

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS

FACULDADE DE CIÊNCIAS AGRÁRIAS

**USO DE IMAGENS AÉREAS COM DRONES PARA
IDENTIFICAÇÃO DE FALHAS NO ESTABELECIMENTO DA
SOJA**

GABRIEL HERNANDES NUNES SIMAS

DOURADOS

MATO GROSSO DO SUL

2023

USO DE IMAGENS AÉREAS COM DRONES PARA IDENTIFICAÇÃO DE FALHAS NO ESTABELECIMENTO DA SOJA

GABRIEL HERNANDES NUNES SIMAS

Orientador: Prof. Dr. Jorge Wilson Cortez

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

2023

Dados Internacionais de Catalogação na Publicação (CIP).

S588u Simas, Gabriel Hernandes Nunes

Uso de imagens aéreas com drones para identificação de falhas no estabelecimento da soja
[recurso eletrônico] / Gabriel Hernandes Nunes Simas. -- 2023.

Arquivo em formato pdf.

Orientador: Jorge Wilson Cortez.

TCC (Graduação em Engenharia Agrícola)-Universidade Federal da Grande Dourados, 2023.

Disponível no Repositório Institucional da UFGD em:

<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. Drone. 2. Tecnologia. 3. Agricultura de precisão. 4. Índice de vegetação. I. Cortez, Jorge Wilson. 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.

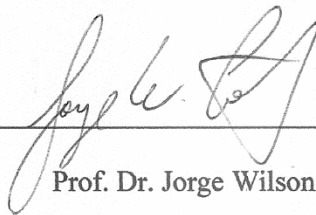
**USO DE IMAGENS AÉREAS COM DRONES PARA IDENTIFICAÇÃO
DE FALHAS NO ESTABELECIMENTO DA SOJA**

Por

Gabriel Hernandes Nunes Simas

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

Aprovado em: 25 de agosto de 2023



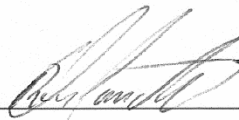
Prof. Dr. Jorge Wilson Cortez

Orientador – UFGD/FCA



Profa. Dra. Anamari Viegas de Araújo Motomiya

UFGD/FCA



Prof. Dr. Roberto Carlos Orlando

UFGD/FCA

AGRADECIMENTOS

A Deus acima de tudo, por me conceder saúde, força e sabedoria ao longo desta jornada. Agradeço por sua graça e misericórdia que foram fundamentais em todos os momentos por me permitir discernimento e paciência.

À minha família, principalmente ao meu pai e mãe, Wanderlei Simas e Marinete Simas, por todo apoio, carinho e sempre estarem ao meu lado nos momentos difíceis

Ao meu orientador, Prof. Dr. Jorge Wilson Cortez, pelos conhecimentos compartilhados, pela paciência e por me apoiar durante este período. Agradeço por seu tempo e esforço em me guiar neste trabalho, por suas sugestões que contribuíram para o aprimoramento do meu projeto.

Ao meu colega de graduação Silas Fiedler pela sua contribuição no desenvolvimento deste trabalho. E também aos demais colegas, pelo companheirismo, desafios e momentos de aprendizado durante este período.

À Universidade Federal da Grande Dourados, por me proporcionar um ambiente acadêmico estimulante, com professores qualificados e oportunidades de crescimento intelectual.

SIMAS, G. H. N. **Uso de imagens aéreas com drones para identificação de falhas no estabelecimento da soja.** 2023. 34f. Monografia (Trabalho de Conclusão de Curso), Bacharelado em Engenharia Agrícola – Faculdade de Ciências Agrárias, Universidade Federal da Grande Dourados, Dourados, 2023.

RESUMO

A agricultura de precisão utiliza tecnologias avançadas que, através da coleta e análise de dados, permite ao agricultor fazer o melhor manejo na tomada de decisão, com a finalidade de maior produção e redução de custos. O uso de VANT - Veículo aéreo não tripulado na agricultura tem se tornado cada dia mais comum, e pode trazer muitos benefícios para a indústria agrícola. Permite o monitoramento e análise das lavouras, com alta precisão e rapidez. Possibilita acompanhar o desenvolvimento das culturas, identificar pragas e doenças, coletando dados por meio de sensores e imagens de câmeras. Estes dados e imagens, quando analisados por softwares específicos, permitem a identificação das áreas de um talhão que apresentem algum problema no estabelecimento da cultura. Objetivou-se avaliar área de um talhão agrícola por meio de imagens, no espectro visível (RGB), feitas com drone, gerando índices de vegetação e classificação das imagens na identificação de falhas no estabelecimento da soja. Foram empregadas imagens adquiridas por meio de drones, e através de técnicas de geoprocessamento, um ortomosaico foi criado. Isso permitiu a integração dessas imagens no software QGIS, no qual diversos índices como GLI, NGDRI e RI, que possuem relação com a vegetação, foram calculados. Posteriormente, as imagens foram submetidas a processos de classificação supervisionada e limiarização binária. Essa abordagem possibilitou o cálculo do coeficiente Kappa, o qual foi empregado para avaliar a precisão do método e para identificar áreas nos talhões onde ocorreu o amassamento das plantas e falhas. A combinação de índices GLI e RI fornece análise mais consistente e precisa em comparação com a combinação GLI e NGRDI, conforme refletido pelos coeficientes Kappa e pelas porcentagens de acertos. Considerando os métodos de Limiarização Binária pode-se observar que foram eficientes, principalmente máximo/mínimo ou três vezes o desvio padrão quando comparado ao algoritmo Random Forest. Podendo assim identificar com clareza as falhas provenientes no desenvolvimento da cultura e rastros de amassamento advindos da aplicação de defensivos agrícolas no talhão de estudo.

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

SIMAS, G. H. N. **Use of aerial images with drones to identify failures in soybean establishment**. 2023. 34f. Bachelor's Course Completion Work in Agricultural Engineering – Faculty of Agricultural Sciences, Federal University of Grande Dourados, Dourados, 2023.

ABSTRACT

Precision agriculture uses advanced technologies that, through data collection and analysis, allow the farmer to make the best decision-making management, with the aim of greater production and cost reduction. The use of UAV - Unmanned Aerial Vehicle in agriculture has become more and more common, and can bring many benefits to the agricultural industry. Allows the monitoring and analysis of crops, with high precision and speed. It makes it possible to monitor the development of crops, identify pests and diseases, collecting data through sensors and camera images. These data and images, when analyzed by specific software, allow the identification of areas of a plot that present a problem in the establishment of the crop. The objective was to evaluate the area of an agricultural plot through images, in the visible spectrum (RGB), taken with a drone, generating vegetation indexes and classification of images in the identification of failures in the establishment of soybeans. Images acquired by drones were used, and through geoprocessing techniques, an orthomosaic was created. This allowed the integration of these images in the QGIS software, in which several indices such as GLI, NGDRI and RI, which are related to vegetation, were calculated. Subsequently, the images were submitted to supervised classification and binary thresholding processes. This approach enabled the calculation of the Kappa coefficient, which was used to assess the accuracy of the method and to identify areas in the stands where plant crushing and faults occurred. Combining GLI and RI indices provides more consistent and accurate analysis compared to combining GLI and NGRDI, as reflected by Kappa coefficients and percentages of hits. Considering the Binary Threshold methods, it can be observed that they were efficient, mainly maximum/minimum or three times the standard deviation when compared to the Random Forest algorithm. Thus, being able to clearly identify the failures arising from the development of the crop and traces of crushing arising from the application of pesticides in the study plot.

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

SUMÁRIO

RESUMO	iv
ABSTRACT	v
1 INTRODUÇÃO	7
2 REVISÃO DE LITERATURA	8
2.1 Agricultura de precisão	8
2.2 Sensoriamento remoto e geoprocessamento	9
2.3 Drones	10
2.4 Índices de vegetação	10
2.4.1 Índice de Folha Verde (GLI)	11
2.4.2 Índice da Diferença Normalizada do Verde e do Vermelho (NGRDI)	11
2.4.3 Índice de Vermelhidão (RI)	12
2.5 Classificação supervisionada e limiarização binária	12
3 MATERIAIS E MÉTODOS	14
3.1 Localização e histórico da área	14
3.2 Planejamento de Voo e Coleta de Imagens	15
3.3 Índices de vegetação (IVs)	16
3.4 Classificação supervisionada e limiarização	16
3.5 Cálculo de área	17
3.6 Análise dos dados	17
4 RESULTADOS E DISCUSSÕES	18
4.1 Ortomosaico	18
4.2 Índices de vegetação	19
4.3 Classificação supervisionada e limiarização	22
5 CONCLUSÃO	26
REFERÊNCIAS BIBLIOGRÁFICAS	27

1 INTRODUÇÃO

Com o crescente aumento da população mundial e alta demanda de alimentos, se faz necessário produzir mais alimentos, segundo a ONU (2019), a população mundial em 2050 será de 9,7 bilhões de habitantes. Diante disso, há necessidade de se produzir em maiores escalas, para isso é preciso aliar tecnologias à produção no campo. A difusão de novas tecnologias no campo está contribuindo com o aumento da produção e reduzindo custos aos produtores.

A agricultura de precisão (AP) visa aprimorar processos, aumentar a produção agrícola e reduzir custos. A AP está presente desde o plantio, com a prática das semeadoras distribuindo uniformemente nos sulcos, até a colheita, as máquinas gerando em tempo real os mapas de produtividade. Com a utilização de novas tecnologias, a AP juntamente com boas práticas de cultivo e outras tecnologias tem propiciado o melhoramento dos sistemas produtivos, otimizando recursos e mitigando efeitos no ambiente (OLIVEIRA, de. et al., 2020).

O uso de drones na agricultura de precisão se torna a cada dia mais viável e eficiente, isso devido ao seu menor custo e por poder ter várias aplicações: pulverização, irrigação, monitoramento, coleta, processamento e análise de imagens, entre outras aplicações. Nos drones, são acoplados sensores ou outros equipamentos conforme sua necessidade, os sensores usados são de faixa visível (RGB), sensores infravermelhos (IV), sensores multiespectrais, sensores hiperespectrais, e sensores de monitoramento do espectro de frequência, radares e sensores termais (Rex et al., 2020).

Segundo Breunig et. al (2019), os drones podem acompanhar de forma adequada a fenologia de culturas agrícolas, demandas dos processos de manejo da lavoura e qualificar a tomada de decisões. Fixando as condições das câmeras, a escala cartográfica de uma imagem de drone pode equivaler a uma resolução espacial de poucos centímetros a decímetros, dependendo da altura do voo. Os índices de vegetação são utilizados como meio de avaliar as imagens obtidas nas diversas fases de desenvolvimento da cultura.

O trabalho objetivou identificar falhas em um talhão agrícola cultivado com soja por meio de imagens RGB feitas com drone, gerando índices de vegetação e classificação da imagem.

2 REVISÃO DE LITERATURA

2.1 Agricultura de precisão

A agricultura de precisão (AP) é a tecnologia cujo objetivo consiste em aumentar a eficiência, com base no manejo diferenciado de áreas na agricultura. A agricultura de precisão não consiste simplesmente na habilidade em aplicar tratamentos que variam de local para local, porém, deve ser considerada com a habilidade em monitorar e acessar a atividade agrícola, precisamente em um nível local, tanto que as técnicas de agricultura de precisão devem ser compreendidas como uma forma de manejo sustentável, na qual as mudanças ocorrem sem prejuízos para as reservas naturais, ao mesmo tempo em que os danos ao meio ambiente são minimizados. Além de útil à agricultura de precisão, esta definição engloba a ideia de compromisso no uso da terra, relativamente às gerações futuras. Um manejo sustentável implica algo mais além da manutenção dos índices de produtividade (MANTOVANI et al., 1998).

As áreas agrícolas não são uniformes, tanto em termos dos fatores de produção (fertilidade, topografia, clima) como da própria produtividade obtida, sendo assim, 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) enfatiza que a informação coletada ou utilizada é tão crucial para o sucesso da agricultura de precisão quanto os próprios dispositivos empregados. O conceito dessa abordagem difere da agricultura tradicional devido ao seu nível de gerenciamento. Em vez de tratar uma área inteira como uma unidade uniforme, o enfoque está na adaptação do manejo a pequenas regiões dentro do campo (apud TSCHIEDEL e FERREIRA, 2002).

Para Doerge (1999) a agricultura de precisão consiste em colecionar informações agronômicas para prover necessidades atuais de partes de campos em lugar de necessidades comuns para campos inteiros. Aplicação de insumos em locais específicos comumente usada dividindo-se os campos inteiros em zonas de manejo menores, homogêneas.

Capelli (2004) complementa que a agricultura de precisão apresenta as vantagens de possibilitar um melhor conhecimento do campo de produção, permitindo, desta forma a tomada de decisões melhor embasadas. Com isto, tem-se uma maior capacidade e flexibilidade para a distribuição dos insumos naqueles locais e no tempo em que são mais necessários, minimizando os custos de produção.

A uniformidade é alcançada pela correção dos fatores que, contribuem para sua variabilidade, obtendo-se com isto, um aumento global da produtividade. A aplicação

localizada dos insumos necessários para sustentar uma alta produtividade contribui com a preservação do meio ambiente, já que estes insumos são aplicados somente nos locais, quantidades e no tempo necessário.

2.2 Sensoriamento remoto e geoprocessamento

O Sensoriamento Remoto (SR) pode ser entendido como um conjunto de atividades que permite a obtenção de informações dos objetos que compõem a superfície terrestre sem a necessidade de contato direto com os mesmos. Estas atividades envolvem a detecção, aquisição e análise (interpretação e extração de informações) da energia eletromagnética emitida ou refletida pelos objetos terrestres e registradas por sensores remotos. A energia eletromagnética utilizada na obtenção dos dados por sensoriamento remoto é também denominada de radiação eletromagnética (MORAES, 2002). Ainda, segundo Geoinova (2023), o SR consiste na coleta de informações sobre a superfície terrestre por meio de sensores instalados em satélites, aviões ou drones. Esses sensores captam diferentes espectros ou faixas de radiação eletromagnética, como luz visível, infravermelho e micro-ondas, que são transformados em imagens e dados utilizados para diversas finalidades.

O geoprocessamento pode ser definido por Rosa (2013), como sendo o conjunto de tecnologias destinadas a coleta e tratamento de informações espaciais, assim como o desenvolvimento de novos sistemas e aplicações, com diferentes níveis de sofisticação.

Segundo Reghini e Cavichioli (2020), para se obter um planejamento adequado na área de estudo é necessário a utilização de geoprocessamento, com o tratamento e análise dos dados obtidos é possível auxiliar o produtor em diversas formas, como por exemplo, na tomada de decisões, no aumento da eficiência, produtividade, controle de pragas dentre outros.

A coleta de dados de uma área, a edição de mapas digitais complexos e o cruzamento de informações espaciais se tornaram tarefas fáceis e rápidas de serem realizadas, isso graças a associação das ciências matemática e computacional com a ciência geográfica. Hoje o sensoriamento remoto e o Geoprocessamento são ferramentas de extrema relevância para a análise espacial e temporal em suas diferentes e variadas discussões. Esses sistemas trazem para o usuário uma série de comodidade em suas pesquisas, além de proporcionar uma maior confiabilidade e precisão das informações (LEITE e ROSA, 2006).

2.3 Drones

Os Drones ou Veículos Aéreos Não Tripulados (VANTs) ou Sistemas de Aeronaves Remotamente Pilotadas (SARP) segundo o Instituto Nacional de Pesquisas Espaciais – INPE (2018), têm se tornado cada vez mais relevantes nas áreas de sensoriamento remoto e geoprocessamento. Os drones oferecem uma plataforma flexível e acessível para a aquisição de dados geográficos e têm uma série de aplicações em diversas indústrias, incluindo agricultura, mapeamento, monitoramento ambiental, inspeção de infraestruturas, entre outras. Nos drones são acoplados sensores ou outros equipamentos conforme sua necessidade, os sensores usados são de faixa visível (RGB), sensores infravermelhos, sensores multiespectrais, sensores hiperespectrais, e sensores de monitoramento do espectro de frequência.

A agricultura de precisão faz a utilização de geotecnologias como o Sistema Global de Navegação por Satélite (GNSS), o sensoriamento remoto orbital, o Sistema de Informação Geográfica, o geoprocessamento e a aerofotogrametria para obter, processar e analisar dados e, assim, auxiliar no entendimento das condições ideais para o cultivo das principais culturas agrícolas. Problemas como falhas de plantio, estresse hídrico, competição com outras espécies e doenças das plantas podem ser identificados e mapeados a partir do uso combinado dessas tecnologias (SENAR, 2018).

Com isso, uma vez detectado o problema, o produtor rural poderá tomar decisões com mais assertividade, segurança e celeridade. Nesse contexto, os drones facilitam o levantamento de dados, fornecendo informações estratégicas aos agricultores. Sua aplicação na área agrícola vem sendo favorecida pelo avanço tecnológico, pela redução dos custos de equipamentos e softwares e, finalmente, pela crescente necessidade de otimização dos recursos de produção.

2.4 Índices de vegetação

Os índices de vegetação representam um dos principais produtos gerados a partir das imagens adquiridas por meio de drones. Em geral, operações algébricas são aplicadas para promover esse realce, numa base pixel-a-pixel (BREUNING et al., 2019). De acordo com Galvão et al. (2011), os índices de vegetação podem ser relacionados ao redor ou concentração de pigmentos; índices mais relacionados ao conteúdo de água do dossel ou folha; índices relacionados ao estresse ou eficiência da luz e índices associados a borda do vermelho. Seus resultados se configuram em medidas radiométricas adimensionais obtidas por meio de combinações aritméticas de bandas espectrais para monitoramento de parâmetros como: área foliar, porcentagem de cobertura verde, teor de clorofila, biomassa verde, entre outros (JENSEN, 2009; WANG et al, 2003).

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). Ainda Louhaichi, Borman e Johnson (2001) acreditam que a utilização deste índice tem potencial promissor de aplicação para análises vegetais, uma vez que apresentou 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) apresentam resultados que demonstram uma alta correlação entre os seus resultados e os valores de biomassa verde. Já Wan et al. (2018) demonstram em sua pesquisa altas correlações deste índice com o número de flores em campos de girassóis na China, demonstrando sua alta aplicabilidade em realizar estimativas sobre as vegetações.

2.4.3 Índice de Vermelhidão (RI)

Segundo Escadafal e Huete (1991), o índice *Redness Index* - RI (Índice de vermelhidão), consiste em uma razão da diferença entre bandas do verde e vermelho, facilitando a aplicação em ambientes áridos, focando na identificação de ervas daninhas em colheitas sob a presença de iluminação/sombreamento, resíduos e solos distintos. O cálculo de 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.

Vargas (2021) utilizou o RI para a comparação de diferentes índices para o rendimento da cultura do feijão.

2.5 Classificação supervisionada e limiarização binária

Conforme Vale et al. (2018), definem a classificação supervisionada como técnicas e ferramentas essenciais no processo de mapeamento da cobertura do solo de grandes áreas, visto que dispende-se de recursos limitados, imagens de baixo custo e de sistemas livres para processamento e integração das informações, é possível obter parâmetros com altos níveis de precisão, sendo fundamentais para subsidiar o planejamento territorial e ambiental. Se baseia na identificação de diferentes classes com comportamentos espectrais diferenciados. Para isso, algoritmos de classificação são adotados para extrair as feições de interesse em um espaço multidimensional (BERNARDI, 2007). Venturieri (2007) afirma que a classificação supervisionada requer que o analista tenha um conhecimento prévio das classes presentes na imagem. Em tal abordagem, o analista treina o algoritmo para poder distinguir as classes umas das outras, baseando-se em regras estatísticas pré-estabelecidas.

Dentre os algoritmos mais utilizados, alguns são descritos por Ateliware (2021) da seguinte forma:

- **KNN:** O classificador do vizinho mais próximo, onde o aprendizado é fundamentado na medida de similaridade entre os dados de um elemento específico e seus k-vizinhos.
- **SVM:** A *Support Vector Machine*, também conhecida como máquina de vetores de suporte, tem aplicação em problemas de classificação ou regressão. Sua operação pode ser resumida como a busca por um hiperplano que otimamente separe as classes dentro do conjunto de dados.
- **Árvores de decisão:** Este algoritmo faz uso da estrutura de árvore, composta por nós raiz e folhas, comum na ciência da computação. As árvores de decisão baseiam-se nessa estrutura para operar. Decisões são tomadas ao percorrer o caminho da raiz até um nó folha na árvore de decisão. Analogamente, respostas são encontradas por meio da navegação pelos nós da árvore até alcançar um nó terminal.
- **Redes neurais:** As redes neurais artificiais operam de maneira análoga a redes de neurônios biológicos. Elas recebem estímulos, processam funções e retornam valores correspondentes, em um arranjo de interconexões complexas.

A limiarização consiste em separar uma imagem, em regiões, como por exemplo, interesse e não interesse, por meio da escolha de um ponto de corte (limiar). Essas regiões são representadas por pixels pretos e brancos. Os métodos mais simples de limiarização utilizam um único ponto de corte. Em alguns casos, no entanto, não se consegue apenas um limiar que resulte em uma boa segmentação para a imagem analisada, segundo Monteiro (2004).

3 MATERIAIS E MÉTODOS

3.1 Localização e histórico da área

O estudo foi conduzido no município de Caarapó-MS, na Latitude de $-22,8068674$ e Longitude de $-54,8930786$, utilizando um talhão de 14,50 ha onde foi realizado a coleta das imagens com o drone (Figura 1).

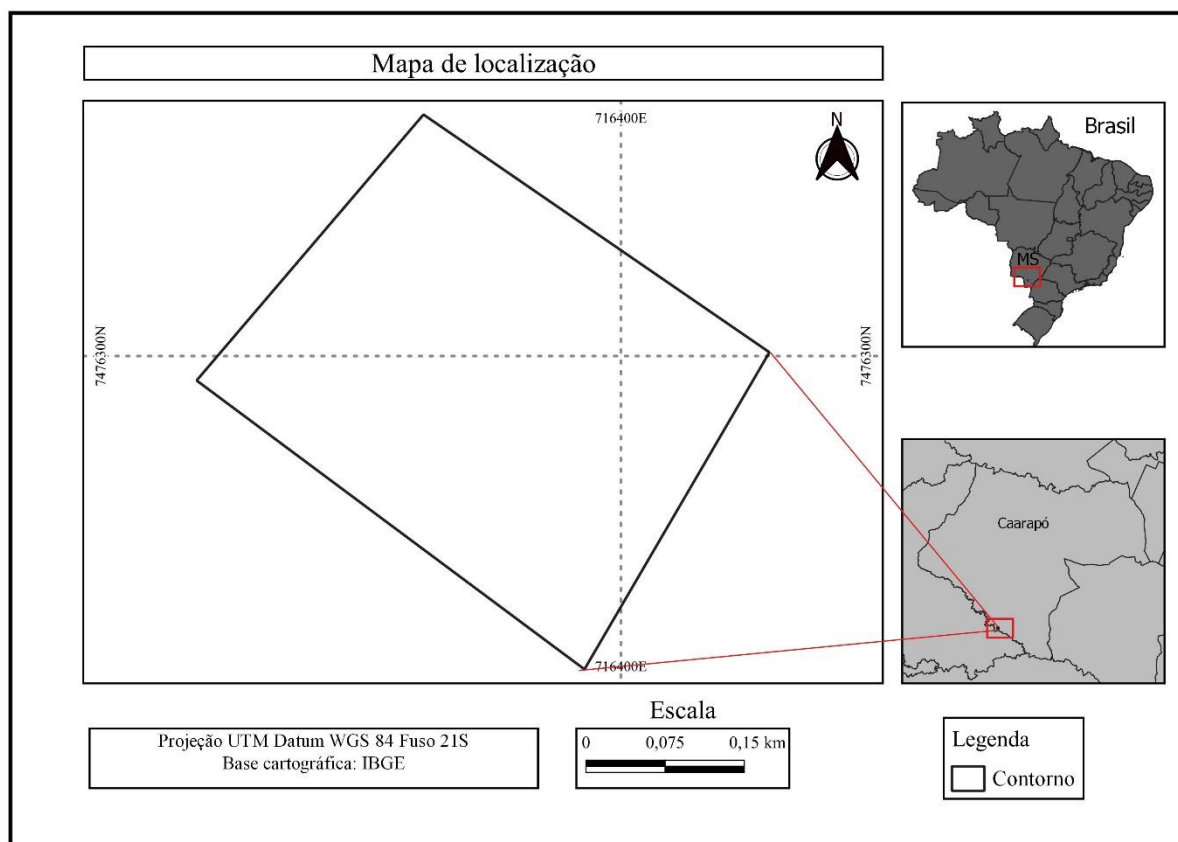


FIGURA 1. Localização da área de estudo. Fonte: Autor (2023).

O sistema utilizado na área é de semeadura na palha, com sucessão de soja e do milho no local. A área estava com soja variedade Brasmax Fibra IPRO, semeada no final da segunda quinzena de setembro de 2022.

A área experimental possui altitude média de 324,3 m, variando de 315 a 331 m; e declividade média de 3,4%, variando de 0,7 a 7,4%.

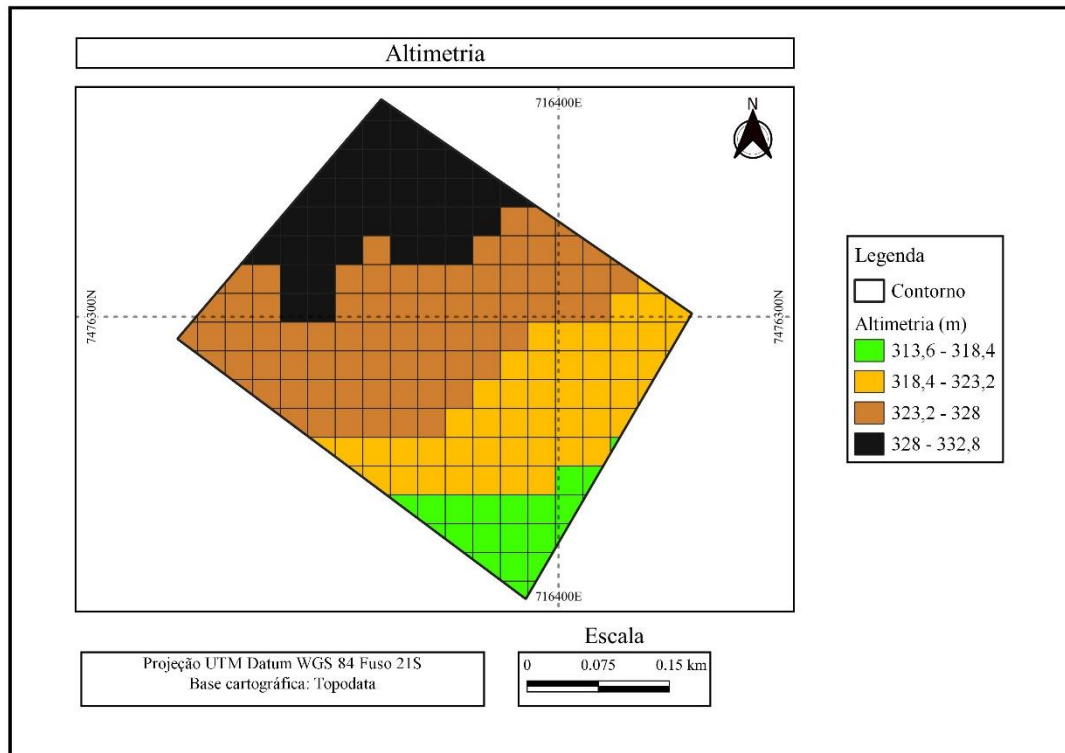


FIGURA 2. Altitude da área experimental. Fonte: Autor (2023).

O clima da região se caracteriza pelo CWa (classificação de Koeppen), possuindo uma precipitação pluvial anual em média de 1350 mm.

3.2 Planejamento de Voo e Coleta de Imagens

O planejamento de voo foi feito utilizando a aplicação DJI Pilot®, em um smartphone. A coleta das imagens foi realizada com uma câmera RGB embarcada (com 12,35 milhões de pixels efetivos e 12,71 milhões de pixels totais) no drone Mavic PRO Platinum da marca DJI model M1X t®, controlado por um controle remoto e bateria que garante autonomia de voo.

O voo foi realizado no dia 15 de dezembro de 2022, no período das 10 horas e 20 minutos às 10 horas e 49 minutos, 75 dias após o plantio a cultura encontra-se em um estágio de floração, caracterizado por uma atividade metabólica intensificada para sustentar o desenvolvimento reprodutivo.

A altitude de voo foi de 80 metros e a taxa de sobreposição correspondeu a 75% na faixa horizontal e 75% na faixa longitudinal. A velocidade de voo foi na ordem de $5,5 \text{ m}\cdot\text{s}^{-1}$ ou $19,8 \text{ km}\cdot\text{h}^{-1}$.

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

A geração do ortomosaico foi realizada com o *software* WEBODM® (*OPEN DRONE MAPA*, 2022) que é *open source* (*software* de código aberto).

3.3 Índices de vegetação (IVs)

Os IVs foram calculados no QGIS seguindo as expressões matemáticas (Tabela 2) de cada índice: Índice de Folha Verde (GLI), Equação (I) para dados em número digital; Índice verde/vermelho por diferença normalizada (NGRDI), Equação (II); Índice de vermelhidão (RI), Equação (III);

Tabela 2. Equações dos índices de vegetação

Índice	Equação	Fonte
$GLI = (2 * Green - Red - Blue) / (2 * Green + Red + Blue)$	(I)	Louhaichi et al. (2001)
$NGRDI = (Green - Red) / (Green + Red)$	(II)	Tucker (1979)
$RI = (Red - Green) / (Red + Green)$	(III)	Escadafal e Huete (1991)

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

Na etapa de finalização dos mapas do índice de vegetação utilizou-se a banda simples falsa-cor, interpolador linear e o gradiente foi o Red-Yellow-Green.

O GLI foi classificado em cinco classes: solo exposto (-1 a 0,0709), onde solo era observado; vegetação debilitada (0,071 a 0,1209), mediana (0,121 a 0,1609), sadia (0,161 a 0,409) e muito sadia (0,41 a 1,0) conforme Silva et al. (2022). Para os demais índices, buscou 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), Classe 4 (0,12 a 0,40) e Classe 5 (0,40 a 1,0); e RI - Classe 1 (1 a 0,0), Classe 2 (0,00 a -0,07), Classe 3 (-0,07 a -0,12), Classe 4 (-0,12 a -0,40) e Classe 5 (-0,40 a -1,0);

3.4 Classificação supervisionada e limiarização

A classificação supervisionada é um método que identificará alguns pixels pertencentes às classes desejadas e o *software* localizará todos os demais pixels pertencentes à classificação definida, baseando-se em regras estatísticas pré-estabelecidas (GANAN et al., 2005).

A ferramenta utilizada para esse tipo de classificação foi o complemento do QGIS *Dzetsaka: Classification tool* (KARASIAK, 2016) com o algoritmo *Random Forest*. Foram estabelecidas as classes: solo exposto (Classe 1) e plantas (Classe 2).

A limiarização binária gera um raster binário considerando duas áreas distintas, conforme amostras de testes (FRANÇA et al., 2017). As áreas testes foram divididas baseadas nos valores dos índices de vegetação, sendo coletados 1,25 ha de área teste (amostras) que representa vegetação. Foram utilizados como parâmetros de seleção: Min/Max; Quantil (2% - 98%); Média 2 vezes o desvio padrão; Média 3 vezes o desvio padrão.

3.5 Cálculo de área

O cálculo de área das classes no QGIS foi realizado utilizando o comando “*r.report*” que gera, a partir de um raster, um arquivo de saída com a área de cada classe. Para isso a camada com cada índice foi reclassificada em classes de 1 a 5, conforme a legenda.

O cálculo de área também foi aplicado às camadas resultantes da limiarização binária.

3.6 Análise dos dados

Os dados dos IVs foram inicialmente submetidos à análise descritiva para obtenção de medidas de tendência central e dispersão.

Foi calculado o índice Kappa (COHEN, 1960) dos mapas de índice de vegetação tendo como referência o GLI. E também para a comparação entre a classificação supervisionada e a limiarização, tendo como testemunha o Randon Forest.

4 RESULTADOS E DISCUSSÕES

4.1 Ortomosaico

O Ortomosaico (Figura 3) foi obtido através das imagens processadas e serviu de base para todas as subseqüentes análises, sem que houvesse a perda das informações georreferenciadas.

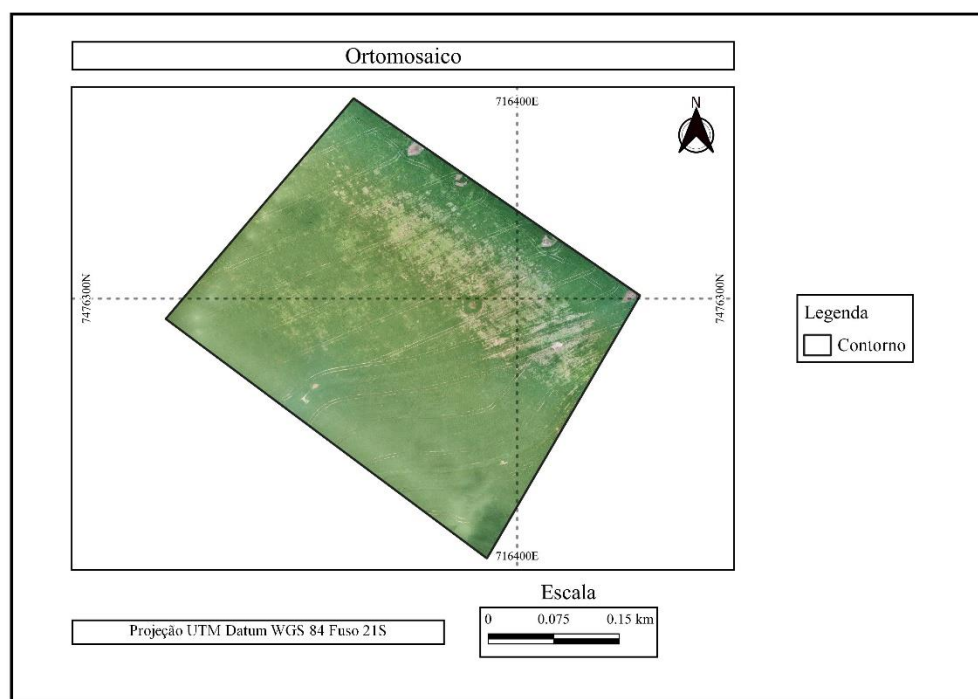


FIGURA 3. Ortomosaico

Fonte: Autor (2023).

Pode-se visualizar que conforme no Ortomosaico, principalmente nas faixas de cima do talhão, há algumas regiões que se observa falhas sejam no plantio ou desenvolvimento da cultivar, e também faixas de amassamento, provenientes da ação de pulverizadores utilizados na aplicação de defensivos agrícolas.

4.2 Índices de vegetação

Como pode se observar na Tabela 3, os parâmetros do índice de folhas verdes (GLI), está classificado como mediano (0,12 a 0,16), sendo mais próxima da classificação vegetação sadia. Enquanto os índices de vegetação da diferença normalizada do verde e do vermelho (NGRDI) pode se considerar que está na classe 3, com uma fração de vegetação acima de 0, que indica que está no desenvolvimento pleno das plantas. O índice de vermelhidão (RI), está em sua maioria abaixo de 0, e indicando falhas na parte superior da área de estudo, provenientes de falhas e amassamento nas regiões.

TABELA 3. Estatística descritiva dos índices de vegetação.

Parâmetros	Índices		
	GLI	NGRDI	RI
Média	0,16	0,12	-0,12
DP ¹	0,05	0,07	0,07
Mínimo	-0,08	-0,20	-1,0
Máximo	1,0	1,0	0,20
CV ² (%)	31,25	58,33	58,33

(¹) DP: desvio padrão; (²) CV (%): coeficiente de variação. Fonte: Autor (2023).

Ao avaliar os gráficos apresentados na Figura 4, é possível notar uma relação comum. Cada gráfico exibe uma linha vermelha que atinge um pico central e diminui nas bordas. Essa configuração sugere que a maioria dos valores de pixel está concentrada em torno da média, com poucos valores excepcionalmente altos ou baixos.

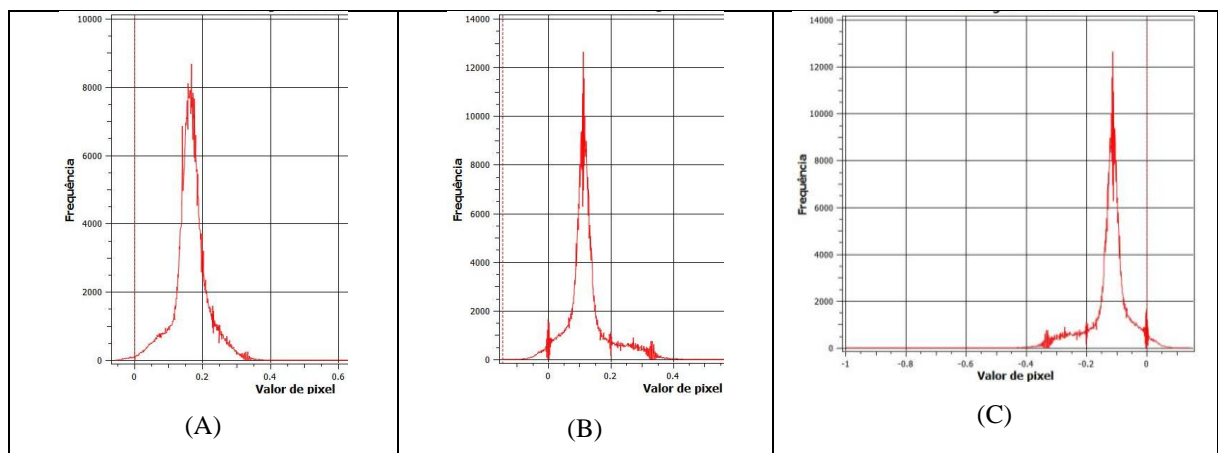


FIGURA 4. Histograma dos índices de vegetação: A – GLI; B – NGRDI; C – RI. Fonte: Autor (2023).

No contexto do GLI, valores negativos estão associados a solos ou vegetação ressecada, enquanto valores positivos indicam a presença de folhas verdes. A Figura 5 ilustra que valores inferiores a 0,07 podem ser relacionados a áreas com solo exposto ou vegetação seca no GLI. Isso implica que a região apresenta uma combinação de solo e vegetação, com predominância de folhagem verde.

Para o NGRDI, valores menores que 0 sugerem a presença de solo exposto, enquanto valores próximos a 0,1 indicam uma cobertura vegetal substancial. Quanto ao índice RI, que se comporta inversamente ao NGRDI, valores superiores a 0 são indicativos de solo exposto, com poucas ocorrências de falhas ou amassamento.

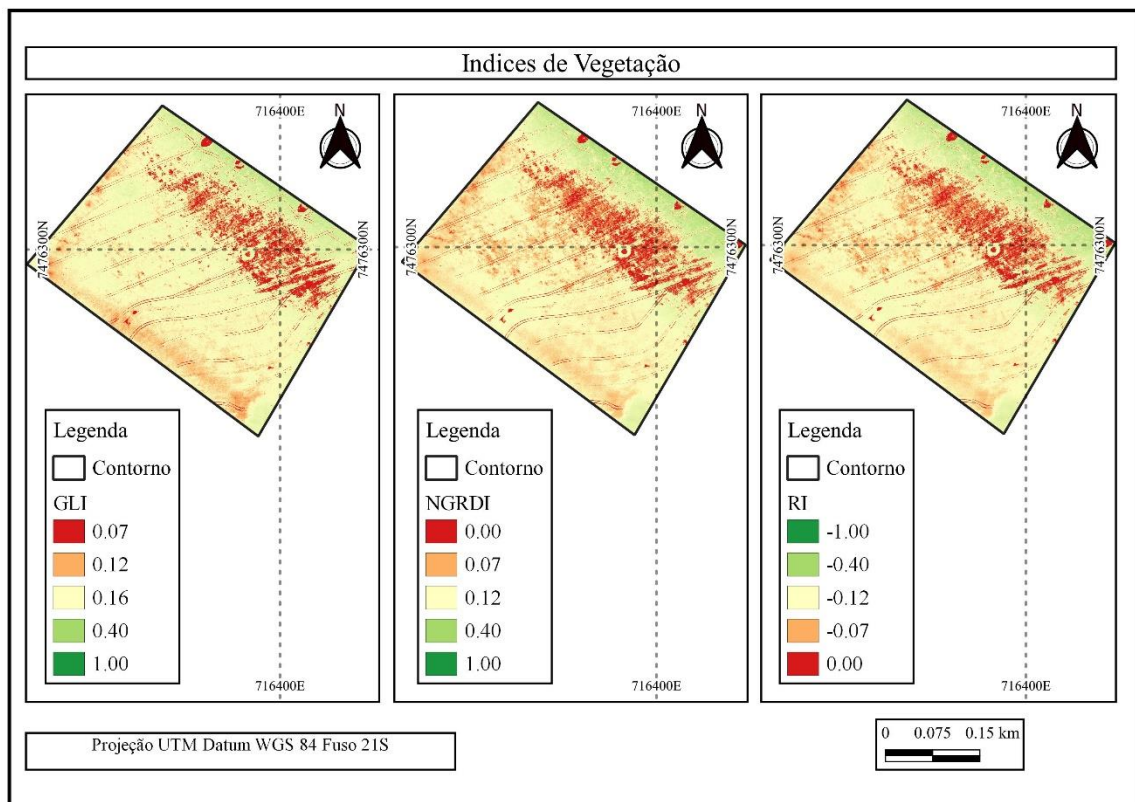


FIGURA 5. Índices de vegetação Fonte: Autor (2023).

Diante dos índices da Figura 5, é possível observar uma significativa semelhança entre os índices avaliados. Predominantemente, destaca-se a presença de tonalidades amareladas, condizentes com a fase vegetativa da cultura em questão. Adicionalmente, ao analisar a totalidade da imagem, destacam-se marcas em coloração vermelha, indicativas de amassamento da cultura devido à aplicação de defensivos agrícolas pelos pneus. Na porção superior direita das imagens, nota-se uma coloração tendendo ao avermelhado, possivelmente sugerindo falhas no processo de plantio, amassamento ou possíveis doenças. Conforme apontado por Vieira

(2021), o Índice de Diferença Normalizada entre o Verde e o Vermelho Infravermelho (NGRDI) revela sua capacidade em discernir os espectros de vegetação e solo, evidenciando a reflectância nas faixas de verde e vermelho.

Ao considerar as classes do índice GLI, a Classe 4 destaca-se por possuir a maior área, abrangendo 8,17 hectares (Tabela 4). Esses números indicam uma forte presença de folhas verdes, sugerindo uma extensão caracterizada por vegetação saudável e abundante.

TABELA 4. Cálculo de área (ha) das classes dos índices de vegetação.

Índices	Classes (ha)					Total
	1	2	3	4	5	
GLI	0,65	1,11	4,56	8,17	0,01	14,50
NGRDI	4,11	1,54	6,38	2,46	0,01	14,50
RI	0,38	1,58	6,38	6,15	0,01	14,50

Fonte: Autor (2023).

Ao analisar as categorias do índice NGRDI (Tabela 4), a Classe 1 ocupa uma área de 4,11 ha, denotando uma região com cobertura vegetal limitada. Em contraste, a Classe 3 detém a maior extensão, totalizando 6,38 hectares. Esses resultados sugerem que, de modo geral, o terreno exibe uma cobertura vegetal considerável. Quando examinamos as classes do índice RI em relação à área, as Classes 1 e 2 destacam-se, somando uma área de 1,96 há, na qual aponta para uma predominância de solo exposto, com uma pequena presença de vegetação.

Na comparação entre os índices GLI (*Green Leaf Index*) e NGRDI (*Normalized Green-Red Difference Index*), o coeficiente Kappa foi calculado como 0,33 (Tabela 5). Isso sugere uma concordância moderada entre os resultados observados e esperados ao usar esses dois índices de vegetação. Além disso, a taxa de acertos foi de 50,04%. Isso significa que metade das classificações ou análises feitas usando esses índices foi considerada correta.

TABELA 5. Cálculo do Kappa para os índices de vegetação.

Índices	Parâmetros	
	Kappa	Acertos (%)
GLI x NGRDI	0,33	50,04
GLI x RI	0,54	71,78

Fonte: Autor (2023).

Por outro lado, quando comparamos os índices GLI e RI, o coeficiente Kappa foi calculado como 0,54. Essa pontuação indica uma concordância substancialmente melhor entre os resultados previstos e os resultados observados ao usar esses índices. A taxa de acertos para

essa combinação foi de 71,78%, o que aponta para um desempenho mais preciso nas análises realizadas usando esses índices de vegetação.

As diferenças encontradas entre a taxa de acertos e o índice Kappa é normal (FERREIRA et al., 2005; MATHER, 2004), sendo que a taxa é referente a informação da matriz do erro, enquanto o índice representa a média da precisão individual das classes. (apud GANEM, 2017).

4.3 Classificação supervisionada e limiarização

Observando a Figura 6, é possível identificar as seguintes classificações dos parâmetros de limiarização binária (LB): No caso do LB Min/Max, a maior parte está classificada como planta (1). Por outro lado, na classificação LB Média 2 vezes o desvio padrão, é evidente uma extensa área classificada como solo/palha (0), localizada na parte superior da imagem. Ao analisar a classificação LB Quantil (2% - 98%), tornam-se visíveis os contornos e traços que indicam as falhas no talhão e o amassamento. Quanto à classificação LB Média 3 vezes o desvio padrão, ela aparenta ser semelhante a classificação LB Min/Max, visto que predominantemente foi categorizada como planta (1), com algumas áreas de contorno usando o parâmetro de solo/palha (0).

Coppin (2004) destaca que alterações na cobertura da terra podem causar mudanças significativas no nível de sinal registrado por um dado sensor embarcado, tais como variações nas condições de geometria de imageamento, iluminação da cena, atmosfera e umidade do solo, entre outros fatores.

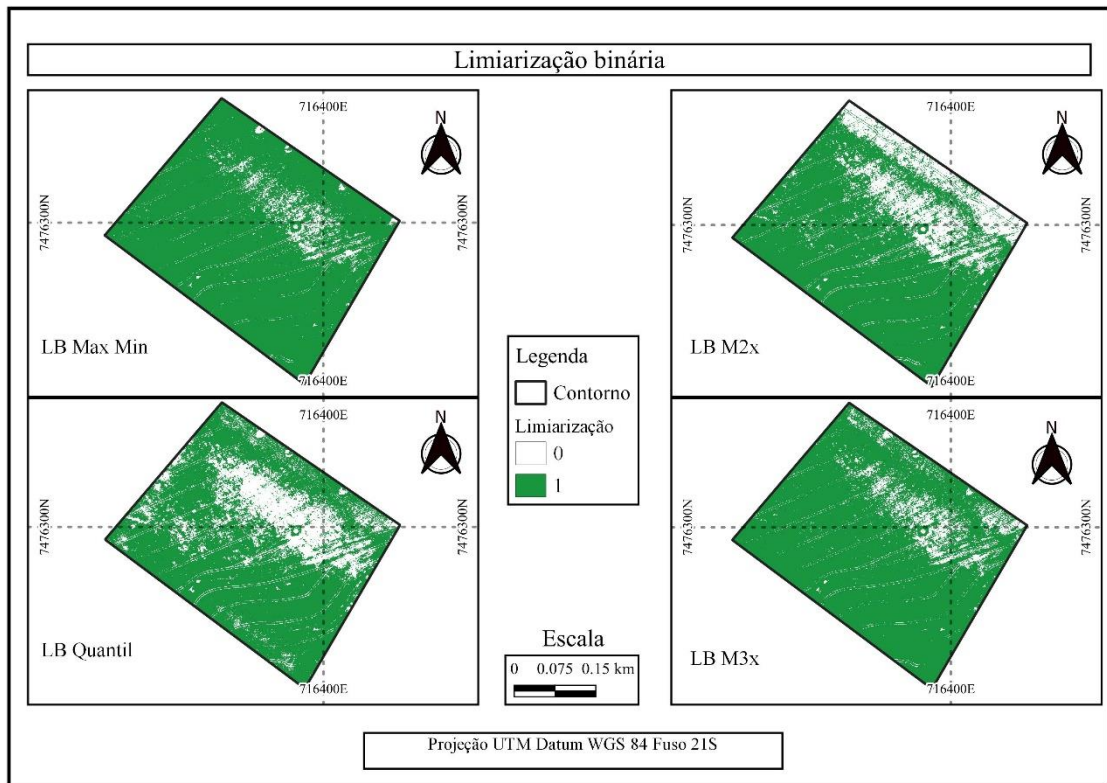


FIGURA 6. Classificação da imagem pela limiarização binária (métodos), sendo que 0 (zero) é solo ou palha e 1 (um) é planta. Fonte: Autor (2023).

Conforme observado na Figura 7, a classificação resulta em dois rótulos diferentes: 1 (um) e 2 (dois). O rótulo 1 (um) é atribuído a áreas identificadas como solo ou palha, enquanto o rótulo 2 (dois) é associado a áreas de planta ou vegetação. Assim pode-se notar nos pontos da imagem em que aparenta a classe 2 (planta), identifica-se com maior nitidez onde ocorreu as falhas e também rastro de amassamento nas plantas. Esse tipo de classificação binária é útil para distinguir e mapear diferentes tipos de cobertura do solo, permitindo uma análise mais precisa das características da paisagem.

Portanto, a combinação do algoritmo *Random Forest* com a classificação binária em que 1 (solo/palha) e 2 (planta) oferece uma abordagem sólida para identificar e mapear as áreas de interesse em imagens de sensoriamento remoto.




FIGURA 7. Classificação da imagem pelo Dzetsaka (*Randon Forest*), sendo que 1 (um) é solo ou palha e 2 (dois) é planta/vegetação. Fonte: Autor (2023).

Na Tabela 6 fica evidente que o método de limiarização utilizando Min/Max se identifica melhor com o método Dzetsaka. Ao olhar para as áreas específicas das classes, há diferenças entre os dois métodos. No caso da classe "Vegetação", o método Dzetsaka atribui uma área de 14,09 ha, enquanto o método LB Min/Max atribui uma área ligeiramente menor de 13,58 hectares. Isso sugere que o método Dzetsaka identificou uma área um pouco maior como vegetação em comparação com o método LB Min/Max.

TABELA 6. Áreas calculadas (ha) por classe e algoritmo das Figuras 6 e 7.

Classificador	Dzetsaka		Limiarização		
	Randon Forest	Max/min	Quantil	M2x	M3x
Vegetação	14,09	13,58	10,96	11,24	13,04
Solo/Palha	0,41	0,92	3,54	3,26	1,46
Total (ha)	14,50	14,50	14,50	14,50	14,50

Fonte: Autor (2023).

Para a classe "Solo/Palha", o método Dzetsaka atribui uma área de 0,41 hectares, enquanto o método LB Min/Max atribui uma área um pouco maior de 0,92 hectares. Isso indica

que o método Dzetsaka identificou uma área menor como solo/palha em comparação com o método LB Min/Max.

Pinto et al. (2019) em sua pesquisa concluíram que os índices de vegetação possuem grande potencial no que se diz respeito ao monitoramento de queimadas e desmatamentos no Cerrado brasileiro. A partir deles é possível detectar, separar e quantificar com maior precisão estas mudanças, o que poderá facilitar e automatizar o aumento e a manutenção das bases de dados existentes para este bioma. Já Sant’Anna e Reis (2015) contradizem e afirmam que os melhores resultados foram obtidos pelo método que estabelece o limiar em função do desvio padrão.

Analisando os valores da Tabela 7, pode-se observar o resultado do valor do Kappa e acerto global da relação Randon Forest com a limiarização.

TABELA 7. Valor do Kappa e acerto global da relação Randon Forest com a limiarização.

Classificador	Dzetsaka		Limiarização		
	<i>Randon Forest</i>	Max/min	Quantil	M2x	M3x
Kappa	1,00	0,015	0,017	0,016	0,018
% acerto	100	48,41	39,73	40,62	46,72

Fonte: Autor (2023).

Os métodos de limiarização (Max/min, Quantil, M2x e M3x) apresentam coeficientes Kappa muito baixos (Tabela 7), indicando baixa concordância com o método Dzetsaka, e porcentagens de acertos globais que variam de 39,73% a 48,41%.

A Tabela 7 fornece informações sobre a concordância e a precisão dos métodos de classificação, destacando a superioridade que a limiarização com máx/min ou três vezes o desvio padrão se mostraram mais adequados. Stehman e Foody (2019) alertam que o limiar de 85% para qualidade de classificação de uso e cobertura do solo não tem status universal, como é usado na maioria dos trabalhos, por que quantificar a precisão destes mapeamentos é uma propriedade difícil de medir e expressar com clareza. Ainda alertam que, por isso, a matriz de erro e as precisões associadas ao usuário, produtor e acurácia geral devem ser os elementos centrais da avaliação da precisão da classificação.

5 CONCLUSÃO

A combinação de índices GLI e RI fornece análise mais consistente e precisa em comparação com a combinação GLI e NGRDI, conforme refletido pelos coeficientes Kappa e pelas porcentagens de acertos.

Considerando os métodos de Limiarização Binária pode se observar que foram eficientes, principalmente máximo/mínimo ou três vezes o desvio padrão quando comparado ao algoritmo Random Forest. Podendo assim identificar com clareza as falhas que ocorreram durante o desenvolvimento vegetal da soja e rastros de amassamento advindos da aplicação de defensivos agrícolas no talhão de estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

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. May, p. 66-75, 2018.

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. **XIII Simpósio Brasileiro de Sensoriamento Remoto**, INPE, Florianópolis - SC. p. 5595-5602, 2007.

BREUNIG, F. M; GALVÃO, L. S.; NETO, R. P. M. Drones na agricultura de precisão. **Drones e Ciência**. Santa Maria – RS, cap. 6, p. 91-110, 2019.

CAMBRAIA-FILHO, D. J. utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do cerrado. **Instituto de Geociências da Universidade de Brasília**. Brasília, 147 p., 2019.

CAPELLI, N.L. **Agricultura de precisão - Novas tecnologias para o processo produtivo**. LIE/ DMAQAG/ FEAGRI/ UNICAMP. 2004. Disponível em: <<http://www.bases.cnptia.embrapa.br>>. Acesso em: 05 ago. 2023.

COHEN, J.A. Coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v.20, p. 37-46, 1960.

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.

DAVIS, G.; CASADY, W.; MASSEY, R. *Precision agriculture: An introduction*. Water quality. University of Missouri System, 1998. P.8. Disponível em: <<http://www.fse.missouri.edu/mpac/pubs/wq0450.pdf>> em 17 jun. 1999. **Introdução à**

agricultura de precisão: conceitos e vantagens. Ciência Rural, v. 32, n. 1, 2002. p. 159-163. Acesso em 05 ago. 2023.

DOERGE, T.A. Management zone concepts. Site-specific management guidelines. 1999. p.4. Disponível em: <<http://www.farmresearch.com/SSMG/ssmg-02/SSMG02.pdf>> em 04 Dez. 1999. **Introdução à agricultura de precisão: conceitos e vantagens. Ciência Rural**, v. 32, n. 1, 2002. p. 159-163.) Acesso em 05 ago. 2023.

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'Academie des Sciences. Serie 2, Mecanique, Physique Chimie, Scinces de l'Univers, Sciences de la Terre**, França, v. 312, 1991.

FRANÇA, L. L. S.; SILVA, L. F. C. F.; SILVA, W. B. Mapping of the spatial-temporal change for vegetation canopy in rough relief areas. **R. bras. Geom.**, Curitiba, v. 5, n. 3, p. 343-360, jul/set. 2017.

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**, 115(9), 2350–2359. <https://doi.org/10.1016/j.rse.2011.04.035>, 2011. Acesso em: 08 jul. 2023.

GANAN, J. R.; ROCHA, J. V.; MERCANTE, E.; ANTUNES, J. F. G. Mapeamento da cultura da soja com imagens Landsat 5/TM utilizando algoritmos de classificação supervisionada. **XII Simpósio Brasileiro de Sensoriamento Remoto**, INPE, Goiânia - GO, p. 549-555, 2005.

GANEM, K. A.; Classificação da Cobertura do Solo na Caatinga a partir de Imagens do Landsat-8 e da Ferramenta Google Earth Engine: uma comparação entre dados com e sem correção atmosférica. **Instituto de Geociências da Universidade de Brasília**. Brasília, 202p., 2017.

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: 05 ago. 2023.

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.

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.

INPE - Instituto Nacional De Pesquisas Espaciais. Coordenação Geral De Observação Da Terra. **Divisão De Sensoriamento Remoto**. 2018. Disponível em: <<http://www.dsr.inpe.br/DSR/areas-de-atuacao/sensores-plataformas/drones>>. Acesso em: 08 ago. 2023.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2. ed. São José dos Campos – SP, Editora Parêntese, 2009.

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

KARASIAK. Dzetsaka: Classification tool, 2016. Disponível em: <https://github.com/nkarasiak/dzetsaka>. Acesso em: 11 nov. 2022.

LEITE, M. E.; ROSA, R. Geografia e geotecnologias no estudo urbano. **Caminhos de Geografia**, v. 17, n. 17, p. 180-186, 2006. Uberlândia, UFU, 2006.

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

MANTOVANI, E. C., D. M. QUEIROZ, e G. P. DIAS. Máquinas e operações utilizadas na agricultura de precisão. **27º Congresso Brasileiro De Engenharia Agrícola**, 1998, Poços de Caldas, MG. Mecanização e agricultura de precisão. Lavras: UFLA/SBEA. p. 109-157., 1998.

MONTEIRO, L. H., Binarização por Otsu e Outras técnicas usadas na Detecção de Placas - **Instituto de Computação – UFF, Niterói**. 2002.

MORAES, E. C. de., Fundamentos De Sensoriamento Remoto. DSR/INPE, 2002. Disponível em: http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf>. Acesso em: 25 jul. 2023.

MOTOHKA, T., NASAHARA, K.N., OGUMA, H., TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, [s.l.], 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. 2022.

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**, [S. l.], v. 6, n. 9, p. 64140–64149, 2020. DOI: 10.34117/bjdv6n9-010. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/view/15976>>. Acesso em: 28 mar. 2023.

OPENDRONEMAP Authors ODM – A command line toolkit to generate maps, point clouds, 3D models and DEMs from drone, balloon or kite images. OpenDroneMap/ODM GitHub Page 2020; Disponível em: <https://github.com/OpenDroneMap/ODM>>. Acesso em: 11 nov. 2022.

ONU - United Nations. Department of Economic and Social Affairs. World Population Prospects, 2019; Disponível em: https://population.un.org/wpp/Publications/Files/wpp2019_10KeyFindings.pdf>. Acesso em: 28 de março de 2023.

PASSOS, B. T. Tipos de aprendizado de máquina: supervisionado e não supervisionado. **Ateliware**, 2021. Disponível em: <<https://ateliware.com/blog/aprendizado-de-maquina-tipos>>. Acesso em: 15 ago 2023.

PINTO, Á. S. A. S.; DE OLIVEIRA SILVEIRA, E. Ma.; GUIMARÃES, T. Avaliação De Índices Espectrais E Do Algoritmo Random Forest Para A Detecção De Mudanças Da Cobertura Do Solo No Cerrado Brasileiro. **XIX Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Santos-SP, 2019.

PUSCH, M.; MACHADO, T.P.; AMARAL, L.R. Introdução a Agricultura de Precisão, 03/2019. **UNICAMP**, Campinas - SP. Disponível em: <www.feagri.unicamp.br/gitap>. Acesso em: 02 ago. 2023.

QGIS: Um Sistema De Informação Geográfica Livre E Aberto. **QGIS Org**, 2022. Disponível em: <https://qgis.org/pt_BR/site>. Acesso em: 11 nov. 2022.

REGHINI, F. L.; CAVICHIOLI, F. A. Utilização De Geoprocessamento Na Agricultura De Precisão. **Revista Interface Tecnológica**, [S. l.], v. 17, n. 1, p. 329–339, 2020. DOI: 10.31510/infa.v17i1.750. Disponível em: <<https://revista.fatectq.edu.br/interfacetecnologica/article/view/750>>. Acesso em: 08 ago. 2023.

REX, F. E.; DALLA CORTE, A. P. Vants: Potenciais Para A Engenharia Florestal. **Dados Internacionais de Catalogação na Publicação (CIP)**, p. 101, 2020.

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

SANT'ANNA, S. J. S.; REIS, M. S. Análise de métodos limiarização para a detecção de mudanças usando dados ótico e de micro-ondas numa região da Amazônia brasileira, **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, 8p., 2015.

SENAR – Serviço Nacional de Aprendizagem Rural. **Agricultura de precisão: operação de drone**. Coleção SENAR ed. 249, Brasília, 84p. 2018. Disponível em: <<https://www.cnabrazil.org.br/assets/arquivos/249-DRONES.pdf>>. Acesso em: 08 ago. 2023.

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

STEHMAN, S. V.; FOODY, G. M. Key issues in rigorous accuracy assessment of land cover products. **Remote Sensing of Environment**. v. 231, 1199, 2019.

TSCHIEDEL, M.; FERREIRA, M. F. Introdução À Agricultura De Precisão: Conceitos E Vantagens. **Ciência Rural**, v. 32, n. 1, p. 159–163, fev. 2002.

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

VALE, J. R. B., DA COSTA, J. A., DOS SANTOS, J. F., DA SILVA, E. L. S., & FAVACHO, A. T. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **InterEspaço: Revista de Geografia e Interdisciplinaridade**, [S. l.], v. 4, n. 13, p. 26-44, 2018. DOI: 10.18764/2446-6549.v4n13p26-44. Disponível em: <<https://periodicoseletronicos.ufma.br/index.php/interespaco/article/view/7884>>. Acesso em: 08 ago. 2023.

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, 61 p., 2021.

VENTURIEIRI, A. Introdução às técnicas de Sensoriamento Remoto. **UFPA**, Belém - PA, 2007.

VIEIRA, D. S. M. Sistema Agroflorestal No Bioma da Caatinga: Caracterização de Gramíneas Forrageiras e índices de vegetação no Visível. **UFRPE**, Serra Talhada- PE, 70p. 2022.

WAN, L.; LI, Y.; CEN, H.; ZHU, J.; YIN, W.; WU, W.; ZHU, H.; SUN, D.; ZHOU, W.; HE, Y. Combining UAV-Based Vegetation Indices and Image Classification to Estimate Flower Number in Oilseed Rape. **Remote Sensing**, v. 10, n. 9, p. 1484, 2018.

WANG, Z. X.; LIU, C.; HUETE, A. From AVHRRNDVI to MODIS-EVI: advances in vegetation index research. **Acta Ecológica Sínica**, v. 23, n. 5, p. 989-988, 2003.