

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS DOIS VIZINHOS**

MATEUS BATTISTELA

**USO DE IMAGENS OBTIDAS POR RPA NA ESTIMATIVA DE PARÂMETROS
AGRONÔMICOS NA CULTURA DO FEIJÃO (*Phaseolus vulgaris*)**

DOIS VIZINHOS

2025

MATEUS BATTISTELA

**USO DE IMAGENS OBTIDAS POR RPA NA ESTIMATIVA DE PARÂMETROS
AGRONÔMICOS NA CULTURA DO FEIJÃO (*Phaseolus vulgaris*)**

**Use of RPA-based imagery to estimate agronomic parameters in common bean
(*Phaseolus vulgaris*) cultivation**

Trabalho de conclusão de curso apresentado à disciplina de Trabalho de conclusão de curso II, do Curso Superior de Agronomia, da Universidade Tecnológica Federal do Paraná, Campus Dois Vizinhos, como requisito parcial para obtenção do Título de Agrônomo

Orientador: Prof. ^a Dra. Alyne Raminelli Siguel Gemin

DOIS VIZINHOS

2025



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

MATEUS BATTISTELA

**USO DE IMAGENS OBTIDAS POR RPA NA ESTIMATIVA DE PARÂMETROS
AGRONÔMICOS NA CULTURA DO FEIJÃO (*Phaseolus vulgaris*)**

Trabalho de conclusão de curso apresentado à disciplina de Trabalho de conclusão de curso II, do Curso Superior de Agronomia, da Universidade Tecnológica Federal do Paraná, Campus Dois Vizinhos, como requisito parcial para obtenção do Título de Agrônomo.

Data de aprovação: 16/Julho/2025

Alyne Raminelli Siguel Gemin
Doutorado em Ciências Geodésicas
Universidade Tecnológica Federal do Paraná

Lucas da Silva Domingues
Doutor em Agronomia
Universidade Tecnológica Federal do Paraná

Fabiane Miranda Das Dores
Doutorado em Ciências Geodésicas
Universidade Tecnológica Federal do Paraná

DOIS VIZINHOS

2025

RESUMO

O feijoeiro (*Phaseolus vulgaris* L.) possui grande relevância socioeconômica no Brasil, que se destaca como o segundo maior produtor mundial da leguminosa. Diante desse cenário, torna-se fundamental buscar estratégias que tornem o manejo da cultura mais eficiente e sustentável. Nesse sentido, o monitoramento aéreo por meio de Aeronaves Remotamente Pilotadas (RPAs) tem se consolidado como uma ferramenta promissora, permitindo a coleta de dados agronômicos de forma rápida, não destrutiva e com alta resolução espacial, o que pode contribuir significativamente para a tomada de decisões no cultivo do feijão. Este estudo avaliou a aplicação de índices espectrais derivados de imagens RGB obtidas com o RPA na estimativa de parâmetros agronômicos da cultura do feijão (*Phaseolus vulgaris* L.), com ênfase na quantificação de clorofila foliar e na medida de cobertura verde para estimativa de produtividade. A pesquisa foi conduzida em área experimental da Universidade Tecnológica Federal do Paraná (UTFPR) – campus Dois Vizinhos. Foram analisados quatro índices espectrais calculados a partir das bandas do visível: *Índice de Folha Verde* (GLI), *Índice de Diferença Verde-Vermelho Normalizado* (NGRDI), *Índice de Verdura Triangular* (TGI) e *Índice Azul-Verde* (BGI). Inicialmente, a variável clorofila, medida com o auxílio de um clorofilômetro digital, foi considerada como parâmetro de referência para verificar se os índices espectrais selecionados poderiam ser utilizados para estimar a clorofila através de imagens aéreas na área. Na sequência, foi incorporada a variável cobertura verde medida por PDI (processamento digital de imagens) para verificar se os dados poderiam ser relacionados com a produtividade. Neste caso, foram 11 tratamentos e 3 repetições, que incluíram aplicações de quatro herbicidas pré-emergentes distintos. As análises estatísticas indicaram ausência de diferenças significativas nos valores de clorofila obtidos em campo com o uso do clorofilômetro digital. De igual modo, a estimativa da cobertura verde por meio de PDI não apresentou diferença estatística. Esses resultados sugerem que o estágio fenológico em que foi realizada a medida da clorofila não foi o mais apropriado para capturar variações representativas entre os tratamentos. Além disso, indicam que, nas condições metodológicas adotadas, os índices espectrais aplicados não foram suficientemente sensíveis para estimar a produtividade.

Palavras-chave: Clorofila; Sensoriamento remoto; Índices RGB; Monitoramento aéreo.

ABSTRACT

The common bean (*Phaseolus vulgaris* L.) holds great socioeconomic importance in Brazil, which stands out as the second largest producer of this legume worldwide. In this context, it is essential to seek strategies that make crop management more efficient and sustainable. Aerial monitoring through Remotely Piloted Aircraft (RPAs) has emerged as a promising tool, enabling rapid, non-destructive, and high spatial resolution collection of agronomic data, which can significantly support decision-making in bean cultivation. This study evaluated the application of spectral indices derived from RGB images obtained using RPA to estimate agronomic parameters in common bean (*Phaseolus vulgaris* L.) crops, with emphasis on the quantification of leaf chlorophyll and the measurement of green cover for yield estimation. The research was conducted in an experimental area at the Federal University of Technology - Paraná (UTFPR), Dois Vizinhos campus. Four spectral indices calculated from the visible bands were analyzed: Green Leaf Index (GLI), Normalized Green-Red Difference Index (NGRDI), Triangular Greenness Index (TGI), and Blue-Green Index (BGI). Initially, the chlorophyll variable, measured with a digital chlorophyll meter, was used as a reference parameter to assess whether the selected spectral indices could estimate chlorophyll from aerial images. Subsequently, the green cover variable, estimated through Digital Image Processing (DIP), was incorporated to evaluate potential correlations with productivity. The experimental design consisted of 11 treatments and 3 replications, which included applications of four different pre-emergent herbicides. Statistical analyses indicated no significant differences in chlorophyll values obtained in the field using the chlorophyll meter. Likewise, the green cover estimated through DIP showed no statistical difference. These results suggest that the phenological stage during which chlorophyll was measured was not ideal for capturing representative variations among treatments. Furthermore, under the adopted methodological conditions, the applied spectral indices were not sufficiently sensitive to estimate crop productivity.

Keywords: Chlorophyll; Remote sensing; RGB indices; Aerial monitoring.

SUMÁRIO

1	INTRODUÇÃO.....	8
2	OBJETIVOS.....	10
2.1	Objetivo Geral.....	10
2.2	Objetivos Específicos.....	10
3	REVISÃO BIBLIOGRÁFICA.....	11
3.1	Feijão.....	11
3.2	Parâmetros Agronômicos.....	12
3.2.1	Teor de Clorofila.....	12
3.2.2	Índice de Área Foliar.....	13
3.3	Sensoriamento Remoto da Vegetação.....	15
3.3.1	RPA.....	16
3.3.2	Índices Espectrais de Vegetação.....	17
4	MATERIAL E MÉTODOS.....	20
4.1	Área de Estudo.....	20
4.2	Planejamento e Execução de Voo com RPA.....	21
4.3	Análise do Clorofilômetro.....	24
4.4	Processamento de Dados.....	27
4.5	Análise Estatística.....	29
5	RESULTADOS E DISCUSSÕES.....	31
6	CONCLUSÃO.....	40
	REFERÊNCIAS.....	41
	APÊNDICE A - Dados da ANOVA dos índices GLI, NGRDI, TGI e BGI.....	48

1 INTRODUÇÃO

A agricultura desempenha um papel fundamental na alimentação da crescente população global e na garantia da segurança alimentar (FAO, 2010). Diante dessa demanda, torna-se essencial aumentar a eficiência produtiva do setor agrícola por meio de tecnologias inovadoras que auxiliem no monitoramento da saúde das plantas, permitindo a detecção precoce de estresses que possam comprometer seu crescimento e rendimento (KOVÁCS e HUSTI, 2018).

Entre essas tecnologias, destacam-se os Sistemas de Aeronaves Remotamente Pilotadas (RPAS), que viabilizam a captação de imagens aéreas de alta resolução e, com isso, proporcionam um manejo mais eficiente e preciso (NÄSI et al., 2015). Tais ferramentas vêm se consolidando como aliadas na agricultura de precisão, ao permitir avaliações detalhadas e rápidas de grandes áreas cultivadas.

Segundo Malavolta *et al.* (1997), os sintomas visuais de deficiência ou toxidez nutricional nas plantas geralmente aparecem apenas após alterações metabólicas irreversíveis, o que implica em perdas de produtividade. Assim, ferramentas que permitam antecipar esse diagnóstico tornam-se indispensáveis no manejo moderno. O uso de RPA para o monitoramento agrícola é uma dessas soluções, possibilitando a visualização e quantificação de padrões que, até então, demandavam tempo e observação direta (GOMES et al., 2019).

Uma das abordagens para analisar a saúde das plantas por meio de imagens é o uso de índices de vegetação, que fornecem informações valiosas sobre o estado nutricional e o desenvolvimento das culturas. Dentre os sensores disponíveis em RPAS, os mais acessíveis capturam imagens nas bandas do espectro visível (RGB), ao passo que modelos mais avançados utilizam sensores multiespectrais. No entanto, estudos têm demonstrado que índices calculados a partir de imagens RGB também apresentam potencial para estimar variáveis agronômicas relevantes.

Dentre as culturas de interesse, o feijoeiro merece destaque por seu elevado valor nutricional, ampla adaptabilidade e importância socioeconômica no Brasil, plantando cerca de 2,5 milhões de toneladas de feijão por ano, sendo considerado o segundo maior produtor mundial (FIORENTINO, J., 2007), e o consumo per capita gira em torno de 17 kg ao ano, evidenciando sua presença significativa na alimentação nacional (BRASIL, 2015).

Considerando sua relevância, torna-se estratégico o desenvolvimento de metodologias que auxiliem na avaliação rápida de características agronômicas dessa cultura. Para este estudo, foram selecionados dois parâmetros: clorofila foliar e cobertura verde (área foliar estimada). A clorofila está diretamente associada à fotossíntese, ao estado nutricional das plantas e ao potencial produtivo, sendo um excelente indicador fisiológico (LACERDA, E.; NEVES, D. H. M.; ROCHA, D. M. S., 2020). Já a cobertura vegetal reflete a interceptação de luz, o crescimento vegetativo e a capacidade de acúmulo de biomassa, sendo fortemente relacionada ao rendimento final (KIM, Y.; JEONG, J.; SHIN, Y.; HAN, D, 2019).

Neste contexto, o presente estudo teve como objetivo avaliar a aplicabilidade de quatro índices espectrais extraídos de imagens RGB: GLI (LOUHAICHI et al., 2001), o BGI (ZARCO-TEJADA, 2005), o NGRDI (TUCKER, 1979) e o TGI (HUNT JR. et al., 2011) na estimativa da clorofila e cobertura verde na cultura do feijão (*Phaseolus vulgaris* L.).

2 OBJETIVOS

2.1 Objetivo Geral

Avaliar a aplicação de índices espectrais obtidos a partir de imagens RGB capturadas por RPA no monitoramento da cultura do feijão, com foco na estimativa indireta da clorofila foliar e cobertura verde.

2.2 Objetivos Específicos

- Quantificar a clorofila de plantas de feijão em 11 tratamentos e 3 repetições com clorofilômetro.
- Avaliar a correlação da clorofila com a resposta espectral obtida pelos índices GLI, BGI, TGI e NGRDI;
- Aplicar uma metodologia por PDI para medir a cobertura verde de plantas de feijão;
- Analisar o desempenho de diferentes índices espectrais RGB na estimativa de cobertura verde na cultura do feijão por meio da correlação com a produtividade.

3 REVISÃO BIBLIOGRÁFICA

3.1 Feijão

No gênero *Phaseolus*, o feijão comum (*Phaseolus vulgaris* L.) é a espécie mais cultivada em todo o mundo e é a segunda leguminosa mais significativa na dieta global (SANTOS, 2019). O feijão desempenha um papel fundamental na alimentação diária dos brasileiros, já que seus grãos são uma importante fonte de proteínas, carboidratos e ferro (DERAL, 2017).

O feijão tem grande potencial produtivo, porém, sua produtividade é considerada baixa. Isso devido ao pouco investimento que pequenos e médios produtores aplicam sobre a cultura, cultivando sobre áreas que necessitam de correção e com fatores limitantes para fixação biológica de nutrientes, diminuindo a disponibilidade de nitrogênio na planta e interferindo diretamente na clorofila (CASSINI; FRANCO, 2006).

A absorção de nitrogênio ocorre ao longo de todo o ciclo da cultura, mas a época de maior demanda (quando a velocidade de absorção é máxima) ocorre entre os 35 e 50 dias após a emergência das plantas, coincidindo com o período de florescimento. Durante esse intervalo, as plantas absorvem cerca de 2,0 a 2,5 quilogramas de nitrogênio por hectare por dia (ROSELEM; MARUBAYASHI, 1994).

Conhecer o estado nutricional das plantas é essencial para a tomada de decisões no manejo da lavoura, principalmente no que se refere à adubação e ao uso eficiente de insumos (HE et al., 2022). Tradicionalmente, essa avaliação pode ser feita por meio de análise foliar em laboratório, uso de clorofilômetros portáteis ou pela simples observação visual de sintomas (CULTIVAR, 2022). Contudo, essas técnicas podem ser demoradas, invasivas ou pouco representativas da variabilidade existente dentro de grandes áreas cultivadas (MUÑOZ-HUERTA, R. F. et al., 2013).

O uso de RPA na agricultura permite a geração de dados que podem ser processados para obtenção de índices de vegetação capazes de estimar variáveis fisiológicas das plantas, como o teor de clorofila foliar. No caso do feijoeiro, essa estimativa pode fornecer informações importantes sobre o estado nutricional e o desempenho fotossintético das plantas, tornando possível identificar variações dentro da lavoura e aplicar manejos localizados, promovendo o uso racional de insumos, a otimização da produtividade e a redução de impactos ambientais. Segundo Yang e Anderson (1999), essa abordagem contribui para a agricultura de

precisão ao permitir decisões baseadas em informações específicas de cada unidade de manejo.

3.2 Parâmetros Agronômicos

Os parâmetros agronômicos são variáveis biofísicas relacionadas às propriedades fisiológicas específicas da vegetação. Entre esses parâmetros estão a biomassa, a porcentagem de cobertura vegetal, a área foliar e a radiação fotossinteticamente ativa absorvida (BATISTA et al., 2013).

Estudar e compreender a correlação entre os fatores biofísicos das culturas e sua resposta espectral pode contribuir de forma eficaz para o uso de imagens de alta resolução espacial no cadastro das culturas, além de auxiliar os métodos atuais de previsão e monitoramento de safras (RAMIREZ et al., 2010).

A cobertura vegetal foi escolhida neste estudo por refletir diretamente o desenvolvimento vegetativo da planta, sua capacidade de interceptar luz e sua relação com a produtividade, sendo considerada uma variável-chave na modelagem do crescimento e no planejamento agrícola (FERREIRA et al., 2017).

Já a clorofila foliar foi selecionada por ser um indicador fisiológico diretamente relacionado à fotossíntese, ao estado nutricional e à eficiência no uso do nitrogênio, sendo amplamente utilizada como variável para monitoramento remoto de lavouras (PADILLA et al., 2014).

3.2.1 Teor de Clorofila

No processo de fotossíntese, as clorofilas desempenham um papel crucial, pois são os componentes responsáveis por absorver a luz e, quando combinadas com os fotossistemas na etapa fotoquímica da fotossíntese, impulsionam a geração de ATP e NADPH na cadeia de transporte de elétrons. Essas substâncias são posteriormente empregadas na assimilação do dióxido de carbono (CO₂) (TAIZ; ZEIGER, 2013).

A clorofila é o pigmento predominante nas folhas verdes e sua quantificação é um indicador importante da saúde das plantas, sendo capaz de revelar deficiências de nitrogênio, condições de estresse hídrico e presença de certas doenças (ZARCO-TEJADA et al. 2004).

A avaliação da quantidade de clorofila presente nas folhas é uma técnica amplamente utilizada na agricultura para monitorar o progresso das plantas, fornecendo dados importantes sobre a saúde das plantas, os níveis de nitrogênio nas folhas e a capacidade de realizar a fotossíntese das plantas (RICCARDI et al., 2014; YANG et al., 2015).

As técnicas convencionais de medição da clorofila por meio de métodos laboratoriais são precisas, mas apresentam desvantagens como alto custo, longo tempo de processamento e inviabilidade de estudos em grande escala (CORTAZAR et al., 2015). Além disso, essas medições tradicionais, por serem destrutivas para as folhas, não permitem o monitoramento das mudanças nos pigmentos em folhas individuais. Como alternativa, os cientistas têm desenvolvido métodos ópticos rápidos e convenientes para medir a clorofila foliar, aproveitando as propriedades de absorção de luz (LIU, P. et al, 2018).

Entre os dispositivos mais recentes, o ClorofiLOG® utiliza fotodiodos emissores em três comprimentos de onda: dois sinais são emitidos e captados dentro da faixa do vermelho, próximos aos picos de cada tipo de clorofila ($\lambda = 635$ e 660 nm), e um no infravermelho próximo ($\lambda = 880$ nm). Dessa forma, um sensor inferior capta a radiação transmitida pela estrutura foliar e, a partir desses dados, o aparelho fornece valores chamados de índice de clorofila Falker (ICF), que são proporcionais à absorbância das clorofilas (FALKER, 2008).

Para medir o teor de clorofila, as folhas das plantas são posicionadas entre o emissor e o receptor do equipamento, permitindo que a radiação transmitida através da folha seja convertida em sinais eletrônicos (BOECHAT, 2012).

Alguns estudos mostram o uso de imagens digitais, uma abordagem não invasiva de avaliação em que as características obtidas por meio do Processamento Digital de Imagens (PDI) oferecem parâmetros que ajudam no diagnóstico da clorofila (LEE; LEE, 2013; WANG et al., 2013).

3.2.2 Índice de Área Foliar

Além da clorofila, que atua diretamente no desempenho fotossintético das plantas, outro parâmetro agrônômico de grande importância é a área foliar, pois está relacionada à superfície disponível para interceptação da luz e, conseqüentemente, à capacidade de síntese de compostos orgânicos (SHEN, X.; WANG, X.; YOU, J.; et al., 2012). A associação entre o teor de clorofila e a expansão foliar oferece uma

visão mais completa sobre o estado fisiológico e nutricional da planta, sendo especialmente útil em estudos que envolvem estimativas de produtividade (SHEN, X.; WANG, X.; YOU, J.; et al., 2012).

A área foliar é um parâmetro fundamental no desenvolvimento do feijoeiro, pois está diretamente relacionada à capacidade fotossintética da planta. As folhas são os principais órgãos responsáveis pela interceptação da radiação solar e pela conversão da energia luminosa em compostos orgânicos, processo essencial para o crescimento e a produtividade da cultura (EMBRAPA, 2023).

O índice de área foliar (IAF), que representa a relação entre a área total de folhas e a área de solo ocupada, é amplamente utilizado para avaliar a eficiência fotossintética das plantas. No feijoeiro, valores ótimos de IAF situam-se entre 3,0 e 4,5, especialmente durante o início do período reprodutivo, fase em que a planta necessita maximizar a interceptação de radiação solar para sustentar a formação de vagens e o enchimento de grãos (EMBRAPA, 2023).

A área foliar no feijoeiro é influenciada por diversos fatores, como o genótipo, as condições ambientais e as práticas de manejo. Estudos demonstram que cultivares com maior responsividade à adubação mineral apresentam maior número de folhas e área foliar quando submetidos a doses adequadas de nutrientes, refletindo em maior acúmulo de biomassa e potencial produtivo. Por outro lado, cultivares menos responsivos mostram menor expansão foliar sob as mesmas condições, evidenciando a importância da escolha do material genético e do manejo nutricional para otimizar o desenvolvimento da área foliar (SILVA, J. H. B. da et al., 2023).

A medição da área foliar pode ser realizada por métodos diretos, como o uso de planímetros ou escaneamento de folhas, ou por métodos indiretos, utilizando equações baseadas em medidas lineares das folhas, como comprimento e largura (ZAFFARONI, E., 2001). Essa última abordagem tem ganhado destaque na agricultura de precisão, permitindo a estimativa da área foliar a partir de imagens obtidas por RPA equipadas com sensores ópticos. Índices de vegetação derivados dessas imagens, como NDVI, GLI e TGI, têm sido utilizados com sucesso para inferir características morfofisiológicas das plantas, como a área foliar e o teor de clorofila (ZAFFARONI, E., 2001).

Portanto, a área foliar é um atributo agrônomo fundamental para o feijoeiro, pois influencia diretamente o rendimento e a eficiência de uso de recursos como luz, água e nutrientes (EMBRAPA, 2023).

3.3 Sensoriamento Remoto da Vegetação

O sensoriamento remoto (SR), segundo Meneses e Almeida (2012), é definido como uma técnica de obtenção de imagens dos objetos da superfície terrestre sem contato físico direto entre o sensor e o alvo. Essa tecnologia surgiu como resposta ao avanço dos dispositivos capazes de registrar imagens em larga escala a partir de plataformas posicionadas a certa distância da superfície, revolucionando a forma como se acessam informações ambientais (MENESES; ALMEIDA, 2012).

A base do sensoriamento remoto está na captação da radiação eletromagnética emitida ou refletida pelos objetos. Todo corpo com temperatura acima do zero absoluto ($-273,15\text{ }^{\circ}\text{C}$) emite radiação devido à movimentação de suas partículas, e essa radiação pode ser detectada por sensores, possibilitando a geração de dados mesmo sem contato físico direto com o objeto (MENESES; ALMEIDA, 2012).

Esses dados podem ser coletados a partir de diferentes níveis de observação: orbital, suborbital ou terrestre. O nível orbital corresponde aos sensores instalados em satélites. O suborbital envolve sensores embarcados em aeronaves tripuladas ou não tripuladas (como RPAs), permitindo alcançar resoluções espaciais centimétricas. Já o nível terrestre compreende sensores ópticos acoplados a plataformas no solo, como tratores ou mesmo operados manualmente (ALMEIDA; CARNEIRO, 2019).

O sensoriamento remoto tem se destacado como uma das ferramentas mais eficientes na coleta de dados com alto nível de detalhamento em grandes áreas, aliando precisão, rapidez e custo-benefício. Essa tecnologia permite o monitoramento em tempo real, o que é especialmente valioso na agricultura (FORMAGGIO; SANCHES, 2017).

A aplicação de sensores via sensoriamento remoto tem ampliado significativamente o potencial de avaliação das condições das culturas, permitindo desde o diagnóstico nutricional até a previsão de safras. Além disso, auxilia diretamente na tomada de decisão para o manejo de fertilizantes, controle de pragas, doenças e outras práticas agrônomicas (FORMAGGIO; SANCHES, 2017).

Além das plataformas orbital e terrestre, os sistemas suborbital, especialmente os RPAs, têm ganhado destaque por suas vantagens em precisão, flexibilidade operacional e resolução espacial centimétrica, superando limitações dos satélites, como cobertura temporal inflexível e baixa resolução, devido os sensores terrestres serem menos práticos para grandes áreas (XIANG, T.-Z.; XIA, G.-S.; ZHANG, LI., 2018). De fato, o uso de RPAs permite aquisição de imagens sob demanda e detalhadas, possibilitando monitoramento mais ágil e preciso de áreas agrícolas, além de suportar integração com sensores multiespectrais ou RGB, o que eleva significativamente o potencial de avaliação de parâmetros fisiológicos, fitossanitários e produtivos das culturas (TSOUROS et al., 2019) .


3.3.1 RPA

Uma Aeronave Remotamente Pilotada segundo a Agência Nacional de Aviação Civil (ANAC), tem esse nome devido seu modo de operação se ausentar de um piloto a bordo, porém a aeronave é controlada a partir de uma interface, por exemplo, um computador, dispositivo digital, controle remoto e entre outros.

Atualmente, os RPAS são divididos em duas categorias principais: Asa Fixa e Asa Rotativa (JU, C.; SON, H., 2018). A categoria asa fixa é equipada com asas, trazendo uma maior autonomia de voo, operando em maiores áreas. Porém, como desvantagem, necessita de uma pista para decolagem e pouso, precisam estar em movimento constante e não conseguem permanecer estacionários durante o voo. O asa rotativa possui capacidade de decolar e pousar na vertical, o que facilita a fotogrametria terrestre (SOUSA, 2017), porém apresentam baixo tempo de voo devido as baterias utilizadas nesse modelo (JU & SON, 2018).

Independentemente do tipo de RPA utilizado, uma variedade de sensores podem ser acoplados aos RPAS, possibilitando diferentes finalidades. Conforme Gonzales e Woods (2001), entre os sensores disponíveis estão as câmeras digitais comuns (RGB), que capturam o espectro de luz visível, incluindo as cores vermelha, verde e azul. Além disso, há câmeras multiespectrais personalizadas que capturam três ou quatro faixas além do espectro visível, e sensores hiperespectrais, que são capazes de capturar todo o espectro eletromagnético de luz (Figura 1).

Figura 1 – Espectro eletromagnético



Fonte: Toda Matéria (2024)

Além da variedade de sensores que podem ser acoplados a RPAs, a informação capturada por essas plataformas ganha verdadeiro valor ao ser convertida em índices espectrais de vegetação, ferramentas essenciais para estimar variáveis como cobertura vegetal e conteúdo de clorofila. Esses índices derivados de imagens RGB e multiespectrais, têm sido amplamente empregados em sensores embarcados em RPAs para monitorar a saúde das plantas e prever rendimento agrícola (YEOM et al., 2019). A adoção dessas métricas permite análise rápida, quantitativa e sensível de parâmetros morfofisiológicos, superando métodos tradicionais em custo-benefício e oferecendo robustez para suportar decisões técnicas precisas na agricultura de precisão (REHMAN; LUNDY; LINQUIST, 2022).

3.3.2 Índices Espectrais de Vegetação

Os índices de vegetação são cálculos matemáticos realizados nos pixels de imagens que permitem a análise das características espectrais da vegetação, tanto em ecossistemas naturais quanto em áreas agrícolas (FRANCISCO; RUIZ, 2020).

Há uma crescente necessidade de empregar o sensoriamento remoto com índices de vegetação para acompanhar fenômenos e objetos em constante mudança. Isso se deve ao fato de que essa abordagem permite a coleta de dados em tempo real e intervalos de análise mais curtos reduzem a dependência de métodos de avaliação de campo que exigem trabalho manual extensivo (COSTA; NUNES, 2020).

Os índices de vegetação desempenham um papel essencial no acompanhamento de áreas com vegetação, sendo usados para estimar a área foliar, biomassa, níveis de clorofila e radiação fotossinteticamente ativa (RODRIGUES, B.; RODRIGUES, M., 2017).

Estimar o conteúdo de clorofila nas folhas por meio de espectros de reflectância foliar é um método eficaz e não destrutivo (LIU, P. et al, 2018). Diante disso, um conjunto de índices RGB são comumente usados para estimativa da clorofila: GLI, BGI, TGI e NGRDI.

O índice GLI, segundo Yeom *et al.* (2019) é amplamente utilizado na agricultura de precisão por sua simplicidade de cálculo e forte contraste entre vegetação ativa e fundo do solo, utilizando a diferença ponderada entre os canais verde, vermelho e azul para evidenciar a presença de dossel vegetal, sendo particularmente eficaz em culturas com dossel descontínuo ou baixa densidade foliar. Sua eficácia já foi comprovada em diversas culturas agrícolas por meio de imagens obtidas com RPAs equipados com câmeras RGB (YEOM et al., 2019).

O índice BGI foi selecionado neste estudo por sua sensibilidade à reflectância nas faixas do azul e do verde, que segundo Hunt *et al.* (2013), se mostram úteis para destacar a vegetação em contraste com o solo exposto. Essa resposta espectral é especialmente relevante em lavouras de menor porte, como o feijoeiro. O BGI tem sido utilizado com êxito em estudos que buscam identificar áreas com vegetação ativa a partir de imagens RGB comuns, tornando-se uma alternativa acessível ao uso de sensores multiespectrais (HUNT et al., 2013).

O TGI, segundo Hunt *et al.* (2013) foi desenvolvido especificamente para estimar o teor de clorofila com base na geometria da reflectância nas bandas visíveis, formando um triângulo com os valores do azul, verde e vermelho. Ele é altamente correlacionado ao conteúdo de clorofila foliar e pode ser utilizado em imagens obtidas com câmeras RGB convencionais, o que o torna uma ferramenta prática e de baixo custo. Por essa razão, o TGI tem se consolidado como um dos principais índices visuais no sensoriamento remoto com RPAs (HUNT et al., 2013).

O NGRDI foi incluído pois segundo Rehman; Lundy; Linqvist. (2022), apresenta forte correlação com a atividade fotossintética, uma vez que compara a reflectância do verde com a do vermelho, este último altamente absorvido pela clorofila e é um índice robusto, de fácil implementação, e com excelente desempenho em imagens RGB. Sua aplicação tem sido validada em estudos que

visam a estimativa de clorofila e cobertura verde em diferentes estágios fenológicos, contribuindo significativamente para o monitoramento do vigor vegetativo (REHMAN; LUNDY; LINQUIST, 2022).

Tabela 1: Índices de vegetação a serem avaliados.

Índice de vegetação	Equação¹	Referências
Índice de Pigmento Azul-Verde (BGI)	B/G	Zarco-Tejada et al. (2005)
Índice de Folha Verde (GLI)	$(2G-R-B)/(2G+R+B)$	Louhaichi, Borman e Johnson (2001)
Índice de Diferença Verde-Vermelho Normalizado (NGRDI)	$(G-R)/(G+R)$	Tucker (1979)
Índice de Verde Triangular (TGI)	$G-0,39*R*0,61*B$	Hunt et al. (2011)

¹R= banda do vermelho; G= banda do verde; B= banda do azul.

Fonte: Autoria Própria (2024)

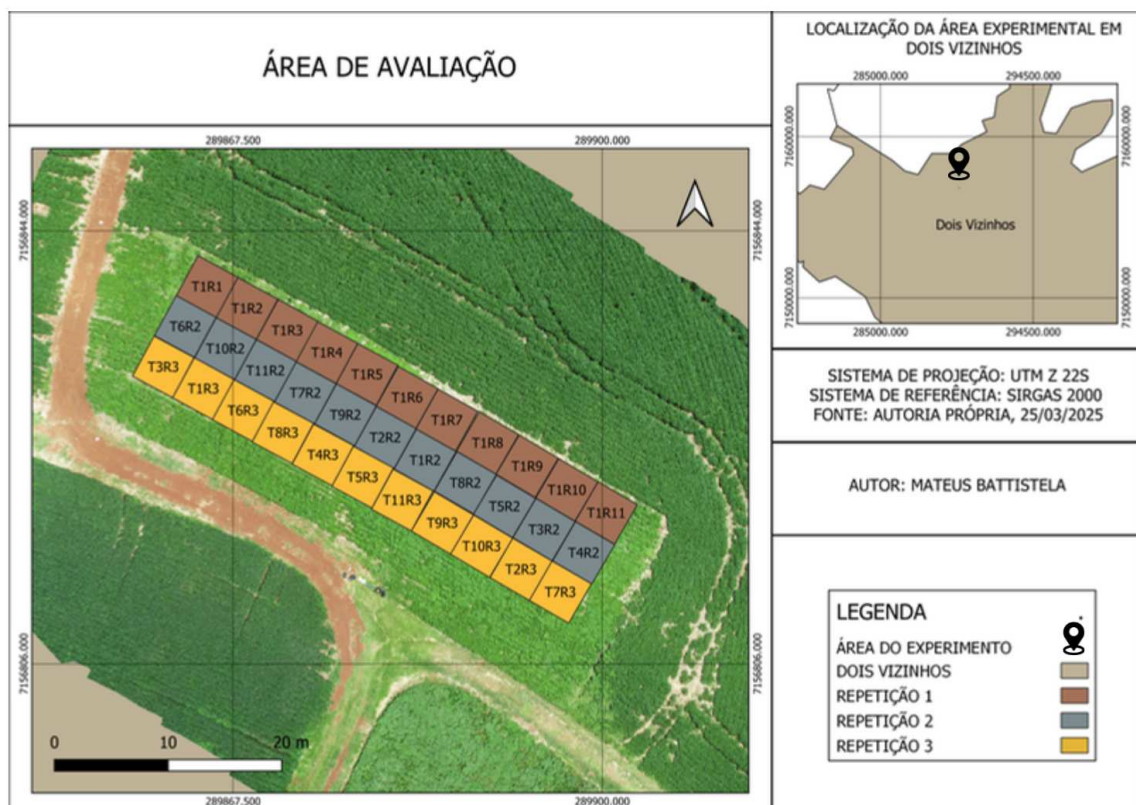
4 MATERIAL E MÉTODOS

4.1 Área de Estudo

A área de estudo foi um experimento de outro autor (PIOVESAN A. M., 2025) conduzido na área experimental da Universidade Tecnológica Federal do Paraná – Campus Dois Vizinhos (25°41'33" S, 53°05'43" W) localizado na região sudoeste do estado. O solo local foi descrito como Latossolo Vermelho (SANTOS et al., 2013) com textura argilosa (773 g kg⁻¹ de argila). O clima da região, segundo a classificação de Köppen, é do tipo Cfa, subtropical úmido, sem estação seca definida (ALVARES et al., 2013).

A cultivar semeada na área de estudo foi a IPR Urutau, no dia 22 de outubro de 2024, com o delineamento experimental de blocos casualizado (DBC), com 33 parcelas de cerca de 16m² (Figura 2), sendo 11 tratamentos e 3 repetições (Tabela 2).

Figura 2 – Croqui da área de avaliação



Fonte: Autoria própria (2025)

Tabela 2 - Descrição dos tratamentos

Tratamento	Descrição	Momento de Aplicação
1	Testemunha absoluta	-
2	Manejo produtor (Bentazona + Fomesafem + haloxifope)	20 DAP
3	Testemunha capinada	Semanalmente
4	Fomesafem + S-Metolacoloro	Aplique e Plante
5	S-Metolacoloro	Aplique e Plante
6	Piroxasulfona + Fluymioxazina	Aplique e Plante
7	Diclosulam	Aplique e Plante
8	Fomesafem + S-Metolacoloro	Plante e Aplique
9	S-Metolacoloro	Plante e Aplique
10	Piroxasulfona + Fluymioxazina	Plante e Aplique
11	Diclosulam	Plante e Aplique

Fonte: Autoria própria (2025)

4.2 Planejamento e Execução de Voo com RPA

Para a obtenção de imagens aéreas da área de estudo foi utilizado o RPA DJI Phantom 4 (Figura 3), com uma câmera RGB com resolução de 12,4 MP. As imagens foram coletadas aos 50 dias após o plantio, quando a cultura estava no estágio R5, correspondente ao início da floração, fase proposta por Rosolem e Marubayashi (1994).

Para a definição dos parâmetros do plano de voo, foi utilizado o software Drone Deploy. Neste, foram definidas a delimitação da área de voo, a altura de voo a 30 metros, a sobreposição lateral e longitudinal de 70%, velocidade de voo de 2m/s e resolução de 1cm por píxel. A altura de voo foi definida a 30m com a intenção de alcançar boa resolução espacial e, conseqüentemente, influenciando em maior detalhamento das imagens capturadas

Figura 3 – Imagem do RPA

Fonte: Aatoria própria (2024)

Durante o voo na área, levou-se em consideração os fatores climáticos, como baixa cobertura de nuvens, com baixa velocidade do vento e próximo às 12:00 horas para não ocorrer sombreamento das plantas a serem avaliadas.

Com o planejamento de voo concluído, foram realizados o levantamento e a marcação dos pontos de controle na área a ser imageada.

Para o levantamento dos pontos de controle, foi utilizado o RTK Spectra SP60® do laboratório de Topografia e Georreferenciamento da UTFPR - Dois Vizinhos. Inicialmente foi instalada a base RTK (figura 4) em uma base de coordenada conhecida. Os pontos de controle levantados com o rover RTK (figura 5) permitiram o georreferenciamento do mosaico de imagens.

O método de levantamento Stop and Go com receptor GNSS RTK foi escolhido neste trabalho por aliar alta precisão no georreferenciamento com maior praticidade em campo, que consiste na coleta de coordenadas em pontos fixos, onde o receptor móvel permanece parado por um curto intervalo de tempo, 120 segundos neste caso, permitindo o registro de dados corrigidos em tempo real com base em uma estação de referência (CASTRO et al., 2020). Essa abordagem é especialmente adequada para delimitação de parcelas experimentais e coleta de pontos de controle para ortorretificação de imagens obtidas por RPAs, pois oferece precisão centimétrica sem demandar o tempo ou infraestrutura de um levantamento estático completo (CASTRO et al., 2020). Além disso, o método Stop and Go reduz significativamente o tempo de trabalho de campo em relação a outras técnicas de

posicionamento geodésico, mantendo a acurácia necessária para aplicações em sensoriamento remoto agrícola (NANNI; GENOVESE; RODRIGUES, 2011).


Foram coletados seis pontos de controle georreferenciados com RTK, distribuídos estrategicamente na área de estudo para garantir maior precisão no georreferenciamento das imagens obtidas por RPA. Quatro desses pontos foram posicionados nos cantos da área experimental, com o objetivo de corrigir eventuais distorções nas bordas das imagens. Os dois pontos adicionais foram inseridos nas laterais, próximos ao centro, a fim de reforçar o controle posicional em regiões intermediárias e aumentar a acurácia do modelo gerado. Essa configuração é amplamente recomendada para garantir estabilidade geométrica durante o processo de ortorretificação e para melhorar a fidelidade espacial em todo o mosaico de imagens (KARPINA et al., 2019; WANG et al., 2021).

Figura 4 - Base RTK



Fonte: Autoria própria (2024)

Figura 5 - Rover RTK



Fonte: Autoria própria (2024)

4.3 Análise do Clorofilômetro

A determinação dos teores de clorofila das plantas de feijão foi realizada por meio não invasivo utilizando o clorofilômetro digital ClorofiLOG® CFL 1030 (Figura 6) da marca Falker®. Para realizar esta análise, direcionou-se o leitor do clorofilômetro próximo ao tecido da folha e iniciou-se a leitura, em alguns segundos se determina o teor da clorofila.

Figura 6 – Clorofilômetro digital ClorofiLOG® CFL 1030



Fonte: Autoria própria (2024)

O índice é calculado com base na absorção de luz em comprimentos de onda característicos da clorofila. O clorofiLOG® mede a quantidade de radiação transmitida através das folhas, de forma óptica, em três diferentes comprimentos de onda (dois na faixa do vermelho, próximos aos picos de absorção da clorofila e um no infravermelho próximo). A combinação destes valores de transmitâncias nestes três comprimentos de onda gera o ICF – Índice de Clorofila Falker (FALKER; 2011).

O clorofiLOG®, assim como todos clorofilômetros eletrônicos, apresenta sua medição com um índice adimensional. Este índice é proporcional a valores medidos em laboratório, como g de clorofila / g de folha ou g de clorofila / área de folha (FALKER; 2011).

Para a mensuração da clorofila foliar, foi realizada uma única leitura por planta, com o objetivo de manter a uniformidade na amostragem e reduzir o tempo de coleta, sem comprometer a representatividade dos dados. A leitura foi realizada na região superior do dossel, considerando que essa é a parte mais exposta à radiação solar e, conseqüentemente, a principal responsável pela atividade fotossintética. Além disso, essa região é a mais visível nas imagens aéreas obtidas

por RPA, o que garante coerência metodológica ao comparar os dados de campo com os índices espectrais calculados por meio do processamento digital de imagens (HABOUSH et al., 2019).

Em cada parcela, foram avaliadas cinco plantas, número considerado suficiente para representar a variabilidade interna de pequenas áreas experimentais, desde que os indivíduos sejam escolhidos com critério. A seleção foi feita de forma aleatória e representativa, priorizando uma planta localizada aproximadamente no centro da parcela e as demais posicionadas em diferentes extremos. Essa estratégia visa capturar possíveis gradientes de variação dentro da parcela, garantindo maior robustez estatística e equilíbrio espacial na amostragem (GONÇALVES et al., 2021).

As plantas estavam no estágio fenológico R5, correspondente ao início da floração, conforme escala proposta por Rosolem e Marubayashi (1994). A coleta dos dados com o clorofilômetro foi realizada simultaneamente à captura das imagens aéreas com o RPA, a fim de evitar variações temporais que pudessem comprometer a correspondência entre os dados espectrais e os teores de clorofila.

Figura 7 – Leitura da clorofila



Fonte: A autoria própria (2024)

4.4 Processamento de Dados

Após a coleta das imagens e das coordenadas dos pontos de controle, realizou-se o processamento no software *Agisoft Metashape Professional*®, fazendo o alinhamento das imagens nos pontos de controle, gerando o Modelo Digital de Elevação e o ortomosaico georreferenciado, que é a base de dados para o processamento dos índices espectrais (Figura 8).

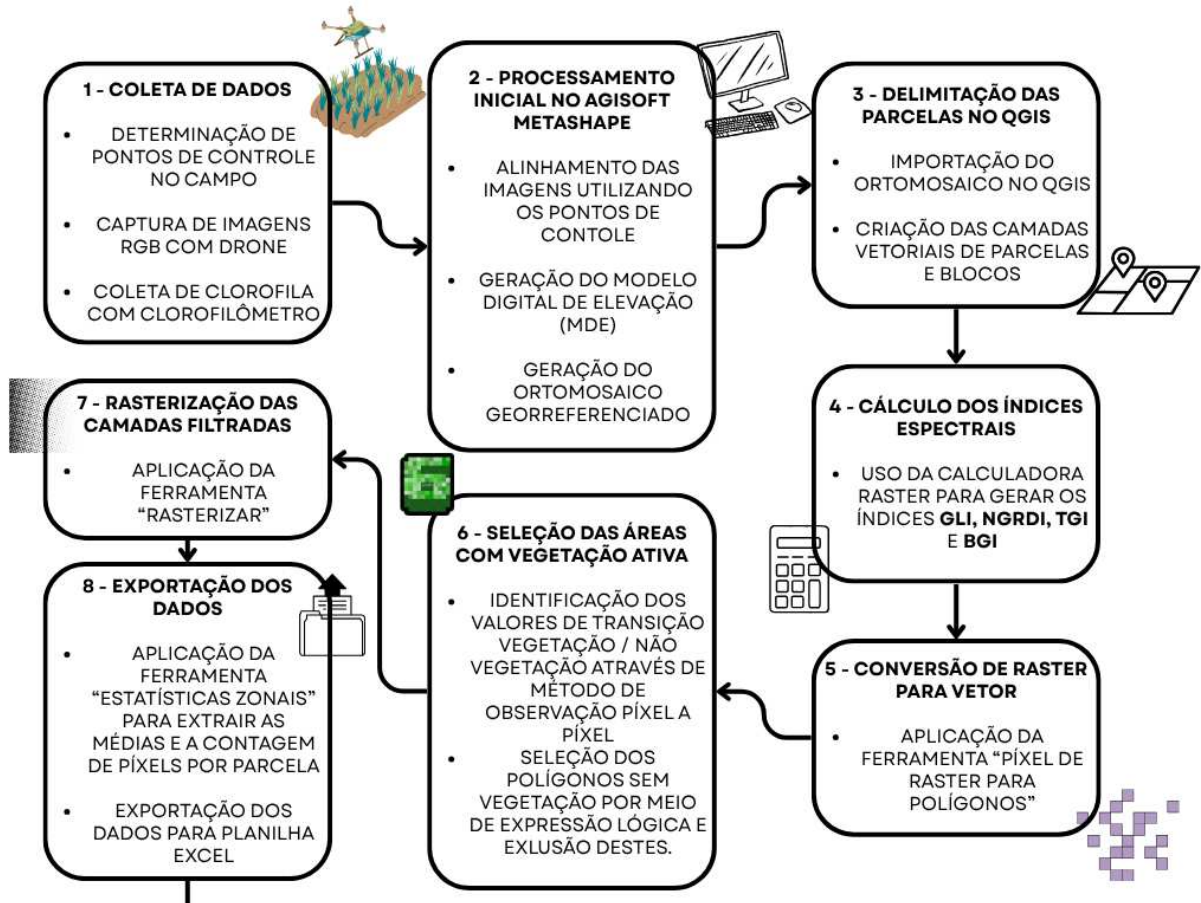
Para realizar o processamento digital das imagens e calcular os índices espectrais de interesse, utilizou-se o software *QGIS*® versão 3.10.5 A Coruña. Para facilitar a compreensão de toda a metodologia aplicada é possível analisar a Figura 9.

Figura 8 - Ortomosaico georreferenciado



Fonte: Autoria própria (2025)

Figura 9 - Fluxograma do passo a passo da metodologia



Fonte: Autoria própria (2025)

Após o processamento inicial das imagens e a geração do ortomosaico, foi realizado o recorte da área correspondente a cada unidade experimental. A delimitação das parcelas experimentais nas imagens foi realizada com base na sobreposição visual dos dados geoespaciais e na referência aproximada aos pontos de controle obtidos via RTK. Embora não tenham sido utilizados alvos físicos demarcatórios no campo, a identificação das parcelas foi conduzida com base no conhecimento prévio da distribuição das unidades experimentais e na análise da resposta espectral nas imagens, o que possibilitou sua inferência visual. Em seguida, procedeu-se ao cálculo dos índices espectrais GLI, NGRDI, BGI e TGI por meio da ferramenta "Calculadora Raster" no QGIS, utilizando as expressões específicas para cada índice. Com os rasters resultantes de cada índice já recortados por parcela, aplicou-se a ferramenta "Píxels de Raster para Polígonos", que converteu todos os píxels de cada parcela em polígonos vetoriais dentro de uma mesma camada.

A próxima etapa consistiu na identificação dos valores de transição entre vegetação ativa e áreas sem vegetação, realizada por inspeção visual pixel a pixel. Foram definidos os seguintes limiares: 0,04 para os índices GLI e NGRDI; 0,8 para o BGI; e -9000 para o TGI. Com base nesses valores, utilizou-se a ferramenta “Selecionar por Expressão” para isolar os pixels que representavam áreas sem vegetação. A expressão utilizada foi “VALOR < X” para GLI, NGRDI e TGI, e “VALOR > X” no caso do BGI, por se tratar de um índice com escala invertida.

Após a seleção, os pixels não vegetativos foram excluídos, restando apenas as áreas com presença de vegetação em cada parcela. Esses vetores filtrados foram convertidos novamente em raster por meio da ferramenta “Rasterizar”. Com a nova base raster contendo apenas vegetação ativa, foi aplicada a ferramenta “Estatísticas Zonais”, que permitiu calcular, para cada parcela, a média dos valores dos índices espectrais, utilizada para correlacionar com os valores de clorofila, e a contagem de pixels, visando estimar a cobertura verde em cada unidade experimental.

Para a estimativa da cobertura verde em cada parcela, foi adotado o método de contagem de pixels sobre os segmentos de imagem previamente classificados como vegetação. Calculou-se o total de pixels classificados por parcela e multiplicou-se esse valor pela resolução espacial da imagem, considerando o tamanho de cada pixel em metros quadrados. Dessa forma, obteve-se uma estimativa da área foliar em unidade de superfície, representando a ocupação das plantas no campo com base em dados de sensoriamento remoto. Por fim, os dados extraídos foram exportados para planilhas Excel, a fim de viabilizar as análises estatísticas subsequentes.

4.5 Análise Estatística

Os dados coletados das variáveis clorofila A e cobertura verde estimada foram organizados em planilhas eletrônicas.

As análises estatísticas foram realizadas utilizando o software Rbio®, por meio de análise de variância (ANOVA), considerando o delineamento em blocos casualizados (DBC). Os pressupostos da ANOVA foram avaliados pelos testes de Shapiro-Wilk (normalidade) e O'Neill e Mathews (homogeneidade de variâncias), adotando-se nível de significância de 5% ($\alpha = 0,05$).

Após a análise de variância, foi realizada uma análise de correlação entre os valores de clorofila e os índices espectrais (GLI, NGRDI, TGI e BGI), bem como entre a cobertura verde estimada e os mesmos índices. Para isso, foi utilizada a função =CORREL no software Microsoft Excel®, que calcula o coeficiente de correlação de Pearson (r) entre duas variáveis. Em seguida, foi determinado o coeficiente de determinação (r^2) ao elevar o valor de r ao quadrado, permitindo avaliar a proporção da variabilidade da clorofila ou cobertura verde que pode ser explicada por cada índice espectral. Por fim, foi calculada a média dos valores de r^2 para os 11 tratamentos analisados, bem como o desvio padrão correspondente a cada índice, com o objetivo de avaliar a consistência da resposta espectral ao longo dos diferentes tratamentos.

5 RESULTADOS E DISCUSSÕES

Após análise da variável Clorofila A (Tabela 3), não foram observadas diferenças significativas entre os tratamentos ($p = 0,1548$). O teste de Shapiro-Wilk indicou normalidade dos resíduos ($p = 0,9089$), e o teste de homogeneidade de variâncias (O'Neill e Mathews) confirmou homocedasticidade ($p = 0,3333$), validando os pressupostos da ANOVA.

Tabela 3 – Médias dos tratamentos para a variável clorofila A.

Tratamento	Média de Clorofila A
Testemunha absoluta	45,63
Manejo produtor (Bentazona + Fomesafem + haloxifope)	47,31
Testemunha capinada	47,53
Fomesafem + S-Metolacoloro	46,85
S-Metolacoloro	45,81
Piroxasulfona + Fluymioxazina	47,61
Diclosulam	46,46
Fomesafem + S-Metolacoloro	48,50
S-Metolacoloro	47,29
Piroxasulfona + Fluymioxazina	49,01
Diclosulam	45,71

Fonte: Autoria própria (2025)

A análise de variância dos teores de clorofila foliar indicou ausência de diferenças estatisticamente significativas entre os tratamentos aplicados. Essa uniformidade pode ser explicada por diferentes fatores relacionados ao desenvolvimento fisiológico da cultura no momento da coleta e à capacidade do feijoeiro de suprir suas necessidades nutricionais por meio de processos biológicos.

O uso de herbicidas pré-emergentes nos tratamentos pode não ter causado efeitos fitotóxicos significativos, o que explicaria a ausência de impacto sobre a atividade fotossintética das plantas. Estudo conduzido por Silva et al. (2018) demonstrou que, em determinadas condições, cultivares de feijão apresentam boa tolerância à aplicação de herbicidas em pré-emergência, sem alterações expressivas nos teores de clorofila avaliados por meio de medidores ópticos.

Assim, os dados obtidos sugerem que, nas condições em que o experimento foi conduzido, os tratamentos aplicados não foram suficientes para provocar alterações nos teores de clorofila detectáveis pelo clorofilômetro. Isso ressalta a importância de considerar o momento da coleta, o estágio da cultura e a natureza dos tratamentos ao interpretar os resultados fisiológicos em experimentos agrônômicos.

Os valores de coeficiente de determinação (r^2) obtidos para a correlação entre os índices espectrais RGB e os valores de clorofila demonstram correlações moderadas, com destaque para os índices GLI (0,499) e BGI (0,486), que apresentaram os maiores valores médios. Esses resultados indicam que, em média, cerca de 49,9% (GLI) e 48,6% (BGI) da variação na clorofila medida em campo pode ser explicada pelas respostas espectrais desses índices, o que sugere potencial uso prático, especialmente quando não se dispõe de sensores multiespectrais ou hiperespectrais. A correlação mais baixa foi observada para o NGRDI (0,439).


No entanto, os valores relativamente elevados de desvio padrão (variando de 0,299 a 0,348) apontam para inconsistência na correlação entre os tratamentos, indicando que a resposta dos índices não foi uniforme ao longo das diferentes condições experimentais.

Além disso, mesmo os melhores índices (GLI e BGI) não ultrapassaram 50% de correlação, o que reforça que os índices RGB, apesar de úteis, possuem limitações na estimativa precisa da clorofila, especialmente em estágios fenológicos avançados ou sob cobertura vegetal mais homogênea. Esses achados estão alinhados com estudos como Yeom et al. (2019), que observaram boa correlação dos índices RGB apenas sob condições controladas ou estágios iniciais de desenvolvimento, e Rehman et al. (2022), que recomendam o uso de sensores multiespectrais para maior sensibilidade espectral.

Após o cálculo dos índices espectrais BGI, GLI, NGRDI e TGI, foi possível visualizar, nas Figuras 10, 11, 12 e 13, respectivamente, as áreas cobertas com vegetação ativa, destacadas em diferentes tons de verde. Segundo Louhaichi, Borman e Johnson (2001), cada índice apresenta sensibilidade distinta na detecção da vegetação, em razão das combinações específicas entre as bandas do espectro visível utilizadas em suas fórmulas. Índices baseados em cores visíveis são úteis na diferenciação entre vegetação e solo, especialmente em imagens de alta resolução

obtidas por sensores embarcados em RPAs (LOUHAICHI, BORMAN e JOHNSON, 2001).

Figura 10 – Parcelas com índice BGI



Fonte: Autoria própria - QGis (2025)

Figura 11 – Parcelas com índice GLI




Fonte: Autoria própria - QGis (2025)

Figura 12 – Parcelas com índice NGRDI



Fonte: Autoria própria - QGis (2025)

Figura 13 - Parcelas com índice TGI



Fonte: Autoria própria - QGis (2025)

Observou-se que alguns índices apresentaram maior contraste entre vegetação e solo, o que favorece sua aplicação em processos de segmentação e extração de áreas vegetadas. O índice GLI (Figura 11), por exemplo, costuma destacar melhor a vegetação verde saudável, enquanto o NGRDI (Figura 12) pode apresentar maior sensibilidade a variações na intensidade da luz incidente (CASAL et al., 2020). Essa variação entre os índices justifica a utilização combinada de diferentes métricas espectrais na análise de cobertura vegetal, permitindo a seleção daquele que melhor separa vegetação ativa do solo em cada situação.

No presente estudo, os índices foram utilizados como critério espectral para isolar a vegetação ativa nas imagens, com o objetivo de estimar a cobertura verde de cada parcela. No entanto, os resultados estatísticos indicaram que os valores médios desses índices não apresentaram diferenças significativas entre os tratamentos.

Resultados semelhantes foram relatados por Silva et al. (2024), que avaliaram índices de vegetação obtidos por VANT na cultura do feijão. Embora alguns índices apresentassem boa resposta visual na separação entre vegetação e solo, as correlações com os componentes de rendimento não foram consistentes ao longo do ciclo, indicando que fatores como o estágio fenológico e a homogeneidade do dossel influenciam fortemente a resposta espectral dos índices.

Adicionalmente, uma revisão conduzida por Silva et al. (2019) destacou que índices RGB como GLI, NGRDI e TGI são eficazes para detectar vegetação em imagens aéreas, mas que sua sensibilidade pode ser limitada em condições de estresse, baixa cobertura ou fases tardias do ciclo, especialmente em culturas de porte menor como o feijoeiro. Esses aspectos ajudam a explicar os resultados do presente estudo, nos quais os índices espectrais não diferiram estatisticamente entre os tratamentos avaliados.

Dessa forma, os dados obtidos reforçam a importância de considerar as características da cultura, o estágio de desenvolvimento e o momento da coleta de imagens para garantir maior sensibilidade dos índices espectrais na detecção de variações agronômicas. Além disso, indicam que, em estudos futuros, o uso de sensores multiespectrais ou hiperespectrais podem contribuir para melhorar a acurácia das estimativas.

A Tabela 4 apresenta os resultados das médias dos tratamentos para a cobertura verde em cada parcela medida na imagem. A área foliar é um parâmetro

fisiológico fundamental para a avaliação do desempenho da planta, pois está diretamente relacionada à capacidade de interceptação da radiação solar, à fotossíntese e, conseqüentemente, à produtividade da cultura (EMBRAPA, 2025). Assim, sua mensuração fornece subsídios importantes para o monitoramento do desenvolvimento vegetal em diferentes condições de manejo. O teste de Shapiro-Wilk indicou que os resíduos apresentaram distribuição normal ($p = 0,8401$), e o teste de homogeneidade de variâncias de O'Neill e Mathews confirmou homocedasticidade ($p = 0,5848$), validando a aplicação da ANOVA. O coeficiente de variação (CV) foi de 1,77%, indicando boa precisão experimental. Contudo, não foram observadas diferenças estatísticas significativas entre os tratamentos ($p = 0,283$), sugerindo que a metodologia para a medida de cobertura verde aplicada não foi sensível para identificar as diferenças de produtividade identificadas por Piovesan A. M. (2025).

Tabela 4 – Médias dos tratamentos para a cobertura verde

Tratamento	Média da Cobertura Verde na parcela (m ²)
Testemunha absoluta	15,456
Manejo produtor (Bentazona + Fomesafem + haloxifope)	15,280
Testemunha capinada	15,524
Fomesafem + S-Metolaclo	15,275
S-Metolaclo	15,085
Piroxasulfona + Fluymioxazina	15,558
Diclosulam	15,247
Fomesafem + S-Metolaclo	15,375
S-Metolaclo	15,092
Piroxasulfona + Fluymioxazina	15,259
Diclosulam	15,010

Fonte: Autoria própria (2025)

Santana et al. (2016) observaram que o Índice de Vegetação por Diferença Normalizada (NDVI) saturou-se a partir de 50 dias após a emergência em feijão-comum, limitando sua capacidade de detectar variações na cobertura verde em estádios fenológicos avançados. Isso sugere que, em fases como o início da

floração (R5), os índices espectrais baseados em reflectância podem não ser suficientemente sensíveis para captar diferenças sutis na densidade foliar.

A baixa variabilidade entre os tratamentos pode ter contribuído para a ausência de diferenças significativas na cobertura verde. Em experimentos onde as condições de cultivo são uniformes e os tratamentos não induzem variações marcantes no crescimento vegetativo, é esperado que a cobertura verde não apresente diferenças estatísticas detectáveis (PIMENTEL-GOMES, F., 2009).

Outra possível explicação para a ausência de diferenças significativas entre os tratamentos está relacionada à metodologia utilizada para a estimativa da cobertura verde. Métodos indiretos, como a contagem de pixels a partir de imagens digitais, podem apresentar limitações em termos de acurácia, especialmente quando não são devidamente calibrados para a cultura-alvo. De acordo com Martin et al. (2017), a estimativa da área foliar em feijão por meio de imagens analisadas com o software ImageJ apresentou boa correlação com métodos diretos, mas a precisão dos resultados dependeu fortemente das condições de aquisição das imagens e da parametrização adequada do método. Assim, o uso de imagens RGB sem calibração específica para o feijoeiro pode ter comprometido a sensibilidade do processo, contribuindo para a uniformidade dos dados observados entre os tratamentos.

Considerando que não foram observadas diferenças estatísticas, pode-se sugerir que o intervalo de tempo decorrido entre a aplicação dos herbicidas pré-emergentes e o momento das medidas de campo da clorofila, assim como a obtenção das imagens, não foram ideais. Segundo Rosolem e Marubayashi (1994), os maiores teores de clorofila no feijoeiro ocorrem entre 35 e 50 dias após a emergência, faixa do momento da coleta das imagens, o que pode ter resultado na homogeneidade dos valores de clorofila em campo e inviabilizando a avaliação por imagem. Ressalta-se que a ideia inicial era identificar possíveis variações no teor foliar de pigmentos por imagens em função da resposta fisiológica das plantas aos tratamentos em campo.

Em contraste, Abrahão (2011), ao estudar o feijoeiro com sensores ópticos de baixo custo, encontrou melhor resposta espectral aos 21 dias após a emergência, sugerindo que esse seria o período ideal para detectar diferenças em teores foliares de clorofila, especialmente em condições de campo com sensoriamento remoto.

Outro fator que pode ter limitado os resultados foi o tipo de sensor utilizado. Neste estudo, a captação das imagens foi realizada com câmera RGB embarcada em drone, a qual apresenta restrições quanto à sensibilidade espectral em relação a sensores hiperespectrais ou ao menos com faixa no infravermelho próximo (NIR). A utilização de sensores mais sensíveis, como os hiperespectrais, poderia ter favorecido a discriminação de teores de clorofila entre os tratamentos. Dessa forma, os resultados obtidos não invalidam a metodologia, mas apontam limitações práticas relacionadas ao momento da coleta e à tecnologia empregada.

O estudo de Epiphanyo e Formaggio (2000) demonstrou que dados espectrais de sensores orbitais, como o TM/Landsat-S, podem ser utilizados para estimar parâmetros agronômicos, incluindo a densidade de clorofila, em culturas como o feijão. No entanto, a eficácia desses sensores depende da correção dos efeitos radiométricos e atmosféricos, bem como da consideração das condições ambientais no momento da coleta das imagens.

Os resultados da análise de correlação indicam que os índices espectrais calculados a partir de imagens RGB apresentaram bons níveis de associação com a cobertura verde estimada por PDI. O índice que obteve o melhor desempenho médio foi o NGRDI ($r^2 = 0,709$), seguido pelo TGI ($r^2 = 0,636$), GLI ($r^2 = 0,579$) e BGI ($r^2 = 0,577$). Esses valores sugerem que, em média, mais de 70% da variação da cobertura vegetal pode ser explicada pelo NGRDI, tornando-o o índice mais promissor dentro deste contexto experimental.

O bom desempenho do NGRDI pode ser atribuído à sua sensibilidade ao contraste entre o verde e o vermelho, o que facilita a detecção de vegetação ativa sobre o fundo do solo, especialmente em estágios com maior desenvolvimento vegetativo. Já o TGI, que também apresentou correlação expressiva, é um índice geométrico derivado do balanço entre as três bandas RGB, sendo especialmente eficaz para capturar a intensidade de verde nas imagens, fator diretamente associado à densidade foliar e à interceptação luminosa.

Apesar de o GLI e o BGI apresentarem valores de r^2 ligeiramente menores, seus resultados ainda indicam correlação moderada a forte, mostrando-se úteis para estimativas preliminares de cobertura verde, principalmente em condições onde sensores mais avançados não estão disponíveis.

No entanto, assim como observado na análise da clorofila, os valores de desvio padrão entre os tratamentos foram relativamente altos (variando de 0,273 a

0,344), o que indica certa instabilidade na resposta dos índices ao longo dos diferentes tratamentos. Essa variabilidade, segundo Aboutaleb, M. *et al.* (2019), pode ter origem em fatores como sombreamento ou pequenas imprecisões na delimitação das parcelas, o que reforça a importância de padronizações rigorosas no processo de aquisição e segmentação das imagens.

De maneira geral, os resultados obtidos nesta etapa indicam que os índices espectrais RGB, especialmente o NGRDI e o TGI, possuem boa capacidade de estimar a cobertura verde em lavouras de feijão com base em imagens aéreas, e podem ser utilizados em projetos de agricultura de precisão voltados ao monitoramento não destrutivo de atributos vegetativos.

6 CONCLUSÃO

O presente trabalho teve como objetivo avaliar a aplicação de índices espectrais derivados de imagens RGB obtidas por Aeronave Remotamente Pilotada (RPA) no monitoramento da cultura do feijão, com foco na estimativa indireta da clorofila foliar e da cobertura verde. Para isso, foi realizada a coleta de dados em uma área experimental com 11 tratamentos e 3 repetições, utilizando clorofilômetro para a mensuração da clorofila e imagens aéreas para o processamento digital de índices espectrais (GLI, BGI, TGI e NGRDI).

Os resultados obtidos indicaram que não houve diferenças estatisticamente significativas entre os tratamentos quanto aos teores de clorofila medidos a campo. A ausência de diferenças pode estar relacionada ao intervalo de tempo decorrido entre a aplicação dos tratamentos e a realização das coletas, o que pode ter favorecido a homogeneização das respostas fisiológicas entre as plantas. Com o avançar do ciclo da cultura, especialmente após o estabelecimento do dossel e a estabilização da absorção de nutrientes, as diferenças iniciais entre os tratamentos tendem a se atenuar, dificultando a detecção de contrastes significativos por meio de avaliações pontuais.

Com relação à estimativa da cobertura verde, foi aplicada uma metodologia utilizando PDI, baseada na separação de pixels de vegetação ativa nas imagens obtidas por RPA. Apesar da boa precisão experimental ($CV = 1,77\%$), os resultados da ANOVA não indicaram diferenças significativas entre os tratamentos. Essa homogeneidade pode estar relacionada à baixa sensibilidade dos índices RGB em fases mais avançadas da cultura ou a uniformidade do desenvolvimento vegetativo nas parcelas.

De modo geral, a metodologia desenvolvida demonstrou ser funcional para extração de parâmetros morfofisiológicos do feijoeiro a partir de imagens RGB, mas os resultados sugerem que sua aplicação prática pode ser limitada por fatores como o estágio fenológico, a escolha do sensor e as condições experimentais. Portanto, para aprimorar a detecção de diferenças nos teores de clorofila e cobertura verde por meio de sensoriamento remoto, é fundamental considerar o momento adequado para a coleta das imagens, preferencialmente em fases em que as variações fisiológicas entre os tratamentos sejam mais evidentes, além de explorar sensores com maior resolução espectral, como os multiespectrais e hiperespectrais.

REFERÊNCIAS

- ABOUTALEBI, M.; TORRES-RUA, A. F.; KUSTAS, W. P.; NIETO, R.; COOPMANS, C.; McKEE, M. **Assessment of different methods for shadow detection in high-resolution optical imagery and evaluation of shadow impact on calculation of NDVI**. *Irrigation Science*, v. 37, n. 4, p. 407–429, 2019. Disponível em: <<https://doi.org/10.1007/s00271-019-00610-5>>. Acesso em: 27 jun. 2025
- ABRAHÃO, Selma Alves. **Discriminação de classes de teores de nitrogênio e de clorofila foliares e de produtividade do feijoeiro usando sistema de sensoriamento remoto de baixo custo**. 2011. 105 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, 2011. Disponível em: <<https://locus.ufv.br/handle/123456789/2824>>. Acesso em: 30 mai. 2025.
- ALMEIDA, SAMIRA; CARNEIRO, FRANCIELE. **INTRODUÇÃO AO SENSORIAMENTO: SENSORIAMENTO REMOTO NA CULTURA DO AMENDOIM. NOVAS TECNOLOGIAS DA ENGENHARIA PARA APROVEITAMENTO**, p. 60. 2019. Disponível em: <https://www.researchgate.net/profile/Rouverson-Silva/publication/338372238_NOVA_S_TECNOLOGIAS_DA_ENGENHARIA_PARA_APROVEITAMENTO_DO_AMENDOIM/links/5e0f684792851c8364afd6dd/NOVAS-TECNOLOGIAS-DA-ENGENHARIA-PARA-APROVEITAMENTO-DO-AMENDOIM.pdf#page=60>. Acesso em: 4 nov. 2023.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. **Köppen's climate classification map for Brazil**. 2013. Stuttgart, Alemanha: *Meteorologische Zeitschrift*, v.22, p.711-728.
- BATISTA, E.R.; BETTIOL, W.; GHINI, R.; BRAGA, M.R.; SILVA, E.A. **Aumento da concentração atmosférica de CO₂ altera a fotossíntese e acúmulo de biomassa em duas cultivares de Coffea arabica**. XIV Congresso Brasileiro de Fisiologia Vegetal, 2013, Poços de Caldas. Anais, 2013. p. 408-408
- BOECHAT, L.T. **Técnica de sensoriamento remoto na detecção do mofo branco e da mancha-angular no feijoeiro**. 128 f. Tese (Doutorado) – Curso de Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, 2012.
- BRASIL. **Golden Mosaic of Common Beans in Brazil: Management with a Sustainable Approach**. APSnet Features, 2015. Disponível em: <<https://www.apsnet.org/edcenter/apsnetfeatures/Pages/GoldenMosaic.aspx>>. Acesso em: 24 jun. 2025.
- B.T. RODRIGUES, M.T. RODRIGUES, S. CAMPOS, M. CAMPOS, M.B. TARUMOTO. **Possibilidades e métodos de utilização no uso de DRONES/VANTS na agricultura**. In: Associação Amigos da Natureza da Alta Paulista. (pp. 249-269), 2017.
- CASAL, A. et al. **Use of vegetation indices from RGB imagery for estimating green cover in maize under different water regimes**: *Computers and Electronics in Agriculture*, v. 178, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105776>. Acesso em: 5 jun. 2025.

CASSINI, S.T.A; FRANCO, M.C. **Fixação biológica de Nitrogênio**: microbiologia, fatores ambientais e genéticos. In: VIEIRA, C.; PAULA JÚNIOR, T.J.; BORÉM, A. (ed.). Feijão. 2ª edição atualizada – Viçosa: UFV, 2006. p. 143-170.

CASTRO, S. P.; BASTOS, L. F. D.; GUIMARÃES, B. S. **Avaliação da acurácia posicional em levantamentos com RTK stop and go e pós-processado para pontos de apoio fotogramétrico**. *Revista Brasileira de Cartografia*, v. 72, n. 1, p. 155–168, 2020. Disponível em: <<https://www.rbc.ufpe.br/index.php/rbc/article/view/1848>>. Acesso em: 25 jun. 2025.

DERAL, Departamento de Economia Rural. **Feijão - Análise da Conjuntura Agropecuária**, novembro de 2017. Disponível em: <http://www.agricultura.pr.gov.br/arquivos/File/deral/Prognosticos/2018/_feijao_2017_18.pdf>. Acesso em: 04 nov. de 2023.

EMBRAPA. **Fisiologia do feijoeiro**. Agência Embrapa de Informação Tecnológica – Feijão. Empresa Brasileira de Pesquisa Agropecuária, 2023. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/feijao/pre-producao/fisiologia>>. Acesso em: 2 jun. 2025.

EPIPHANIO, J. C. N.; FORMAGGIO, A. R. **Sensoriamento remoto de três parâmetros agronômicos de trigo e feijão**. Embrapa Monitoramento por Satélite, 2000. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/106165/sensoriamento-remoto-de-tres-parametros-agronomicos-de-trigo-e-feijao>>. Acesso em: 31 mai. 2025.

FALKER, Automação agrícola. **Manual do medidor eletrônico de teor de clorofila (ClorofiLOG/CFL 1030)**. Porto Alegre, 2008. 34p. Disponível em: <https://www.falker.com.br/download?product=cfl1030&file=MAN_CFL1030_D.pdf>. Acesso em: 24 jul. de 2024.

FALKER, Base de Informações. **clorofiLOG - CFL1030**. 2011. Disponível em: <<https://www.falker.com.br/base/category/41/10/10/Clorofila/clorofiLOG-CFL1030/#:~:text=Qual%20%C3%A9%20a%20unidade%20de,de%20clorofila%20/%20%C3%A1rea%20de%20folha>>. Acesso em: 04 abr. 2025

FAO. **“Climate-smart” agriculture**: policies, practices and financing for food security, adaptation and mitigation. Rome: FAO, 2010. Disponível em: <https://www.fao.org/fileadmin/user_upload/newsroom/docs/the-hague-conference-fao-paper.pdf>. Acesso em: 25 out. 2023.

FERREIRA, J. R. et al. **Estimativa da cobertura do dossel vegetal em soja utilizando imagens aéreas e regressão por mínimos quadrados parciais**. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 21, n. 5, p. 324–329, 2017. Disponível em: <<https://doi.org/10.1590/1807-1929/agriambi.v21n5p324-329>>. Acesso em: 25 jun. 2025.

FIORENTINO, J. **Nutritional richness of beans**. Unicamp Hoje, 2007. Disponível em: <https://unicamp.br/en/unicamp/unicamp_hoje/ju/novembro2007/ju380pag02.html>. Acesso em: 24 jun. 2025.

FORMAGGIO, ANTONIO ROBERTO; SANCHES, IEDA DEL'ARCO. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017. Disponível em: <<https://books.google.com.br/books?hl=pt-BR&lr=&id=hk88DwAAQBAJ&oi=fnd&pg=PT4&dq=sensoriamento+remoto+na+agricultura&ots=2MinNcZJbt&sig=rBBOLMn3SrpttAaNipG50lcCTHo#v=onepage&q=sensoriamento%20remoto%20na%20agricultura&f=false>>. Acesso em: 10 nov. 2023.

GONÇALVES, A. P.; SILVA, M. A.; FERREIRA, R. C. **Planejamento experimental e representatividade amostral em ensaios agrícolas**. Revista Brasileira de Ciências Agrárias, v. 16, n. 1, e8513, 2021. Disponível em: <<https://doi.org/10.5039/agraria.v16i1a8513>>. Acesso em: 25 jun. 2025.

HABOUSH, H. S.; BAKKER, R. R.; WANG, J. **Estimating chlorophyll concentration from UAV-acquired RGB imagery in leafy crops**. Computers and Electronics in Agriculture, v. 162, p. 803–812, 2019. Disponível em: <<https://doi.org/10.1016/j.compag.2019.05.032>>. Acesso em: 25 jun. 2025.

HE, X. et al. **Estimating chlorophyll content of winter wheat using RGB and multispectral images from unmanned aerial vehicles**. *Journal of Plant Ecology*, [S. l.], v. 15, n. 1, p. 65–78, 2022. Disponível em: <<https://doi.org/10.1093/jpe/rtab088>>. Acesso em: 25 jun. 2025.

HUNT, E. R. Jr. et al. **Remote sensing leaf chlorophyll content using a visible band index**. *International Journal of Applied Earth Observation and Geoinformation*, v. 21, p. 102–112, 2013. Disponível em: <<https://doi.org/10.1016/j.jag.2012.07.020>>. Acesso em: 25 jun. 2025.

JU, C.; SON, H. **Multiple UAV systems for agricultural applications: control, implementation, and evaluation**. *Electronics*, v.7, art.162, 2018. Disponível em: <<https://doi.org/10.3390/electronics7090162>>. Acesso em: 25 out. 2023.

KARPINA, M.; KOPÁČEK, J.; KAPLAN, V. **Accuracy assessment of UAV orthophoto using different number and distribution of ground control points**. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. XLII-2/W13, p. 865–871, 2019. Disponível em: <<https://doi.org/10.5194/isprs-archives-XLII-2-W13-865-2019>>. Acesso em: 25 jun. 2025.

KIM, Y.; JEONG, J.; SHIN, Y.; HAN, D. **Estimation of chlorophyll content in soybean leaves using RGB images**. *Journal of Imaging*, Basel, v. 5, n. 4, p. 108, 2019. Disponível em: <<https://www.mdpi.com/2624-7402/5/4/108>>. Acesso em: 25 jun. 2025.

KOVÁCS, I.; HUSTI, I. **The role of digitalization in the agricultural 4.0—how to connect the industry 4.0 to agriculture?**. Hungarian Agricultural Engineering, n. 33, p. 38-42, 2018.

LACERDA, E.; NEVES, D. H. M.; ROCHA, D. M. S. **Remote sensing applications in agriculture: A review**. Current Research in Environmental Sustainability, v. 2, p. 100058, 2020. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S2666351120300589>>. Acesso em: 25 jun. 2025.

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. **A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms**. Computers and Electronics in Agriculture, New York. (172), (pp 1-13), 2020.

LEE, K.-J.; LEE, B.-W. **Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis**. European Journal of Agronomy, v. 48, p. 57–65, jul 2013. ISSN 11610301. Disponível em:
<<https://linkinghub.elsevier.com/retrieve/pii/S1161030113000294>>. Acesso em: 04 nov. 2023.

LIU, P., SHI, R. & GAO, W. **Estimativa do conteúdo de clorofila nas folhas combinando vários índices espectrais com uma rede neural artificial**. Earth Sci Informe 11 , 147–156 (2018). Disponível em:
<<https://doi.org/10.1007/s12145-017-0319-1>>. Acesso em: 04 nov. 2023.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. **Spatially located platform and aerial photography for documentation of grazing impacts on wheat**. Geocarto International, vol.16, n.1, p. 65-70, 2001. Disponível em:
<<https://doi.org/10.1080/10106040108542184>>. Acesso em: 04 nov. 2023.

MALAVOLTA, E. e VITTI, GODOFREDO CÉSAR e OLIVEIRA, SEBASTIÃO ALBERTO DE. **Avaliação do estado nutricional das plantas: princípios e aplicações**. Piracicaba: POTAFOS, 1997. Acesso em: 25 out. 2023.

MARTIN, T. N. et al. **Uso do software ImageJ na estimativa de área foliar para a cultura do feijão**. *Interciencia*, v. 42, n. 12, p. 844–849, 2017. Disponível em:
<<https://www.interciencia.net/wp-content/uploads/2017/12/843-MARTIN-6.pdf>>. Acesso em: 5 jun. 2025.

MENESES, PAULO ROBERTO; ALMEIDA, T. DE. **Introdução ao processamento de imagens de sensoriamento remoto**. Universidade de Brasília, Brasília, 2012. Disponível em:
<<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 04 nov. 2023.

MUÑOZ-HUERTA, R. F. et al. **A review of methods for sensing the nitrogen status in plants: Advantages, disadvantages and recent advances**. *Sensors*, Basel, v. 13, n. 8, p. 10823–10843, 2013. Disponível em:
<<https://doi.org/10.3390/s130810823>>. Acesso em: 25 jun. 2025.

NANNI, M. R.; GENOVESE, M. M.; RODRIGUES, D. B. **Aplicações de geotecnologias em agricultura de precisão**. In: BERLATO, M. A. (Org.). *Agricultura de precisão: Resultados de um novo olhar*. Porto Alegre: Evangraf, 2011. cap. 3, p. 65–90.

NÄSI, R.; HONKAVAARA, E.; LYYTIKÄINEN-SAARENMAA, P.; BLOMQVIST, M.; LITKEY, P.; HAKALA, T.; HOLOPAINEN, M. **Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level**. *Remote Sensing*, v. 7, n. 11, p. 15467-15493, 2015.

PADILLA, F. M. et al. **Chlorophyll index as an estimator of nitrogen status in lettuce**. *Scientia Horticulturae*, v. 158, p. 14–19, 2014. Disponível em: <<https://doi.org/10.1016/j.scienta.2013.10.033>>. Acesso em: 25 jun. 2025.

PIOVESAN, A. M. **A EFICIÊNCIA DE DIFERENTES HERBICIDAS PRÉ EMERGENTES NA CULTURA DO FEIJÃO EM DIFERENTES MOMENTOS DE APLICAÇÃO**. 2025. Trabalho de Conclusão de Curso - Curso de graduação em Agronomia, Universidade Tecnológica Federal do Paraná, Dois Vizinhos

PIMENTEL-GOMES, F. *Curso de estatística experimental*. 15. ed. Piracicaba: FEALQ, 2009. 451 p.

RAMIREZ, G.M.; JÚNIOR ZULLO, J. **Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial**. Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura. Jaboticabal, v.30, n.3, p. 468-479, 2010.

REHMAN, T. U.; LUNDY, M. E.; LINQUIST, B. A. **Evaluating the use of vegetation indices from drone-acquired imagery for estimating rice nitrogen status and predicting grain yield**. *Field Crops Research*, v. 278, p. 108447, 2022. Disponível em: <<https://doi.org/10.1016/j.fcr.2021.108447>>. Acesso em: 25 jun. 2025.

ROSELEM, C.A; MARUBAYASHI, O.M. **Seja o doutor do seu feijoeiro**. Arquivo do agrônomo - Nº 7. Encarte de informações agronômicas - Nº 68 , 1994.

SANTANA, A. V. de et al. **Índice de refletância na estimativa da área foliar e biomassa das folhas em feijão-comum**. *Embrapa Arroz e Feijão*, 2016. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1071173/indice-de-refletancia-na-estimativa-da-area-foliar-e-biomassa-das-folhas-em-feijao-comum>>. Acesso em: 5 jun. 2025.

SANTOS, ANA CLAUDIA SCHLLEMER DOS. **CARACTERIZAÇÃO MORFOAGRONÔMICA E MOLECULAR DE GENÓTIPOS DE FEIJÃO COMUM (*Phaseolus vulgaris* L.)**. 2019. 105 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Agroecossistemas, Universidade Tecnológica Federal do Paraná, Dois Vizinhos.

SILVA, F. M. et al. **Tolerância de cultivares de feijão-comum a herbicidas aplicados em pré-emergência**. *Planta Daninha*, v. 36, 2018. Disponível em:

<<https://www.scielo.br/j/pd/a/N9ppBGNksKRMq9Fx4ZCkCMK/?lang=pt>>. Acesso em: 05 jun. 2025.

SILVA, J. F. et al. **Índices de vegetação do Sensoriamento Remoto para processamento de imagens na faixa do visível (RGB)**. *Journal of Hyperspectral Remote Sensing, Recife*, v. 9, p. 228–240, 2019. Disponível em: <<https://periodicos.ufpe.br/revistas/index.php/jhrs/article/view/242924>>. Acesso em: 5 jun. 2025.

SILVA, J. H. B. da et al. **Técnicas agronômicas visando o aumento da produção e qualidade do feijoeiro (*Phaseolus vulgaris* L.)**: Uma revisão integrativa. *Scientific Electronic Archives*, v. 16, n. 12, 2023. Disponível em: <<https://sea.ufr.edu.br/index.php/SEA/article/view/1816>>. Acesso em: 2 jun. 2025.

SOUSA, H. L. DE. **Sensoriamento Remoto com VANTs**: uma nova possibilidade para a aquisição de geoinformações. *Revista Brasileira de Geomática*, v. 5, n. 3, p. 326, 2017.

TAIZ, L., ZEIGER, E. **Fisiologia Vegetal**, 5ª Edição. Editora Artmed, Porto Alegre, Brasil. 2013. 954p

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. **A Review on UAV-Based Applications for Precision Agriculture**. *MDPI Agric.*, 2019. Disponível em: <https://www.researchgate.net/publication/337187714_A_Review_on_UAV-Based_Applications_for_Precision_Agriculture>. Acesso em: 25 jun. 2025.

TUCKER, C. J. **Red and Photographic Infrared Linear Combinations for Monitoring Vegetation**. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979. Disponível em: <[https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)>. Acesso em: 25 jun. 2025.

WANG, C.; ZHANG, Z.; LI, J. **Effect of ground control point distribution on UAV-derived DSM and orthomosaic accuracy**. *Remote Sensing*, v. 13, n. 2, p. 1–17, 2021. Disponível em: <<https://doi.org/10.3390/rs13020197>>. Acesso em: 25 jun. 2025.

XIANG, T.-Z.; XIA, G.-S.; ZHANG, L. **Mini-Unmanned Aerial Vehicle-Based Remote Sensing**: Techniques, Applications, and Prospects. *ArXiv*, 2018. Disponível em: <<https://arxiv.org/abs/1812.07770?>>. Acesso em: 25 jun. 2025.

YEOM, J. M.; KIM, Y.; KIM, Y. **Estimating vegetation indices for agricultural monitoring using UAV-based RGB imagery**. *Remote Sensing, Basel*, v. 11, n. 15, p. 1733, 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/15/1733>>. Acesso em: 25 jun. 2025.

ZAFFARONI, E. **Estimativa da área foliar do feijão-vagem (*Phaseolus vulgaris* L.) por meio da largura máxima do folíolo central**. *Horticultura Brasileira*, v. 19, n. 2, p. 161–164, 2001. Disponível em: <<https://www.scielo.br/j/hb/a/6cMGHk6MrFJyStzhDvbWrhC>>. Acesso em: 2 jun. 2025.

ZARCO-TEJADA, PJ et al. **Avaliação da condição da vinha com índices hiperespectrais**: Simulação de reflectância foliar e de copa numa copa descontínua estruturada em fileiras. *Sensoriamento Remoto Meio Ambiente*. 99 (3), 271–287 (2005).

ZARCO-TEJADA PJ, MILLER JR, MORALES A, BERIÓN A, AGUERA J. **Índices hiperespectrais e simulação de modelo para estimativa de clorofila em culturas arbóreas de copa aberta**. *Ambiente de Sensoriamento Remoto* (2004) 90:463–476. Disponível em: <<https://doi.org/10.1016/j.rse.2004.01.017>>. Acesso em: 04 nov. 2023.

APÊNDICE A - Dados da ANOVA dos índices GLI, NGRDI, TGI e BGI

Tabela 5 - Resumo da análise de variância (ANOVA) para o índice GLI

Fonte de Variação	GL	SQ	QM	F	p-valor
Tratamento	10	0,0043552	0,00043552	0,97394	0,49436
Bloco	2	0,0001878	0,00009391	0,21000	0,81234
Resíduo	20	0,0089435	0,00044718		
Total	32	0,0134865			

GL: graus de liberdade; SQ: soma dos quadrados; QM: quadrado médio; F: valor de F calculado; p-valor: probabilidade associada à F.

Fonte: Autoria própria (2025)

Tabela 6 – Médias dos tratamentos para o índice GLI

Tratamento	Média do índice GLI
1	0,3490
2	0,3567
3	0,3473
4	0,3670
5	0,3680
6	0,3627
7	0,3620
8	0,3570
9	0,3257
10	0,3590
11	0,3477

Fonte: Autoria própria (2025)

Tabela 7 - Resumo da análise de variância (ANOVA) para o índice NGRDI

Fonte de Variação	GL	SQ	QM	F	p-valor
Tratamento	10	0,0026340	0,00026340	0,68160	0,72917
Bloco	2	0,0000964	0,00004821	0,12476	0,88339
Resíduo	20	0,0077289	0,00038645		
Total	32	0,0104593			

GL: graus de liberdade; SQ: soma dos quadrados; QM: quadrado médio; F: valor de F calculado; p-valor: probabilidade associada à F.

Fonte: Autoria própria (2025)

Tabela 8 – Médias dos tratamentos para o índice NGRDI

Tratamento	Média do índice NGRDI
1	0,2513
2	0,2733
3	0,2723
4	0,2697
5	0,2687
6	0,2613
7	0,2433
8	0,2687
9	0,2633
10	0,2673
11	0,2573

Fonte: Autoria própria (2025)

Tabela 9 - Resumo da análise de variância (ANOVA) para o índice TGI

Fonte de Variação	GL	SQ	QM	F	p-valor
Tratamento	10	459684	45968	1,23155	0,33028
Bloco	2	9804	4902	0,13133	0,33028
Resíduo	20	746510	37326		
Total	32	1215998			

GL: graus de liberdade; SQ: soma dos quadrados; QM: quadrado médio; F: valor de F calculado; p-valor: probabilidade associada à F.

Fonte: Autoria própria (2025)

Tabela 10 – Médias dos tratamentos para o índice TGI

Tratamento	Média do índice TGI
1	-2045,55
2	-1892,84
3	-1857,40
4	-1924,99
5	-1961,81
6	-2059,76
7	-2286,57
8	-1960,85
9	-2125,65
10	-2048,38
11	-2119,04

Fonte: Autoria própria (2025)

Tabela 11 - Resumo da análise de variância (ANOVA) para o índice BGI

Fonte de Variação	GL	SQ	QM	F	p-valor
Tratamento	10	0,0044625	0,00044625	1,34976	0,27172
Bloco	2	0,0003230	0,00016148	0,48843	0,62072
Resíduo	20	0,0066124	0,00033062		
Total	32	0,0113979			

GL: graus de liberdade; SQ: soma dos quadrados; QM: quadrado médio; F: valor de F calculado; p-valor: probabilidade associada à F.

Fonte: Autoria própria (2025)

Tabela 12 – Médias dos tratamentos para o índice BGI

Tratamento	Média do índice BGI
1	0,3907
2	0,3813
3	0,3730
4	0,3800
5	0,3837
6	0,3843
7	0,4170
8	0,3803
9	0,4003
10	0,3923
11	0,3953

Fonte: Autoria própria (2025)