



Universidade Federal de Sergipe
Campus do Sertão
Departamento de Engenharia Agrônômica do Sertão



MARIO SERGIO RODRIGUES BARRETO

MAPEAMENTO DA RESPONSABILIDADE AO USO DO NITROGÊNIO POR MEIO DE IMAGENS NA CULTURA DO MILHO

Trabalho de Conclusão de Curso

Nossa Senhora da Glória/Sergipe
Dezembro de 2025

MARIO SERGIO RODRIGUES BARRETO

**MAPEAMENTO DA RESPONSABILIDADE AO USO DO NITROGÊNIO POR
MEIO DE IMAGENS NA CULTURA DO MILHO**

Trabalho de Conclusão do Curso de Graduação
em Engenharia Agrônômica da Universidade
Federal de Sergipe, como requisito parcial à
obtenção do título de bacharel em Engenharia
Agrônômica.

Orientador: Gustavo Hugo Ferreira de Oliveira

Coorientadora: Barbara Nascimento Santos

Nossa Senhora da Glória/Sergipe

Dezembro de 2025

MARIO SERGIO RODRIGUES BARRETO

MAPEAMENTO DA RESPONSABILIDADE AO USO DO NITROGÊNIO POR MEIO DE IMAGENS NA CULTURA DO MILHO

Este documento foi julgado adequado como requisito parcial à obtenção do título de bacharel em Engenharia Agrônoma.

Aprovado em: 17 /12/2025

Banca examinadora:

Documento assinado digitalmente
 **GUSTAVO HUGO FERREIRA DE OLIVEIRA**
Data: 18/02/2026 19:22:16-0300
Verifique em <https://validar.iti.gov.br>

Gustavo Hugo Ferreira de Oliveira, Doutor
Universidade Federal de Sergipe

Documento assinado digitalmente
 **JOSE JAIRO FLORENTINO CORDEIRO JUNIOR**
Data: 19/02/2026 09:55:01-0300
Verifique em <https://validar.iti.gov.br>

Jose Jairo Florentino Cordeiro Junior, Doutor
Universidade Federal de Sergipe

Documento assinado digitalmente
 **NARTENIA SUSANE COSTA ARAGAO**
Data: 18/02/2026 20:07:28-0300
Verifique em <https://validar.iti.gov.br>

Nartênia Susane Costa Aragão, Eng. Agrônoma
Universidade Federal de Sergipe

Documento assinado digitalmente
 **JADSON DOS SANTOS TEIXEIRA**
Data: 19/02/2026 09:49:23-0300
Verifique em <https://validar.iti.gov.br>

Jadson dos Santos Teixeira, Doutor
Universidade Federal de Sergipe

Índice

Resumo.....	9
Abstract.....	10
1. Introdução.....	11
2. Material e métodos.....	12
2.1 Planejamento experimental.....	12
2.2 Planejamento dos planos de voos e processamento de imagens.....	14
2.3 Análise estatística.....	15
3. Resultados e discussão.....	17
4. Conclusões.....	25
5. Referências bibliográficas.....	25

MAPEAMENTO DA RESPONSIVIDADE AO USO DO NITROGÊNIO POR MEIO DE IMAGENS NA CULTURA DO MILHO

Periódico a ser submetido na Revista Crop Breeding and Applied Biotechnology (CBAB)

Resumo

A fenotipagem de alto rendimento (HTP) é uma ferramenta estratégica para o melhoramento de milho, permitindo a avaliação rápida e acurada de caracteres agronômicos. Este trabalho teve como objetivo selecionar índices de vegetação baseados em imagens RGB para a identificação de genótipos de milho produtivos em situações distintas de adubação nitrogenada a nível de parcela. Foram avaliados 35 genótipos de milho em delineamento de blocos casualizados, em esquema de parcelas subdivididas com três repetições, submetidos a dois níveis de nitrogênio com 20 kg ha⁻¹ e 160 kg ha⁻¹. Realizaram-se quatro voos com VANT em duas alturas (60 m e 80 m), utilizando modelos mistos (REML/BLUP) para análise genética e espacial. Os resultados demonstraram que o voo realizado aos 61 dias após o plantio (V7/V8) a 60 m de altura apresentou a maior repetibilidade e acurácia. O índice de vegetação BGI (*Blue Green Pigment Index*) demonstrou alta sensibilidade na discriminação dos níveis de nitrogênio e na seleção indireta de genótipos produtivos. Foram identificados os genótipos G42, G4, G34, G31, G20, G16 e o G1 como superiores para produtividade de grãos. Conclui-se que índices baseados na banda do azul, como o BGI, são eficientes para seleção de genótipos sob estresse de nitrogênio antes do florescimento.

Palavras-chave: BLUP; Estresse de Nitrogênio; Índice RGB; Melhoramento Vegetal; VANTs; *Zea mays* L.

Abstract

MAPPING NITROGEN USE RESPONSIVENESS THROUGH IMAGERY IN MAIZE CULTIVATION

High-throughput phenotyping (HTP) is a strategic tool for maize breeding, enabling rapid and accurate evaluation of agronomic traits. This study aimed to select RGB image-based vegetation indices for identifying productive maize genotypes under distinct nitrogen fertilization conditions at the plot level. Thirty-five maize genotypes were evaluated in a randomized complete block design arranged in a split-plot scheme with three replications, subjected to two nitrogen levels (20 kg ha⁻¹ and 160 kg ha⁻¹). Four UAV flights were conducted at two altitudes (60 m and 80 m), and mixed models (REML/BLUP) were used for genetic and spatial analyses. The results showed that the flight performed at 61 days after planting (V7/V8) at an altitude of 60 m presented the highest repeatability and accuracy. The BGI (Blue Green Pigment Index) vegetation index showed high sensitivity in discriminating against nitrogen levels and in the indirect selection of productive genotypes. Genotypes G42, G4, G34, G31, G20, G16, and G1 were identified as superior for grain yield. It is concluded that blue-band-based indices, such as BGI, are efficient for selecting genotypes under nitrogen stress before flowering.

Keywords: BLUP; Nitrogen Stress; RGB Index; Plant Breeding; UAVs; *Zea mays* L.

1. Introdução

O milho (*Zea mays* L.) é um dos cereais mais cultivados mundialmente e destaca-se por sua ampla versatilidade de uso, sendo aplicada em vários setores como principal fonte de matéria-prima. A sua alta variabilidade genética permite a ampla adaptação em diferentes climas, tornando-se uma cultura de grande importância socioeconômica (Erenstein *et al.*, 2022).

No ano-safra de 2024, a produção global de milho atingiu a marca de 1.218.205.573 toneladas (FAO, 2024). Nesse cenário, o Brasil manteve sua relevância mundial, contribuindo com 115.722.800 toneladas, enquanto, em âmbito regional, o estado de Sergipe registrou uma produção de 913.909 toneladas (CONAB, 2024).

Em regiões como o Nordeste brasileiro, a produção é limitada pelos fatores edafoclimáticos, sendo agravado pelo mau uso da adubação nitrogenada, à qual a cultura do milho é altamente responsiva. Diante disso, o monitoramento precoce, ágil e não destrutivo torna-se essencial na tomada de decisão para minimizar o estresse por falta de nutrientes e otimizar a produção (Aslan *et al.*, 2022). Neste cenário, a utilização de métodos de monitoramento baseados em imagens, através da utilização de veículos aéreos não tripulados (VANTS) acoplados com sensores RGB, torna-se um grande aliado para o agricultor (Sarkar *et al.*, 2021).

O uso dos VANTS acoplados de sensores RGB de alta resolução, cresce exponencialmente na agricultura. A captura de imagens através dos VANTS, é utilizada para obter informações inerentes das culturas (Sarkar *et al.*, 2021). As imagens fornecem informações precisas e acuradas, sendo utilizadas para verificar a ocorrência de pragas e doenças, assim como deficiência nutricional, contagem de estande e predição da produtividade da cultura antes da maturidade fisiológica (Liakos *et al.*, 2018; Santos *et al.*, 2023).

A fenotipagem de alto rendimento é uma ferramenta crítica no melhoramento genético, quantificando com rapidez e precisão os fenótipos vegetais, com potencial de acelerar o desenvolvimento de culturas de alto rendimento e com tolerância aos estresses (Bhandari *et al.*, 2023; Silva *et al.*, 2023; Zhang *et al.*, 2023). O método de fenotipagem baseado em imagens apresenta eficiência, não é destrutivo e tem alta capacidade de fenotipagem em larga escala (Gao *et al.*, 2021).

Os sensores de imagem que realizam a captura com bandas de cores vermelho (R), verde (G) e azul (B), vem sendo amplamente explorados e desenvolvidos para suprir a demanda crescente por análises de imagem que integram diversas informações ópticas, o que possibilita a extração de informações que são invisíveis aos olhos humanos (Miyata *et al.*, 2026). As informações são extraídas por meio dos índices de vegetação (IVs), que são fórmulas empíricas

utilizadas na medição primária da refletância nas bandas espectrais do RGB (Loesdau; Chabrier; Gabillon, 2014). Os índices foram desenvolvidos para avaliar a vegetação utilizando os sensores de captura de imagens. De um total de 519 índices, 261 são voltados para aplicação na agricultura (Henrich *et al.*, 2012).

Vários estudos mostraram que os IVs são amplamente aplicados no diagnóstico de características fisiológicas das culturas (Cvetković *et al.*, 2023; Xu *et al.*, 2021), a exemplo dos índices chamados de “sobre-verde”, em que são utilizados para estimar o teor de clorofila e nitrogênio (N) nas folhas (Kior *et al.*, 2024; Liu *et al.*, 2021). O nitrogênio é o principal componente na síntese de proteínas e enzimas, assim como na clorofila, sendo o responsável direto pela coloração verde das plantas (Taiz e Zeiger, 2017). A deficiência de N provoca alterações fisiológicas visuais, como a clorose foliar, que é refletida nos espectros RGB das imagens (Colovic *et al.*, 2024).

Apesar do avanço no uso de VANTs, a maioria dos estudos foca na predição de produtividade média de talhões inteiros. Há uma escassez de validações metodológicas que identifiquem a eficiência de seleção em nível de parcela experimental (unidade básica do melhoramento), especialmente discriminando genótipos sob estresse nutricional de N usando apenas sensores RGB de baixo custo. A hipótese deste trabalho é que índices que exploram bandas espectrais específicas (como o Azul e Verde) podem detectar variações sutis de refletância causadas pela clorose nitrogenada antes mesmo da detecção visual humana.

2. Material e métodos

2.1 Planejamento experimental

O experimento foi conduzido no ano agrícola 2024, na Fazenda Experimental da Universidade Federal de Sergipe, Campus do Sertão, localizada no município de Nossa Senhora da Glória, Sergipe (10°13'06" S 37°25'13" O e 291 m). O clima predominante da região é do tipo tropical seco nordestino do Brasil (tr**neb), com precipitação anual variando entre 506 e 1301 mm e temperatura média do mês mais frio entre 18,0 e 27,5 °C (Novais; Machado, 2023).

A Figura 1 evidencia as condições climáticas observadas durante a condução experimental e os estágios fenológicos em que foram realizados os voos. A precipitação pluviométrica total foi de 774 mm, a maior temperatura máxima registrada foi 39,6 °C e a menor temperatura mínima 15,9 °C.




Figura 1. Precipitação pluviométrica mensal, temperatura máxima, média e mínima do ar no ano de 2024, durante a condução experimental, obtidos pela estação meteorológica da fazenda experimental. Estágios fenológicos: V_3 / V_4 , V_7 / V_8 , VT e R_1 .

Foram avaliadas 35 progênies de meios irmãos de milho, obtidas a partir da seleção de 2000 plantas da população PopTol2 semeadas no ano agrícola 2023. O experimento foi conduzido com delineamento em blocos ao acaso (DBC) em esquema de parcelas subdivididas, com três repetições. As parcelas foram constituídas pela baixa e alta adubação nitrogenada, sendo a baixa adubada apenas em fundação com dose de 20 kg ha^{-1} e a alta adubada com 20 kg ha^{-1} em fundação e 140 kg ha^{-1} de N em cobertura. As subparcelas foram representadas pelos genótipos de milho.

As subparcelas foram constituídas por duas linhas com três metros de comprimento, espaçadas em 0,20 m entre plantas e 0,70 m entre linhas, totalizando 30 plantas por parcela e densidade populacional de $71.428 \text{ plantas ha}^{-1}$. A variável fenotípica peso de grãos foi coletada de forma manual, com amostragem da área útil total da parcela, ajustada para 13% de umidade e convertida para produtividade de grãos utilizando o método de Zuber (Zuber, 1942).

A área experimental foi preparada de forma convencional (Alvarenga; Cruz; Viana, 2008), para a abertura das linhas de plantio foi utilizado o sulcador com 3 linhas de forma mecanizada e o plantio foi realizado de forma manual. A adubação de fundação e cobertura

(Tabela 1) foram realizadas de forma manual, sendo a de cobertura fracionada em 50%, nos estádios fenológicos V4 e V6.

Tabela 1. Adubos utilizados durante a condução experimental.

Adubos	Plantio	Cobertura
	kg ha ⁻¹	
MAP (11-52-00)	182,82	0
Super simples (00-18-00)	30,30	0
Cloreto de potássio 60% (00-00-60)	100,00	0
Ureia (46-00-00)	0	304,34

2.2 Planejamento dos planos de voos e processamento de imagens

Na área experimental foram implantados pontos de controle terrestre (PCT) com diâmetro de 30 cm com coloração amarela, totalizando 13 PCT, para corrigir os possíveis erros inerentes do GNSS do drone. As coordenadas foram coletadas com o GPS/RTK da marca FOIF, modelo A60.

O drone utilizado para o imageamento experimental foi o Mavic 2 Pro, com sensor RGB de 20 megapixels. No planejamento dos voos foi utilizado o aplicativo DroneDeploy®, considerando o intervalo das 11h às 13h, evitando dias chuvosos e nublados. Em cada data de voo foram realizados voos em duas alturas (60 m e 80 m), conforme apresentado na Tabela 2.

Tabela 2. Datas de voos e captura de imagens realizados durante a condução experimental.

Nº	Data	Altura (m)	DAP	Fenologia
1	14/06/2024	60 / 80	28	V ₃ / V ₄
2	17/07/2024	60 / 80	61	V ₇ / V ₈
3	31/07/2024	60 / 80	75	VT
4	21/08/2024	60 / 80	96	R ₁

Nº: Número de voo; DAP: dias após o plantio.

As imagens foram processadas no programa Agisoft Metashape Professional® (versão 2.2.2), na versão de teste, para cada data e para ambas as alturas de voo. Após as etapas de correção e processamento, foram obtidos os ortomosaicos. A extração dos índices de vegetação foi realizada utilizando o pacote FIELDimageR (Matias; Caraza-Harter; Endelman, 2020), com base em fórmulas empíricas específicas para cada índice (Tabela 3).

Os índices de vegetação foram calculados a partir das três bandas espectrais disponíveis no sensor RGB: vermelho (R), verde (G) e azul (B).

Tabela 3. Índices de Vegetação (IV) RGB utilizados nas análises de fenotipagem por imagem.

Índices de Vegetação	Equação ¹	Referência
Normalized Green e Red Difference Index (NGRDI)	$\frac{G-R}{G+R}$	(Tucker, 1979)
Green Leaf Index (GLI)	$\frac{2 * G - R - B}{2 * G + R + B}$	(Louhaichi; Borman; Johnson, 2001)
Blue Green Pigment Index (BGI)	$\frac{B}{G}$	(Zarco-Tejada <i>et al.</i> , 2005)
Excess Red Vegetation Index (ExR)	$((1.4 * R) - G)$	(Meyer; Neto, 2008)
Normalized blue (BCC)	$b = \frac{B}{R+G+B}$	(De Swaef <i>et al.</i> , 2021)
Green red difference (GmR)	$G - R$	-
Green blue difference (GmB)	$G - B$	-
Green blue ratio index (GdB)	$\frac{G}{B}$	-
Green red ratio index (GdR)	$\frac{G}{R}$	-
Normalized green (GCC)	$g = \frac{G}{R+G+B}$	(Karcher; Richardson, 2003)
Modified Excess Green Index (MExG)	$((1.262 * G) - (0.884 * R) - (0.311 * B))$	(Burgos-Artizzu <i>et al.</i> , 2011)
Modified green red vegetation index (MGVRI)	$((G^2) - (R^2)) / ((G^2) + (R^2))$	(Bendig <i>et al.</i> , 2015)
(NDI)	$\frac{G-R}{(G+R)}$	(Hamuda; Glavin; Jones, 2016)
Normalized Blue Green Difference Index (NGBDI)	$\frac{G-B}{G+B}$	(Hunt <i>et al.</i> , 2005)
Red green blue vegetation index (RGBVI)	$\left(\frac{(G^2) - (R * B)}{(G^2) + (R * B)} \right)$	(Bendig <i>et al.</i> , 2015)
MSRGR	$\sqrt{\left(\frac{G}{R} \right)}$	(Chen <i>et al.</i> , 2019)
TNDGR	$\sqrt{\frac{G-R}{G+R} + 0.5}$	(Chen <i>et al.</i> , 2019)

¹R= Banda do Vermelho; G= Banda do Verde; B= Banda do Azul.

2.3 Análise estatística

A análise estatística foi realizada no software R Studio® (versão 4.4) (R Core Team, 2025), utilizando os pacotes lmr4 (versão 1.1-35.2) (Bates *et al.*, 2015) para a montagem dos modelos e análise de variância, e os gráficos foram construídos com ggplot2 (versão 3.5.0) (Wickham, 2016).

Os dados da variável produtividade de grãos, foram submetidos aos testes de pressuposição estatística para validar a análise de variância. Foi utilizado o teste de Shapiro – Wilk para a normalidade dos resíduos (Shapiro; Wilk, 1965) e Levene para a homogeneidade das variância (Brown; Forsythe, 1974) com pacote car (Fox *et al.*, 2024).

Na avaliação de fenotipagem de alto rendimento, foram extraídos os TBLUPs (Melhor Preditor linear não viesado temporal) aplicado para cada índice de vegetação ao longo do tempo e em diferentes alturas de voo, sendo utilizada a Equação 1, e para o cálculo da repetibilidade dos índices de vegetação a Equação 2.

Para identificar os melhores índices de vegetação, os valores das repetibilidade obtidos para o voo selecionado foram categorizados em baixa ($r < 0,40$), média ($r > 0,40$ e $r < 0,60$) e alta ($r > 0,60$). Essa classificação, adaptada de Santos *et al.* (2023), permite selecionar os índices com maior estabilidade entre as duas alturas de voo avaliadas (60 m e 80 m).

Os dados dos índices de vegetação foram analisados via modelos mistos (REML/BLUP). O modelo estatístico considerou os níveis de nitrogênio (NN) como efeito fixo, enquanto os efeitos de genótipo (Pedigree), voo e suas interações foram tratados como aleatórios. A equação do modelo é descrita a seguir:

$$Y_{ijkl} = \mu + Nitrogenio_i + Voo_j + [Nitrogenio(Voo)]_{ij} + Pedigree_k + [Pedigree(Voo)]_{kj} + Rep(Voo)_{jl} \quad (1)$$

Onde:

- Y_{ijkl} : Valor do índice de vegetação observado no genótipo k , nível de nitrogênio i , voo j e repetição l ;
- μ : Média geral;
- $Nitrogenio_i$: Efeito fixo do i -ésimo nível de Nitrogênio;
- Voo_j : Efeito aleatório do j -ésimo Voo, representa a data de voo, onde $Voo_j \sim N(0, \sigma_j^2)$;
- $[Nitrogenio(Voo)]_{ij}$: Efeito aleatório da interação Nitrogênio $\times$ Voo;
- $Pedigree_k$: Efeito aleatório do genótipo, onde $Pedigree_k \sim N(0, \sigma_k^2)$;
- $[Pedigree(Voo)]_{kj}$: Efeito aleatório da interação Genótipo $\times$ Voo, capturando a interação $G \times A$, onde $[Pedigree(Voo)]_{kj} \sim N(0, \sigma_{kj}^2)$;

- $[Rep(Voo)]_{jl}$: Efeito aleatório da repetição l aninhada ao voo j assumindo $[Rep(Voo)]_{jl} \sim N(0, \sigma_{jl}^2)$;
- $error_{ijkl}$: Erro residual aleatório, assumindo $error_{ijkl} \sim N(0, \sigma_{\epsilon}^2)$.

$$R = \frac{\sigma_{Pedigree}^2}{\sigma_{Pedigree}^2 + \frac{\sigma_{error}^2}{n_{Rep}}} \quad (2)$$

Onde:

- R : Coeficiente de repetibilidade (herdabilidade baseada na média de genótipos);
- $\sigma_{Pedigree}^2$: Variância genética (entre genótipos);
- σ_{error}^2 : Variância do erro residual;
- n_{Rep} : Número de repetições.

3. Resultados e discussão

A análise de variância indicou efeito significativo da adubação nitrogenada e dos genótipos avaliados sobre a produtividade de grãos, ao nível de 0,1% de probabilidade pelo teste F (Tabela 4). Esse resultado evidencia que, tanto entre os níveis de adubação quanto entre os genótipos, houve pelo menos uma diferença, sendo essencial para o melhoramento genético no que se concerne a adaptar genótipos sob estresse abiótico.

Os coeficientes de variação obtidos foram de 10,05% (CV A) e 19,77% (CV B), valores considerados adequados para experimentos com a cultura do milho, indicando boa precisão experimental e confiabilidade dos resultados, conforme critérios estabelecidos na literatura (GURGEL; FERREIRA; SOARES, 2013).

Tabela 4. Resumo da análise de variância para produtividade de grãos

FV	G.L	QM
		PG
Bloco	2	3.598.203,08 *
Adubação (A)	1	514.325.158,62 ***
Residuo A	2	164.787,59
Genótipos (B)	34	1.891.926,59 ***
Interação (AxB)	34	698.508,51 ns
Residuo B	136	636.883,65

Cv A	10,05
Cv B	19,77
Média	4.035,99

FV = fonte de variação; GL = graus de liberdade; CV = coeficiente de variação; *, **, *** = nível de significância a 5%, 1% e 0,1% de probabilidade pelo teste F, respectivamente; ns = não significativo PG= produtividade de grãos (kg ha^{-1}).

Na avaliação dos índices de vegetação e das diferentes datas de voo, o estudo da repetibilidade torna-se essencial para assegurar a confiabilidade das análises temporais e espaciais. Valores de repetibilidade mais próximos de 1 indicam maior consistência das medições, sendo influenciados pela relação entre a variância genotípica e o erro residual. Dessa forma, maiores valores de repetibilidade são obtidos quando o erro experimental é reduzido e adequadamente controlado pelo delineamento e pelos blocos experimentais, conforme destacado por Santos et al. (2023).

Na Figura 2, observa-se que o voo realizado aos 75 dias após o plantio (DAP) apresentou os menores valores de repetibilidade, independentemente da altura de voo, indicando baixa confiabilidade dos índices de vegetação nesse estágio fenológico. Em contraste, os voos realizados aos 28, 61 e 96 DAP apresentaram valores de repetibilidade moderados a elevados, com destaque para o voo aos 61 DAP, que apresentou os maiores valores para ambas as alturas avaliadas (60 m e 80 m).

Os voos realizados aos 28 e 61 DAP apresentaram os melhores resultados de repetibilidade para a altura de voo de 60 m, enquanto, para a altura de 80 m, apenas o voo aos 61 DAP apresentou desempenho consistente. Esses períodos coincidem com fases críticas do desenvolvimento do milho, nas quais ocorre a definição do potencial produtivo da cultura.

A maior eficiência de seleção observada aos 61 DAP (estádio V7/V8) coincide com o período de máxima demanda de Nitrogênio pela cultura, onde a diferenciação do número de fileiras da espiga está sendo definida. (Vergara-Díaz *et al.*, 2016), avaliando índices RGB em milho, também reportaram que o estágio de pré-florescimento oferece o melhor balanço entre cobertura de solo e expressão de sintomas de deficiência, permitindo predições de produtividade com alta correlação genética. Isso valida o uso de VANTs para descartar genótipos inferiores precocemente, otimizando recursos antes da colheita.

A superioridade da altura de voo de 60 m sobre a de 80 m para a estimativa da repetibilidade corrobora a necessidade de resolução espacial adequada para microparcelas. Voos mais baixos aumentam o Ground Sampling Distance (GSD), reduzindo o efeito de bordadura e a contaminação espectral pelo solo entre as linhas de plantio. Estes resultados alinham-se aos

observados por (Zhu *et al.*, 2019), que ao avaliarem dados de VANT em múltiplas escalas espaciais, demonstraram que a alta resolução espacial é determinante para reduzir o erro na estimativa de biomassa e traços estruturais em milho, uma vez que resoluções mais grosseiras (voos mais altos) tendem a suavizar a variabilidade genotípica existente dentro das parcelas.

Os resultados indicam que os voos realizados após 61 DAP tendem a apresentar menor repetibilidade, sugerindo contribuição limitada para a diferenciação dos genótipos avaliados. Assim, a priorização de voos em estádios fenológicos mais precoces pode otimizar o processo de fenotipagem de alto rendimento, reduzindo custos operacionais sem comprometer a eficiência da seleção. Resultados semelhantes foram reportados por Santos *et al.* (2023), que observaram valores consistentes de repetibilidade para alturas de voo de 60 m e 80 m em avaliações realizadas aos 27 DAP.




Figura 2. Identificação da melhor Data de Voo após Plantio (DAP) para obtenção de altos valores de repetibilidade dos índices de vegetação em relação as altitudes de voo. Triângulo representa a média para cada data de voo.

Após a identificação da melhor data de voo, avaliada com base nos valores da repetibilidade dos índices de vegetação para as alturas de 60 m e 80 m (Figura 3). Dentre os índices avaliados, RGBVI, NGRDI, GmR, GmB, GLI, GdB, GCC e BGI apresentaram repetibilidade média, enquanto o índice MExG foi o único classificado com repetibilidade alta nas duas alturas analisadas.

Resultados semelhantes foram observados por Santos *et al.* (2023), que selecionaram índices de vegetação com valores de repetibilidade superiores a 50% para a altura de voo de 60

m. Para a altura de 80 m, os mesmos índices apresentaram valores de repetibilidade inferiores a 45%, indicando que voos realizados a menores alturas tendem a proporcionar maior estabilidade dos índices de vegetação. Esses resultados sugerem que a utilização da altura de voo de 60 m é mais eficiente para a fenotipagem de genótipos de milho, podendo reduzir a necessidade de voos adicionais a 80 m sem prejuízo à qualidade das informações obtidas.




Figura 3. Identificação dos índices de vegetação com os maiores valores de repetibilidade para cada altura de voo com 61 DAP.

A seleção de índices com alta repetibilidades indica que o percentual do erro residual foi baixo e que parte da variância observada foi alta. Já os índices com repetibilidade média ou baixa indicam que os níveis foram levemente alto ou alto, respectivamente. Essa etapa de seleção permite priorizar somente os índices que são mais promissores, capazes de diferenciar e selecionar os genótipos milho, assim como identificar estresse nutricional pelo nutriente nitrogênio

Com o objetivo de explicar a variabilidade experimental observada, foi realizado o estudo de todos os componentes experimentais, sendo eles: dias após o plantio (DAP), altura de voo (AV), índices de vegetação (Ped), repetição (Rep), nível de nitrogênio (NN) e suas interações. Para essa finalidade, utilizou-se o melhor preditor linear imparcial temporal (TBLUPs), obtendo-se a variância individual de cada componente do modelo estatístico (Figura 4).

Na Figura 4, observa-se a decomposição dos componentes de variância dos índices de vegetação avaliados nas alturas de voo de 60 m e 80 m. Os índices GmB, BCC, GdB, NGBDI e BGI apresentaram maior contribuição da variabilidade associada à interação entre nível de nitrogênio e voo ($NN \times VOO$), com valores variando de 70,38% a 50,06% para a altura de 60 m e de 70,03% a 52,54% para a altura de 80 m.

O componente altura de voo (VOO) explicou a maior variabilidade experimental nos índices de vegetação GmR, MExG, TNDGR, MGVRI, NDI, NGRDI, MSRGR, GdR, ExR, GLI, GCC e RGBVI, variando de 68,47% e 42,80% para 60 m, e de 64,16% e 31,41% para 80 m. A presença dessa variabilidade no voo e as suas interações têm influência direta e indireta nos cálculos dos índices de vegetação e, conseqüentemente, na repetibilidade. Resultados semelhantes foram relatados por Adak *et al.* (2021) e Adak e Murray & Washburn (2024), em que o componente VOO também explicou a maior variação percentual em índices que utilizam as bandas RGB.

Resultados semelhantes são apresentados nos trabalhos de Adak *et al.* (2021) e Adak e Murray & Washburn (2024), em que o componente VOO explicou a maior variação percentual para os índices de vegetação que utilizam as bandas RGB.




Figura 4. Componente de variância para cada característica predição para o voo de 60 m e 80 m. A: 60 m; B: 80 m; Ped: Pedigree e Rep: Repetição e NN: Nível de nitrogênio.

Para identificar a sensibilidade dos índices de vegetação à adubação nitrogenada, foram extraídos os TBLUPs das parcelas para cada índice de vegetação (Figura 5). Observou-se que os índices GmR, MExG, TNDGR, MGVRI, NDI, NGRDI, MSRGR, ExR, GdR, GLI, GCC e RGBVI não apresentaram sensibilidade suficiente para diferenciar os níveis de adubação nitrogenada na cultura do milho. Em contraste, apenas o índice BGI foi capaz de discriminar os tratamentos, apresentando valores distintos de TBLUPs para cada nível de adubação.

O destaque do índice BGI (Blue Green Pigment Index) na discriminação dos níveis de nitrogênio e na seleção de genótipos produtivos pode ser explicado pela fisiologia da refletância

foliar. O Nitrogênio é um constituinte estrutural das moléculas de clorofila. Sob deficiência de N, ocorre degradação da clorofila e aumento relativo da concentração de carotenoides e xantofilas.

Enquanto índices tradicionais focados no Vermelho (como NGRDI) saturam rapidamente com o fechamento do dossel, a banda do Azul (utilizada no numerador do BGI = B/G) mantém sensibilidade à absorção por pigmentos acessórios. Segundo (Buchailot *et al.*, 2019), índices RGB derivados de VANTs mostraram-se eficazes em prever a produtividade de milho sob baixos níveis de N, superando, em alguns casos, medições terrestres. O BGI, ao contrastar a banda do Azul (forte absorção por clorofilas a/b) com o Verde (pico de refletância), consegue capturar a 'clorose incipiente' de maneira mais eficaz que índices baseados apenas na relação Vermelho/Verde.




Figura 5. Análise da sensibilidade dos índices de vegetação na diferenciação entre as adubações nitrogenadas para o voo de 60 m.

Após a seleção do índice de vegetação, os BLUPs foram avaliados a nível de subparcela para identificar os genótipos mais produtivos. No mapa de calor (Figuras 6A), verificou-se que

os genótipos G34, G50, G5, G31, G26, G23 e G42 obtiveram maior produtividade, variando entre 6068,42 kg ha⁻¹ e 7417,48 na adubação nitrogenada de 140 kg ha⁻¹ de N. Para a adubação de 0 kg ha⁻¹ de N (Figuras 6B), a produtividade para esses mesmos genótipos variou de 3171,02 kg ha⁻¹ e 4252,81.

O índice BGI identificou as parcelas mais produtivas nos dois níveis de adubação nitrogenada. Os genótipos selecionados foram o G42, G4, G34, G31, G20, G16 e o G1, com valores dos BLUPs superiores a 0,61 nos blocos 2 e 3 (Figura 7A). Da mesma forma, o índice identificou os genótipos menos produtivos que foram os G37, G47, G5, G14, G24, G19 e G40, no bloco 1, com valores de BLUPs inferiores a 0,58.

De modo geral, o índice BGI mostrou-se promissor tanto na identificação de parcelas produtivas quanto de parcelas com menor desempenho. Resultados semelhantes foram reportados por Adak et al. (2021), que observaram elevada robustez do BGI na predição da produtividade de grãos, bem como por Sarkar et al. (2021), que destacaram esse índice como um dos melhores preditores do índice de área foliar.




Figura 6. Mapa de calor do índice de vegetação e produtividade grão para cada parcela experimental avaliada. A: Adubação nitrogenada com 140 kg ha⁻¹; B: Adubação nitrogenada com 0 kg ha⁻¹; PG: produtividade de grãos.

4. Conclusões

A utilização de fenotipagem de alto rendimento via VANTs mostrou-se eficaz para o melhoramento genético de milho.

A altura de voo de 60 m proporciona maior repetibilidade dos dados espectrais em comparação aos 80 m.

O voo realizado aos 61 DAP (V7/V8) é o ponto ideal para seleção, dispensando avaliações tardias em R1.

O índice BGI é a ferramenta mais robusta entre os índices RGB testados para discriminar genótipos responsivos à adubação nitrogenada, permitindo a identificação acurada dos genótipos de elite G42, G4 e G34.

Recomendamos a implementação do índice BGI em protocolos de seleção assistida por VANTs para otimizar a identificação de materiais tolerantes ao estresse nutricional.

5. Referências bibliográficas

ALVARENGA, R. C.; CRUZ, J. C.; VIANA, J. H. M. Manejo de solos: preparo convencional do solo. [S. l.], 2008. Disponível em: <http://www.alice.cnptia.embrapa.br/handle/doc/491199>. Acesso em: 28 jan. 2026.

ASLAN, M. F.; DURDU, A.; SABANCI, K.; ROPELEWSKA, E.; GÜLTEKIN, S. S. A Comprehensive Survey of the Recent Studies with UAV for Precision Agriculture in Open Fields and Greenhouses. **Applied Sciences** **2022**, Vol. 12, Page 1047, [S. l.], v. 12, n. 3, p. 1047, jan. 2022. <https://doi.org/10.3390/AP12031047>.

BATES, D.; MÄCHLER, M.; BOLKER, B.; WALKER, S. Fitting Linear Mixed-Effects Models Using lme4. **Journal of Statistical Software**, [S. l.], v. 67, p. 1–48, 7 out. 2015. <https://doi.org/10.18637/jss.v067.i01>.

BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 39, p. 79–87, 1 jul. 2015. <https://doi.org/10.1016/j.jag.2015.02.012>.

BHANDARI, M.; CHANG, A.; JUNG, J.; IBRAHIM, A. M. H.; RUDD, J. C.; BAKER, S.; LANDIVAR, J.; LIU, S.; LANDIVAR, J. Unmanned aerial system-based high-throughput phenotyping for plant breeding. **The Plant Phenome Journal**, [S. l.], v. 6, n. 1, p. e20058, jan. 2023. <https://doi.org/10.1002/PPJ2.20058>.

BROWN, M. B.; FORSYTHE, A. B. Robust Tests for the Equality of Variances. **Journal of the American Statistical Association**, [S. l.], v. 69, n. 346, p. 364–367, 1 jun. 1974. <https://doi.org/10.1080/01621459.1974.10482955>.

BUCHAILLOT, M. L.; GRACIA-ROMERO, A.; VERGARA-DIAZ, O.; ZAMAN-ALLAH, M. A.; TAREKEGNE, A.; CAIRNS, J. E.; PRASANNA, B. M.; ARAUS, J. L.; KEFAUVER, S. C. Evaluating Maize Genotype Performance under Low Nitrogen Conditions Using RGB UAV Phenotyping Techniques. **Sensors**, [S. l.], v. 19, n. 8, 15 abr. 2019. DOI: 10.3390/s19081815. Disponível em: <https://www.mdpi.com/1424-8220/19/8/1815>. Acesso em: 1 fev. 2026.

BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; GUIJARRO, M.; PAJARES, G. Real-time image processing for crop/weed discrimination in maize fields. **Computers and Electronics in Agriculture**, [S. l.], v. 75, n. 2, p. 337–346, 1 fev. 2011. <https://doi.org/10.1016/j.compag.2010.12.011>.

CHEN, Z.; MIAO, Y.; LU, J.; ZHOU, L.; LI, Y.; ZHANG, H.; LOU, W.; ZHANG, Z.; KUSNIEREK, K.; LIU, C. In-Season Diagnosis of Winter Wheat Nitrogen Status in Smallholder Farmer Fields Across a Village Using Unmanned Aerial Vehicle-Based Remote Sensing. **Agronomy**, [S. l.], v. 9, n. 10, 8 out. 2019. DOI: 10.3390/agronomy9100619. Disponível em: <https://www.mdpi.com/2073-4395/9/10/619>. Acesso em: 3 fev. 2026.

COLOVIC, M.; STELLACCI, A. M.; MZID, N.; VENOSA, M. D.; TODOROVIC, M.; CANTORE, V.; ALBRIZIO, R. Comparative Performance of Aerial RGB vs. Ground Hyperspectral Indices for Evaluating Water and Nitrogen Status in Sweet Maize. **Agronomy**, [S. l.], v. 14, n. 3, 10 mar. 2024. DOI: 10.3390/agronomy14030562. Disponível em: <https://www.mdpi.com/2073-4395/14/3/562>. Acesso em: 10 fev. 2026.

CONAB – COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da safra brasileira de grãos: safra 2023/24, décimo segundo levantamento. Brasília, DF, v. 11, n. 12, set. 2024.

CVETKOVIĆ, N.; ĐOKOVIĆ, A.; DOBROTA, M.; RADOJIČIĆ, M. New Methodology for Corn Stress Detection Using Remote Sensing and Vegetation Indices. **Sustainability**, [S. l.], v. 15, n. 6, 20 mar. 2023. DOI: 10.3390/su15065487. Disponível em: <https://www.mdpi.com/2071-1050/15/6/5487>. Acesso em: 10 fev. 2026.

DE SWAEF, T.; MAES, W. H.; APER, J.; BAERT, J.; COUGNON, M.; REHEUL, D.; STEPPE, K.; ROLDÁN-RUIZ, I.; LOOTENS, P. Applying RGB- and Thermal-Based Vegetation Indices from UAVs for High-Throughput Field Phenotyping of Drought Tolerance in Forage Grasses. **Remote Sensing**, [S. l.], v. 13, n. 1, p. 147, jan. 2021. <https://doi.org/10.3390/rs13010147>.

ERENSTEIN, O.; JALETA, M.; SONDER, K.; MOTTALEB, K.; PRASANNA, B. M. Global maize production, consumption and trade: trends and R&D implications. **Food Security**, [S. l.], v. 14, n. 5, p. 1295–1319, 1 out. 2022. <https://doi.org/10.1007/s12571-022-01288-7>.

FAO. **World Food and Agriculture – Statistical Yearbook 2024**. Rome, Italy: FAO, 2024. 384 p. (FAO Statistical Yearbook – World Food and Agriculture, 2024). DOI: 10.4060/cd2971en. Disponível em: <https://openknowledge.fao.org/handle/20.500.14283/cd2971en>. Acesso em: 10 fev. 2026.

FOX, J.; WEISBERG, S.; PRICE, B.; ADLER, D.; BATES, D.; BAUD-BOVY, G.; BOLKER, B.; ELLISON, S.; FIRTH, D.; FRIENDLY, M.; GORJANC, G.; GRAVES, S.; HEIBERGER, R.; KRIVITSKY, P.; LABOISSIERE, R.; MAECHLER, M.; MONETTE, G.; MURDOCH, D.; NILSSON, H.; OGLE, D.; RIPLEY, B.; SHORT, T.; VENABLES, W.; WALKER, S.; WINSEMIUS, D.; ZEILEIS, A.; R-CORE. **car: Companion to Applied Regression**. Versão

3.1-3. [S. l.]: [S. n.], 27 set. 2024. Disponível em:

<https://cran.r-project.org/web/packages/car/index.html>. Acesso em: 29 jan. 2026.

GAO, T.; ZHU, F.; PAUL, P.; SANDHU, J.; DOKU, H. A.; SUN, J.; PAN, Y.; STASWICK, P.; WALIA, H.; YU, H. Novel 3D Imaging Systems for High-Throughput Phenotyping of Plants. **Remote Sensing** **2021**, Vol. **13**, Page **2113**, [S. l.], v. 13, n. 11, p. 2113, maio 2021. <https://doi.org/10.3390/RS13112113>.

GURGEL, F. de L.; FERREIRA, D. F.; SOARES, A. C. S. e. O coeficiente de variação como critério de avaliação em experimentos de milho e feijão. [S. l.], 2013. Disponível em: <http://www.infoteca.cnptia.embrapa.br/handle/doc/955896>.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and Electronics in Agriculture**, [S. l.], v. 125, p. 184–199, 1 jul. 2016. <https://doi.org/10.1016/j.compag.2016.04.024>.

HENRICH, V.; KRAUSS, G.; GÖTZE, C.; SANDOW, C. IDB - Index DataBase. 2012. Disponível em: <https://www.indexdatabase.de/>. Acesso em: 8 fev. 2026.

HUNT, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY, J. E.; WALTHALL, C. L. Evaluation of Digital Photography from Model Aircraft for Remote Sensing of Crop Biomass and Nitrogen Status. **Precision Agriculture**, [S. l.], v. 6, n. 4, p. 359–378, 1 ago. 2005. <https://doi.org/10.1007/s11119-005-2324-5>.

KIOR, A.; YUDINA, L.; ZOLIN, Y.; SUKHOV, V.; SUKHOVA, E. RGB Imaging as a Tool for Remote Sensing of Characteristics of Terrestrial Plants: A Review. **Plants**, [S. l.], v. 13, n. 9, p. 1262, 30 abr. 2024. <https://doi.org/10.3390/plants13091262>.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: A Review. **Sensors**, [S. l.], v. 18, n. 8, p. 2674, n. 8, ago. 2018. <https://doi.org/10.3390/s18082674>.

LIU, Y.; HATOU, K.; AIHARA, T.; KUROSE, S.; AKIYAMA, T.; KOHNO, Y.; LU, S.; OMASA, K. A Robust Vegetation Index Based on Different UAV RGB Images to Estimate SPAD Values of Naked Barley Leaves. **Remote Sensing**, [S. l.], v. 13, n. 4, 12 fev. 2021. DOI: 10.3390/rs13040686. Disponível em: <https://www.mdpi.com/2072-4292/13/4/686>. Acesso em: 8 fev. 2026.

LOESDAU, M.; CHABRIER, S.; GABILLON, A. Hue and Saturation in the RGB Color Space. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, [S. l.], v. 8509 LNCS, p. 203–212, 2014. https://doi.org/10.1007/978-3-319-07998-1_23.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, [S. l.], v. 16, n. 1, p. 65–70, 1 mar. 2001. <https://doi.org/10.1080/10106040108542184>.

MATIAS, F. I.; CARAZA-HARTER, M. V.; ENDELMAN, J. B. FIELDImageR: An R package to analyze orthomosaic images from agricultural field trials. **The Plant Phenome Journal**, [S. l.], v. 3, n. 1, p. e20005, 2020. <https://doi.org/10.1002/ppj2.20005>.

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and Electronics in Agriculture**, [S. l.], v. 63, n. 2, p. 282–293, 1 out. 2008. <https://doi.org/10.1016/j.compag.2008.03.009>.

MIYATA, M.; SHIKAMA, K.; TAKEHARA, H.; OHTA, J.; HASHIMOTO, T. High-Sensitivity RGB–NIR Image Sensor with Dispersion-Engineered Meta-Optics. **ACS Photonics**, [S. l.], v. 13, n. 3, p. 849–860, 4 fev. 2026. <https://doi.org/10.1021/acsp Photonics.5c02801>.

NOVAIS, G. T.; MACHADO, L. A. Os climas do Brasil: segundo a classificação climática de Novais. **Revista Brasileira de Climatologia**, [S. l.], v. 32, p. 1–39, 10 jan. 2023. <https://doi.org/10.55761/abclima.v32i19.16163>.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.R-project.org/>.

SANTOS, B. N.; ARAGÃO, N. S. C.; BARRETO, M. S. R.; SANTOS, H. R. A.; SANTOS, J. F. S.; JUNIOR, J. J. F. C.; OLIVEIRA, G. H. F. de. Protocolo de processamento de imagens RGB aéreas para identificação de genótipos potenciais de milho em fase vegetativa. **Revista Eletrônica Competências Digitais para Agricultura Familiar**, [S. l.], v. 9, n. 2, p. 149–173, n. 2, 2023.

SARKAR, S.; CAZENAVE, A. B.; OAKES, J.; MCCALL, D.; THOMASON, W.; ABBOTT, L.; BALOTA, M. Aerial high-throughput phenotyping of peanut leaf area index and lateral growth. **Scientific Reports**, [S. l.], v. 11, n. 1, p. 1–17, dez. 2021. <https://doi.org/10.1038/S41598-021-00936-W>;SUBJMETA=114,1305,1564,2163,2415,631;KWRD=HIGH-THROUGHPUT+SCREENING,IMAGE+PROCESSING,MACHINE+LEARNING,STATISTICAL+METHODS.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, [S. l.], v. 52, n. 3/4, p. 591–611, 1965. <https://doi.org/10.2307/2333709>.

SILVA, P. F. da; CASSA, N.; MELO, A. S. de; NETO, J. D.; MENEGHETTI, L. A. M.; CUSTÓDIO, A. S. C.; OLIVEIRA, N. P. R. de; SILVA, T. J. A. da; BONFIM-SILVA, E. M.; ANDRADE, S. P.; DUARTE, T. F.; BERILLI, S. da S.; SOUZA, M. N.; OLIVEIRA, A. de F. M. de; MOULIN, M. M.; BERILLI, A. P. C. G. Advances in Crop Genetic Improvement to Overcome Drought Stress: Bibliometric and Meta-Analysis. **Agriculture 2023, Vol. 13, Page 1860**, [S. l.], v. 13, n. 10, p. 1860, set. 2023. <https://doi.org/10.3390/AGRICULTURE13101860>.

TAIZ, L.; ZEIGER, E.; MOLLER, I. M.; MURPHY, A. Fisiologia e desenvolvimento vegetal, 6 eds., p. 731, 2017.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, [S. l.], v. 8, n. 2, p. 127–150, 1 maio 1979. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).

VERGARA-DÍAZ, O.; ZAMAN-ALLAH, M. A.; MASUKA, B.; HORNERO, A.; ZARCO-TEJADA, P.; PRASANNA, B. M.; CAIRNS, J. E.; ARAUS, J. L. A Novel Remote Sensing Approach for Prediction of Maize Yield Under Different Conditions of Nitrogen Fertilization. **Frontiers in Plant Science**, [S. l.], v. 7, 18 maio 2016. DOI: 10.3389/fpls.2016.00666.

Disponível em: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2016.00666/full>. Acesso em: 1 fev. 2026.

WICKHAM, H. **ggplot2**. Cham: Springer International Publishing, 2016. (Use R!). DOI: 10.1007/978-3-319-24277-4. Disponível em: <http://link.springer.com/10.1007/978-3-319-24277-4>. Acesso em: 28 jul. 2025.

XU, X.; FAN, L.; LI, Z.; MENG, Y.; FENG, H.; YANG, H.; XU, B. Estimating Leaf Nitrogen Content in Corn Based on Information Fusion of Multiple-Sensor Imagery from UAV. **Remote Sensing**, [S. l.], v. 13, n. 3, 19 jan. 2021. DOI: 10.3390/rs13030340. Disponível em: <https://www.mdpi.com/2072-4292/13/3/340>. Acesso em: 10 fev. 2026.

ZARCO-TEJADA, P. J.; BERJÓN, A.; LÓPEZ-LOZANO, R.; MILLER, J. R.; MARTÍN, P.; CACHORRO, V.; GONZÁLEZ, M. R.; DE FRUTOS, A. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. **Remote Sensing of Environment**, [S. l.], v. 99, n. 3, p. 271–287, 30 nov. 2005. <https://doi.org/10.1016/j.rse.2005.09.002>.

ZHANG, H.; WANG, L.; JIN, X.; BIAN, L.; GE, Y. High-throughput phenotyping of plant leaf morphological, physiological, and biochemical traits on multiple scales using optical sensing. **The Crop Journal**, [S. l.], v. 11, n. 5, p. 1303–1318, out. 2023. <https://doi.org/10.1016/J.CJ.2023.04.014>.

ZHU, W.; SUN, Z.; PENG, J.; HUANG, Y.; LI, J.; ZHANG, J.; YANG, B.; LIAO, X. Estimating Maize Above-Ground Biomass Using 3D Point Clouds of Multi-Source Unmanned Aerial Vehicle Data at Multi-Spatial Scales. **Remote Sensing**, [S. l.], v. 11, n. 22, 14 nov. 2019. DOI: 10.3390/rs11222678. Disponível em: <https://www.mdpi.com/2072-4292/11/22/2678>. Acesso em: 1 fev. 2026.

ZUBER, M. S. Relative Efficiency of Incomplete Block Designs Using Corn Uniformity Trial Data. **Agronomy Journal**, [S. l.], v. 34, n. 1, p. 30–47, 1942. <https://doi.org/10.2134/agronj1942.00021962003400010004x>.