ressalta a importância de índices menos suscetíveis a variações, assegurando uma interpretação mais precisa.

Observou-se que após o corte do cultivo em 25 de setembro, os índices de vegetação, incluindo NDRE, RGBVI, TVI, NDVI, ExG, ExGR, GLI, GNDVI, GRVI, e MGVR, aumentaram significativamente, atingindo valores próximos ao máximo, indicando maior biomassa. Este comportamento está alinhado com a resposta fisiológica das plantas ao corte, seguido pelo desenvolvimento do dossel.

Índices específicos, como DVI, ExG, ExGR, GLI, e GNDVI, destacam-se na sua sensibilidade às mudanças no conteúdo de água no solo, sendo essenciais para compreender as condições hídricas em diferentes profundidades. A análise de equações lineares e coeficientes de determinação demonstra que GNDVI e NDRE se destacam como indicadores robustos da umidade do solo, fundamentais para estratégias de irrigação.

Além disso, ao explorar a relação entre os índices de vegetação e a altura das plantas, observou-se que ExG, ExGR, GNDVI, NDRE, TVI, e NDVI apresentam correlações significativas, tornando-os valiosos para estimativas precisas do crescimento vegetativo em ambientes agrícolas.

Contudo, é crucial reconhecer as limitações e considerações específicas, como a presença de sombras afetando o comportamento dos índices, destacando a importância de ajustes metodológicos para otimizar a precisão em cenários agronômicos.

## Referências

- Abdollahnejad, A., Panagiotidis, D., & Surový, P. (2017). Forest canopy density assessment using different approaches—Review. *Journal of forest science*, 63(3), 107-116. DOI: 10.17221/110/2016-JFS
- Abrahão, S. A., Pinto, F. D. A. D. C., Queiroz, D. M. D., Santos, N. T., Gleriani, J. M., & Alves, E. A. (2009). Índices de vegetação de base espectral para discriminar doses de nitrogênio em capim-tanzânia. *Revista Brasileira de Zootecnia*, 38, 1637-1644.
- Ahmad, F. (2012). Spectral vegetation indices performance evaluated for Cholistan Desert. *J. Geogr. Reg. Plan*, 5(6), 165-172.
- Ali, S. M., & Salman, S. S. (2015). Estimating the yield of rice farms in southern Iraq using Landsat images. *International Journal of Scientific & Engineering Research*, 6(8), 1607-1614. DOI: 10.13140/RG.2.1.3121.6806
- Almeida, A. Q. D., Silva, G. F. D., Pezzopane, J. E. M., & Ribeiro, C. A. D. (2008). Enhanced Vegetation Index (EVI) na análise da dinâmica da vegetação da reserva biológica de Sooretama, ES. *Revista Arvore*, 32, 1099-1107.

- Änäkälä, M., Lajunen, A., Hakojärvi, M., & Alakukku, L. (2022). Evaluation of the Influence of Field Conditions on Aerial Multispectral Images and Vegetation Indices. *Remote Sensing*, *14*(19), 4792. DOI: <https://doi.org/10.3390/rs14194792>
- Barbosa, B. D. S., Ferraz, G. A. S., Gonçalves, L. M., Marin, D. B., Maciel, D. T., Ferraz, P. F. P., & Rossi, G. (2019). RGB vegetation indices applied to grass monitoring: A qualitative analysis. DOI: <https://doi.org/10.15159/AR.19.119>
- Bayaraa, B., Hirano, A., Purevtseren, M., Vandansambuu, B., Damdin, B., & Natsagdorj, E. (2022). Applicability of different vegetation indices for pasture biomass estimation in the north-central region of Mongolia. *Geocarto International*, *37*(25), 7415-7430.
- Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote sensing*, *7*(4), 4026-4047.
- Chen, A., Orlov-Levin, V., & Meron, M. (2018). Applying high-resolution visible-channel aerial scan of crop canopy to precision irrigation management. In *Proceedings* (Vol. 2, No. 7, p. 335). MDPI.
- da Silva Quinaia, T. L., do Valle Junior, R. F., de Miranda Coelho, V. P., da Cunha, R. C., Valera, C. A., Sanches Fernandes, L. F., & Pacheco, F. A. L. (2021). Application of an improved vegetation index based on the visible spectrum in the diagnosis of degraded pastures: Implications for development. *Land Degradation & Development*, *32*(16), 4693-4707.
- Freire-Silva, J., Paz, Y. E., Lima-Silva, P. P., Pereira, J. A. S., & Candeias, A. L. B. (2019). Índices de vegetação do sensoriamento remoto para processamento de imagens na faixa do visível (RGB). *J. Hyperspectr. Remote Sens*, *9*, 228-239.
- García-Fernández, M., Sanz-Ablanedo, E., & Rodríguez-Pérez, J. R. (2021). High-resolution drone-acquired RGB imagery to estimate spatial grape quality variability. *Agronomy*, *11*(4), 655. DOI: <https://doi.org/10.3390/agronomy11040655>
- Gorgan, D., Bacu, V., Rodila, D., Pop, F., & Petcu, D. (2010). Experiments on ESIP—Environment oriented satellite data processing platform. *Earth Science Informatics*, *3*, 297-308. DOI: [10.1007/s12145-010-0065-0](https://doi.org/10.1007/s12145-010-0065-0)
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P. J., Burgos-Artizzu, X. P., & Ribeiro, A. (2011). Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, *75*(1), 75-83. DOI: <https://doi.org/10.1016/j.compag.2010.09.013>
- Gurung, R. B., Breidt, F. J., Dutin, A., & Ogle, S. M. (2009). Predicting Enhanced Vegetation Index (EVI) curves for ecosystem modeling applications. *Remote Sensing of Environment*, *113*(10), 2186-2193.
- Lee, G., Hwang, J., & Cho, S. (2021). A novel index to detect vegetation in urban areas using UAV-based multispectral images. *Applied Sciences*, *11*(8), 3472.

- Li, F., Miao, Y., Feng, G., Yuan, F., Yue, S., Gao, X., ... & Chen, X. (2014). Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crops Research*, *157*, 111-123.
- Lu, N., Zhou, J., Han, Z., Li, D., Cao, Q., Yao, X., ... & Cheng, T. (2019). Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. *Plant Methods*, *15*(1), 1-16. DOI: <https://doi.org/10.1186/s13007-019-0402-3>
- Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, *24*(14), 2855-2877.
- Orsini, R., Fiorentini, M., & Zenobi, S. (2019). Testing vegetation index categories as influenced by soil management and nitrogen fertilization in cereal based cropping systems. In *2019 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)* (pp. 13-18). IEEE. DOI:
- Palaś, K. W., & Zawadzki, J. (2020). Sentinel-2 imagery processing for tree logging observations on the białowieża forest world heritage site. *Forests*, *11*(8), 857. DOI: [10.1109/MetroAgriFor.2019.8909216](https://doi.org/10.1109/MetroAgriFor.2019.8909216)
- Peel, M. C.; Finlayson, B. L.; McMahon, T. A. (2007). Updated world map of the Köppen-Geiger climate classification. *Hydrology and Earth System Sciences* *11* (5), 1633–1644. URL <<http://www.hydrol-earth-syst-sci.net/11/1633/2007/>>
- Prudente Junior, A. C. (2019) Utilização de sonda capacitiva FDR para estimativa do consumo de água e coeficiente da cultura de *Urochloa brizantha* cv Marandu em cultivo solteiro e consorciado. Universidade de São Paulo – Escola Superior de Agricultura “Luiz de Queiroz”.
- Prudente Junior, A. C.; Mendonça, F. C.; Souza, D. P.; Bretas, L. M.; Amorim, D. M. (2019). Calibration of FDR probe in eutroferric red nitisol. In: V Inovagri Meeting. Fortaleza: [s.n.].
- Ren, H., & Zhou, G. (2014). Determination of green aboveground biomass in desert steppe using litter-soil-adjusted vegetation index. *European Journal of Remote Sensing*, *47*(1), 611-625.
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote sensing of environment*, *55*(2), 95-107.
- Thompson, C. N., Guo, W., Sharma, B., & Ritchie, G. L. (2019). Using normalized difference red edge index to assess maturity in cotton. *Crop Science*, *59*(5), 2167-2177.
- Tong, X., Duan, L., Liu, T., & Singh, V. P. (2019). Combined use of in situ hyperspectral vegetation indices for estimating pasture biomass at peak productive period for harvest decision. *Precision Agriculture*, *20*, 477-495.
- Torino, M. S., Ortiz, B. V., Fulton, J. P., Balkcom, K. S., & Wood, C. W. (2014). Evaluation of vegetation indices for early assessment of corn status and yield potential in the southeastern United States. *Agronomy Journal*, *106*(4), 1389-1401. DOI: [10.2134/agronj13.0578](https://doi.org/10.2134/agronj13.0578)

Van Genuchten Mt. (1980). A Closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Sci Soc Am J.* 44:892-8. DOI: <https://doi.org/10.2136/sssaj1980.03615995004400050002x>



**Anexo A – Valores médios dos índices de vegetação analisados para os quatro canteiros de cultivo**

índice de vegetação	Canteiro	23/09/2020	25/09/2020	28/09/2020	30/09/2020	02/10/2020	06/10/2020	13/10/2020	17/10/2020	21/10/2020
DVI	1	0,53 ( $\pm 0,1$ )	0,43 ( $\pm 0,13$ )	0,52 ( $\pm 0,14$ )	0,52 ( $\pm 0,14$ )	0,35 ( $\pm 0,1$ )	0,24 ( $\pm 0,06$ )	0,38 ( $\pm 0,08$ )	0,51 ( $\pm 0,1$ )	0,46 ( $\pm 0,09$ )
	2	0,54 ( $\pm 0,11$ )	0,45 ( $\pm 0,14$ )	0,55 ( $\pm 0,15$ )	0,46 ( $\pm 0,13$ )	0,33 ( $\pm 0,1$ )	0,23 ( $\pm 0,06$ )	0,39 ( $\pm 0,09$ )	0,46 ( $\pm 0,1$ )	0,47 ( $\pm 0,1$ )
	3	0,49 ( $\pm 0,1$ )	0,42 ( $\pm 0,13$ )	0,48 ( $\pm 0,13$ )	0,5 ( $\pm 0,18$ )	0,18 ( $\pm 0,1$ )	0,23 ( $\pm 0,06$ )	0,34 ( $\pm 0,08$ )	0,49 ( $\pm 0,11$ )	0,42 ( $\pm 0,09$ )
	4	0,52 ( $\pm 0,11$ )	0,47 ( $\pm 0,13$ )	0,57 ( $\pm 0,14$ )	0,51 ( $\pm 0,13$ )	0,34 ( $\pm 0,09$ )	0,24 ( $\pm 0,06$ )	0,4 ( $\pm 0,09$ )	0,5 ( $\pm 0,1$ )	0,48 ( $\pm 0,1$ )
EVI	1	0,75 ( $\pm 0,08$ )	0,51 ( $\pm 0,11$ )	0,59 ( $\pm 0,14$ )	0,67 ( $\pm 0,14$ )	0,54 ( $\pm 0,12$ )	0,43 ( $\pm 0,09$ )	0,58 ( $\pm 0,08$ )	0,71 ( $\pm 0,08$ )	0,68 ( $\pm 0,08$ )
	2	0,76 ( $\pm 0,08$ )	0,51 ( $\pm 0,13$ )	0,59 ( $\pm 0,15$ )	0,6 ( $\pm 0,14$ )	0,5 ( $\pm 0,12$ )	0,42 ( $\pm 0,09$ )	0,58 ( $\pm 0,09$ )	0,65 ( $\pm 0,09$ )	0,67 ( $\pm 0,1$ )
	3	0,71 ( $\pm 0,09$ )	0,51 ( $\pm 0,12$ )	0,56 ( $\pm 0,14$ )	0,64 ( $\pm 0,17$ )	0,32 ( $\pm 0,14$ )	0,42 ( $\pm 0,09$ )	0,54 ( $\pm 0,09$ )	0,68 ( $\pm 0,09$ )	0,64 ( $\pm 0,1$ )
	4	0,74 ( $\pm 0,08$ )	0,56 ( $\pm 0,11$ )	0,64 ( $\pm 0,13$ )	0,67 ( $\pm 0,13$ )	0,53 ( $\pm 0,11$ )	0,45 ( $\pm 0,08$ )	0,6 ( $\pm 0,09$ )	0,69 ( $\pm 0,08$ )	0,69 ( $\pm 0,09$ )
ExB	1	-0,36 ( $\pm 0,1$ )	-0,22 ( $\pm 0,06$ )	-0,25 ( $\pm 0,07$ )	-0,32 ( $\pm 0,09$ )	-0,29 ( $\pm 0,08$ )	-0,35 ( $\pm 0,12$ )	-0,31 ( $\pm 0,05$ )	-0,3 ( $\pm 0,06$ )	-0,33 ( $\pm 0,06$ )
	2	-0,34 ( $\pm 0,08$ )	-0,21 ( $\pm 0,06$ )	-0,24 ( $\pm 0,07$ )	-0,28 ( $\pm 0,08$ )	-0,24 ( $\pm 0,08$ )	-0,38 ( $\pm 0,14$ )	-0,31 ( $\pm 0,06$ )	-0,29 ( $\pm 0,06$ )	-0,32 ( $\pm 0,06$ )
	3	-0,33 ( $\pm 0,08$ )	-0,23 ( $\pm 0,06$ )	-0,24 ( $\pm 0,07$ )	-0,31 ( $\pm 0,09$ )	-0,24 ( $\pm 0,1$ )	-0,31 ( $\pm 0,12$ )	-0,3 ( $\pm 0,06$ )	-0,29 ( $\pm 0,05$ )	-0,31 ( $\pm 0,06$ )
	4	-0,34 ( $\pm 0,08$ )	-0,24 ( $\pm 0,06$ )	-0,26 ( $\pm 0,07$ )	-0,31 ( $\pm 0,08$ )	-0,29 ( $\pm 0,08$ )	-0,44 ( $\pm 0,13$ )	-0,32 ( $\pm 0,06$ )	-0,3 ( $\pm 0,06$ )	-0,33 ( $\pm 0,06$ )
ExG	1	0,87 ( $\pm 0,18$ )	0,43 ( $\pm 0,14$ )	0,44 ( $\pm 0,17$ )	0,59 ( $\pm 0,23$ )	0,7 ( $\pm 0,2$ )	0,85 ( $\pm 0,17$ )	0,75 ( $\pm 0,1$ )	0,76 ( $\pm 0,11$ )	0,81 ( $\pm 0,11$ )
	2	0,83 ( $\pm 0,13$ )	0,43 ( $\pm 0,16$ )	0,42 ( $\pm 0,17$ )	0,51 ( $\pm 0,2$ )	0,57 ( $\pm 0,2$ )	0,9 ( $\pm 0,2$ )	0,75 ( $\pm 0,13$ )	0,74 ( $\pm 0,11$ )	0,78 ( $\pm 0,11$ )
	3	0,8 ( $\pm 0,14$ )	0,44 ( $\pm 0,16$ )	0,42 ( $\pm 0,17$ )	0,57 ( $\pm 0,23$ )	0,68 ( $\pm 0,21$ )	0,78 ( $\pm 0,17$ )	0,74 ( $\pm 0,12$ )	0,73 ( $\pm 0,11$ )	0,78 ( $\pm 0,12$ )
	4	0,83 ( $\pm 0,14$ )	0,5 ( $\pm 0,15$ )	0,47 ( $\pm 0,17$ )	0,58 ( $\pm 0,2$ )	0,66 ( $\pm 0,19$ )	1 ( $\pm 0,2$ )	0,79 ( $\pm 0,13$ )	0,75 ( $\pm 0,11$ )	0,8 ( $\pm 0,11$ )
ExR	1	-0,36 ( $\pm 0,11$ )	-0,01 ( $\pm 0,11$ )	0,02 ( $\pm 0,13$ )	-0,08 ( $\pm 0,18$ )	-0,22 ( $\pm 0,16$ )	-0,35 ( $\pm 0,12$ )	-0,27 ( $\pm 0,08$ )	-0,3 ( $\pm 0,07$ )	-0,32 ( $\pm 0,07$ )
	2	-0,34 ( $\pm 0,08$ )	-0,01 ( $\pm 0,13$ )	0,02 ( $\pm 0,13$ )	-0,03 ( $\pm 0,15$ )	-0,13 ( $\pm 0,15$ )	-0,38 ( $\pm 0,14$ )	-0,28 ( $\pm 0,09$ )	-0,29 ( $\pm 0,08$ )	-0,3 ( $\pm 0,07$ )
	3	-0,31 ( $\pm 0,09$ )	0 ( $\pm 0,13$ )	0,04 ( $\pm 0,13$ )	-0,07 ( $\pm 0,18$ )	-0,27 ( $\pm 0,17$ )	-0,31 ( $\pm 0,12$ )	-0,28 ( $\pm 0,09$ )	-0,27 ( $\pm 0,08$ )	-0,31 ( $\pm 0,08$ )
	4	-0,34 ( $\pm 0,08$ )	-0,06 ( $\pm 0,12$ )	-0,01 ( $\pm 0,12$ )	-0,08 ( $\pm 0,15$ )	-0,19 ( $\pm 0,14$ )	-0,44 ( $\pm 0,13$ )	-0,31 ( $\pm 0,09$ )	-0,28 ( $\pm 0,07$ )	-0,31 ( $\pm 0,07$ )
ExGR	1	1,23 ( $\pm 0,29$ )	0,44 ( $\pm 0,24$ )	0,42 ( $\pm 0,29$ )	0,68 ( $\pm 0,4$ )	0,91 ( $\pm 0,36$ )	1,2 ( $\pm 0,28$ )	1,03 ( $\pm 0,18$ )	1,07 ( $\pm 0,18$ )	1,13 ( $\pm 0,18$ )
	2	1,17 ( $\pm 0,22$ )	0,44 ( $\pm 0,29$ )	0,4 ( $\pm 0,3$ )	0,54 ( $\pm 0,35$ )	0,69 ( $\pm 0,36$ )	1,28 ( $\pm 0,34$ )	1,04 ( $\pm 0,22$ )	1,03 ( $\pm 0,18$ )	1,08 ( $\pm 0,18$ )
	3	1,12 ( $\pm 0,22$ )	0,43 ( $\pm 0,29$ )	0,38 ( $\pm 0,3$ )	0,64 ( $\pm 0,41$ )	0,96 ( $\pm 0,38$ )	1,09 ( $\pm 0,29$ )	1,02 ( $\pm 0,21$ )	1 ( $\pm 0,18$ )	1,09 ( $\pm 0,19$ )

	4	1,17 ( $\pm 0,22$ )	0,56 ( $\pm 0,27$ )	0,48 ( $\pm 0,29$ )	0,66 ( $\pm 0,35$ )	0,85 ( $\pm 0,32$ )	1,44 ( $\pm 0,33$ )	1,1 ( $\pm 0,21$ )	1,03 ( $\pm 0,18$ )	1,11 ( $\pm 0,18$ )
GEMI	1	0,86 ( $\pm 0,08$ )	0,75 ( $\pm 0,12$ )	0,82 ( $\pm 0,1$ )	0,83 ( $\pm 0,11$ )	0,68 ( $\pm 0,12$ )	0,53 ( $\pm 0,11$ )	0,72 ( $\pm 0,09$ )	0,84 ( $\pm 0,09$ )	0,81 ( $\pm 0,09$ )
	2	0,87 ( $\pm 0,08$ )	0,76 ( $\pm 0,13$ )	0,83 ( $\pm 0,1$ )	0,79 ( $\pm 0,11$ )	0,66 ( $\pm 0,12$ )	0,52 ( $\pm 0,1$ )	0,73 ( $\pm 0,11$ )	0,8 ( $\pm 0,1$ )	0,81 ( $\pm 0,11$ )
	3	0,83 ( $\pm 0,09$ )	0,74 ( $\pm 0,12$ )	0,79 ( $\pm 0,1$ )	0,8 ( $\pm 0,15$ )	0,41 ( $\pm 0,18$ )	0,52 ( $\pm 0,11$ )	0,68 ( $\pm 0,11$ )	0,83 ( $\pm 0,1$ )	0,77 ( $\pm 0,11$ )
	4	0,85 ( $\pm 0,09$ )	0,79 ( $\pm 0,11$ )	0,85 ( $\pm 0,09$ )	0,83 ( $\pm 0,1$ )	0,67 ( $\pm 0,12$ )	0,54 ( $\pm 0,1$ )	0,74 ( $\pm 0,11$ )	0,84 ( $\pm 0,09$ )	0,82 ( $\pm 0,1$ )
GLI	1	0,54 ( $\pm 0,09$ )	0,29 ( $\pm 0,08$ )	0,29 ( $\pm 0,1$ )	0,38 ( $\pm 0,13$ )	0,44 ( $\pm 0,11$ )	0,53 ( $\pm 0,09$ )	0,47 ( $\pm 0,06$ )	0,48 ( $\pm 0,06$ )	0,5 ( $\pm 0,06$ )
	2	0,52 ( $\pm 0,07$ )	0,29 ( $\pm 0,1$ )	0,28 ( $\pm 0,1$ )	0,33 ( $\pm 0,12$ )	0,37 ( $\pm 0,12$ )	0,55 ( $\pm 0,1$ )	0,47 ( $\pm 0,07$ )	0,47 ( $\pm 0,06$ )	0,49 ( $\pm 0,06$ )
	3	0,5 ( $\pm 0,07$ )	0,28 ( $\pm 0,1$ )	0,28 ( $\pm 0,1$ )	0,36 ( $\pm 0,13$ )	0,43 ( $\pm 0,12$ )	0,49 ( $\pm 0,09$ )	0,47 ( $\pm 0,07$ )	0,46 ( $\pm 0,06$ )	0,49 ( $\pm 0,06$ )
	4	0,51 ( $\pm 0,07$ )	0,33 ( $\pm 0,09$ )	0,31 ( $\pm 0,1$ )	0,38 ( $\pm 0,11$ )	0,42 ( $\pm 0,11$ )	0,6 ( $\pm 0,1$ )	0,49 ( $\pm 0,07$ )	0,47 ( $\pm 0,06$ )	0,5 ( $\pm 0,06$ )
GNDVI	1	0,85 ( $\pm 0,05$ )	0,72 ( $\pm 0,06$ )	0,74 ( $\pm 0,05$ )	0,8 ( $\pm 0,05$ )	0,81 ( $\pm 0,04$ )	0,81 ( $\pm 0,06$ )	0,8 ( $\pm 0,05$ )	0,82 ( $\pm 0,06$ )	0,83 ( $\pm 0,05$ )
	2	0,85 ( $\pm 0,06$ )	0,7 ( $\pm 0,06$ )	0,73 ( $\pm 0,06$ )	0,78 ( $\pm 0,05$ )	0,78 ( $\pm 0,05$ )	0,81 ( $\pm 0,06$ )	0,79 ( $\pm 0,06$ )	0,8 ( $\pm 0,06$ )	0,82 ( $\pm 0,05$ )
	3	0,85 ( $\pm 0,06$ )	0,73 ( $\pm 0,06$ )	0,74 ( $\pm 0,05$ )	0,8 ( $\pm 0,05$ )	0,78 ( $\pm 0,05$ )	0,81 ( $\pm 0,05$ )	0,81 ( $\pm 0,06$ )	0,8 ( $\pm 0,05$ )	0,83 ( $\pm 0,05$ )
	4	0,85 ( $\pm 0,06$ )	0,73 ( $\pm 0,06$ )	0,76 ( $\pm 0,05$ )	0,81 ( $\pm 0,04$ )	0,8 ( $\pm 0,04$ )	0,82 ( $\pm 0,06$ )	0,8 ( $\pm 0,06$ )	0,82 ( $\pm 0,06$ )	0,83 ( $\pm 0,05$ )
GRVI	1	0,54 ( $\pm 0,1$ )	0,17 ( $\pm 0,11$ )	0,15 ( $\pm 0,12$ )	0,25 ( $\pm 0,17$ )	0,4 ( $\pm 0,16$ )	0,53 ( $\pm 0,12$ )	0,45 ( $\pm 0,08$ )	0,48 ( $\pm 0,08$ )	0,5 ( $\pm 0,07$ )
	2	0,52 ( $\pm 0,08$ )	0,18 ( $\pm 0,13$ )	0,14 ( $\pm 0,13$ )	0,2 ( $\pm 0,15$ )	0,31 ( $\pm 0,15$ )	0,55 ( $\pm 0,14$ )	0,46 ( $\pm 0,09$ )	0,47 ( $\pm 0,08$ )	0,48 ( $\pm 0,07$ )
	3	0,49 ( $\pm 0,08$ )	0,17 ( $\pm 0,13$ )	0,13 ( $\pm 0,13$ )	0,24 ( $\pm 0,18$ )	0,46 ( $\pm 0,19$ )	0,49 ( $\pm 0,13$ )	0,45 ( $\pm 0,09$ )	0,45 ( $\pm 0,08$ )	0,49 ( $\pm 0,08$ )
	4	0,51 ( $\pm 0,08$ )	0,22 ( $\pm 0,12$ )	0,17 ( $\pm 0,12$ )	0,25 ( $\pm 0,15$ )	0,36 ( $\pm 0,14$ )	0,61 ( $\pm 0,12$ )	0,49 ( $\pm 0,09$ )	0,46 ( $\pm 0,07$ )	0,49 ( $\pm 0,07$ )
MGVRI	1	0,82 ( $\pm 0,09$ )	0,33 ( $\pm 0,19$ )	0,28 ( $\pm 0,22$ )	0,43 ( $\pm 0,28$ )	0,66 ( $\pm 0,22$ )	0,81 ( $\pm 0,13$ )	0,74 ( $\pm 0,09$ )	0,78 ( $\pm 0,09$ )	0,79 ( $\pm 0,08$ )
	2	0,81 ( $\pm 0,08$ )	0,33 ( $\pm 0,23$ )	0,27 ( $\pm 0,23$ )	0,36 ( $\pm 0,26$ )	0,54 ( $\pm 0,25$ )	0,82 ( $\pm 0,14$ )	0,75 ( $\pm 0,12$ )	0,76 ( $\pm 0,1$ )	0,77 ( $\pm 0,08$ )
	3	0,78 ( $\pm 0,09$ )	0,31 ( $\pm 0,23$ )	0,24 ( $\pm 0,23$ )	0,42 ( $\pm 0,29$ )	0,71 ( $\pm 0,23$ )	0,76 ( $\pm 0,16$ )	0,74 ( $\pm 0,13$ )	0,74 ( $\pm 0,11$ )	0,78 ( $\pm 0,09$ )
	4	0,8 ( $\pm 0,08$ )	0,41 ( $\pm 0,2$ )	0,33 ( $\pm 0,22$ )	0,44 ( $\pm 0,25$ )	0,61 ( $\pm 0,21$ )	0,87 ( $\pm 0,1$ )	0,78 ( $\pm 0,12$ )	0,75 ( $\pm 0,09$ )	0,78 ( $\pm 0,08$ )
MSAVI2	1	0,85 ( $\pm 0,08$ )	0,62 ( $\pm 0,13$ )	0,69 ( $\pm 0,12$ )	0,75 ( $\pm 0,13$ )	0,62 ( $\pm 0,15$ )	0,46 ( $\pm 0,11$ )	0,67 ( $\pm 0,11$ )	0,81 ( $\pm 0,09$ )	0,78 ( $\pm 0,1$ )
	2	0,85 ( $\pm 0,09$ )	0,63 ( $\pm 0,14$ )	0,7 ( $\pm 0,13$ )	0,69 ( $\pm 0,14$ )	0,58 ( $\pm 0,14$ )	0,44 ( $\pm 0,11$ )	0,67 ( $\pm 0,12$ )	0,76 ( $\pm 0,11$ )	0,77 ( $\pm 0,12$ )
	3	0,81 ( $\pm 0,1$ )	0,62 ( $\pm 0,14$ )	0,67 ( $\pm 0,13$ )	0,71 ( $\pm 0,17$ )	0,34 ( $\pm 0,18$ )	0,45 ( $\pm 0,12$ )	0,62 ( $\pm 0,12$ )	0,78 ( $\pm 0,11$ )	0,73 ( $\pm 0,12$ )

	4	0,84 ( $\pm 0,09$ )	0,68 ( $\pm 0,12$ )	0,74 ( $\pm 0,11$ )	0,75 ( $\pm 0,12$ )	0,6 ( $\pm 0,14$ )	0,47 ( $\pm 0,1$ )	0,7 ( $\pm 0,12$ )	0,8 ( $\pm 0,1$ )	0,79 ( $\pm 0,11$ )
NDRE	1	0,64 ( $\pm 0,06$ )	0,4 ( $\pm 0,06$ )	0,47 ( $\pm 0,06$ )	0,52 ( $\pm 0,06$ )	0,53 ( $\pm 0,05$ )	0,58 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,61 ( $\pm 0,06$ )	0,62 ( $\pm 0,06$ )
	2	0,64 ( $\pm 0,06$ )	0,38 ( $\pm 0,06$ )	0,46 ( $\pm 0,07$ )	0,5 ( $\pm 0,06$ )	0,5 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,55 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,6 ( $\pm 0,06$ )
	3	0,64 ( $\pm 0,07$ )	0,4 ( $\pm 0,06$ )	0,47 ( $\pm 0,06$ )	0,52 ( $\pm 0,06$ )	0,52 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,57 ( $\pm 0,06$ )	0,62 ( $\pm 0,06$ )
	4	0,64 ( $\pm 0,07$ )	0,41 ( $\pm 0,06$ )	0,49 ( $\pm 0,05$ )	0,53 ( $\pm 0,05$ )	0,52 ( $\pm 0,05$ )	0,59 ( $\pm 0,06$ )	0,56 ( $\pm 0,06$ )	0,6 ( $\pm 0,06$ )	0,61 ( $\pm 0,06$ )
OSAVI	1	0,85 ( $\pm 0,04$ )	0,69 ( $\pm 0,09$ )	0,73 ( $\pm 0,09$ )	0,78 ( $\pm 0,09$ )	0,73 ( $\pm 0,08$ )	0,65 ( $\pm 0,08$ )	0,76 ( $\pm 0,05$ )	0,83 ( $\pm 0,05$ )	0,81 ( $\pm 0,05$ )
	2	0,85 ( $\pm 0,04$ )	0,69 ( $\pm 0,1$ )	0,73 ( $\pm 0,1$ )	0,74 ( $\pm 0,09$ )	0,69 ( $\pm 0,09$ )	0,64 ( $\pm 0,08$ )	0,76 ( $\pm 0,06$ )	0,8 ( $\pm 0,05$ )	0,81 ( $\pm 0,06$ )
	3	0,83 ( $\pm 0,05$ )	0,69 ( $\pm 0,09$ )	0,72 ( $\pm 0,09$ )	0,76 ( $\pm 0,11$ )	0,54 ( $\pm 0,15$ )	0,64 ( $\pm 0,08$ )	0,73 ( $\pm 0,07$ )	0,81 ( $\pm 0,06$ )	0,79 ( $\pm 0,06$ )
	4	0,84 ( $\pm 0,04$ )	0,73 ( $\pm 0,08$ )	0,77 ( $\pm 0,08$ )	0,79 ( $\pm 0,07$ )	0,72 ( $\pm 0,08$ )	0,67 ( $\pm 0,07$ )	0,77 ( $\pm 0,06$ )	0,82 ( $\pm 0,05$ )	0,82 ( $\pm 0,05$ )
RGBVI	1	0,82 ( $\pm 0,07$ )	0,56 ( $\pm 0,11$ )	0,58 ( $\pm 0,13$ )	0,69 ( $\pm 0,14$ )	0,73 ( $\pm 0,13$ )	0,81 ( $\pm 0,09$ )	0,77 ( $\pm 0,06$ )	0,78 ( $\pm 0,06$ )	0,8 ( $\pm 0,06$ )
	2	0,81 ( $\pm 0,07$ )	0,55 ( $\pm 0,14$ )	0,56 ( $\pm 0,14$ )	0,63 ( $\pm 0,14$ )	0,65 ( $\pm 0,15$ )	0,83 ( $\pm 0,09$ )	0,77 ( $\pm 0,08$ )	0,77 ( $\pm 0,07$ )	0,79 ( $\pm 0,06$ )
	3	0,79 ( $\pm 0,07$ )	0,57 ( $\pm 0,13$ )	0,56 ( $\pm 0,14$ )	0,67 ( $\pm 0,15$ )	0,72 ( $\pm 0,15$ )	0,78 ( $\pm 0,1$ )	0,76 ( $\pm 0,08$ )	0,76 ( $\pm 0,07$ )	0,79 ( $\pm 0,07$ )
	4	0,81 ( $\pm 0,07$ )	0,61 ( $\pm 0,12$ )	0,6 ( $\pm 0,13$ )	0,68 ( $\pm 0,13$ )	0,71 ( $\pm 0,13$ )	0,87 ( $\pm 0,08$ )	0,79 ( $\pm 0,08$ )	0,77 ( $\pm 0,06$ )	0,8 ( $\pm 0,06$ )
RI	1	-0,54 ( $\pm 0,1$ )	-0,17 ( $\pm 0,11$ )	-0,15 ( $\pm 0,12$ )	-0,25 ( $\pm 0,17$ )	-0,4 ( $\pm 0,16$ )	-0,53 ( $\pm 0,12$ )	-0,45 ( $\pm 0,08$ )	-0,48 ( $\pm 0,08$ )	-0,5 ( $\pm 0,07$ )
	2	-0,52 ( $\pm 0,08$ )	-0,18 ( $\pm 0,13$ )	-0,14 ( $\pm 0,13$ )	-0,2 ( $\pm 0,15$ )	-0,31 ( $\pm 0,15$ )	-0,55 ( $\pm 0,14$ )	-0,46 ( $\pm 0,09$ )	-0,47 ( $\pm 0,08$ )	-0,48 ( $\pm 0,07$ )
	3	-0,49 ( $\pm 0,08$ )	-0,17 ( $\pm 0,13$ )	-0,13 ( $\pm 0,13$ )	-0,24 ( $\pm 0,18$ )	-0,46 ( $\pm 0,19$ )	-0,49 ( $\pm 0,13$ )	-0,45 ( $\pm 0,09$ )	-0,45 ( $\pm 0,08$ )	-0,49 ( $\pm 0,08$ )
	4	-0,51 ( $\pm 0,08$ )	-0,22 ( $\pm 0,12$ )	-0,17 ( $\pm 0,12$ )	-0,25 ( $\pm 0,15$ )	-0,36 ( $\pm 0,14$ )	-0,61 ( $\pm 0,12$ )	-0,49 ( $\pm 0,09$ )	-0,46 ( $\pm 0,07$ )	-0,49 ( $\pm 0,07$ )
SAVI	1	0,74 ( $\pm 0,07$ )	0,6 ( $\pm 0,11$ )	0,66 ( $\pm 0,11$ )	0,69 ( $\pm 0,11$ )	0,58 ( $\pm 0,1$ )	0,47 ( $\pm 0,09$ )	0,61 ( $\pm 0,07$ )	0,72 ( $\pm 0,07$ )	0,69 ( $\pm 0,07$ )
	2	0,75 ( $\pm 0,07$ )	0,61 ( $\pm 0,12$ )	0,68 ( $\pm 0,12$ )	0,65 ( $\pm 0,11$ )	0,55 ( $\pm 0,11$ )	0,45 ( $\pm 0,08$ )	0,62 ( $\pm 0,09$ )	0,68 ( $\pm 0,08$ )	0,69 ( $\pm 0,09$ )
	3	0,71 ( $\pm 0,08$ )	0,6 ( $\pm 0,11$ )	0,64 ( $\pm 0,11$ )	0,67 ( $\pm 0,14$ )	0,36 ( $\pm 0,15$ )	0,46 ( $\pm 0,09$ )	0,58 ( $\pm 0,09$ )	0,7 ( $\pm 0,09$ )	0,65 ( $\pm 0,09$ )
	4	0,74 ( $\pm 0,08$ )	0,64 ( $\pm 0,1$ )	0,71 ( $\pm 0,1$ )	0,7 ( $\pm 0,1$ )	0,57 ( $\pm 0,1$ )	0,47 ( $\pm 0,08$ )	0,63 ( $\pm 0,09$ )	0,71 ( $\pm 0,07$ )	0,7 ( $\pm 0,08$ )
TVI	1	1,2 ( $\pm 0,01$ )	1,13 ( $\pm 0,03$ )	1,14 ( $\pm 0,04$ )	1,17 ( $\pm 0,03$ )	1,19 ( $\pm 0,02$ )	1,2 ( $\pm 0,01$ )	1,19 ( $\pm 0,01$ )	1,2 ( $\pm 0,01$ )	1,2 ( $\pm 0,01$ )
	2	1,2 ( $\pm 0,01$ )	1,13 ( $\pm 0,04$ )	1,13 ( $\pm 0,04$ )	1,16 ( $\pm 0,04$ )	1,17 ( $\pm 0,03$ )	1,2 ( $\pm 0,02$ )	1,19 ( $\pm 0,02$ )	1,19 ( $\pm 0,01$ )	1,2 ( $\pm 0,01$ )
	3	1,2 ( $\pm 0,01$ )	1,14 ( $\pm 0,04$ )	1,13 ( $\pm 0,04$ )	1,17 ( $\pm 0,03$ )	1,19 ( $\pm 0,02$ )	1,19 ( $\pm 0,02$ )	1,19 ( $\pm 0,02$ )	1,19 ( $\pm 0,02$ )	1,2 ( $\pm 0,01$ )
	4	1,2 ( $\pm 0,01$ )	1,15 ( $\pm 0,03$ )	1,15 ( $\pm 0,03$ )	1,17 ( $\pm 0,03$ )	1,18 ( $\pm 0,02$ )	1,2 ( $\pm 0,01$ )	1,19 ( $\pm 0,02$ )	1,19 ( $\pm 0,01$ )	1,2 ( $\pm 0,01$ )

NDVI	1	0,95 ( $\pm 0,02$ )	0,79 ( $\pm 0,08$ )	0,79 ( $\pm 0,08$ )	0,86 ( $\pm 0,07$ )	0,91 ( $\pm 0,05$ )	0,94 ( $\pm 0,03$ )	0,92 ( $\pm 0,03$ )	0,93 ( $\pm 0,03$ )	0,94 ( $\pm 0,02$ )
	2	0,95 ( $\pm 0,03$ )	0,77 ( $\pm 0,09$ )	0,78 ( $\pm 0,09$ )	0,84 ( $\pm 0,08$ )	0,87 ( $\pm 0,06$ )	0,94 ( $\pm 0,04$ )	0,92 ( $\pm 0,04$ )	0,92 ( $\pm 0,03$ )	0,93 ( $\pm 0,03$ )
	3	0,95 ( $\pm 0,02$ )	0,79 ( $\pm 0,08$ )	0,78 ( $\pm 0,08$ )	0,86 ( $\pm 0,08$ )	0,91 ( $\pm 0,06$ )	0,93 ( $\pm 0,04$ )	0,92 ( $\pm 0,04$ )	0,92 ( $\pm 0,03$ )	0,94 ( $\pm 0,03$ )
	4	0,95 ( $\pm 0,02$ )	0,82 ( $\pm 0,07$ )	0,82 ( $\pm 0,07$ )	0,87 ( $\pm 0,06$ )	0,9 ( $\pm 0,05$ )	0,95 ( $\pm 0,03$ )	0,93 ( $\pm 0,04$ )	0,93 ( $\pm 0,03$ )	0,94 ( $\pm 0,02$ )
Temperatura (°C)	1	24,6 ( $\pm 0,27$ )	32,9 ( $\pm 1,05$ )	35 ( $\pm 0,53$ )	39,6 ( $\pm 0,79$ )	38,9 ( $\pm 0,5$ )	33,1 ( $\pm 0,51$ )	31,9 ( $\pm 0,51$ )	25 ( $\pm 0,38$ )	25,6 ( $\pm 0,29$ )
	2	25,4 ( $\pm 0,41$ )	33,4 ( $\pm 1,42$ )	36,1 ( $\pm 0,7$ )	41,4 ( $\pm 1,08$ )	40,2 ( $\pm 0,82$ )	33,5 ( $\pm 0,54$ )	33,3 ( $\pm 0,79$ )	27,6 ( $\pm 0,55$ )	26,3 ( $\pm 0,36$ )
	3	25,5 ( $\pm 0,47$ )	33,5 ( $\pm 0,83$ )	34,7 ( $\pm 0,54$ )	39,2 ( $\pm 0,96$ )	37,3 ( $\pm 0,98$ )	33,4 ( $\pm 0,57$ )	32,4 ( $\pm 0,76$ )	26,1 ( $\pm 0,55$ )	26,8 ( $\pm 0,38$ )
	4	25,2 ( $\pm 0,39$ )	32,3 ( $\pm 0,72$ )	34,9 ( $\pm 0,53$ )	39,7 ( $\pm 0,79$ )	39,1 ( $\pm 0,69$ )	32,9 ( $\pm 0,63$ )	32,6 ( $\pm 0,86$ )	26,7 ( $\pm 0,38$ )	26,4 ( $\pm 0,27$ )