

**UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
FACULDADE DE CIÊNCIAS AGRÁRIAS**

ANÁLISE DE IMAGENS OBTIDAS COM DRONE

PEDRO BARBOSA COLMAN

**DOURADOS
MATO GROSSO DO SUL
2024**

ANÁLISE DE IMAGENS OBTIDAS COM DRONE

Pedro Barbosa Colman

Orientador: Profa. Dra. Anamari Viegas de Araujo Motomiya

Trabalho de Conclusão de Curso apresentado à
Universidade Federal da Grande Dourados, como
parte dos requisitos para obtenção do título de
Engenheiro Agrícola.

DOURADOS
MATO GROSSO DO SUL
2024

Dados Internacionais de Catalogação na Publicação (CIP).

C716a Colman, Pedro Barbosa
ANÁLISE DE IMAGENS OBTIDAS COM DRONE [recurso eletrônico] / Pedro Barbosa
Colman. -- 2024.
Arquivo em formato pdf.

Orientadora: Anamari Viegas de Araujo Motomiya .
TCC (Graduação em Engenharia Agrícola)-Universidade Federal da Grande Dourados, 2024.
Disponível no Repositório Institucional da UFGD em:
<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. drones. 2. agricultura de precisão. 3. índice de vegetação. I. Motomiya, Anamari Viegas De Araujo. II. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

ANÁLISE DE IMAGENS OBTIDAS COM DRONE

Por

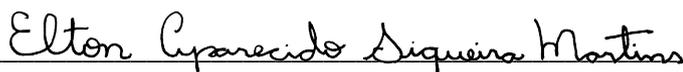
Pedro Barbosa Colman

Trabalho de Conclusão de Curso apresentado como parte dos requisitos exigidos para
obtenção do título de ENGENHEIRO AGRÍCOLA

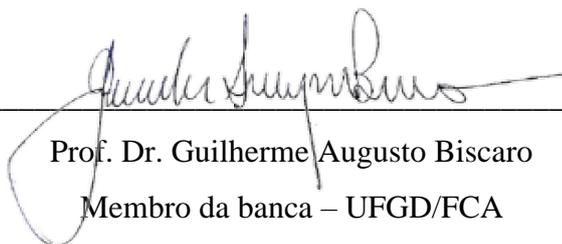
Aprovado em: 05 de julho de 2024.



Profa. Dr. Anamari Viegas de Araujo Motomiya
Orientador – UFGD/FCA



Prof. Dr. Elton Aparecido Siqueira Martins
Membro da banca – UFGD/FCA



Prof. Dr. Guilherme Augusto Biscaro
Membro da banca – UFGD/FCA

AGRADECIMENTOS

A Deus por sempre me mostrar que seu caminho é o melhor e por todas as oportunidades que tem me dado. A São José por estar comigo e guiar meu caminho.

Aos meus pais, Carlos e Edna por nunca desistirem de mim e acreditar nos meus sonhos, apesar de tudo vocês são a minha inspiração.

A minha irmã Carina por ser a minha base da vida, sempre me apoiar e estar ao meu lado.

A todos os professores e supervisores, aos quais tive a oportunidade de caminhar junto, e de um modo muito especial a Professora Dra. Anamari Viegas de Araujo Motomiya minha orientadora de Trabalho de Conclusão de Curso.

Aos meus irmãos, Adrienne e Christian pelo amor e pelo apoio que me transmitiram durante essa caminhada.

À minha namorada Ariane Moura por sempre me incentivar e mostrar que desistir não é uma opção e brigar comigo quando deixava as coisas para última hora, você foi essencial para eu chegar até aqui.

Aos meus amigos do grupo “amigos de Santa Cecília” Samuel, Henrique Lenis, Daniel, Carol, Talita, Lucas, João Lucas, Adib e Glauber por mostrar que a vida é bela e que temos que ter amizades verdadeiras que te levam para Deus.

Aos meus amigos Matheus e Galeno por me motivarem nessa caminhada e sempre estarem comigo, amizade que levarei para sempre.

BARBOSA, C, Pedro. **Análise de imagens obtidas com drone**. 2024. XX f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Agrícola) – Faculdade de Ciências Agrárias, Universidade Federal da Grande Dourados, Dourados, 2024.

RESUMO

A agricultura de precisão se apresenta como uma alternativa crucial para superar os desafios da agricultura tradicional, como baixa produtividade, degradação ambiental e crescente demanda por alimentos. Essa abordagem inovadora utiliza tecnologias avançadas, como drones, para coletar e analisar dados em tempo real, permitindo aos produtores tomar decisões mais precisas e eficientes. Neste estudo, avaliamos a viabilidade do uso de drones para monitorar áreas de plantio direto com intercessão de soja e milho. As imagens RGB coletadas por drones foram processadas para gerar índices de vegetação (GLI, NGDRI e RI) e classificar as áreas de acordo com a presença de amassamentos causados por máquinas e falhas no plantio. A combinação dos índices GLI e RI proporcionou uma análise mais consistente e precisa em comparação com a combinação GLI e NGDRI. Através dessa análise, foi possível identificar com clareza as falhas no plantio e os rastros de amassamento, permitindo aos produtores tomar medidas corretivas para otimizar o manejo da lavoura e aumentar a produtividade.

Palavras-chave: drones, tecnologia, agricultura de precisão, índice de vegetação.

ABSTRACT

Precision agriculture emerges as a crucial alternative to overcome the challenges of traditional agriculture, such as low productivity, environmental degradation, and increasing food demand. This innovative approach utilizes advanced technologies, such as drones, to collect and analyze real-time data, enabling producers to make more precise and efficient decisions. In this study, we evaluated the feasibility of using drones to monitor soybean and corn intercropping direct planting areas. RGB images collected by drones were processed to generate vegetation indices (GLI, NGDRI, and RI) and classify areas according to the presence of machine-caused rutting and planting failures. The combination of GLI and RI indices provided a more consistent and accurate analysis compared to the GLI and NGDRI combination. Through this analysis, it was possible to clearly identify planting failures and rutting trails, allowing producers to take corrective measures to optimize crop management and increase productivity.

Keywords: drones, technology, precision agriculture, vegetation index.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. REVISÃO DE LITERATURA	2
2.1 Agricultura de precisão.....	2
2.2 Sensoriamento remoto e geoprocessamento.....	3
2.3 Drone	4
2.4 Índice de vegetação	4
2.4.1 Índice de Folha Verde (GLI)	4
2.4.2 Índice da Diferença Normalizada do Verde e do Vermelho (NGRDI)	5
2.4.3 Índice de Vermelhidão (RI).....	6
3. MATERIAL E MÉTODOS.....	7
3.1 Localização e conhecimento da área	7
3.2 Planejamento de Voo e Coleta de Imagens	9
3.3 Índices de Vegetação (IV)	9
3.4 Calculo de área	11
4. RESULTADOS E DISCUSSÕES.....	11
4.1 Ortomosaico.....	11
4.2 Índice de Vegetação.....	12
5. CONCLUSÃO.....	18
6. REFERÊNCIAS BIBLIOGRÁFICAS	19

1.INTRODUÇÃO

A partir de 1998, os agricultores brasileiros tiveram acesso a equipamentos de colheita mecânica com sistema de mapeamento de produtividade das culturas do milho e da soja. Essa tecnologia possibilitou uma análise mais criteriosa da variabilidade espacial da produtividade nos campos de produção. Recentemente, tecnologias de mapeamento aéreo realizado por um VANT (Veículo Aéreo Não Tripulado) permitem a análise das lavouras de forma rápida, segura e eficaz, sem a necessidade de coleta de material físico do solo e das folhas.

A agricultura de precisão vem se tornando cada vez mais utilizada como ferramenta para uma boa produção. Essa abordagem utiliza ferramentas como sensores, sistemas de posicionamento global por satélite (GNSS), drones, mapas, entre outras, para coletar, processar e analisar dados sobre as condições do solo, das plantas, do clima e da operação agrícola, gerando informações para apoiar a gestão da lavoura.

A tomada de decisões mais precisas e eficientes sobre o que, quando, onde e como aplicar os insumos (sementes, fertilizantes, defensivos, água, etc.) nas diferentes áreas da lavoura é crucial para otimizar a produção e minimizar o impacto ambiental. No entanto, a implementação da agricultura de precisão no Brasil enfrenta desafios como a falta de infraestrutura, de capacitação, de informação e de pesquisa.

Diversos casos de sucesso e inovação na aplicação da agricultura de precisão em diferentes culturas e regiões do País demonstram as potencialidades e as oportunidades desse sistema de produção. O uso de drones nas propriedades rurais para facilitar o monitoramento, o manejo e, até mesmo, a aplicação de defensivos vem crescendo, evidenciando a versatilidade dessa tecnologia e seu potencial para contribuir para o aumento da produtividade, da qualidade e da rentabilidade da agricultura.

Segundo Geebers & Adamchuk (2010), a agricultura de precisão é um processo que se baseia na coleta de dados com equipamentos específicos, na análise e interpretação desses dados por meio de software, na geração de recomendações adequadas, na aplicação dessas recomendações no campo e na avaliação dos resultados obtidos.

A coleta desses dados é realizada através de uso de equipamentos ou sensores ou de imagens de sensoriamento remoto, obtidos então por drone, ou por satélites. Tais equipamentos tem possibilitado ampliar o resultado dos dados obtidos em tempo real e em larga escala no campo. De acordo com Hatfield et al. (2008), o sensoriamento remoto é uma ferramenta essencial para a agricultura de precisão, pois permite estimar variáveis como a produção e os índices de vegetação sem a necessidade de contato direto com as plantas.

A agricultura se beneficia do uso de imagens de satélite de média resolução, que permitem acompanhar diversos fatores que influenciam a produção agrícola, como o clima, o solo e a vegetação. O Landsat é um dos satélites mais empregados nesse tipo de monitoramento, especialmente para estimar a safra (LILLESAND et al., 2004).

Segundo Albuquerque et al. (2017), as imagens de satélite de alta resolução espacial que são vendidas no mercado geralmente têm um custo elevado e abrangem áreas superiores a 2.500 hectares. Assim, o uso de drone para a obtenção de imagens de grande resolução é alternativa às imagens de satélite, devido ao baixo custo e rapidez no mapeamento agrícola.

Objetivou-se com o presente trabalho avaliar um experimento de campo usando um drone com câmeras de imagens RGB, gerando índices de vegetação.

2. REVISÃO DE LITERATURA

2.1 Agricultura de precisão

A agricultura de precisão (AP) é uma tecnologia em constante crescimento, com novas atualizações e equipamentos sendo lançados a cada dia. Ela é fundamental para maximizar a produção e minimizar os custos, tornando-se a chave para uma agricultura mais eficiente e sustentável. Os drones agrícolas, por exemplo, desempenham um papel importante nesse cenário, fornecendo dados precisos e em tempo real sobre o estado das culturas, auxiliando os agricultores na otimização de seus processos de cultivo. A aplicação da agricultura de precisão vai além da mera aplicação de tratamentos variáveis em diferentes culturas e locais. Ela se configura como um manejo sustentável que exige habilidades no monitoramento e na análise precisa das atividades agrícolas em nível local. Um manejo sustentável implica algo mais além da manutenção dos índices de produtividade (MANTOVANI et al., 1998).

O processo de implementação de ferramentas para registrar e analisar grandes conjuntos de dados do solo, clima, plantas e insetos moldou a agricultura moderna permite caminhar em direção a um futuro na produção agrícola com maior conhecimento e controle das informações da lavoura. Assim sendo possível o monitoramento do campo de cultivo até mesmo ao nível da planta, aumentando a implementação de práticas agronômicas mais eficientes.

Para Doerge (1999), a agricultura de precisão consiste em coletar informações agronômicas para prover as necessidades específicas de cada porção do campo, em vez de atender às necessidades gerais de toda a lavoura.

Capelli (1999) complementa que a agricultura de precisão apresenta as vantagens de melhor conhecimento do campo de produção: Permite a tomada de decisões mais embasadas, com maior capacidade e flexibilidade para a distribuição dos insumos nos locais e no tempo em que são mais necessários. Minimização dos custos de produção: Os insumos são utilizados de forma mais eficiente, otimizando os recursos disponíveis. Aumento da produtividade: A correção dos fatores que contribuem para a variabilidade da produtividade resulta em um aumento global da produção. Preservação do meio ambiente: A aplicação localizada dos insumos minimiza o impacto ambiental, pois os produtos são utilizados apenas nos locais, quantidades e no tempo necessários.

Devido à grande variabilidade das áreas agrícolas, tanto em termos dos fatores de produção (fertilidade, topografia, clima) quanto da produtividade obtida, cada porção da lavoura necessita de um manejo específico para otimizar a rentabilidade do agricultor e evitar impactos ambientais (PUSCH et al., 2019). Davis (1998) afirma que a agricultura de precisão foi frequentemente definida com base nas tecnologias que permitem sua realização, como o GPS (Sistema de Posicionamento Global) e sistemas de taxa variável.

2.2 Sensoriamento remoto e geoprocessamento

Segundo Paranhos Filho, Lastoria e Torres (2008), o geoprocessamento é o conjunto de técnicas de processamento e análise de dados espaciais, dividido em três grandes linhas: cartografia, sensoriamento remoto e SIG (Sistema de Informações Geográficas).

O sensoriamento remoto, por sua vez, é uma técnica fundamental para a obtenção de informações sobre a superfície terrestre sem a necessidade de contato direto com os objetos ou de estar no local (MORARES, 2002). Como explica Geoinova (2023), as informações são coletadas por meio de sensores instalados em satélites, aviões ou drones. Esses sensores captam diferentes tipos de radiação eletromagnética, como luz visível, infravermelho e micro-ondas, que são processados e transformados em imagens e dados utilizados para diversas finalidades.

Segundo Reghini e Cavichioli (2020), a escala espacial desempenha um papel crucial na tomada de decisões. No contexto das estratégias de manejo, a escala espacial determina a extensão da área tratada. Assim, ferramentas digitais são fundamentais para o gerenciamento em diferentes escalas: desde áreas amplas até locais específicos dentro de um campo.

A coleta de dados em uma área, a edição de mapas digitais complexos e a integração de informações espaciais se tornaram tarefas rápidas e simples, graças à combinação das ciências matemática e computacional com a ciência geográfica. Atualmente, o sensoriamento remoto e o geoprocessamento são ferramentas extremamente relevantes para a análise espacial

em diversas e variadas discussões. Esses sistemas oferecem aos usuários uma série de facilidades em suas pesquisas, além de proporcionar maior confiabilidade e precisão nas informações (LEITE e ROSA, 2006).

2.3 Drone

Os drones estão promovendo uma nova abordagem na agricultura, oferecendo uma nova perspectiva para o monitoramento de culturas. Equipados com tecnologia de sensoriamento remoto, eles permitem a coleta de dados detalhados sobre as culturas em tempo real (Silva et al., 2020). Isso inclui informações sobre a saúde das plantas, a umidade do solo e a presença de pragas ou doenças. Além disso, o geoprocessamento possibilita a análise de dados para tomar decisões sobre o manejo da irrigação, aplicação de fertilizantes e outras práticas agrícolas (Santos et al., 2019).

Os drones estão se tornando uma ferramenta importante para a agricultura de precisão, ajudando a aumentar a produtividade e a sustentabilidade (Souza et al., 2016). Nos drones são acoplados sensores, GNSS, câmeras e outros equipamentos conforme o modelo do drone e sua necessidade. Os sensores dos drones mais comuns e de fácil acesso no mercado são RGB (faixa espectral do visível); sensores com a faixa do infravermelho tem um custo mais elevado. Também há drones com sensores multiespectrais, e sensores hiper espectrais.

2.4 Índice de vegetação

Os índices de vegetação são modelos matemáticos que vêm sendo desenvolvidos com base na reflectância das coberturas vegetais. Ao integrar a reflectância de duas ou mais bandas espectrais, ou comprimentos de ondas, os índices de vegetação conseguem realçar determinadas características. Em geral, operações algébricas são aplicadas para promover esse realce, numa base pixel-a-pixel (BREUNING et al., 2019). O índice de área foliar, a biomassa, a porcentagem de cobertura do solo, a atividade fotossintética, deficiências hídricas e até mesmo estimativas de produtividade são alguns desses parâmetros.

2.4.1 Índice de Folha Verde (GLI)

Elaborado por Louhaichi, Borman e Johnson (2001) com o objetivo de determinar a intensidade de degradação da vegetação por fotografia aérea, o “*Green Leaf Index*” ou índice de folha verde, é um índice de vegetação formado pela diferença normalizada das reflectâncias das faixas espectrais do azul, verde e vermelho (Equação 1). Louhaichi, Borman e Johnson (2001) acreditam que a utilização deste índice tem potencial aplicação para análises vegetais,

com resultados satisfatórios para avaliação da fração da vegetação. Autores como Hunt Jr. et al. (2011) e Ballesteros et al. (2018) afirmam que o GLI apresenta resultados robustos para avaliação da vegetação, podendo ser utilizado como fator indicativo de degradação vegetal, já que apresentaram boas correlações com alterações na clorofila foliar (Apud CAMBRAIA-FILHO, 2019).

$$GLI = \frac{(2*G-R-B)}{(2*G+R+B)} \quad \text{Equação (1)}$$

Onde:

G = valor de reflectância na faixa espectral do verde;

R = valor de reflectância na faixa espectral do vermelho;

B = valor de reflectância na faixa espectral do azul.

2.4.2 Índice da Diferença Normalizada do Verde e do Vermelho (NGRDI)

O “*Normalized Green Red Difference Index*” foi um índice proposto por Tucker (1979) após Kanemasu (1974) concluir que as faixas espectrais do verde e do vermelho podem servir como indicador de crescimento e desenvolvimento das plantas. É um índice elaborado pela diferença normalizada das reflectâncias das bandas espectrais do verde e do vermelho (Equação 2), sendo geralmente utilizado para estimar a fração de vegetação, biomassa verde e indicador de fenologias vegetais.

$$NGRDI = \frac{(G-R)}{(G+R)} \quad \text{Equação (2)}$$

Onde:

G = valor de reflectância na faixa espectral do verde;

R = valor de reflectância na faixa espectral do vermelho.

Hunt Jr et al. (2005) apresentaram resultados que demonstram uma alta correlação entre o NGRDI e os valores de biomassa verde. Wan et al. (2018) demonstraram em sua pesquisa na China, altas correlações deste índice com o número de flores em campos de

girassóis, com alta aplicabilidade na estimativa de vegetação em diferentes contextos ambientais.

2.4.3 Índice de Vermelhidão (RI)

O índice “*Red-Edge Normalized Difference Vegetation Index*” (NDVI_{red}) tem sido eficaz na detecção de vegetação em ambientes agrícolas com variações de iluminação e diferentes tipos de solo (Smith et al., 2015). O cálculo do RI é realizado de acordo com a Equação 3.

$$RI = \frac{(R-G)}{(R+G)} \quad \text{Equação (3)}$$

Onde:

R = valor de reflectância na faixa espectral do vermelho;

G = valor de reflectância na faixa espectral do verde.

3. MATERIAL E MÉTODOS

3.1 Localização e conhecimento da área

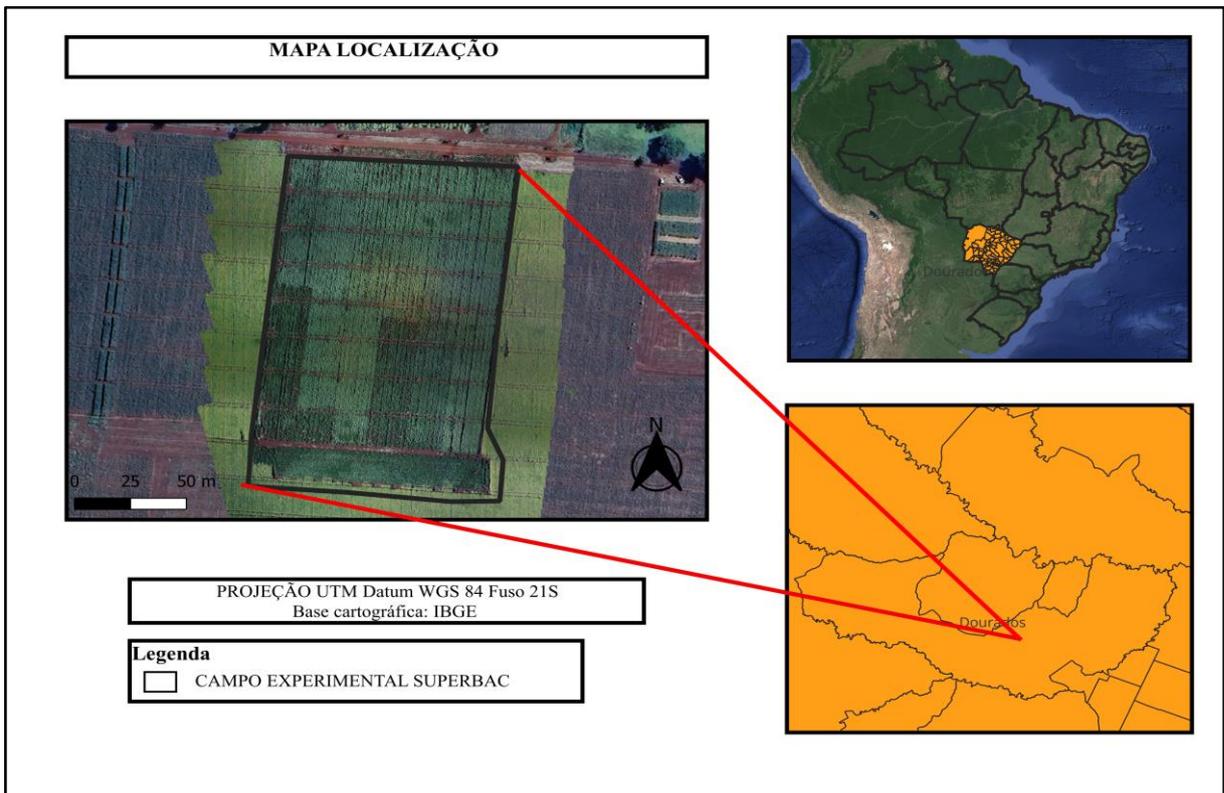


Figura 1 - Localização da área de estudo. Fonte: Autor (2024).

O presente estudo foi realizado no município de Dourados, Mato Grosso do Sul (coordenadas geográficas: Latitude 22.198150° Sul e Longitude 54.746829 Oeste), com foco no cultivo da soja. A região apresenta clima tropical com chuvas concentradas no verão e inverno frio e seco (Alvares et al., 2013). A temperatura média anual é de 23°C (Alvares et al., 2013). O solo é classificado como Latossolo Vermelho (EMBRAPA, 2013). A precipitação pluviométrica média anual é de 1.419 mm (Alvares et al., 2013).

A delimitação da área experimental de 1,33 hectares, foi feita através de aplicativo de celular gratuito *Pix4DCapture* (Figura 2), compatível com o drone utilizado. O drone utilizado é homologado pela ANATEL (Agência Nacional de Telecomunicações) cujo modelo é o DJI Mavic Pro, sem câmeras adicionais. O plano de voo foi elaborado através do aplicativo do drone. Em 20 de dezembro de 2023, às 11 horas, foram realizadas duas capturas de imagens para análise, na faixa visível do espectro eletromagnético (RBG). O drone voou a uma altura de aproximadamente 50 metros. O aplicativo *Pix4Dcapture* indica a área em metros e o tempo de duração do voo, sendo as imagens registradas em cartão de memória.

As condições climáticas no momento da coleta eram adequadas, sem nuvens ou ventos, proporcionando imagens nítidas e com boa resolução.

O primeiro voo teve como objetivo a verificação de falhas na linha de plantio. As variedades de soja utilizadas foram NEXUS IPRO, com diferentes tipos de tratamento para cada protocolo. As variedades de tratamento receberam 13 amostras em 4 blocos, 11 amostras em outro bloco e 8 amostras em outro. Cada bloco possui 8 linhas de 5 metros (Figura 3). As dosagens de cada tratamento não foram disponibilizadas ao público até a publicação deste trabalho, em decorrência do caráter privado do experimento.

O clima no dia do plantio não era ideal, com a região enfrentando falta de chuvas por algumas semanas, o que gerou dúvidas sobre a produtividade da lavoura. Por esse motivo, o monitoramento via drone foi realizado nas fases iniciais do desenvolvimento da soja.

O segundo voo, realizado com as plantas em estágio de maior desenvolvimento, teve como objetivo o monitoramento de pragas e falhas de plantio. O mesmo plano de voo do primeiro voo foi utilizado. Durante essa etapa, foi observada diferença de tonalidade na cor das plantas, decorrente de um erro do operador da máquina de plantio, que misturou as sementes sem identificar a variedade. Apesar dessa falha, não houve impacto no processamento das imagens ou nos cálculos realizados. A variedade erroneamente plantada pode ter apresentado maior ou menor resistência a pragas e à seca que acometeu a lavoura durante seu desenvolvimento.



Figura 2 – Plano de voo feito através do aplicativo *Pix4Dcapture*.

Bionematicida TSI (MAP)	4	1	2	3		4	5	6		7	8	9		10	11
	4	11	10	9		8	7	6		5	4	3		2	1
	4	3	6	8		1	11	9		2	10	5		7	4
	4	5	7	3		10	2	4		8	1	11		9	6

Figura 3 – Croqui do campo experimental com diferentes tratamentos e dosagem de adubo para o tratamento (TSN1)

3.2 Planejamento de Voo e Coleta de Imagens

O planejamento do voo e a coleta de dados para o monitoramento da lavoura de soja foram realizados utilizando uma combinação de aplicativos. A coleta das imagens foi feita por meio da câmera RGB embarcada com pixels efetivos de 12,35 e 12.71 pixels totais no drone Mavic PRO da marca DJI controlado por um controle remoto e com baterias inteligentes para garantir sua autonomia de voo.

O voo foi realizado no dia 20 de dezembro de 2023, no período das 11h20min às 12h00min. A altitude de voo foi de 50 metros e a taxa de sobreposição correspondeu a 75% na faixa horizontal e 75% na faixa longitudinal.

A velocidade de voo foi de 19 km/h. As bandas espectrais coletadas e suas informações estão na Tabela 1.

Tabela 1 - Dados de ordem das bandas.

Resolução (m)	Banda	Nome da banda	Largura da faixa (nm)
0,05	B3	Azul (Blue -B)	465-515
	B2	Verde (Green-G)	547-585
	B1	Vermelho (Red-R)	650-680

Fonte: Autor, 2024.

3.3 Índices de Vegetação (IV)

Os IV foram calculados seguindo as expressões matemáticas (Tabela 2) de cada índice: Índice de Folha Verde (GLI), Equação (1) para dados em número digital; Índice verde/vermelho por diferença normalizada (NGRDI), Equação (2); Índice de vermelhidão (RI), Equação (3);

Tabela 2- Equações dos índices de vegetação

Índice	Equação	Fonte
$GLI = (2 * \text{Green} - \text{Red} - \text{Blue}) / (2 * \text{Green} + \text{Red} + \text{Blue})$	(1)	Louhaichi et al. (2001)
$NGRDI = (\text{Green} - \text{Red}) / (\text{Green} + \text{Red})$	(2)	Tucker (1979)
$RI = (\text{Red} - \text{Green}) / (\text{Red} + \text{Green})$	(3)	Escadafal e Huete (1991)

*vermelho (Red), verde (Green), azul (Blue).

Fonte: Autor, 2024.

Após a coleta das imagens com o drone Mavic Pro, o *software* QGIS foi utilizado para realizar o processamento fotogramétrico e a modelagem espacial 3D.

As imagens JPEG capturadas durante o voo foram importadas no *software*, juntamente com seus metadados de georreferenciamento (latitude, longitude e altitude no sistema WGS 84). O *software* corrige automaticamente as distorções geométricas presentes nas imagens, causadas pelo movimento do drone durante o voo (influenciado pelo vento) e pelas limitações de precisão do GPS embarcado.

As fotos foram agrupadas em um ortomosaico, usando o sistema de coordenadas WGS 84 como referência (Figura 4). O *software* identifica automaticamente pontos de controle nas imagens, utilizando-se de características comuns entre elas. Esses pontos de controle são essenciais para garantir a precisão da modelagem 3D (AGISOFT, 2014).

O processamento gera uma nuvem de pontos densa, representando a superfície tridimensional da área de interesse. Essa nuvem de pontos é composta por milhões de pontos, cada um com uma coordenada X, Y e Z. A partir da nuvem de pontos, é gerada uma malha poligonal que representa a superfície da área de interesse com mais precisão. Essa malha pode ser utilizada para diversas análises espaciais. O ortomosaico formado é uma imagem corrigida geometricamente e livre de distorções, representando a superfície da área de interesse em uma projeção plana. O ortomosaico é fundamental para a visualização e análise detalhadas da área mapeada (QGIS, 2024).

Na etapa de finalização dos mapas do índice de vegetação, utilizou-se a banda simples falsa-cor, interpolador linear e o gradiente de cores foi o *Red-Yellow-Green*. O GLI foi classificado em três classes: solo exposto (-0,1291569 a 0,3548328), onde solo era observado.

Vegetação de plantas (0,5 a 0,2338354). Para os demais índices buscou-se classificar seguindo a mesma lógica: NGRDI - Classe 1 (-1 a 0,00), Classe 2 (0,00 a 0,07), Classe 3 (0,07 a 0,12); e RI - Classe 1 (1 a -0,5), Classe 2 (0,00 a 0,05), Classe 3 (0,5 a 1)

3.4 Cálculo de área

Para o cálculo da área de cada talhão presente na área experimental, foi utilizada a ferramenta de edição de dados vetoriais do QGIS. Cada talhão foi selecionado individualmente utilizando as ferramentas de seleção do QGIS. Foi escolhido o talhão (TSN1), utilizando-se grades e resolução de pixel para identificar os pontos. Os dados foram analisados pela estatística descritiva, com visualização por meio de gráficos de barras, e análise de variância.

4. RESULTADOS E DISCUSSÃO

4.1 Ortomosaico

O ortomosaico (Figura 4) gerado a partir das fotos processadas, serviu como base para todas as análises subsequentes, garantindo a manutenção das informações georreferenciadas.

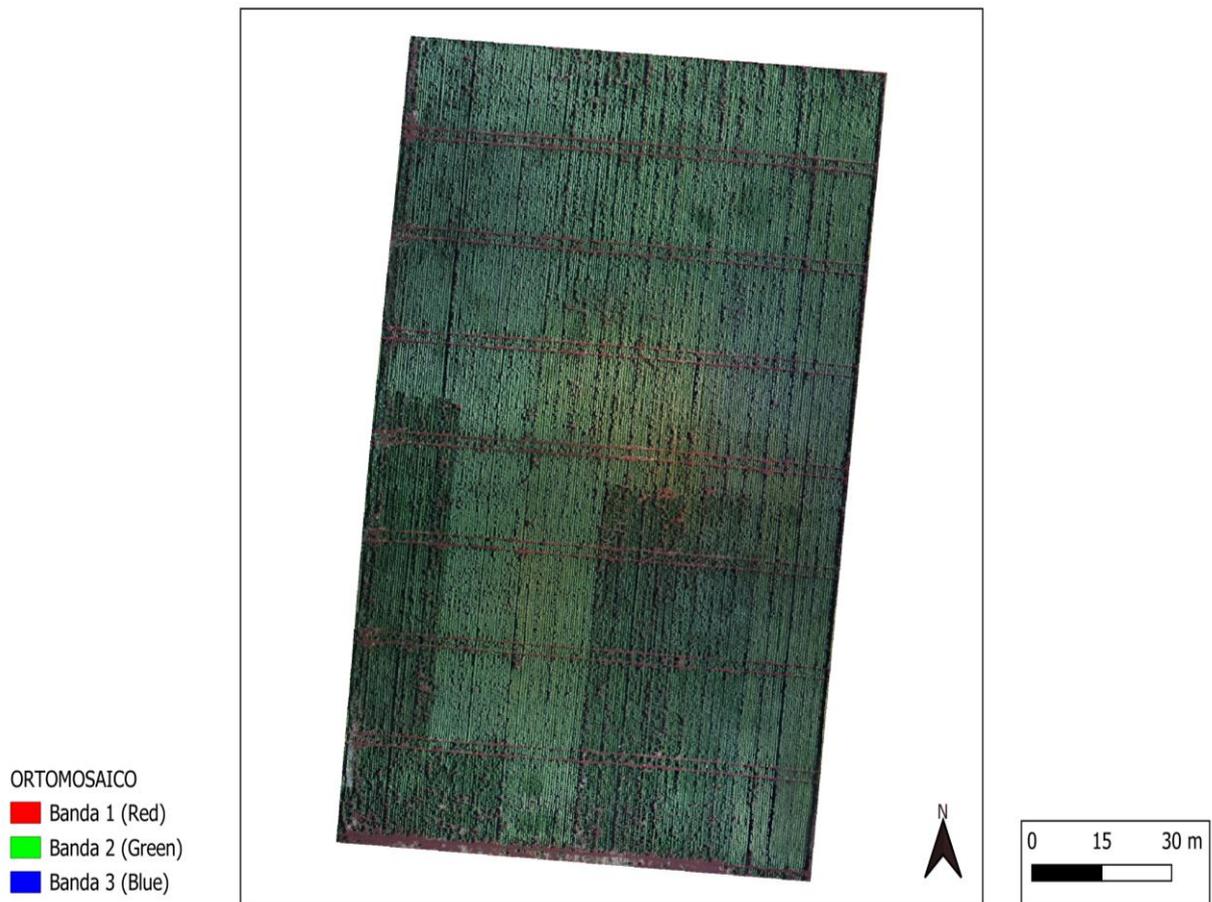


Figura 4 – Ortomosaico campo experimental.

Fonte: Autor, 2024.

O ortomosaico da lavoura de soja apresenta diversas informações relevantes para o monitoramento da cultura e a identificação de áreas com problemas. Nas faixas inferiores do talhão, observa-se uma mudança significativa na coloração das plantas de soja. Essa alteração é provavelmente decorrente da troca de variedade de sementes durante o plantio. A diferença de coloração pode indicar que as variedades utilizadas apresentam características distintas de desenvolvimento, como ciclo de vida, resistência a pragas e doenças, ou adaptação às condições climáticas locais.

O clima severo da safra 2023/24, caracterizado por temperaturas elevadas, parece ter impactado negativamente o desenvolvimento da cultivar de soja. As altas temperaturas podem ter causado estresse hídrico, prejudicando a germinação das sementes e o crescimento das plantas.

A combinação de plantio parcialmente manual e parcialmente mecanizado na área de estudo pode ter contribuído para as falhas no plantio observadas. As falhas na parte manual do plantio podem estar relacionadas à falta de uniformidade na distribuição das sementes e na profundidade de plantio.

As faixas de amassamento presentes no ortomosaico são provavelmente causadas pela ação dos pulverizadores utilizados na aplicação de defensivos agrícolas. O trânsito dos pulverizadores sobre a lavoura pode ter compactado o solo e danificado as plantas, afetando seu desenvolvimento.

4.2 Índices de Vegetação

A análise dos índices de vegetação para todo o experimento forneceu uma visão geral da saúde e do vigor da lavoura de soja. Os resultados indicam que a maior parte da área está em condições favoráveis ao desenvolvimento das plantas, com valores dos índices GLI e NGRDI próximos às classes consideradas como vegetação sadia e desenvolvimento pleno das plantas, respectivamente com algumas falhas. A escolha aleatória do tratamento bionematicida 1 para a análise individual dos índices de vegetação se justifica pela sua maior uniformidade em relação aos demais tratamentos. Essa uniformidade facilita a interpretação dos resultados e permite uma avaliação mais precisa da efetividade do tratamento, como a produção do tratamento (Figura 5) uma vez que não houve diferenças significativas entre os tratamentos sobre a produção de grãos de soja.

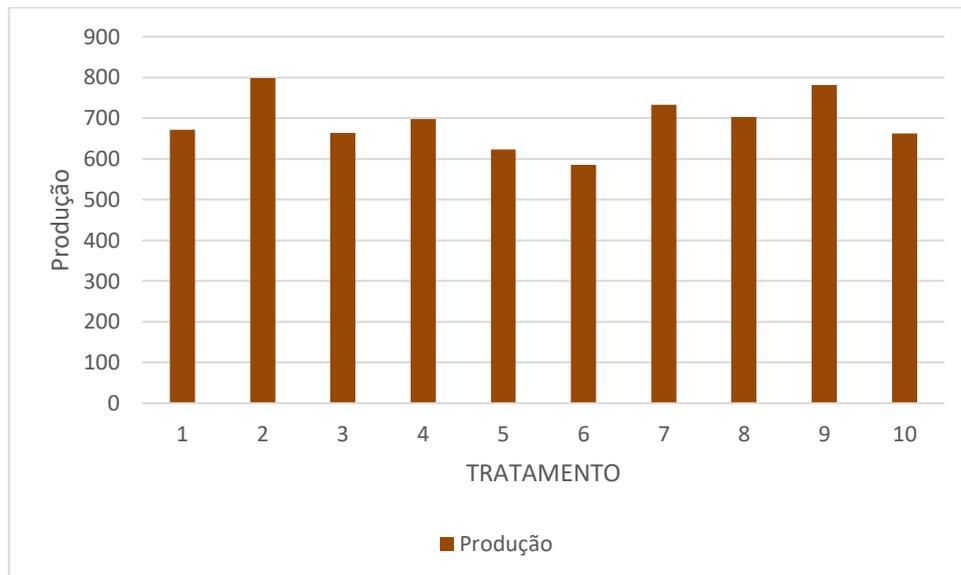


Figura 5. Produção de soja (em gramas) referente ao tratamento bionematicida I
Fonte: Autor, 2024.

Os valores do índice de folhas verdes (GLI) esteve entre -0,3019 a 0,034771 (Figura 6), indicando que a maior parte das plantas no tratamento bionematicida 1 está com folhas verdes e saudáveis. Essa classificação é consistente com a observação do ortomosaico, que não apresenta áreas com descoloração significativa das folhas nesse tratamento.

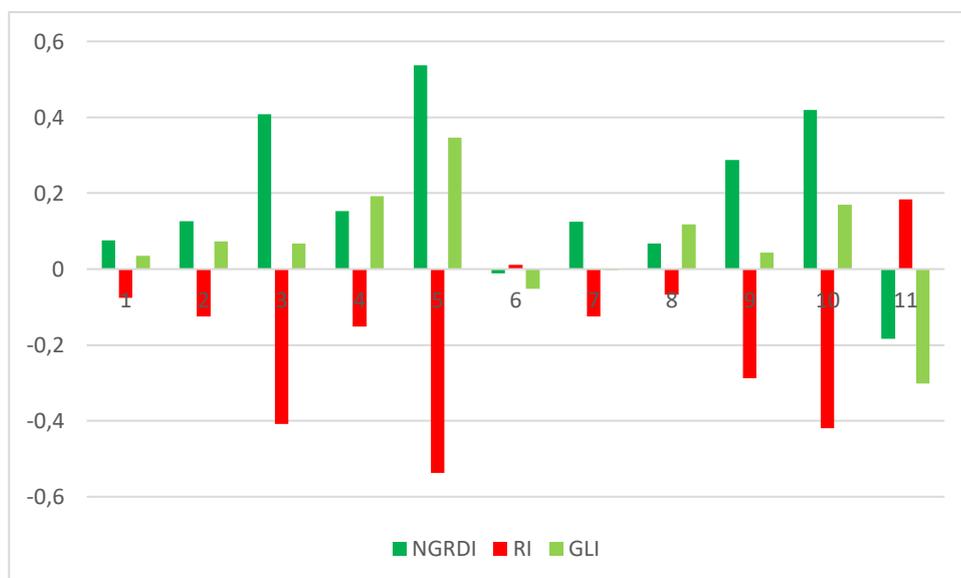


Figura 6. Índices de vegetação NGRDI, RI e GLI na área experimental
Fonte: Autor, 2024.

A classificação do NGRDI na classe 3 indica que a fração de vegetação no tratamento bionematicida 1 está acima de 0, o que significa que as plantas estão em desenvolvimento pleno. Essa classificação também corrobora com as observações do ortomosaico, que não apresentam falhas significativas no desenvolvimento das plantas nesse tratamento.

A maioria dos valores do RI no tratamento bionematicida 1 estar abaixo de 0 indica que as plantas estão com baixo estresse hídrico e nutricional. Essa classificação é positiva, pois o estresse hídrico e nutricional pode prejudicar o desenvolvimento das plantas e reduzir a produtividade da lavoura. Os resultados dos índices de vegetação indicam a presença de falhas na parte central e direita da área de estudo.

A análise dos gráficos de distribuição de pixels para os índices de vegetação GLI e NGRDI revela algumas características importantes sobre a lavoura de soja. A maioria dos valores de pixel está concentrada em torno da média para ambos os índices. Essa distribuição indica que a maior parte da área de estudo apresenta valores homogêneos de vegetação, com poucas áreas com valores significativamente altos ou baixos. A configuração dos gráficos, com colunas verdes altas e colunas vermelhas baixas, sugere que a maioria dos pixels está associada à presença de vegetação sadia. Isso é consistente com os resultados da análise espacial, que não identificou áreas extensas com problemas na lavoura.

Valores negativos do GLI estão associados a solos nus ou vegetação ressecada (Figura 7). Valores inferiores a 0,03 podem indicar áreas com solo exposto ou vegetação seca. Valores positivos do GLI indicam a presença de folhas verdes. A distribuição do GLI no gráfico sugere que a maioria da área de estudo apresenta folhas verdes, o que é um indicador positivo da saúde da lavoura.

Valores do NGRDI menores que 0 sugerem a presença de solo exposto (Figura 8). Valores do NGRDI próximos a 0,1 indicam uma cobertura vegetal substancial. A distribuição do NGRDI no gráfico indica que a maior parte da área de estudo apresenta cobertura vegetal, o que é um indicador positivo do desenvolvimento da lavoura.

O índice RI, em particular, apresenta valores mais altos nessas áreas, o que sugere a presença de estresse hídrico ou nutricional (Figura 9). As falhas observadas no ortomosaico, como amassamento nas regiões, podem ser a causa desse estresse.

A análise dos gráficos de distribuição de pixels complementa os resultados da análise espacial e fornece informações valiosas sobre a distribuição da vegetação na lavoura de soja. A predominância de valores em torno da média e a concentração de pixels nas classes consideradas como vegetação sadia indicam que a maior parte da área de estudo apresenta boa saúde e vigor.

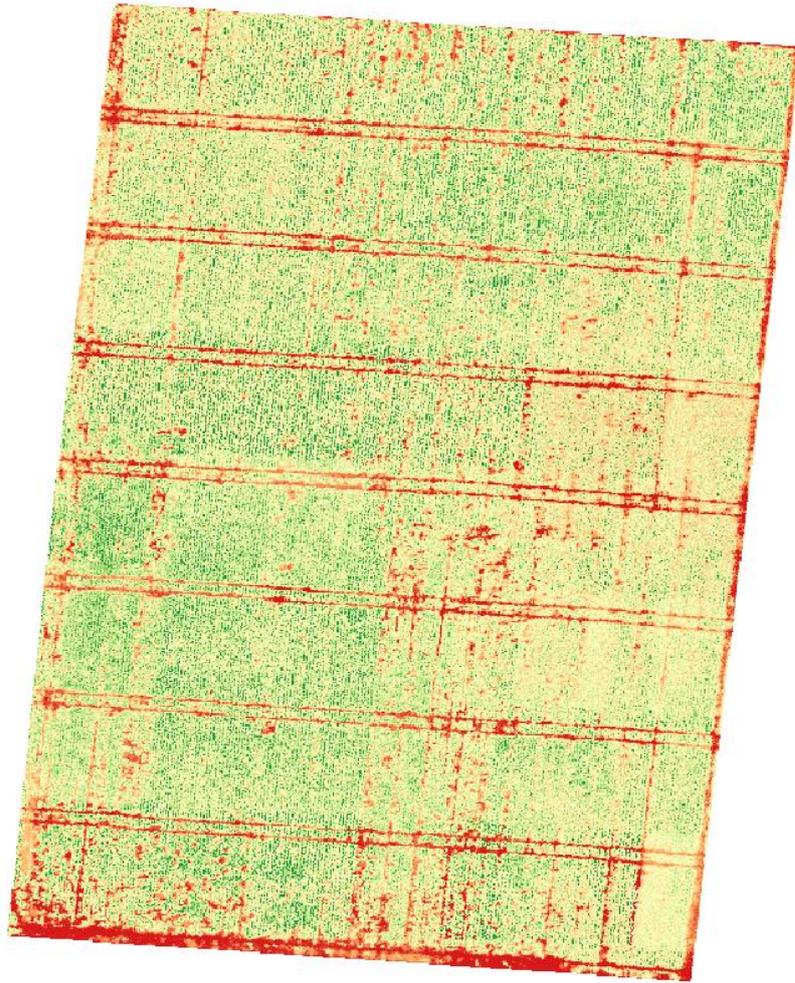


Figura 7 – Índice de vegetação: GLI.

Fonte: Autor, 2024.

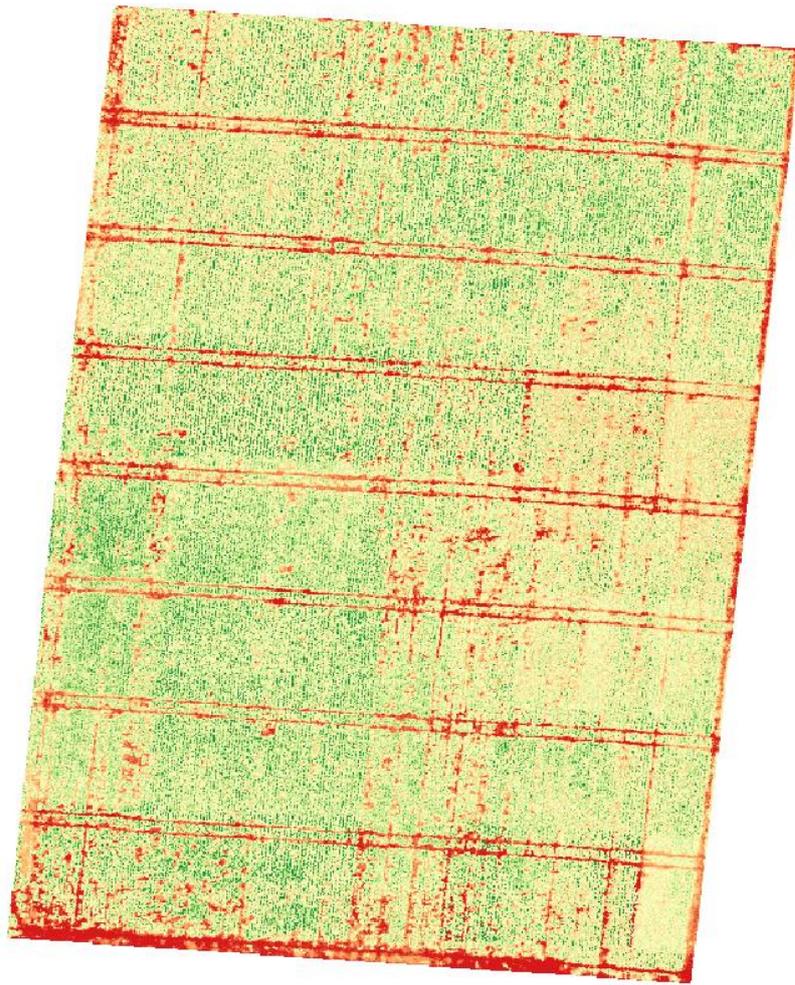


Figura 8 – Índice de vegetação: NGRDI.

Fonte: Autor, 2024.

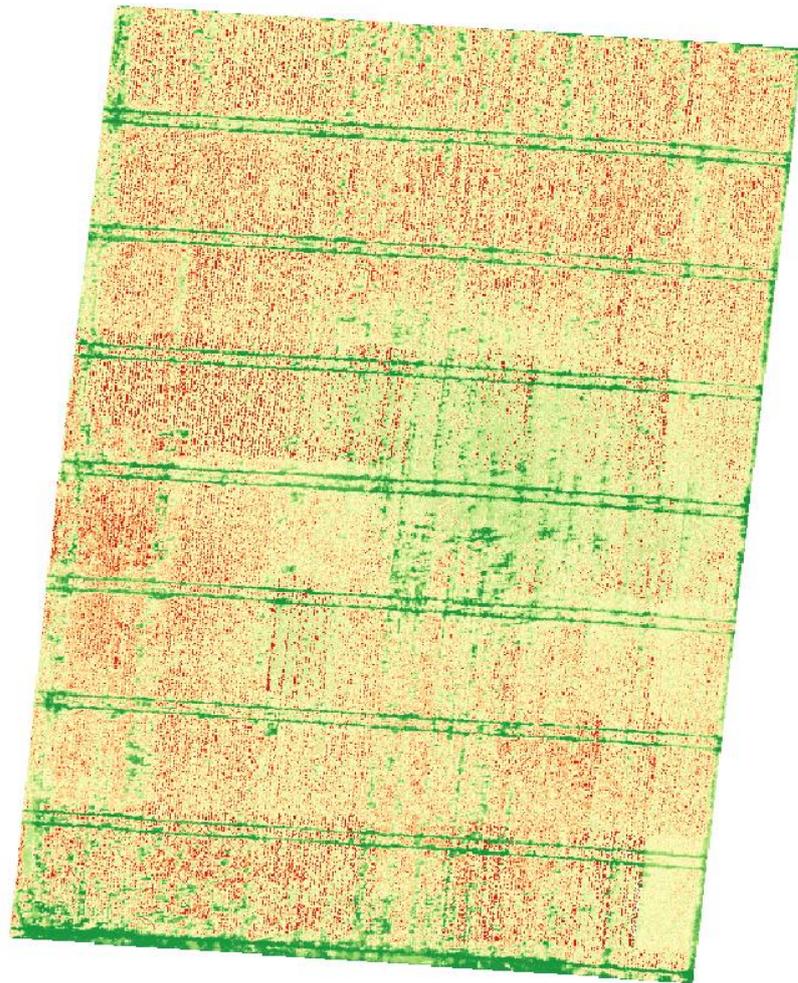


Figura 9 – Índice de vegetação: RI.

Fonte: Autor, 2024.

Todos os índices apresentam tonalidades predominantemente amareladas, o que é consistente com a fase vegetativa da cultura da soja no momento da coleta dos dados. Essa característica indica que a maior parte das plantas está em desenvolvimento ativo e crescendo de forma saudável. Ao analisar a totalidade da imagem, é possível observar a presença de marcas em coloração vermelha. Essas marcas são indicativas de compactação do solo causada pelo tráfego de pneus durante a aplicação de defensivos agrícolas. A compactação do solo pode prejudicar o desenvolvimento das raízes das plantas e reduzir a produtividade da lavoura.

Na porção inferior direita da imagem, nota-se uma coloração tendendo ao avermelhado nos índices GLI e NGRDI. Essa coloração pode indicar falhas no processo de plantio ou não desenvolvimento das plantas devido ao clima severo da safra 2023/24. As falhas no plantio podem estar relacionadas à falta de uniformidade na distribuição das sementes ou à

profundidade de plantio inadequada. O clima severo, com temperaturas elevadas, pode ter causado estresse hídrico nas plantas, prejudicando seu crescimento.

A predominância de tonalidades amareladas nos índices de vegetação indica que a maior parte das plantas está em desenvolvimento ativo. As marcas vermelhas indicam áreas com compactação do solo, enquanto a coloração avermelhada na porção inferior direita da imagem sugere falhas no plantio ou problemas no desenvolvimento das plantas. O NGRDI se destaca como uma ferramenta eficaz para discernir os espectros de vegetação e solo, permitindo identificar áreas com problemas na lavoura.

5. CONCLUSÃO

A análise dos índices de vegetação revelou que a maior parte da área de estudo apresentou valores dentro da faixa considerada como vegetação sadia. Isso indica que as plantas estavam em bom estado de desenvolvimento e crescendo de forma saudável.

Em algumas áreas da lavoura, foram observadas falhas no plantio. Essas falhas podem estar relacionadas à falta de uniformidade na distribuição das sementes ou à profundidade de plantio inadequada.

A viabilidade da utilização de drones e técnicas de sensoriamento remoto para o monitoramento da lavoura de soja. A análise de índices de vegetação permitiu identificar áreas com problemas, como falhas no plantio, compactação do solo e diferenças no desenvolvimento das plantas. Essas informações podem ser utilizadas para tomar decisões mais precisas sobre o manejo da lavoura, visando otimizar a produção e a qualidade da soja.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, R. W. DE. Uso do índice MPRI na avaliação de processos de Restauração Florestal (RF) utilizando sensor RGB a bordo de VANT. **In: XVIII Seminário de Atualização em Sensoriamento Remoto e Sistemas de Informações Geográficas Aplicados à Engenharia Florestal**. São José dos Campos: INPE, 2017. p. 4795-4802. DOI: <https://doi.org/10.18011/bioeng2020v14n2p111-124>

BALLESTEROS, R.; ORTEGA, J. F.; HERNANDEZ, D.; DEL CAMPO, A.; MORENO, M. A. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, n. 5, p. 66-75, 2018. DOI: <https://doi.org/10.1016/j.jag.2018.05.019>

BERNARDI, H. V. F.; DZEDZEJ, M.; CARVALHO, L. M. T.; ACERBI JÚNIOR, F. W. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird. **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 13. (SBSR), 2007, Florianópolis. Anais... São José dos Campos: INPE, 2007. p. 5595-5602. ISBN 978-85-17-00031-7. Disponível em: <http://urlib.net/ibi/dpi.inpe.br/sbsr@80/2006/11.16.02.01.41>. Acesso em: 15 abr. 2024

BREUNIG, F. M.; GALVÃO, L. S.; NETO, R. P. M. Drones na agricultura de precisão. **In: Drones e Ciência**. Santa Maria - RS: Ed. UFSM, 2019. cap. 6, p. ISBN: 978-85-83-84077-0.

CAMBRAIA-FILHO, D. J. Utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do cerrado. 2019. 147 p. Dissertação (Mestrado em Geociências) – Instituto de Geociências, Universidade de Brasília, Brasília, 2019. Disponível em: <http://repositorio2.unb.br/jspui/handle/10482/35980>. Acesso em: 11 mai. 2024

CAPELLI, N. L. Agricultura de precisão: **Novas tecnologias para o processo produtivo**. Campinas: LIE: DMAQAG: FEAGRI: UNICAMP, 1999. DOI: <https://doi.org/10.1590/S0103-84782002000100027>

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v. 25, n. 9, p. 1565-1596, 2004. DOI: <https://doi.org/10.1080/0143116031000101675>

ESCADAFAL, R.; HUETE, A. Improvement in remote sensing of low vegetation cover in arid regions by correcting vegetation indices for soil 'noise'; Etude des propriétés spectrales des sols arides appliquée à l'amélioration des indices de végétation obtenus par télédétection. **Comptes Rendus de l'Académie des Sciences**. Série 2, Mécanique, Physique, Chimie, Sciences de l'Univers, Sciences de la Terre, França, v. 312, 1991.

GEEBERS, A. P.; ADAMCHUK, V. I. Precision agriculture cycle: a review of components and opportunities. **International Journal of Agricultural and Biological Engineering**, v. 3, n. 4, p. 1-13, 2010.

GALVÃO, L. S.; DOS SANTOS, J. R.; ROBERTS, D. A.; BREUNIG, F. M.; TOOMEY, M.; MOURA, Y. M. de. On intra-annual EVI variability in the dry season of tropical forest: A case study with MODIS and hyperspectral data. **Remote Sensing of Environment**, v. 115, n. 9, p. 2350-2359, 2011. DOI: <https://doi.org/10.1016/j.rse.2011.04.035>. Acesso em: 15 abr. 2024

GEOINOVA. **O que é e como funciona o sensoriamento remoto**, 2023. Disponível em: <https://geoinova.com.br/o-que-e-e-como-funciona-o-sensoriamento-remoto/>. Acesso em: 22 jan. 2024

HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, v. 100, n. S3, p. S117-S131, 2008.

HUNT-JR, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S.; MCMURTREY, J. E.; WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359-378, ago. 2005. DOI: <https://doi.org/10.1007/s11119-005-2324-5>

HUNT-JR, E. R.; DAUGHTRY, C. S. T.; EITEL, J. U.; LONG, D. S. Remote sensing leaf chlorophyll content. **Agronomy Journal**, v. 103, n. 2, p. 1090-1099, 2011.

INAMASU, R. Y.; BERNARDI, A. C. C. Agricultura de precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. p. 21-33. ISBN: 978-85-86463-31-0**

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2. ed. São José dos Campos – SP: **Editora Parêntese**, 2009. ISBN: 978-85-60507-06-1

KANEMASU, E. T. Seasonal canopy reflectance patterns of wheat, sorghum, and soybean. **Remote Sensing of Environment**, v. 3, n. 1, p. 43-47, 1974.

LEITE, M. E.; ROSA, R. Geografia e geotecnologias no estudo urbano. **Caminhos de Geografia**, v. 17, n. 17, p. 180-186, 2006. Uberlândia, UFU: Editora Universitária da Universidade Federal de Uberlândia, 2006. DOI: <https://doi.org/10.14393/RCG71715396>
Acesso em: 23 mar. 2024

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 5^a Ed. New York: John Wiley & Sons, 2004. DOI: <https://doi.org/10.2307/634969>

MOTOHKA, T; NASAHARA, K. N; OGUMA, H; TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, v. 2, n. 10, p. 2369-2387, 2010. DOI: 10.3390/rs2102369. Disponível em: <https://www.mdpi.com/2072-4292/2/10/2369>. Acesso em: 11 nov. 2023.

OLIVEIRA, A. J. de.; SILVA, G. F. da.; SILVA, G. R. da.; SANTOS, A. A. C. dos.; CALDEIRA, D. S. A.; VILARINHO, M. K. C.; BARELLI, M. A. A.; OLIVEIRA, T. C. de. Potencialidades da utilização de drones na agricultura de precisão. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140–64149, 2020. DOI: 10.34117/bjdv6n9-010. Acesso em: 23 mar. 2024

PUSCH, M.; MACHADO, T.P.; AMARAL, L.R. **Introdução a Agricultura de Precisão**, 03/2019. UNICAMP, Campinas - SP. Disponível em: <https://www.feagri.unicamp.br/gitap/>. Acesso em: 28 mar. 2024.

QGIS. **Um Sistema de Informação Geográfica Livre e Aberto**. Versão 3.30. QGIS Org, 2022. Disponível em: https://qgis.org/pt_BR/site/. Acesso em: 11 nov. 2023.

REGHINI, F. L.; CAVICHIOLI, F. A. Utilização de Geoprocessamento na Agricultura de Precisão. **Revista Interface Tecnológica**, v. 17, n. 1, p. 329–339, 2020. DOI: 10.31510/infa.v17i1.750.

ROSA, R. **Introdução ao Sensoriamento Remoto**. UFU, Uberlândia - MG, 2013. Cap. 3, p. 59-106.

SENAR – Serviço Nacional de Aprendizagem Rural. **Agricultura de precisão: operação de drone**. Brasília, 84p. 2018. Disponível em: <https://www.cnabrazil.org.br/assets/arquivos/249-DRONES.pdf>. Acesso em: 08 jun. 2024.

SILVA, M. H. da; ELIAS, A. R.; ROSÁRIO, L. L. do. **Análise da cultura da soja a partir de índices de vegetação (ExG – GLI - TGI - VEG) advindos de imagens RGB obtidas com ARP**. R. Bras. Geof., v. 10, n. 2, p. 140-154, 2022.

SMITH, J; JOHNSON, R; WILLIAMS, L. Eficácia do índice Red-Edge Normalized Difference Vegetation Index (NDVIred) na detecção de vegetação em ambientes agrícolas com variações de iluminação e diferentes tipos de solo. **Journal of Agricultural Science**, v. 23, n. 4, p. 345-356, 2015.

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

VARGAS, E G de. Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado (VANT) correlacionados com componentes de rendimento da cultura do feijão. UFTPR, Pato Branco - PR, 2021. 61 p.