

INSTITUTO FEDERAL GOIANO – CAMPUS CERES
BACHARELADO EM AGRONOMIA
LUCAS EDUARDO VIEIRA DE CASTRO

**USO DE IMAGENS MULTIESPECTRAIS OBTIDAS COM RPAS NA PREDIÇÃO
DE PARÂMETROS BIOFÍSICOS DA CULTURA DO FEIJOEIRO**

CERES – GO
2022

LUCAS EDUARDO VIEIRA DE CASTRO

**USO DE IMAGENS MULTIESPECTRAIS OBTIDAS COM RPAS NA PREDIÇÃO
DE PARÂMETROS BIOFÍSICOS DA CULTURA DO FEIJOEIRO**

Trabalho de conclusão de curso apresentado ao curso de Bacharelado em Agronomia do Instituto Federal Goiano – Campus Ceres, como requisito parcial para a obtenção do título de Bacharel em Agronomia, sob orientação do Prof. Dr. Wilian Henrique Diniz Buso e coorientação do Prof. Dr. Henrique Fonseca Elias de Oliveira.

**CERES – GO
2022**

Sistema desenvolvido pelo ICMC/USP
Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas - Instituto Federal Goiano

C355u Castro, Lucas Eduardo Viera de
USO DE IMAGENS MULTIESPECTRAIS OBTIDAS COM RPAS
NA PREDIÇÃO DE PARÂMETROS BIOFÍSICOS DA CULTURA DO
FEIJOEIRO / Lucas Eduardo Viera de Castro;
orientador Wilian Henrique Diniz Buso; co-orientador
Henrique Fonseca Elias de Oliveira. -- Ceres, 2022.
23 p.

TCC (Graduação em Bacharelado em Agronomia) --
Instituto Federal Goiano, Campus Ceres, 2022.

1. RPAS. 2. Sensoriamento remoto. 3. Índices de
vegetação. 4. Reflectância. 5. Nutrição. I. Buso,
Wilian Henrique Diniz, orient. II. Oliveira,
Henrique Fonseca Elias de, co-orient. III. Título.



TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano, a disponibilizar gratuitamente o documento no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| <input type="checkbox"/> Tese | <input type="checkbox"/> Artigo Científico |
| <input type="checkbox"/> Dissertação | <input type="checkbox"/> Capítulo de Livro |
| <input type="checkbox"/> Monografia – Especialização | <input type="checkbox"/> Livro |
| <input checked="" type="checkbox"/> TCC - Graduação | <input type="checkbox"/> Trabalho Apresentado em Evento |
| <input type="checkbox"/> Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Lucas Eduardo Vieira de Castro

Matrícula: 2017103200210091

Título do Trabalho: USO DE IMAGENS MULTIESPECTRAIS OBTIDAS COM RPAS NA PREDIÇÃO DE PARÂMETROS BIOFÍSICOS DA CULTURA DO FEIJOEIRO

Restrições de Acesso ao Documento

Documento confidencial: Não Sim, justifique: _____

Informe a data que poderá ser disponibilizado no RIIF Goiano: 16/12/2022

O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Ceres, 10 de dezembro de 2022

Lucas Eduardo Vieira de Castro

Assinatura do Autor e/ou Detentor dos Direitos Autorais

Ciente e de acordo:

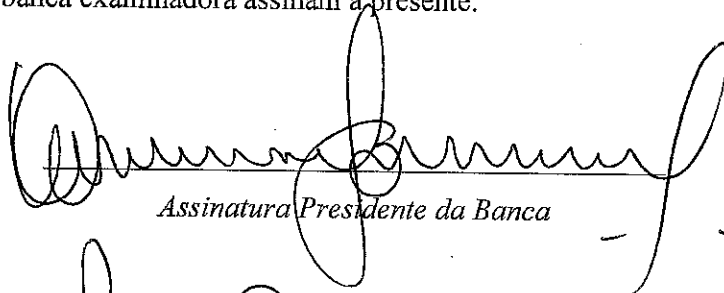
[Assinatura]
Assinatura do(a) orientador(a)

ANEXO IV - ATA DE DEFESA DE TRABALHO DE CURSO

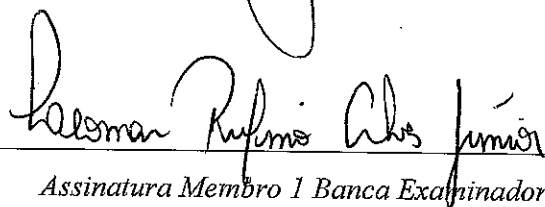
Ao(s) 01 dia(s) do mês de dezembro ano de dois mil e vinte dois realizou-se a defesa de Trabalho de Curso do(a) acadêmico(a) Lucas Eduardo Vieira de Castro do Curso de Bacharelado em Agronomia matrícula 201710320010091, cujo título é "Uso de imagens multiespectrais obtidas por RPAS na predição de parâmetros fisiológicos". A defesa iniciou-se às 10 horas e 08 minutos, finalizando-se às 11 horas e 52 minutos. A banca examinadora considerou o trabalho APROVADO com média 8,9 no trabalho escrito, média 8,9 no trabalho oral, apresentando assim média aritmética final 8,9 de pontos, estando o(a) estudante APTO para fins de conclusão do Trabalho de Curso.

Após atender às considerações da banca e respeitando o prazo disposto em calendário acadêmico, o(a) estudante deverá fazer a submissão da versão corrigida em formato digital (.pdf) no Repositório Institucional do IF Goiano – RIIIF, acompanhado do Termo Ciência e Autorização Eletrônico (TCAE), devidamente assinado pelo autor e orientador.

Os integrantes da banca examinadora assinam a presente.



Assinatura Presidente da Banca



Assinatura Membro 1 Banca Examinadora



Assinatura Membro 2 Banca Examinadora

Dedico este trabalho primeiramente a Deus que me guiou durante minha trajetória, aos meus pais que muito se esforçaram pela minha formação, a minha família, amigos e a todos que contribuíram de alguma forma.

AGRADECIMENTOS

Agradeço a Deus por ter me dado vida, saúde e capacidade para superar os desafios encontrados no decorrer de minha trajetória;

Ao Instituto Federal Goiano – Campus Ceres e a todos os seus servidores, pelas oportunidades, incentivos e contribuições na minha formação, que permitiram concluir o curso superior almejado e desenvolvimento do presente trabalho;

A todo corpo docente do IF Goiano – Campus Ceres, pelo apoio e conhecimento repassado no decorrer dos anos de curso, que tanto contribuíram na minha formação profissional e para realização deste trabalho;

Ao professor Dr. Henrique Fonseca Elias de Oliveira, pela coorientação, incentivo, apoio, confiança, contribuições e ensinamentos durante toda minha trajetória na iniciação científica e na realização deste trabalho;

Ao professor Dr. Wilian Henrique Diniz Buso, pela orientação no presente trabalho, ensinamentos no decorrer do curso, e contribuições em minha formação profissional;

A toda minha família e aos meus pais que foram peça chave neste processo, Robson Rosa de Castro e Nara Rúbia Vieira Tavares de Castro, aos quais graças a seus esforços, incentivo, conselhos, apoio e dedicação pude chegar até aqui;

Agradeço minha companheira pelo apoio, e também meus amigos, colegas e irmãos na amizade que fizeram parte da minha formação e continuarão a fazer parte da minha vida;

Meus sinceros agradecimentos a todos que diretamente ou indiretamente contribuíram na minha formação acadêmica e profissional, e também na realização do presente trabalho.

“O que sabemos é uma gota, o que ignoramos é um oceano”.

Isaac Newton

RESUMO

Com o advento da fotogrametria, amplamente utilizada na agricultura de precisão, atualmente é possível a predição da condição nutricional, fitossanitária e produtiva, de diferentes culturas de forma rápida, não destrutiva e com maior eficiência em relação às técnicas convencionais, utilizando-se para tal, imagens RGB ou multiespectrais captadas por câmeras específicas, embarcadas em veículos aéreos não tripulados ou mesmo em satélites. Neste contexto, o objetivo deste estudo foi avaliar a performance de oito índices de vegetação (Multiespectrais: *Normalized Difference Vegetation Index* (NDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge Index* (NDRE), *Modified Chlorophyll Absorption in Reflective Index* (MCARI), *Leaf Chlorophyll Index* (LCI) e *Structure Insensitive Pigment Index 2* (SIPI2); RGB: *Visible Atmospherically Resistant Index* (VARI) e *Triangular Greenness Index* (TGI)), na cultura do feijoeiro (*Phaseolus vulgaris* L.) submetido à aplicação de 4 doses de magnésio foliar (0, 250, 500 e 1000 g.ha⁻¹) em 2 diferentes estádios fenológicos (V4 – terceiro trifólio desenvolvido e R6 – floração plena). Foram estabelecidas correlações entre estes índices e as características da cultura analisadas “*in loco*”, em função dos tratamentos testados. O experimento foi realizado em uma área de pivô central e as imagens coletadas por um sensor multiespectral acoplado a um drone. Os dados foram submetidos a análises de regressão e a interação entre variáveis analisada pela significância estatística, coeficiente de correlação (r), coeficiente de determinação (R²) e raiz do erro quadrático médio (RMSE). Os índices de vegetação NDVI e MCARI se destacaram para predição da produtividade, ambos com r = 0,82 e RMSE de 330 e 329 kg.ha⁻¹ respectivamente. TGI teve o melhor desempenho em relação à altura de plantas (r = 0,73 e RMSE = 7,4 cm). O melhor índice para detecção do teor de clorofila foi MCARI (r = 0,81; R² = 0,66 e RMSE = 10,14), seguido por NDVI (r = 0,81; R² = 0,65 e RMSE = 10,19). O estágio fenológico com maior acurácia na estimativa das variáveis foi R9 (Maturação fisiológica) em seu início. GNDVI nas fases R6 e R9 e VARI na fase R9, foram significativos a 5% para doses de magnésio, os ajustes de regressão quadrática indicaram a melhor dose em 500 g.ha⁻¹.

Palavras-chave: RPAS. Sensoriamento remoto. Índices de vegetação. Reflectância. Nutrição.

ABSTRACT

With the advent of photogrammetry, widely used in precision agriculture, it is currently possible to predict the nutritional, phytosanitary and productive condition of different crops quickly, in a non-destructive way and with greater efficiency compared to conventional techniques, using RGB or multispectral images captured by specific cameras on board unmanned aerial vehicles or even satellites. In this context, the objective of this study was to evaluate the performance of eight vegetation indices (Multispectral: Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), Normalized Difference Red Edge Index (NDRE), Modified Chlorophyll Absorption in Reflective Index (MCARI), Leaf Chlorophyll Index (LCI) and Structure Insensitive Pigment Index 2 (SIPI2); RGB: Visible Atmospherically Resistant Index (VARI) and Triangular Greenness Index (TGI)), in the bean crop (*Phaseolus vulgaris* L.) subjected to the application of 4 foliar magnesium doses (0, 250, 500 and 1000 g.ha⁻¹) in two different growth stages (V4 - third developed trefoil and R6 - full flowering). Correlations were established between these indices and the characteristics of the crop analyzed "*in loco*", as a function of the treatments tested. The experiment was conducted in a central pivot area and the images collected by a multispectral sensor attached to a drone. The data were submitted to regression analysis and the interaction of variables analyzed by statistical significance, correlation coefficient (r) determination coefficient (R²) and root mean square error (RMSE). The NDVI and MCARI vegetation indices stood out for yield prediction, both with r = 0.82 and RMSE of 330 and 329 kg.ha⁻¹ respectively. TGI performed better for plant height (r = 0.73 and RMSE = 7.4 cm). The best index for detecting chlorophyll content was MCARI (r = 0.81; R² = 0.66 and RMSE = 10.14), followed by NDVI (r = 0.81; R² = 0.65 and RMSE = 10.19). The growth stage with the highest accuracy in estimating the variables was R9 (Physiological maturity) at its onset. GNDVI at R6 and R9 and VARI at R9, were significant at 5% for the treatment magnesium doses, the quadratic regression fits indicated the best dose at 500 g.ha⁻¹.

Keywords: RPAS. Remote sensing. Vegetation index. Reflectance. Nutrition.

LISTA DE ILUSTRAÇÕES

Figura 1 – Dados meteorológicos de temperatura mínima (T mín.), média (T méd.) e máxima (T máx.) e evapotranspiração (ET) em função dos dias após semeadura (DAS)	03
Figura 2 – Dados de umidade relativa do ar mínima (UR mín.), média (UR méd.) e máxima (UR máx.) em função dos dias após semeadura (DAS)	03
Figura 3 – Fluxograma da aquisição, processamento das imagens e obtenção de dados dos índices de vegetação	04
Figura 4 – Ortomosaicos em falsa cor, gerados a partir de imagens multiespectrais. (a) V4: Abertura completa do terceiro trifólio; (b) R5: Presença dos primeiros botões florais; (c) R6: Florescimento pleno; (d) R8: Enchimento de grãos; (e) R9: Senescência foliar e maturação fisiológica dos grãos. Área experimental demarcada pelo polígono na cor vermelha.....	05
Figura 5 – GNDVI e doses de magnésio no estágio fenológico R6.....	07
Figura 6 – GNDVI (a), VARI (b) e doses de magnésio no estágio fenológico R9.....	07
Figura 7 – Mapas de calor da matriz de correlação de Pearson para cada estágio fenológico de avaliação - V4 (a), R5 (b), R6 (c), R8 (d) e R9 (e) - indicando as combinações entre produtividade (Prod), altura de plantas (Alt), massa de mil grãos (MMG), vagens por planta (VPP), grãos por vagem (GPV), ramos por planta (RPP), e os índices de vegetação NDVI, GNDVI, NDRE, MCARI, LCI, SIPI2, VARI e TGI.....	13
Figura 8 – Histograma de distribuição dos dados (Diagonal), Correlação de Pearson (Parte superior direita) e gráfico de dispersão (Parte inferior esquerda) entre índices de vegetação e as variáveis: produtividade (Prod), altura de plantas (Alt), vagens por planta (VPP) e grãos por vagem (GPV)	14
Figura 9 – Regressão linear entre MCARI, VARI e TGI em relação ao teor clorofila para o estágio fenológico R5.....	15
Figura 10 – Gráficos de regressão linear entre teor de clorofila e índices de vegetação calculados (NDVI (a), GNDVI (b), MCARI (c), SIPI2 (d), NDRE (e), LCI (f), VARI (g) e TGI(h)) para o estágio R9	16
Figura 11 – Evolução temporal dos índices de vegetação no decorrer do ciclo da cultura do feijoeiro	18

LISTA DE TABELAS

Tabela 1 – Índices de vegetação, equações utilizando bandas espectrais e referências	06
Tabela 2 – Correlações entre índices de vegetação e produtividade para diferentes estádios fenológicos	08
Tabela 3 – Correlações entre índices de vegetação e altura de plantas para diferentes estádios fenológicos	09
Tabela 4 – Correlações entre índices de vegetação e número de vagens por planta para diferentes estádios fenológicos	10
Tabela 5 – Correlações entre índices de vegetação e número de grãos por vagem para diferentes estádios fenológicos	11
Tabela 6 – Correlações entre índices de vegetação e teor de clorofila para diferentes estádios fenológicos	15

SUMÁRIO

RESUMO.....	01
1. INTRODUÇÃO.....	01
2. MATERIAL E MÉTODOS	02
2.1 LOCAL DO ESTUDO E PRÁTICAS EXPERIMENTAIS	02
2.2 CARACTERÍSTICAS DE CAMPO ANALISADOS	04
2.3 AQUISIÇÃO E ANÁLISE DE IMAGENS.....	04
2.4 ÍNDICES DE VEGETAÇÃO	05
2.5 ANÁLISES ESTATÍSTICAS	06
3. RESULTADOS	07
3.1 RESPOSTA ESPECTRAL AOS TRATAMENTOS	07
3.2 PREDIÇÃO DOS COMPONENTES PRODUTIVOS.....	08
3.3 PREDIÇÃO DO TEOR DE CLOROFILA.....	14
3.4 VARIABILIDADE TEMPORAL DOS IVS	17
4. DISCUSSÃO	18
5. CONCLUSÕES	20
REFERÊNCIAS	21

Uso de imagens multiespectrais obtidas com RPAS na predição de parâmetros biofísicos da cultura do feijoeiro

Lucas Eduardo Vieira de Castro ^{1*}, Henrique Fonseca Elias de Oliveira ², Wilian Henrique Diniz Buso ²

¹ Bacharelado em Agronomia, Instituto Federal Goiano, Ceres, Goiás, Brasil; lucaseduardo171199@gmail.com

² Professor, Instituto Federal Goiano, Ceres, Goiás, Brasil; henrique.fonseca@ifgoiano.edu.br (H.F.E.O.); wilian.buso@ifgoiano.edu.br (W.H.D.B.)

* Correspondência: lucaseduardo171199@gmail.com Tel.: +55 62 99913-9104

Resumo: Com o advento da fotogrametria, amplamente utilizada na agricultura de precisão, atualmente é possível a predição da condição nutricional, fitossanitária e produtiva, de diferentes culturas de forma rápida, não destrutiva e com maior eficiência em relação às técnicas convencionais, utilizando-se para tal, imagens RGB ou multiespectrais captadas por câmeras específicas, embarcadas em veículos aéreos não tripulados ou mesmo em satélites. Neste contexto, o objetivo deste estudo foi avaliar a performance de oito índices de vegetação (Multiespectrais: *Normalized Difference Vegetation Index* (NDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge Index* (NDRE), *Modified Chlorophyll Absorption in Reflective Index* (MCARI), *Leaf Chlorophyll Index* (LCI) e *Structure Insensitive Pigment Index 2* (SIPI2); RGB: *Visible Atmospherically Resistant Index* (VARI) e *Triangular Greenness Index* (TGI)), na cultura do feijoeiro (*Phaseolus vulgaris* L.) submetido à aplicação de 4 doses de magnésio foliar (0, 250, 500 e 1000 g.ha⁻¹) em 2 diferentes estádios fenológicos (V4 – terceiro trifólio desenvolvido e R6 – floração plena). Foram estabelecidas correlações entre estes índices e as características da cultura analisadas “*in loco*”, em função dos tratamentos testados. O experimento foi realizado em uma área de pivô central e as imagens coletadas por um sensor multiespectral acoplado a um drone. Os dados foram submetidos a análises de regressão e a interação das variáveis analisada pela significância estatística, coeficiente de correlação (r), coeficiente de determinação (R²) e raiz do erro quadrático médio (RMSE). Os índices de vegetação NDVI e MCARI se destacaram para predição da produtividade, ambos com r = 0,82 e RMSE de 330 e 329 kg.ha⁻¹ respectivamente. TGI teve o melhor desempenho em relação à altura de plantas (r = 0,73 e RMSE = 7,4 cm). O melhor índice para detecção do teor de clorofila foi MCARI (r = 0,81; R² = 0,66 e RMSE = 10,14), seguido por NDVI (r = 0,81; R² = 0,65 e RMSE = 10,19). O estádio fenológico com maior acurácia na estimativa das variáveis foi R9 (Maturação fisiológica) em seu início. GNDVI nas fases R6 e R9 e VARI na fase R9, foram significativos a 5% para doses de magnésio, os ajustes de regressão quadrática indicaram a melhor dose em 500 g.ha⁻¹.

Palavras-chave: RPAS; Sensoriamento remoto; Índices de vegetação; Reflectância; Nutrição.

1. Introdução

O sensoriamento remoto, por meio da interação da radiação eletromagnética – planta – sensor, apresenta elevado potencial para identificação das condições dos cultivos agrícolas uma vez que permite avaliação não destrutiva, de forma rápida e com custo relativamente baixo. Esta ferramenta pode ser utilizada na definição de áreas de manejo específico, no manejo da adubação e irrigação das culturas, no controle de plantas daninhas e na estimativa de produtividade das safras agrícolas [1]. O sensoriamento remoto apresenta elevada importância prática, ajudando os produtores no gerenciamento de sua produção e também na definição de preço dos produtos agrícolas [2].

As ferramentas de sensoriamento remoto permitem a avaliação de características fisiológicas que são claramente relacionadas à produtividade da cultura e à adaptação ao

estresse em termos de aquisição de recursos [3]. Tudo indica que a próxima revolução agrícola será impulsionada pelo uso inteligente de dados que poderão impactar no aumento da produtividade e contribuir para a sustentabilidade ambiental por meio do uso racional dos recursos [4].

Neste contexto, sistemas de aeronave remotamente pilotada (*Remotely Piloted Aircraft System* - RPAS) tem ganhado cada vez mais espaço no setor agrícola, tal ferramenta pode ser definida como o conjunto de elementos composto por uma aeronave remotamente pilotada, sua respectiva estação de pilotagem remota, o enlace de pilotagem e quaisquer outros componentes necessários para operação [5]. Os RPAS quando integrados com sensores ópticos adequados podem ser uma ferramenta confiável para fenotipagem rápida em condições de campo. Os sensores a bordo podem capturar dados com alto rendimento e gerar vários gráficos em uma resolução espaço-temporal desejada [6].

A aplicação desta tecnologia na agricultura é favorecida por fatores como a redução dos custos e tamanho dos equipamentos, se comparada com ferramentas de sensoriamento convencionais. Vários sensores e índices de vegetação podem ser utilizados para o sensoriamento remoto de áreas agrícolas [7]. Dependendo do índice utilizado e do tipo de equipamento, a acurácia de estimativa do rendimento das culturas pode ser alterada.

São necessários estudos que indiquem os melhores índices e os estádios fenológicos de avaliação que apresentam a maior acurácia na estimativa dos atributos agrônômicos de cada cultura, garantindo a aplicação do sensoriamento remoto com maior precisão [1]. Neste cenário, destaca-se o feijoeiro (*Phaseolus vulgaris* L.), cuja produtividade ainda é baixa visto ser uma planta muito exigente em fertilidade do solo, devido ao ciclo curto e sistema radicular superficial e pouco desenvolvido. Por isso, é importante que os nutrientes estejam prontamente disponíveis para as plantas, de acordo com a demanda durante o ciclo [8], sendo o magnésio (Mg) um importante macronutriente para manutenção de altos índices produtivos.

A função mais conhecida do Mg nas plantas é como átomo central da molécula de clorofila e determina sua estrutura e funcionamento. Em quantidades adequadas, o magnésio pode desempenhar várias funções na planta, tais como: controle da turgidez celular, ativação de enzimas envolvidas na respiração e fotossíntese, regulação dos processos de abertura e fechamento de estômatos, transporte de carboidratos, transpiração, resistência à geada, seca, salinidade e às doenças, aumentar a resistência ao acamamento, além de estar diretamente associado à qualidade dos produtos agrícolas[9,10].

Neste sentido, o objetivo do presente trabalho foi avaliar a viabilidade e eficiência de índices de vegetação derivados de imagens multiespectrais, na avaliação das respostas do feijoeiro em relação a aplicação de magnésio via foliar em diferentes estádios fenológicos e doses. Além disso, testar estes índices para predição de parâmetros biofísicos da cultura e estabelecer correlações entre estes.

2. Materiais e Métodos

2.1 Local do estudo e práticas experimentais

O experimento foi conduzido de 17 de junho a 24 de setembro 2021, sob pivô central, na área experimental do Instituto Federal Goiano - Campus Ceres, Goiás, Brasil (UTM: zona 22, N 8.302.477, E 650.455, altitude ortométrica de 560 m), no cultivo de feijão, variedade BRS Estilo (hábito de crescimento indeterminado e ciclo médio de 90 a 100 dias). O solo local é classificado como Latossolo Vermelho [11,12].

Segundo classificação de Koppen [13], o clima local é Aw (Tropical úmido e seco), com inverno seco e verão chuvoso, temperatura média anual de 25 °C e média pluviométrica anual acima de 1.300 mm. Os dados climáticos foram registrados por uma

estação meteorológica móvel (Davis Vantage Pro2 Wireless). No período decorrente ao experimento não houve precipitações, as necessidades hídricas da cultura foram supridas via irrigação, as médias de temperatura, evapotranspiração e umidade relativa do ar foram de 22,86 °C, 4,19 mm e 59,43 % respectivamente (Figuras 1 e 2).

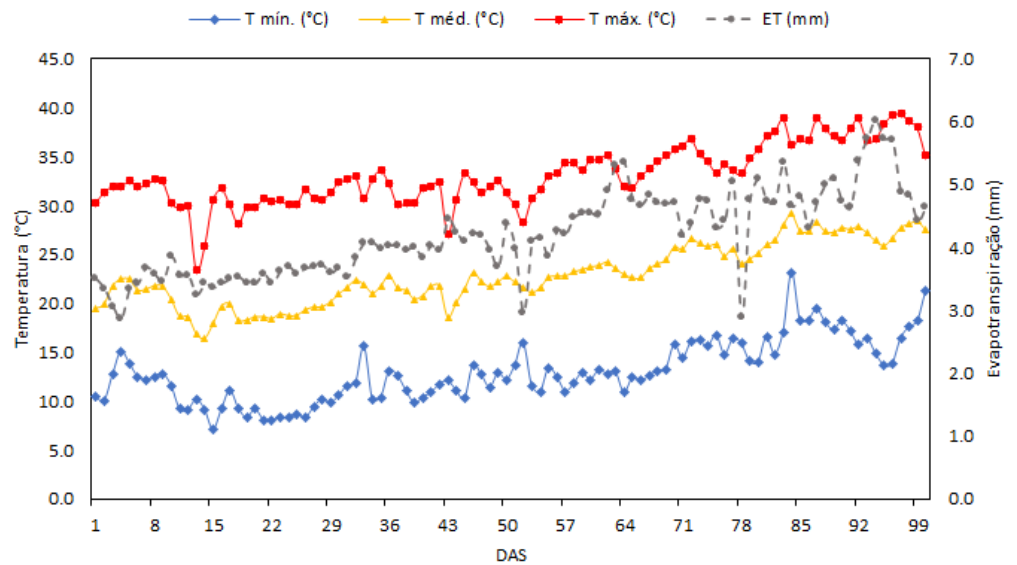


Figura 1. Dados meteorológicos de temperatura mínima (T mín.), média (T méd.) e máxima (T máx.) e evapotranspiração (ET) em função dos dias após semeadura (DAS).

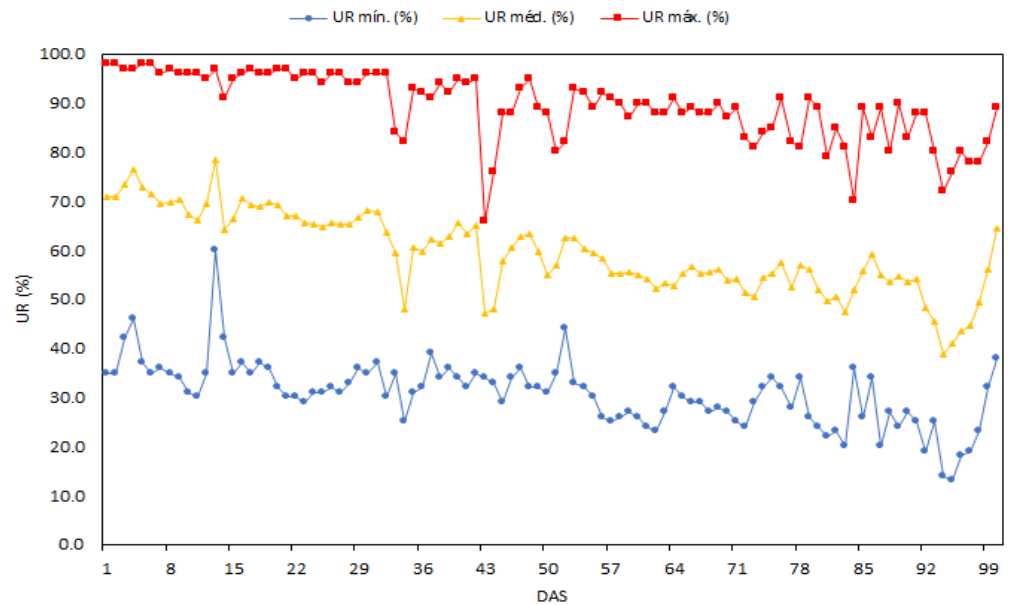


Figura 2. Dados de umidade relativa do ar mínima (UR mín.), média (UR méd.) e máxima (UR máx.) em função dos dias após semeadura (DAS).

O delineamento experimental utilizado foi em blocos ao acaso (DBC), em esquema fatorial 4x2, sendo os tratamentos quatro doses de magnésio (Sulfato de magnésio (MgSO₄)): 0, 250, 500 e 1000 g.ha⁻¹, aplicadas via foliar aos 27 e 56 dias após semeadura (DAS), correspondente a dois estádios fenológicos da cultura (V4 – terceiro trifólio desenvolvido e R6 – floração plena), sendo os momentos de aplicação citados os outros dois tratamentos. O experimento contou com quatro repetições (Blocos), cada uma com oito parcelas correspondentes aos respectivos tratamentos, totalizando assim 32 parcelas.

As parcelas foram compostas por oito linhas de 5,0 m de comprimento, espaçadas em 0,5 m (20 m²), contendo 12 sementes por metro linear (240.000 plantas.ha⁻¹). As avaliações realizadas nas linhas centrais, desprezando-se 0,5 m nas extremidades.

2.2. Características de campo analisados

O teor de clorofila foi determinado em três blocos, com um medidor portátil (Minolta, Mod. SPAD 502), analisando-se três plantas por parcela, selecionando folhas com coloração verde mais intensa e totalmente expandidas. As leituras foram realizadas aos 32, 47, 60, 74 e 89 DAS, correspondendo, respectivamente, as fases fenológicas V4 (Abertura completa do terceiro trifólio), R5 (Presença dos primeiros botões florais), R6 (Florescimento pleno), R8 (Enchimento de grãos) e início do estágio R9 (Senescência foliar e maturação fisiológica dos grãos), buscando assim contemplar todo ciclo da cultura após a primeira aplicação de magnésio. As duas primeiras avaliações contemplaram as parcelas correspondentes a aplicação na fase V4, a terceira e quarta todas as parcelas, e a quinta as parcelas correspondentes a aplicação no estágio R6.

Por ocasião da colheita aos 99 DAS, foi determinada a produtividade (kg.ha⁻¹), altura de plantas (cm) medindo-se o comprimento do ramo principal, massa de mil grãos (g), número de ramos por planta, vagens por planta e número de grãos por vagem.

2.3. Aquisição e análise de imagens

A Figura 3 demonstra um fluxograma que representa todo processo da aquisição das imagens até obtenção dos dados de interesse.

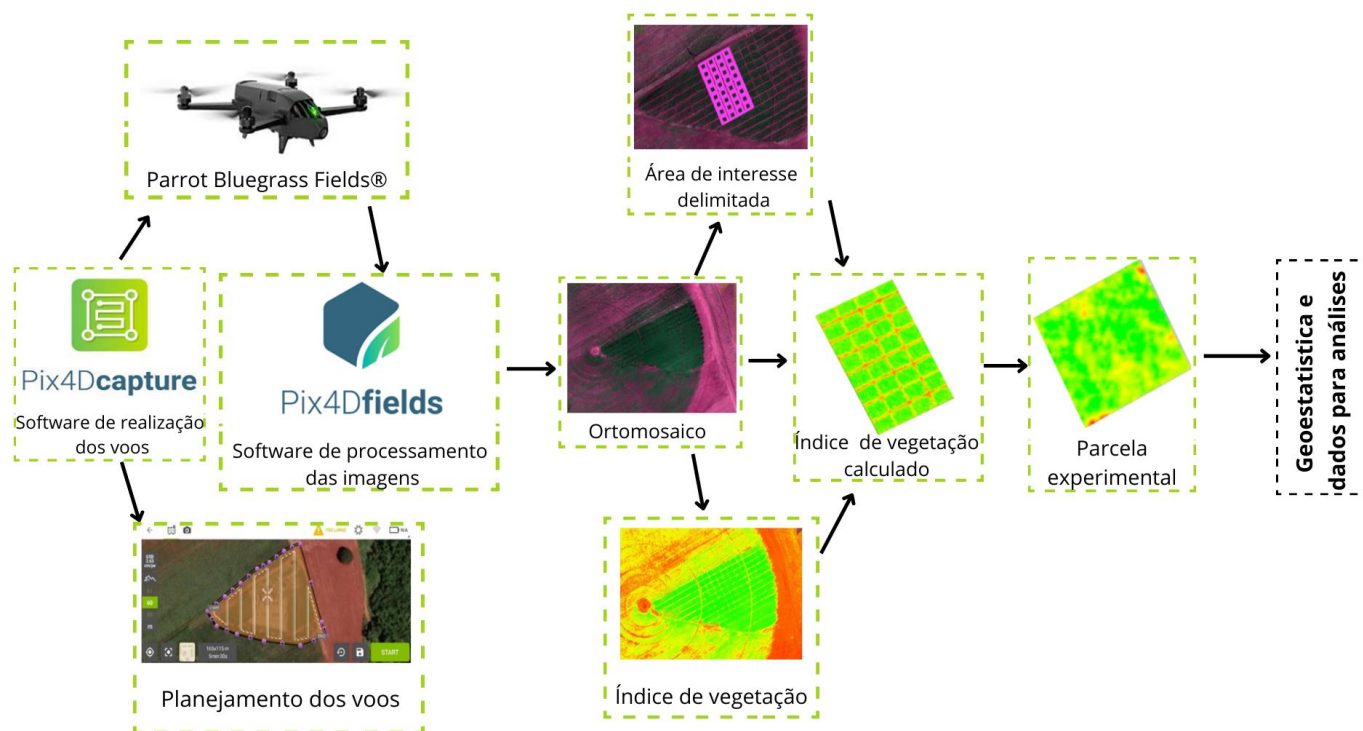


Figura 3. Fluxograma da aquisição e processamento das imagens e obtenção de dados dos índices de vegetação.

As imagens foram obtidas por um RPAS, sendo um drone multirrotor, modelo Parrot Bluegrass Fields® (Parrot Drones S.A, Paris, France), equipado com um sensor Parrot Sequoia® de mesmo fabricante, o qual coletou imagens RGB, no espectro visível (Red, Green e Blue (450 a 690 nm)) e multiespectrais em 4 diferentes bandas: Green (550 nm +/- 40 nm), Red (660 nm +/- 40 nm), RedEdge (735 nm +/- 10 nm) e NIR (790 nm +/- 40 nm). Este

tipo de sensor realiza a autocalibração radiométrica das imagens em tempo real, através de um sensor solar integrado a câmera.

Os voos foram realizados a uma altitude padrão de 60 m, sempre entre 11h00 e 13h00 no intuito de evitar a presença de sombras, com sobreposição frontal e lateral de 80%, resultando em resolução espacial entre 6,0 e 6,19 cm/pixel para imagens multiespectrais e 4,0 e 4,25 cm/pixel para imagens RGB. Os planos de voo foram planejados e executados com o software Pix4D Capture® (Pix4D SA, Lausanne, Switzerland), e as imagens processadas no software Pix4D Fields® (Pix4D SA, Lausanne, Switzerland), neste software foram gerados os ortomosaicos e dados geoestatísticos para análises posteriores. Para cada fase fenológica de interesse (V4, R5, R6, R8 e R9) foram gerados dois ortomosaicos, um a partir das imagens multiespectrais (Figura 4) e outro a partir das imagens RGB.




Figura 4. Ortomosaicos em falsa cor, gerados a partir de imagens multiespectrais. (a) V4: Abertura completa do terceiro trifólio; (b) R5: Presença dos primeiros botões florais; (c) R6: Florescimento pleno; (d) R8: Enchimento de grãos; (e) R9: Senescência foliar e maturação fisiológica dos grãos. Área experimental demarcada pelo polígono na cor vermelha.

2.4. Índices de vegetação

Em cada ortomosaico foram delimitadas áreas de 16 m² em cada parcela, descartando assim 4 m² de bordadura, posteriormente foram calculados e extraídos os índices de vegetação (Tabela 1), utilizando-se a média de cada índice por parcela para análises

posteriores. Os dados provenientes dos índices de vegetação serviram como variável para os tratamentos inseridos a campo, e foram correlacionados estatisticamente aos parâmetros biofísicos da cultura.

Tabela 1. Índices de vegetação, equações utilizando bandas espectrais e referências.

Índice de vegetação	Sigla	Equação	Referência
<i>Normalized Difference Vegetation Index</i>	NDVI	$\frac{pNIR - pRed}{pNIR + pRed}$	[14]
<i>Green Normalized Difference Vegetation Index</i>	GNDVI	$\frac{pNIR - pGreen}{pNIR + pGreen}$	[15]
<i>Normalized Difference Red Edge Index</i>	NDRE	$\frac{pNIR - pRedEdge}{pNIR + pRedEdge}$	[16]
<i>Modified Chlorophyll Absorption in Reflective Index</i>	MCARI	$\frac{[(p700 - p670) - 0,2(p700 - p550)]p700}{p670}$	[17]
<i>Leaf Chlorophyll Index</i>	LCI	$\frac{pNIR - pRedEdge}{pNIR + pRed}$	[18]
<i>Structure Insensitive Pigment Index 2</i>	SIPI2	$\frac{pNIR - pGreen}{pNIR - pRed}$	[19]
<i>Visible Atmospherically Resistant Index</i>	VARI	$\frac{pGreen - pRed}{pGreen + pRed - pBlue}$	[20]
<i>Triangular Greenness Index</i>	TGI	$pGreen - 0,39pRed - 0,61pBlue$	[21]

p indica a reflectância em cada uma das bandas em nm (nanômetros).

2.5. Análises estatísticas

Os dados foram submetidos à análise de variância e regressão a 5% de probabilidade de erro (*p*-valor < 0,05), foi verificada a ausência de *outliers* e a normalidade dos resíduos pelo teste de Shapiro-Wilk. Para prever a acurácia dos modelos utilizou-se raiz do erro quadrático médio (*Root Mean Squared Error* – RMSE), coeficiente de correlação (*r*) e coeficiente de determinação (*R*²), conforme Equações (1), (2) e (3), respectivamente.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_i - X_i)^2}{N}} \quad (1)$$

em que, *N* = número de amostras, *Y_i* = valores preditos e *X_i* = valores observados.

$$r = \frac{\sum (X_i - X_m)(Y_i - Y_m)}{\sqrt{\sum (X_i - X_m)^2} \sqrt{\sum (Y_i - Y_m)^2}} \quad (2)$$

em que, *X_i* = valores da variável *x*, *X_m* = média dos valores de *x*, *Y_i* = valores da variável *y* e *Y_m* = média dos valores de *y*.

$$R^2 = \frac{SQR}{SQT} \quad (3)$$

em que, SQR = soma dos quadrados da regressão e STQ = soma total dos quadrados.


Modelos com coeficientes de regressão significativos, além de maiores valores de r , R^2 e menores RMSE predizem com maior acurácia os resultados de campo. O RMSE é usado para expressar a precisão dos modelos, tendo como vantagem os valores de erro nas mesmas dimensões da variável analisada [22]. Classificaram-se os modelos, conforme a magnitude da correlação: fraca ou desprezível ($-0,40 < r < 0,40$), moderada ($0,40 < r < 0,70$; valores positivos ou negativos) e forte ($r > 0,70$; valores positivos ou negativos) [23,24].

Todas as análises estatísticas foram realizadas no software R (versão 4.2.1) e RStudio (versão 7.2). Cada parcela foi inserida nos modelos, totalizando 32 amostras para variáveis produtivas e 32 amostras em cada estágio fenológico para os índices de vegetação. Para teor de clorofila foram 12 amostras em V4, R5 e R9, e 24 amostras em R6 e R8, considerando os tratamentos que foram avaliados em cada uma destas fases e que as leituras se limitaram a três blocos.

3. Resultados

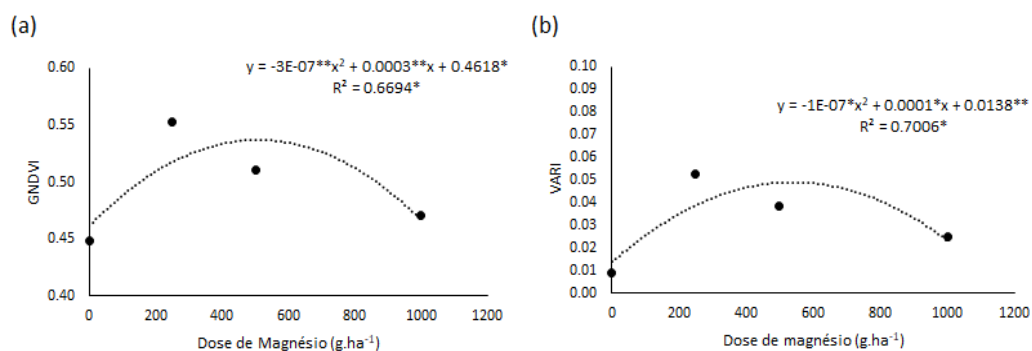
3.1. Resposta espectral aos tratamentos

Entre os índices de vegetação (IVs), GNDVI e VARI foram os mais sensíveis em relação as diferentes doses de magnésio, ambos com ajuste para modelo de regressão quadrática, com base nos coeficientes de regressão (Figuras 5 e 6). GNDVI foi significativo a 1% em R6 e a 5% em R9, com coeficientes de variância (CV) de 1,43% e 16,03 % respectivamente. VARI teve significância a 5% no estágio R9 e CV de 2,83 %. Demais índices de vegetação não foram significativos a 5% para nenhum dos tratamentos, considerando todas as avaliações.



**Significativo a 1% de probabilidade de erro.

Figura 5. GNDVI e doses de magnésio no estágio fenológico R6.



**Significativo a 1% de probabilidade de erro, *significativo a 5% de probabilidade de erro.

Figura 6. GNDVI (a), VARI (b) e doses de magnésio no estágio fenológico R9.

As curvas de regressão apresentaram coeficientes de determinação próximos de 1, com R² de 0,80 em R6 e 0,66 em R9 para GNDVI e R² de 0,70 para VARI em R9. Os IVs GNDVI em R6 e R9, e VARI em R9, indicaram 500 g.ha⁻¹ de magnésio como a melhor dose. Os valores referentes aos IVs não diferiram significativamente entre as aplicações de magnésio nos diferentes estádios fenológicos, apresentando resultados semelhantes para ambos, e com médias pouco superiores para R6 nas avaliações feitas em R8 e R9. Também houve significância (p-valor < 0,01) para altura de plantas em relação a este tratamento, sob modelo de regressão quadrática, com R² = 0,96 e melhor dose em 504,1 g.ha⁻¹.

3.2 Predição dos componentes produtivos

As melhores correlações e eficiência dos modelos de regressão foram encontrados em relação a produtividade (kg.ha⁻¹), para qual houve significância estatística para pelo menos um dos IVs em todos os estádios fenológicos avaliados (Tabela 2).

Tabela 2. Correlações entre índices de vegetação e produtividade para diferentes estádios fenológicos.

IVs	Estádio Fenológico									
	V4		R5		R6		R8		R9	
	r	RMSE	r	RMSE	r	RMSE	r	RMSE	R	RMSE
NDVI	-0,34 ^{ns}	538	0,17 ^{ns}	564	0,26 ^{ns}	553	0,30 ^{ns}	544	0,82 ^{**}	330
GNDVI	-0,16 ^{ns}	565	0,19 ^{ns}	562	0,58 ^{**}	465	0,09 ^{ns}	570	0,78 ^{**}	355
NDRE	-0,25 ^{ns}	554	0,20 ^{ns}	560	0,45 ^{**}	510	0,03 ^{ns}	571	0,75 ^{**}	379
MCARI	-0,37 [*]	532	0,26 ^{ns}	552	0,36 [*]	533	0,37 [*]	530	0,82 ^{**}	329
LCI	-0,08 ^{ns}	570	0,22 ^{ns}	558	0,34 ^{ns}	538	-0,02 ^{ns}	572	0,75 ^{**}	376
SIPI2	-0,33 ^{ns}	540	0,18 ^{ns}	562	0,24 ^{ns}	555	-0,06 ^{ns}	571	-0,60 ^{**}	459
VARI	-0,06 ^{ns}	571	0,49 ^{**}	498	0,44 [*]	512	-0,08 ^{ns}	570	0,67 ^{**}	423
TGI	-0,34 ^{ns}	538	0,10 ^{ns}	569	-0,21 ^{ns}	558	0,09 ^{ns}	569	0,74 ^{**}	385

^{**}Significativo a 1% de probabilidade de erro, ^{*}significativo a 5% de probabilidade de erro, ^{ns}não significativo.

r: coeficiente de correlação de Pearson e RMSE: raiz quadrada do erro médio.

Todos os índices foram significativos a 1% em relação a produtividade em R9. VARI e SIPI2 apresentaram coeficiente de correlação moderado, este segundo sendo inversamente proporcional a variável analisada (r = -0,60). Os demais IVs expressaram coeficientes de correlação fortes e positivos. MCARI e NDVI apresentaram o melhor desempenho (r = 0,82), com RMSE abaixo de 331 kg.ha⁻¹, as Equações (4) e (5) representam os modelos de regressão linear destes índices para predição da produtividade nesta fase. Na sequência os mais eficientes foram GNDVI, LCI, NDRE e TGI com valores de r entre 0,74 e 0,78, e RMSE entre 355 e 385 kg.ha⁻¹, os modelos são expressos pelas equações (6), (7), (8) e (9) respectivamente.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 2.946(x) + 936,5 \quad (4)$$

em que, x = valor referente a MCARI.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 4.195,4(x) + 677,5 \quad (5)$$

em que, x = valor referente a NDVI.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 5.620,7 (x) + 277,4 \quad (6)$$

em que, x = valor referente a GNDVI.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 9.753 (x) + 2.279 \quad (7)$$

em que, x = valor referente a LCI.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 15.575 (x) + 2.247 \quad (8)$$

em que, x = valor referente a NDRE.

$$\text{Produtividade (Kg.ha}^{-1}\text{)} = 21.159 (x) + 1.571 \quad (9)$$

em que, x = valor referente a TGI.

Os IVs apresentaram coeficientes de correlação negativos no estágio V4, o que indica uma proporção inversa entre estes e a variável analisada, apenas MCARI apresentou correlação significativa, porém fraca ($r = -0,37$). Houve correlações significativas para GNDVI, NDRE, MCARI e VARI nos estádios R5, R6 e R8, todas sendo moderadas ou fracas, entre 0,36 e 0,58. Nestas fases todas as parcelas apresentaram alto vigor vegetativo e cobertura do dossel, onde os IVs atingiram seu pico. Vários autores relatam saturação de determinados IVs, em especial NDVI [25], quando atingem valores mais altos.

No geral, MCARI teve a maior eficiência na predição da produtividade com maiores valores de r e menores de RMSE, sendo significativo a 5% em V4, R6 e R8 e também a 1% em R9. Vale ressaltar que GNDVI e NDRE, além de R9 também foram significativos em R6 a 1%. Com correlações classificadas como moderadas, VARI foi significativo em R5, R6 e R9.

Conforme explicito na Tabela 3, os IVs também foram melhor correlacionados a altura de plantas final em R9, onde todos foram significativos (p -valor < 0,01), os coeficientes de correlação foram maiores e o RMSE menor.

Tabela 3. Correlações entre índices de vegetação e altura de plantas para diferentes estádios fenológicos.

IVs	Estádio Fenológico									
	V4		R5		R6		R8		R9	
	r	RMSE	r	RMSE	r	RMSE	r	RMSE	r	RMSE
NDVI	-0,23 ^{ns}	10,6	0,13 ^{ns}	10,8	0,27 ^{ns}	10,5	0,14 ^{ns}	10,8	0,64 ^{**}	8,3
GNDVI	-0,04 ^{ns}	10,9	0,17 ^{ns}	10,8	0,52 ^{**}	9,4	-0,05 ^{ns}	10,9	0,63 ^{**}	8,5
NDRE	-0,31 ^{ns}	10,4	0,16 ^{ns}	10,8	0,43 [*]	9,9	-0,16 ^{ns}	10,8	0,59 ^{**}	8,8
MCARI	-0,25 ^{ns}	10,6	0,24 ^{ns}	10,6	0,29 ^{ns}	10,5	0,40 [*]	10,0	0,65 ^{**}	8,3
LCI	-0,08 ^{ns}	10,9	-0,07 ^{ns}	10,9	0,41 [*]	10,0	-0,18 ^{ns}	10,8	0,60 ^{**}	8,7
SIPI2	-0,38 [*]	10,1	0,17 ^{ns}	10,8	0,29 ^{ns}	10,5	-0,23 ^{ns}	10,6	-0,47 ^{**}	9,7
VARI	0,17 ^{ns}	10,8	0,40 [*]	10,0	0,57 ^{**}	9,0	0,13 ^{ns}	10,9	0,64 ^{**}	8,4
TGI	-0,14 ^{ns}	10,8	0,22 ^{ns}	10,7	-0,12 ^{ns}	10,9	0,19 ^{ns}	10,8	0,73 ^{**}	7,4

^{**}Significativo a 1% de probabilidade de erro, ^{*}significativo a 5% de probabilidade de erro, ^{ns}não significativo.

r: coeficiente de correlação de Pearson e RMSE: raiz quadrada do erro médio.

TGI foi o único a apresentar uma forte correlação ($r = 0,73$) em R9 com menor RMSE (7,4 cm), a Equação (10) expressa o modelo de regressão linear para predição da altura de plantas por este IV. Quille-Mamani *et al.* (2021) também encontrou forte correlação entre índices de vegetação derivados de imagens RGB e altura de plantas do feijoeiro [26]. Com exceção de SIPI2, que teve o menor ajuste em relação aos demais e correlação negativa ($r = -0,47$ e $RMSE = 9,7$ cm), os demais IVs expressaram correlação moderada positiva ($0,59 < r < 0,65$; $8,3 < RMSE < 8,8$ cm), indicando viabilidade dos IVs na predição da altura de plantas, resultado semelhante ao que foi encontrado para produtividade.

$$\text{Altura de plantas (cm)} = 403,86(x) + 72,21 \quad (10)$$

em que, x = valor referente a TGI.

Apenas SIPI2 foi significativo em V4 e VARI o único em R5, todas as correlações em ambos os estádios fenológicos podem ser consideradas fracas. Os IVs VARI e GNDVI foram significativos a 1% em R6, já NDRE e LCI a 5%, com valores de r entre 0,41 e 0,57 e RMSE entre 9 e 10cm. MCARI foi o único IV significativo (p -valor $< 0,05$) em R8, porém com coeficiente de correlação de 0,40. O índice VARI teve o melhor desempenho em relação aos demais nos estádios fenológicos avaliados precedentes ao último, porém em R9 teve desempenho inferior a NDVI, MCARI e TGI, este último sendo de maior destaque, os modelos de regressão linear para predição desta variável por MCARI, NDVI e VARI são descritos pelas Equações (11), (12) e (13) respectivamente.

$$\text{Altura de plantas (cm)} = 45,18(x) + 68,09 \quad (11)$$

em que, x = valor referente a MCARI.

$$\text{Altura de plantas (cm)} = 63,51(x) + 64,59 \quad (12)$$

em que, x = valor referente a NDVI.

$$\text{Altura de plantas (cm)} = 200,87(x) + 94,45 \quad (13)$$

em que, x = valor referente a VARI.

Conforme Tabela 4, para número de vagens por planta, não houve fortes correlações ($r > 0,7$) com os índices de vegetação em nenhum estágio fenológico, com valores de r acima de 0,5 somente em R9, houve correlações moderadas e significativas a 1% nesta fase e a 5% no restante, com exceção de R5

Coefficientes de correlação acima de 0,6 foram encontrados somente para os índices GNDVI, NDVI, LCI, NDRE e MCARI, os respectivos modelos de regressão linear para predição desta variável são descritos pelas Equações (14), (15), (16), (17) e (18).

$$\text{N}^\circ \text{ de vagens por planta} = 42,587(x) + 5,348 \quad (14)$$

em que, x = valor referente a GNDVI.

$$\text{N}^\circ \text{ de vagens por planta} = 29,510(x) + 9,676 \quad (15)$$

em que, x = valor referente a NDVI.

$$\text{N}^\circ \text{ de vagens por planta} = 73,58(x) + 20,54 \quad (16)$$

em que, x = valor referente a LCI.

$$\text{N}^\circ \text{ de vagens por planta} = 117,5(x) + 20,3 \quad (17)$$

em que, x = valor referente a NDRE.

$$\text{N}^\circ \text{ de vagens por planta} = 19,81(x) + 12,16 \quad (18)$$

em que, x = valor referente a MCARI.

Tabela 4. Correlações entre índices de vegetação e número de vagens por planta para diferentes estádios fenológicos.

IVs	Estádio Fenológico									
	V4		R5		R6		R8		R9	
	R	RMSE	r	RMSE	r	RMSE	r	RMSE	r	RMSE
NDVI	-0,34 ^{ns}	4,9	-0,07 ^{ns}	5,2	0,22 ^{ns}	5,1	0,14 ^{ns}	5,2	0,62 ^{**}	4,1
GNDVI	-0,40 [*]	4,8	-0,08 ^{ns}	5,2	0,44 [*]	4,7	0,12 ^{ns}	5,2	0,64 ^{**}	4,0
NDRE	-0,28 ^{ns}	5,0	0,27 ^{ns}	5,0	0,23 ^{ns}	5,1	0,08 ^{ns}	5,2	0,61 ^{**}	4,1
MCARI	-0,29 ^{ns}	5,0	0,02 ^{ns}	5,2	0,20 ^{ns}	5,1	0,38 [*]	4,8	0,60 ^{**}	4,1
LCI	-0,14 ^{ns}	5,2	0,30 ^{ns}	5,0	0,27 ^{ns}	5,0	0,04 ^{ns}	5,2	0,62 ^{**}	4,1
SIPI2	-0,45 ^{**}	4,7	-0,18 ^{ns}	5,1	0,39 [*]	4,8	0,16 ^{ns}	5,2	-0,19 ^{ns}	5,1
VARI	0,05 ^{ns}	5,2	0,18 ^{ns}	5,1	0,25 ^{ns}	5,1	0,06 ^{ns}	5,2	0,53 ^{**}	4,3
TGI	-0,10 ^{ns}	5,19	0,05 ^{ns}	5,2	-0,29 ^{ns}	5,0	-0,03 ^{ns}	5,2	0,50 ^{**}	4,5

^{**}Significativo a 1% de probabilidade de erro, ^{*}significativo a 5% de probabilidade de erro, ^{ns}não significativo.

r: coeficiente de correlação de Pearson e RMSE: raiz quadrada do erro médio.

O índice de vegetação que melhor descreveu esta variável foi GNDVI, este foi significativo em V4, R6 e R9, além de ter o maior valor de r e menor RMSE em relação aos demais em R6 e R9. Além de GNDVI, SIPI2 foi significativo em V4 e R6, e MCARI em R8. Nos estádios que antecedem R9, no qual as vagens já estavam formadas, as correlações foram fracas ou moderadas. Semelhante ao que foi observado em outras variáveis, SIPI2 foi o único índice com coeficiente de correlação negativo, e com menor grau em R9, sendo também não significativo e de correlação considerada fraca na predição do número de vagens.

Com exceção de SIPI2, os índices de vegetação derivados de bandas multiespectrais apresentaram melhor desempenho, considerando que GNDVI, NDVI, NDRE, LCI e MCARI expressaram coeficientes de correlação superiores a 0,60 e RMSE entre 4 e 4,1; enquanto VARI e TGI, coeficientes de correlação inferiores a 0,54 e RMSE entre 4,3 e 4,5.

Não houve nenhuma forte correlação ($r > 0,7$) para o número de grãos por vagem em nenhum estágio fenológico, entre aquelas significativas a maioria é classificada como moderada, com valores de r entre 0,36 e 0,68; o que denota pouca eficiência dos modelos na predição desta variável nas condições estudadas. Na Tabela 5 é possível observar os coeficientes de correlação (r), RMSE e a significância de cada IV por estágio fenológico.

Os melhores ajustes foram encontrados para SIPI2 e VARI em R5 (RMSE = 0,7 e $r = 0,68$ e $0,66$ respectivamente), as Equações (15) e (16) correspondem aos respectivos modelos de regressão linear. MCARI foi o único IV com correlação moderada e significativa em R8 ($r = 0,44$), ao passo que também foi significativo em R5, R6 e R9, com valores de r entre 0,56 e 0,58 e RMSE = 0,8. Pode-se observar que nos estádios fenológicos V4 e R8 os ajustes foram inferiores aos demais.

$$\text{N}^\circ \text{ de grãos por vagem} = 15,516(x) - 5,592 \quad (19)$$

em que, x = valor referente a SIPI2.

$$\text{N}^\circ \text{ de grãos por vagem} = 21,32(x) + 9,42 \quad (20)$$

em que, x = valor referente a VARI.

Tabela 5. Correlações entre índices de vegetação e número de grãos por vagem para diferentes estádios fenológicos.

IVs	Estádio Fenológico									
	V4		R5		R6		R8		R9	
	R	RMSE	r	RMSE	r	RMSE	r	RMSE	r	RMSE
NDVI	0,09 ^{ns}	1,0	0,52**	0,8	0,47**	0,9	0,25 ^{ns}	1,0	0,53**	0,8
GNDVI	0,22 ^{ns}	0,9	0,37*	0,9	0,52**	0,8	-0,05 ^{ns}	1,0	0,47**	0,9
NDRE	-0,11 ^{ns}	1,0	-0,22 ^{ns}	1,0	0,53**	0,8	-0,01 ^{ns}	1,0	0,40*	0,9
MCARI	0,04 ^{ns}	1,0	0,56**	0,8	0,58**	0,8	0,44*	0,9	0,57**	0,8
LCI	-0,10 ^{ns}	1,0	-0,22 ^{ns}	1,0	0,45**	0,8	-0,03 ^{ns}	1,0	0,45**	0,9
SIPI2	0,08 ^{ns}	1,0	0,68**	0,7	0,08 ^{ns}	1,0	-0,14 ^{ns}	1,0	-0,52**	0,8
VARI	0,29 ^{ns}	0,9	0,66**	0,7	0,53**	0,8	0,13 ^{ns}	1,0	0,51**	0,8
TGI	0,03 ^{ns}	1,0	0,21 ^{ns}	1,0	0,09 ^{ns}	1,0	0,39*	0,9	0,55**	0,8

**Significativo a 1% de probabilidade de erro, *significativo a 5% de probabilidade de erro, ^{ns} não significativo.

r: coeficiente de correlação de Pearson e RMSE: raiz quadrada do erro médio.

Os IVs LCI na fase V4 e NDVI e SIPI2 na fase R8, foram significativas a 5% de probabilidade ($p < 0,05$) para as regressões lineares correspondentes a massa de mil grãos, com coeficientes de correlação de -0,42; 0,39 e 0,35 e RMSE de 18,6; 18,9 e 19,2 g respectivamente. No geral, esta variável apresentou apenas correlações fracas com os índices de vegetação em todas as avaliações.

NDRE apresentou a única correlação significativa a 5% para número de ramos por planta, na fase R5 ($r = -0,37$), com valor de $r < 0$, indicando relação inversa entre as variáveis apesar de ser significativa. Assim como massa de mil grãos, esta variável também não apresentou correlações significativas na maioria das amostras, todas sendo classificadas como fracas ($r < 0,40$).

Para melhor visualização das correlações entre os índices de vegetação e as variáveis correspondentes aos componentes produtivos, na Figura 7 são representados mapas de calor com a matriz de correlação de Pearson com todas as combinações possíveis entre os índices de vegetação e os componentes produtivos em cada estágio fenológico.

O estágio V4 apresentou as correlações mais fracas, muitas destas inversas, entre os índices de vegetação e demais variáveis, provavelmente devido forte interferência do solo na reflectância. Os ajustes tiveram certa progressão até o estágio R6, diminuindo em R8, o que pode ser explicado pela uniformidade do dossel vegetativo, diminuição da variância entre parcelas, e saturação de alguns IVs, apresentando nesta fase os valores máximos em todo ciclo.

O melhor período para predição dos parâmetros analisados foi no início de R9, quando as plantas iniciaram o processo de senescência e maturação dos grãos, onde foram encontrados os melhores ajustes, com fortes coeficientes de correlação tanto entre os próprios IVs como entre estes e demais variáveis (Figura 7 (e)). SIPI2 foi o único índice a ter valores negativos de r com todas as outras variáveis.

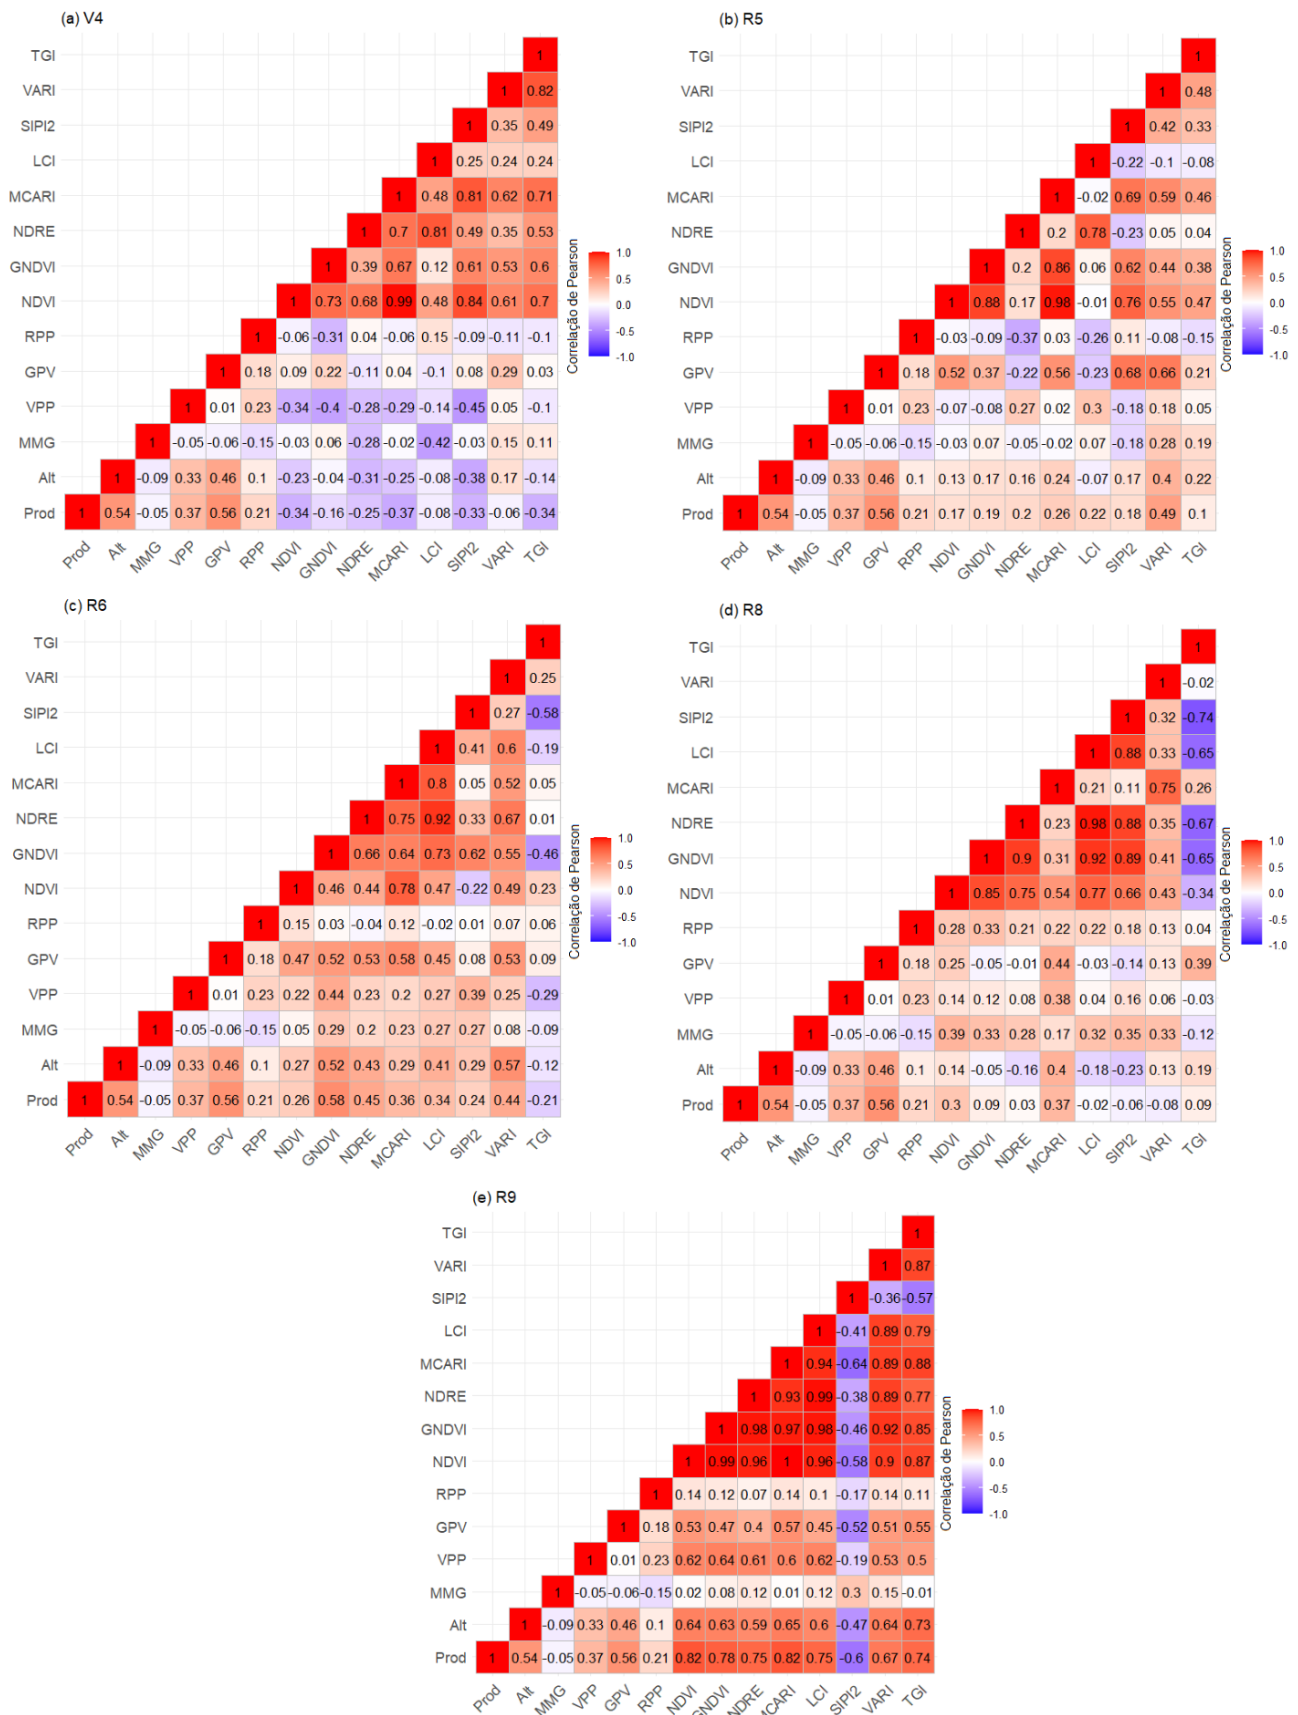
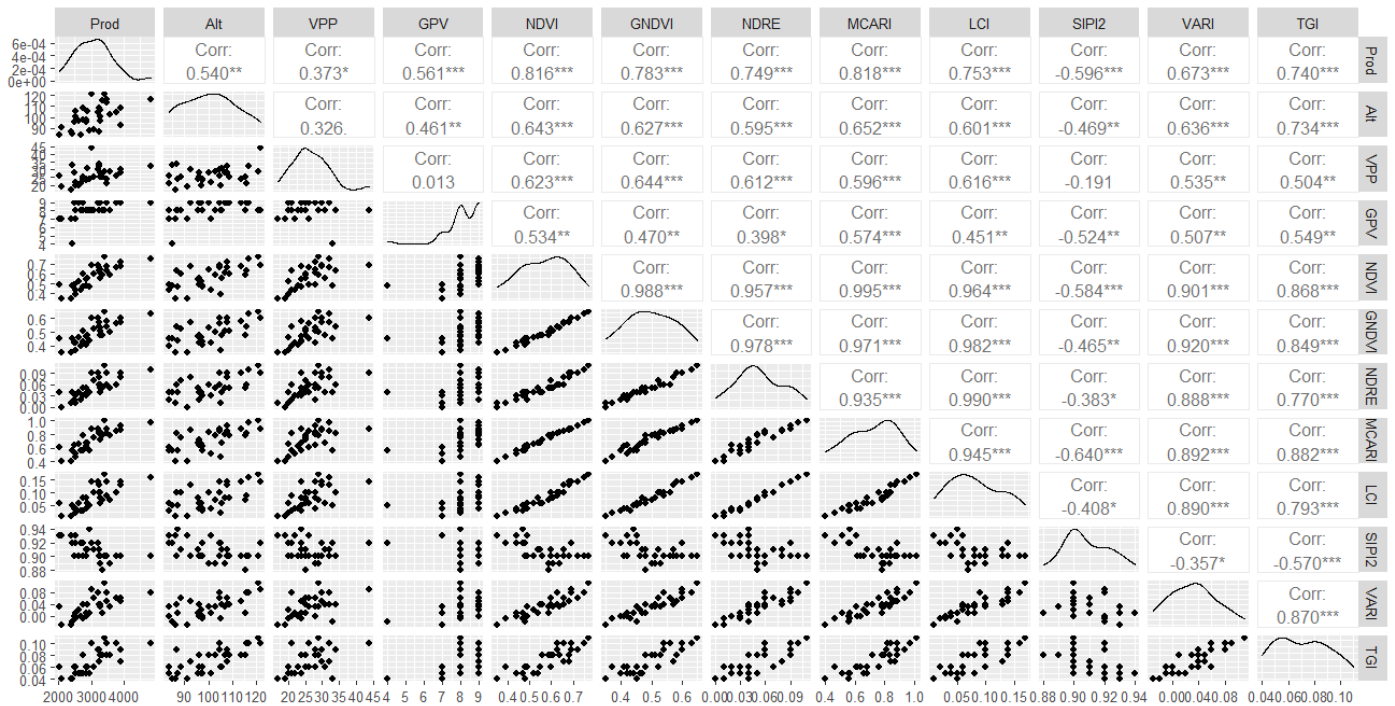


Figura 7. Mapas de calor da matriz de correlação de Pearson para cada estágio fenológico de avaliação - V4 (a), R5 (b), R6 (c), R8 (d) e R9 (e) - indicando as combinações entre produtividade (Prod), altura de plantas (Alt), massa de mil grãos (MMG), vagens por planta (VPP), grãos por vagem (GPV), ramos por planta (RPP), e os índices de vegetação NDVI, GNDVI, NDRE, MCARI, LCI, SIPI2, VARI e TGI.

Produtividade foi a variável com melhor predição pelos índices de vegetação, seguida por altura de plantas. Número de vagens por planta e grãos por vagem expressaram correlações moderadas, porém com menores coeficientes de correlação. No estágio de melhor desempenho dos modelos (R9), estas variáveis apresentaram correlações fortes ou moderadas, com menor RMSE, e proximidade dos dados observados com os preditos pela regressão linear (Figura 8). Não houve boa precisão dos modelos para predição da massa de mil grãos e número de ramos por planta como abordado anteriormente.



***Significativo a 0,1 % de probabilidade de erro, **Significativo a 1% de probabilidade de erro, *significativo a 5% de probabilidade de erro.

Figura 8. Histograma de distribuição dos dados (Diagonal), Correlação de Pearson (Parte superior direita) e gráfico de dispersão (Parte inferior esquerda) entre índices de vegetação e as variáveis: produtividade (Prod), altura de plantas (Alt), vagens por planta (VPP) e grãos por vagem (GPV).

Conforme demonstrado na Figura 8, as correlações entre IVs de maior significância estatística e r mais próximo de 1,0 ($0,93 < r < 0,99$), se deram entre os índices de vegetação derivados de bandas multiespectrais, com exceção de SIPI2, que apresentou relação inversa aos demais e coeficientes de correlação menores que 0,64. Os IVs extraídos de imagens RGB demonstraram forte correlação entre si ($r = 0,87$) e também com os índices NDVI, GNDVI, NDRE, MCARI e LCI ($0,77 < r < 0,92$), sendo que VARI se correlacionou com maior significância a estes índices do que TGI.

3.3 Predição do teor de clorofila


Na Tabela 6 é possível observar que os IVs não apresentaram correlação significativa ($p < 0,05$) com teor de clorofila nas fases V4, R6 e R8. Para a fase R5 houve correlação moderada e significativa a 5% com os índices MCARI ($r = 0,60$), VARI ($r = 0,61$) e TGI ($r = 0,57$). VARI apresentou o menor RMSE (16,76) e maior coeficiente de correlação, e consequentemente o modelo de melhor ajuste. Na Figura 9 é possível observar a dispersão dos dados, o RMSE, a equação e coeficiente de determinação da reta (R^2) para os IVs citados.

Tabela 6. Correlações entre índices de vegetação e teor de clorofila para diferentes estádios fenológicos.

IVs	Estádio Fenológico									
	V4		R5		R6		R8		R9	
	r	RMSE	r	RMSE	r	RMSE	r	RMSE	r	RMSE
NDVI	-0,21 ^{ns}	4,35	0,41 ^{ns}	19,31	-0,02 ^{ns}	18,60	0,29 ^{ns}	23,43	0,81 ^{**}	10,19
GNDVI	-0,14 ^{ns}	4,35	0,19 ^{ns}	20,80	-0,11 ^{ns}	18,49	0,04 ^{ns}	24,51	0,78 ^{**}	10,72
NDRE	0,04 ^{ns}	4,35	0,45 ^{ns}	18,89	-0,05 ^{ns}	18,60	0,12 ^{ns}	24,35	0,79 ^{**}	10,58
MCARI	-0,16 ^{ns}	4,35	0,60 [*]	16,85	0,13 ^{ns}	18,46	0,24 ^{ns}	23,76	0,81 ^{**}	10,14
LCI	-0,03 ^{ns}	4,35	0,40 ^{ns}	19,41	0,12 ^{ns}	18,46	0,11 ^{ns}	24,39	0,79 ^{**}	10,58
SIPI2	-0,12 ^{ns}	4,35	-0,04 ^{ns}	21,21	-0,005 ^{ns}	18,60	0,14 ^{ns}	24,28	-0,48 ^{ns}	15,16
VARI	-0,17 ^{ns}	4,35	0,61 [*]	16,76	0,09 ^{ns}	18,52	0,25 ^{ns}	23,68	0,77 ^{**}	10,90
TGI	0,15 ^{ns}	4,35	0,57 [*]	17,32	0,18 ^{ns}	18,27	0,05 ^{ns}	24,49	0,59 [*]	14,03

^{**}Significativo a 1% de probabilidade de erro, ^{*}significativo a 5% de probabilidade de erro, ^{ns}não significativo.

r: coeficiente de correlação de Pearson e RMSE: raiz quadrada do erro médio.

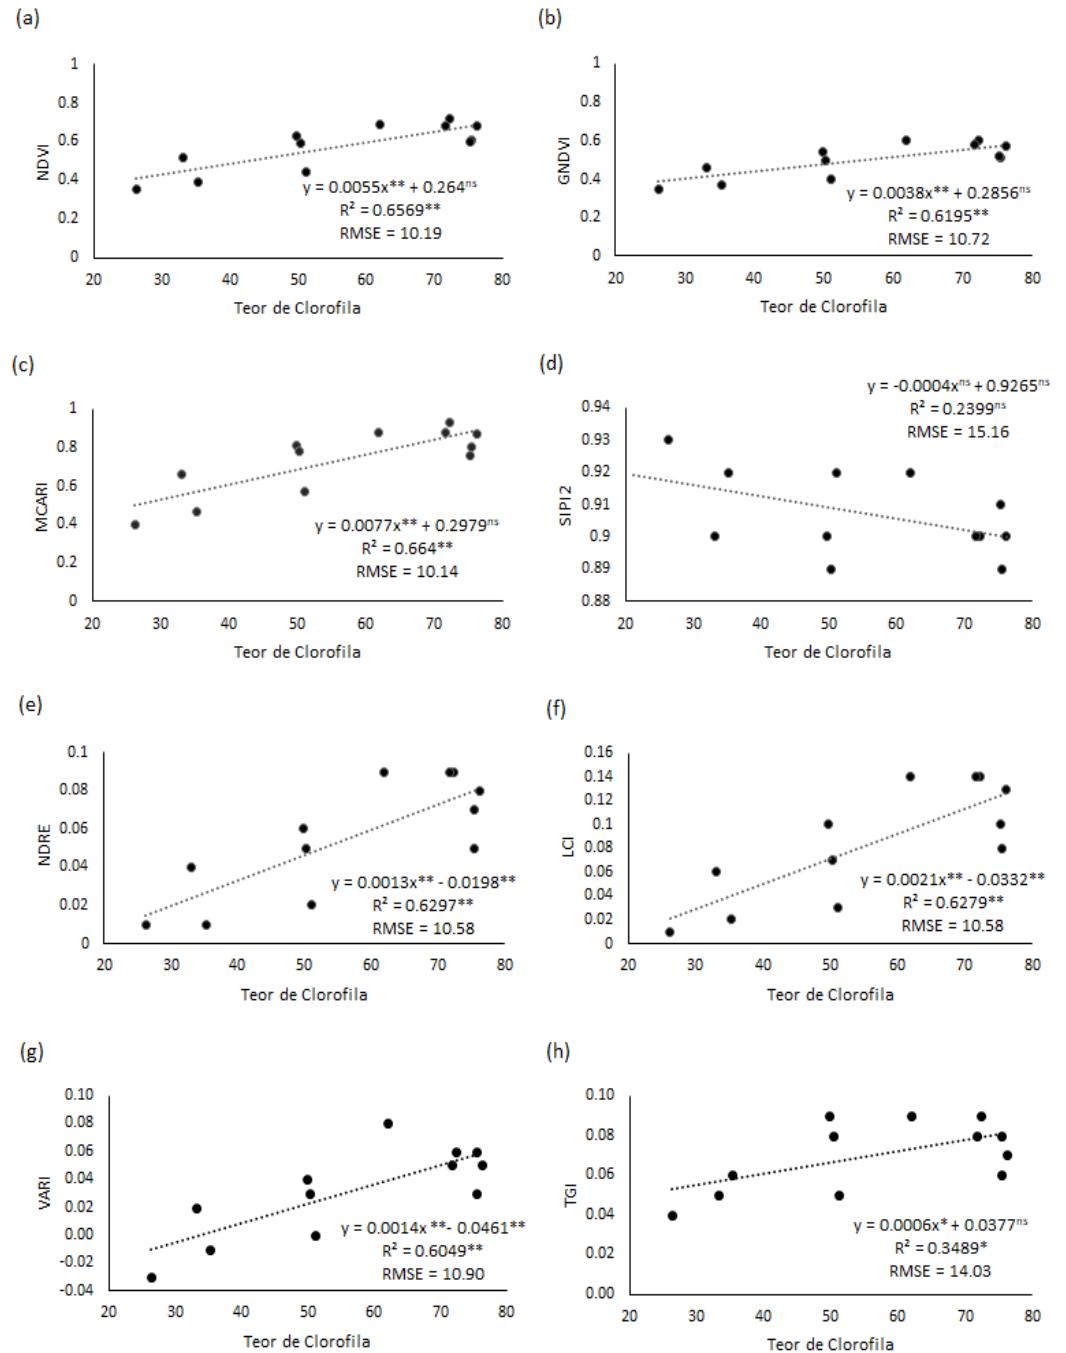


^{**}Significativo a 1% de probabilidade de erro, ^{*}significativo a 5% de probabilidade de erro, ^{ns}não significativo.

Figura 9. Regressão linear entre MCARI, VARI e TGI em relação ao teor clorofila para o estágio fenológico R5.

Os valores de RMSE podem ser comparados somente na mesma coluna da Tabela 6, visto que é influenciado pela magnitude dos valores da variável que descreve e que as médias gerais dos teores de clorofila foram diferentes nas diferentes fases de desenvolvimento da cultura, aumentando até atingir o pico em R6 e decaindo posteriormente. Isso explica os baixos valores para RMSE em V4 por exemplo, mesmo que o coeficiente de correlação tenha sido próximo de zero para todos os índices de vegetação.

Os IVs apresentaram em maioria R² acima de 0,6 (Figura 10), considerando a avaliação feita no início do período de senescência das plantas e maturação dos grãos (R9), demonstrando assim bons ajustes dos modelos de regressão, e consequentemente, elevado potencial destes índices para estimativa do teor de clorofila na cultura do feijoeiro, nas condições do presente estudo.



** Significativo a 1% de probabilidade, *significativo a 5% de probabilidade, ^{ns} não significativo.

Figura 10. Gráficos de regressão linear entre teor de clorofila e índices de vegetação calculados (NDVI (a), GNDVI (b), MCARI (c), SIPI2 (d), NDRE (e), LCI (f), VARI (g) e TGI(h)) para o estágio R9.

Conforme os gráficos da Figura 10, nesta fase houve interação significativa com sete dos oito índices de vegetação testados, com forte correlação de Pearson e menores valores

de RMSE para MCARI ($r = 0,81$), NDVI ($r = 0,81$), NDRE ($r = 0,79$), LCI ($r = 0,79$), GNDVI ($r = 0,78$) e VARI ($r = 0,78$), as Equações (17), (18), (19), (20), (21) e (22) representam os modelos de regressão linear destes índices para predição do teor de clorofila. TGI e SIPI2 expressaram correlação moderada, 0,59 e -0,48, o RMSE para ambos foi mais alto em relação aos demais (14,03 e 15,16) e SIPI2 foi o único IV não significativo.

$$\text{Teor de clorofila} = 85,383 (x) - 6,049 \quad (21)$$

em que, x = valor referente a MCARI.

$$\text{Teor de clorofila} = 119,48 (x) - 12,14 \quad (22)$$

em que, x = valor referente a NDVI.

$$\text{Teor de clorofila} = 476,39 (x) + 30,36 \quad (23)$$

em que, x = valor referente a NDRE.

$$\text{Teor de clorofila} = 300,57 (x) + 31,02 \quad (24)$$

em que, x = valor referente a LCI.

$$\text{Teor de clorofila} = 163,47 (x) - 25,17 \quad (25)$$

em que, x = valor referente a GNDVI.

$$\text{Teor de clorofila} = 440,13 (x) + 42,63 \quad (26)$$

em que, x = valor referente a VARI.

Os IVs com melhor desempenho para análise do teor de clorofila foram MCARI e NDVI, com R^2 de 0,66 e 0,65 respectivamente. NDRE, LCI, GNDVI e VARI também apresentaram coeficientes de determinação próximos destes, com valores de R^2 entre 0,60 e 0,63, o que demonstra elevado potencial destes para monitoramento de teores de clorofila no dossel vegetativo. SIPI2 foi atípico aos demais IVs, apresentando correlação negativa, menor R^2 (0,24) e maior RMSE (15,16). Tisost (2009) também encontrou correlação negativa entre SIPI2 e teor de clorofila, com R^2 de 0,25 [27].

Também foram determinadas as correlações entre teor de clorofila e variáveis produtivas, estas não apresentaram significância nas regressões lineares para as avaliações feitas em V4, R5, R6 e R8. Porém em R9 houve interações significativas com produtividade (p -valor $< 0,01$), vagens por planta e grãos por vagem (p -valor $< 0,05$). As correlações para o número de vagens por planta e grãos por vagem foram moderadas, com valores de $r = 0,59$ e $0,61$ respectivamente. Para produtividade foi encontrada forte correlação ($r = 0,78$), Javed *et al.* (2022) também encontraram correlações positivas entre concentração de clorofila e rendimento de grãos [28].

3.5 Variabilidade temporal dos IVs

No decorrer do experimento, os IVs apresentaram comportamento semelhante entre si e acompanharam o crescimento das plantas e desenvolvimento do dossel vegetativo (Figura 11), houve considerável aumento dos valores até por volta dos 45 DAS, os picos máximos foram entre os 60 e 90 DAS, compreendidos entre os estádios fenológicos R6 e R8, onde houve maior incidência de saturação, sendo a maior para SIPI2 e a menor para MCARI, o mesmo se sobressaiu na predição de produtividade, número de vagens e clorofila.

Após o estágio R8, pouco após os 80 DAS, a refletância do dossel começou a declinar entrando no estágio de senescência, caracterizado pela degradação dos pigmentos de clorofila e desfolha [29]. É válido observar que os índices de vegetação derivados de imagens RGB (VARI e TGI) acompanharam o crescimento da cultura de forma semelhante

aos que se utilizam de bandas multiespectrais, e até se apresentaram superiores a muitos destes na predição de algumas variáveis, como já abordado.




Figura 11. Evolução temporal dos índices de vegetação em todo ciclo da cultura do feijoeiro.

4. Discussão

A aplicação de magnésio no feijoeiro induziu repostas espectrais na cultura, visto que os índices GNDVI e VARI, foram significativos a 5% (p -valor $< 0,05$) para o tratamento doses de magnésio, considerando os dados referentes ao estágio R9 ($R^2 = 0,66$ e $0,70$ respectivamente), ao passo que GNDVI também foi significativo no estágio R6 ($R^2 = 0,80$) a 1% (p -valor $< 0,01$). O GNDVI é considerado um índice confiável para indicar a saúde e o vigor do dossel vegetativo, o mesmo se utiliza do espectro verde e infravermelho próximo, e demonstra ser sensível a mudanças nas concentrações de clorofila das plantas [15,30]. O magnésio (Mg) é o átomo central da molécula de clorofila, e as flutuações em seus níveis no cloroplasto regulam a atividade das principais enzimas fotossintéticas [31], logo, espera-se relação direta entre concentração de Mg^{2+} e clorofila nas plantas, fato que pode explicar a resposta deste índice de vegetação a aplicação de magnésio.

O atual estudo relata correlações relevantes entre IVs, importantes ferramentas no sensoriamento remoto, e parâmetros biofísicos da cultura do feijoeiro. Recentemente, vários autores encontraram resultados significativos na predição de produtividade por meio de IVs no feijoeiro e outras leguminosas [1,6,29,32,33], o que corrobora com os resultados do presente estudo, em que esta foi a variável predita com maior acurácia pelos IVs, com destaque para MCARI e NDVI. Os mesmos expressaram as correlações de maior magnitude para produtividade e também teor de clorofila.

Os IVs NDVI, GNDVI, MCARI, LCI, VARI e TGI puderam mensurar a altura de plantas com coeficientes de correlação acima de 0,60 e RMSE menores que 8,7 cm. Neste quesito TGI obteve melhor desempenho em relação aos demais ($r = 0,73$ e $RMSE = 7,4$ cm), nota-se também que VARI ($r = 0,63$ e $RMSE = 8,4$ cm), outro índice que se utiliza de bandas RGB, foi inferior apenas a dois IVs multiespectrais (NDVI e MCARI). Ji *et al.* (2022), ao verificar a acurácia de modelos baseados em imagens RGB e multiespectrais, na predição da altura de plantas na cultura do feijão-fava (*Vicia faba* L.), demonstrou resultados altamente significativos, com $R^2 = 0,99$ e $RMSE = 8,05$ cm para modelos extraídos de

imagens RGB, além de $R^2 = 0,95$ e $RMSE = 10,17\text{cm}$ para modelos de imagens multiespectrais [34].

Correlações classificadas como moderadas ou fracas foram encontradas para número de vagens por planta e grãos por vagem, a avaliação com maior presença de correlações significativas para vagens por planta foi em R9, sendo a melhor para o índice GNDVI ($r = 0,64$ e $RMSE = 4,0$). Quanto ao número de grãos por vagem a predição de maior significância foi em R5, para o índice SIPI2 ($r = 0,68$ e $RMSE = 0,7$), porém, considerando que os coeficientes de correlação referentes a MCARI foram mais próximos de 1,0 que os demais IVs nos três últimos estádios fenológicos de avaliação, com significância também para R5 ($r = 0,56$ e $RMSE = 0,8$), é possível defini-lo como o índice de vegetação de melhor desempenho na predição desta variável no presente estudo.

Com base na magnitude das correlações, nenhum dos IVs demonstrou eficiência na predição das variáveis massa de mil grãos e número de ramos por planta, da mesma forma também não se correlacionaram de forma significativa a outros componentes produtivos. Na literatura são encontrados poucos estudos que abordam a predição destas variáveis através de técnicas de sensoriamento remoto, o mesmo vale para número de vagens por planta e grãos por vagem, o que demanda mais estudos que abordem o assunto.

O conhecimento de variáveis que envolvem propriedades físicas de produtos agrícolas, em especial grãos, é de suma importância na tomada de decisões quanto a conservação, dimensionamento e manutenção de equipamentos para as operações pós-colheita. A fim de minimizar os custos de produção e obter maior competitividade e melhoria da qualidade dos produtos [35]. Neste sentido, ferramentas de sensoriamento remoto são alternativas a serem estudadas para obtenção destas informações, no intuito de adquiri-las de forma antecipada, não destrutiva, precisa e rápida.

Os índices testados demonstraram potencial na predição dos teores de clorofila, levando em consideração os resultados obtidos na avaliação feita em R9. Dados espectrais preveem o teor de clorofila medindo a refletância espectral das folhas do dossel, esta é fortemente afetada por mudanças na concentração de clorofila e por outros fatores como arquitetura do dossel, radiação no espectro visível, comprimentos de onda refletidos pelo solo e o índice de área foliar [36].

Neste sentido, entende-se que a baixa precisão dos IVs na predição de clorofila em V4 se deve provavelmente pela interferência da refletância do solo. O teor de clorofila influencia a refletância principalmente na a região do visível (RGB), onde controla grande parte da resposta espectral da vegetação normal e saudável, absorvendo mais radiação nas regiões vermelha e azul e refletindo mais nas regiões verdes [37]. O solo reflete a maior parte da luz que recebe no comprimento de onda da banda vermelha (630 – 690 nm), enquanto a clorofila absorve grande parte das ondas que recebe nesse espectro, esse comportamento inverso prejudica predições em fases vegetativas, não só de clorofila, mas como também outros parâmetros de interesse agrônomico.

Os melhores resultados na predição das variáveis no início do período de maturação fisiológica dos grãos (R9), onde as plantas já se encontravam no processo de senescência, pode ser explicado pela maior variabilidade na refletância das parcelas nesse período, devido a degradação gradual de clorofila e expressão de carotenoides na superfície foliar [38,39]. Pôde ser notado maiores médias dos valores referentes aos IVs e produtividade em parcelas que apresentaram vigor vegetativo por mais tempo.

Em contrapartida, quanto as análises referentes ao período vegetativo da cultura (V4), de modo geral foi constatada uma baixa precisão dos modelos de predição das variáveis. Como abordado anteriormente, este comportamento pode ser explicado pela interferência da refletância do solo, que ainda apresentava área bastante representativa nesta fase, visto que a cobertura do dossel vegetativo ainda era baixa, além das plantas ainda estarem expostas a diversos fatores bióticos e abióticos que influenciam de forma direta ou indireta no rendimento até o final do ciclo.

A imprecisão dos modelos na predição dos parâmetros biofísicos em R6 e R8, pode ser parcialmente explicada pela saturação de alguns dos IVs durante estas fases, em que o vigor do dossel vegetativo atingiu o pico e os IVs seus valores máximos. NDVI por exemplo, apesar dos coeficientes de correlação acima de 0,80 para produtividade e clorofila em R9, não foi significativo em outros estádios fenológicos, o que pode ser explicado pela alta reflectância do solo em V4 e saturação nos demais estádios fenológicos em valores acima de 0,7.

Os IVs com maior grau de correlação entre si foram NDVI e MCARI, com $r > 0,90$ V4, R5 e R9, os mesmos se destacaram na predição de importantes variáveis como produtividade e clorofila, demais índices derivados de imagens multiespectrais, em maioria também expressaram $r > 0,9$ nesta fase. Nota-se fortes correlações entre VARI e TGI com os demais IVs, principalmente no estádio R9, o que é de bastante interesse do ponto de vista econômico, visto que sensores RGB tem valor de mercado consideravelmente menor que sensores multiespectrais, o que torna este tipo de ferramenta mais acessível e contribui com a difusão do uso do sensoriamento remoto no meio agrícola.

Atualmente, há uma integração na agricultura de precisão cada vez mais comum de tecnologias como câmeras multiespectrais/hiperspectrais/RGB, plataformas UAV e resultados de monitoramento do rendimento por IVs, no intuito de fornecer uma alta capacidade de análise de dados, se utilizando de conjuntos de dados geoespaciais de alta resolução para ampliar a rede de informações referentes ao campo [25]. Identificar áreas de baixo, médio e alto rendimento a nível de campo e a variação temporal ao longo do tempo permite práticas de manejo direcionadas, o que reflete na lucratividade [40].

Tecnologias de sensoriamento remoto tem se consolidado cada vez mais na agricultura, vários trabalhos já foram desenvolvidos na área, que gera grande interesse em diversos meios [41]. Os resultados aqui expostos denotam o potencial do uso de ferramentas de sensoriamento remoto, em especial índices de vegetação, no monitoramento da cultura do feijoeiro e predição de parâmetros de interesse. Foram descritos os IVs com melhor desempenho para cada parâmetro avaliado dentro dos estádios fenológicos da cultura. Mais estudos são necessários para melhor compreensão das interações entre variáveis de campo e respostas espectrais. Por último, uma melhor compreensão das relações entre dados espectrais parâmetros biofísicos de cada cultura tem repercussões na lucratividade das fazendas, na disponibilidade de mão de obra e no uso de insumos agrícolas.

5. Conclusões

O melhor período para determinação dos parâmetros biofísicos da cultura do feijoeiro foi o início do estádio fenológico R9. Considerando o RMSE e a magnitude da correlação, os IVs MCARI e NDVI expressaram as melhores correlações com as variáveis produtividade ($r = 0,82$ e $RMSE = 330$ e 329 kg.ha^{-1}) e clorofila ($r = 0,81$ e $RMSE = 10,14$ e $10,19$). GNDVI, NDRE e LCI também apresentaram correlação forte ($r > 0,7$) para produtividade e teor de clorofila. Para estas características ainda se obteve correlação forte para o TGI com produtividade e VARI para teor de clorofila. Para altura de plantas TGI teve melhor desempenho ($r = 0,73$ e $RMSE = 7,4 \text{ cm}$), os demais índices tiveram correlação moderada ou fraca. As demais variáveis não apresentaram fortes correlações com os índices de vegetação. IVs derivados de imagens RGB apresentaram resultados relativamente próximos dos derivados de imagens multiespectrais, com coeficientes de correlação fortes, entre 0,89 e 0,92 para VARI e 0,77 e 0,87 para TGI na avaliação de melhor desempenho. Com base nos IVs GNDVI e VARI, a dose de magnésio foliar indicada foi a de 500 g.ha^{-1} .

Contribuições dos autores: Conceituação, L.E.V.C., H.F.E.O. e W.H.D.B.; metodologia, L.E.V.C., H.F.E.O. e W.H.D.B.; gestão de campo, W.H.D.B.; software, L.E.V.C.; redação—preparação do rascunho original, L.E.V.C., H.F.E.O. e W.H.D.B.; redação – revisão e edição, L.E.V.C.; supervisão, H.F.E.O. e W.H.D.B.; administração de projetos, H.F.E.O. e W.H.D.B. Todos os autores leram e concordaram com a versão publicada do manuscrito.

Financiamento: Esta pesquisa não recebeu financiamento externo.

Declaração de disponibilidade de dados: Não se aplica.

Agradecimentos: Ao Instituto Federal Goiano – Campus ceres por fornecer a área experimental e equipamentos necessários para a pesquisa.

Conflitos de interesse: Os autores declaram não haver interesses conflitantes.

Referências

1. Sandrini, F. de O.T.; Leal, F.T.; Coelho, A.P.; Lemos, L.B.; Rosalen, D.L. Vegetation Indices in the Estimation of Common Bean Yield Cultivated under Nitrogen Rates. *Rev. Bras. Ciências Agrar.* **2019**, *14*, 2–9, doi:10.5039/agraria.v14i4a7310.
2. Mosleh, M.K.; Hassan, Q.K.; Chowdhury, E.H. Application of Remote Sensors in Mapping Rice Area and Forecasting Its Production: A Review. *Sensors (Switzerland)* **2015**, *15*, 769–791, doi:10.3390/s150100769.
3. Souza, T.C. de; Souza, K.R.D. de; Magalhães, P.C. Respostas Morfisiológicas Do Milho e Sorgo Sob Déficit Hídrico. *XXXII Congr. Nac. Milho e Sorgo “Soluções Integr. para os Sist. produção milho e sorgo no Bras.* **2018**.
4. Andrade, R.G. Uso de Veículo Aéreo Não Tripulado (VANT) No Monitoramento Dos Estádios de Desenvolvimento Da Cultura Do Milho. In *Embrapa Gado de Leite-Capítulo em livro técnico (INFOTECA-E)*; 2019; pp. 225–234.
5. Agência Nacional de Aviação Civil (ANAC). Regulamento Brasileiro Da Aviação Civil (RBAC-E) Nº 94. *Diário Of. da União* **2021**, *117*, 1–34.
6. Sankaran, S.; Zhou, J.; Khot, L.R.; Trapp, J.J.; Mndolwa, E.; Miklas, P.N. High-Throughput Field Phenotyping in Dry Bean Using Small Unmanned Aerial Vehicle Based Multispectral Imagery. *Comput. Electron. Agric.* **2018**, *151*, 84–92, doi:10.1016/j.compag.2018.05.034.
7. Candiago, S.; Remondino, F.; De Giglio, M.; Dubbini, M.; Gattelli, M. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sens.* **2015**, *7*, 4026–4047, doi:10.3390/rs70404026.
8. Pereira, V.G.C.; Gris, D.J.; Marangoni, T.; Frigo, J.P.; Azevedo, K.D. De; Grzesiuck, A.E. Exigências Agroclimáticas Para a Cultura Do Feijão (*Phaseolus Vulgaris* L.) Vinicius. *Rev. Bras. Energias Renov.* **2014**, 32–42.
9. Feletti, E.F.; Gomes, L. dos S.; Oliveira, Ramon Alexandre Capucho, L.; Dalvi, L.P. Efeito Da Adubação Foliar Nos Teores de Nutrientes Em Grãos de Feijão. *Univ. Fed. do Espírito St. SEAGRO An. DA Sem. ACADÊMICA DO CURSO Agron. DO CCAE/UFES EFEITO* **2017**.
10. Kano, C.; Cardoso, A.I.I.; Villas Bôas, R.L. Macronutrient Content in Lettuce Affected by Potassium Side Dressing. *Hortic. Bras.* **2010**, *28*, 287–291, doi:10.1590/s0102-05362010000300008.
11. Santos, H.G.; Jacomine, P.K.; Anjos, L.H.C.; Oliveira, V.A.; Lumbreras Coelho, M. R., Almeida, J.A., Filho A., J.C., Oliveira, J.B. de, Cunha, T.J.F. *Brazilian Soil Classification System*; 5th ed.; Embrapa Soils, Brasília, 2018; ISBN 9788570358219.
12. Darim, E.P.; Machado, R.L.; Marques, V. dos S. Variabilidade Espacial De Atributos Físico-Hídricos Do Solo Em Área Irrigada. **2011**, *7*, 1043–1059.
13. Peel, M.C.; Finlayson, B.L.; McMahon, T.A. Updated World Map of the Koppen-Geiger Climate Classificatio. *Hydrol. Earth Syst. Sci.* **2007**, *11*, 1633–1644, doi:https://doi.org/10.5194/hess-11-1633-2007.
14. Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W.; Harlan, J.C. Monitoring the Vernal Advancements and Retrogradation of Natural Vegetation. *NASA/GSFC, Final Report, Greenbelt, MD, USA* **1974**, 1–137.
15. Gitelson, A.A.; Merzlyak, M.N. Remote Sensing of Chlorophyll Concentration in Higher Plant Leaves. *Adv. Sp. Res.* **1998**, *22*, 689–692, doi:10.1016/S0273-1177(97)01133-2.
16. Barnes, E.M.; Clarke, T.R.; Richards, S.E.; Colaizzi, P.D.; Haberland, J.; Kostrzewski, M.; Waller, P.; Choi C., R.E.;

- Thompson, T.; Lascano, R.J.; et al. Coincident Detection of Crop Water Stress, Nitrogen Status and Canopy Density Using Ground Based Multispectral Data. *Proc. 5th Int. Conf. Precis Agric* **2000**.
17. Daughtry, C.S.T.; Walthall, C.L.; Kim, M.S.; Colstoun, E.B. de; McMurtrey, J.E. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sens. Environ.* **2000**, *74*, 229–239.
 18. Datt, B. A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants: Tests Using Eucalyptus Leaves. *J. Plant Physiol.* **1999**, *154*, 30–36, doi:10.1016/S0176-1617(99)80314-9.
 19. Peñuelas, J.; Frederic, B.; Filella, I. Semi-Empirical Indices to Assess Carotenoids/Chlorophyll a Ratio from Leaf Spectral Reflectance. *Photosynthetica* **1995**, *31*, 221–230.
 20. Gitelson, A.A.; Kaufman, Y.J.; Stark, R.; Rundquist, D. Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote Sens. Environ.* **2002**, *80*, 76–87, doi:10.1016/S0034-4257(01)00289-9.
 21. Hunt, R.E.; Daughtry, C.S.T.; Eitel, J.U.H.; Long, D.S. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agron. J.* **2011**, *103*, 1090–1099, doi:10.2134/agronj2010.0395.
 22. Hallak, R.; Filho, A.J.P. Metodologia Para Análise de Desempenho de Simulações de Sistemas Convectivos Na Região Metropolitana de São Paulo Com o Modelo ARPS: Sensibilidade a Variações Com Os Esquemas de Advecção e Assimilação de Dados. *Rev. Bras. Meteorol.* **2011**, 591–608.
 23. Figueiredo, D.B.; Júnior, J.A.D.S. Desvendando Os Mistérios Do Coeficiente de Correlação de Pearson (R). *Rev. Política Hoje* **2009**, *18*, 115–146.
 24. Mukaka, M.M. Statistics Corner: A Guide to Appropriate Use of Correlation Coefficient in Medical Research. *Malawi Med. J.* **2012**, *24*, 69–71.
 25. Yuan, M.; Burjel, J.C.; Martin, N.F.; Isermann, J.; Goeser, N.; Pittelkow, C.M. Advancing On-Farm Research with UAVs: Cover Crop Effects on Crop Growth and Yield. *Agron. J.* **2021**, *113*, 1071–1083, doi:10.1002/agj2.20546.
 26. Quille-mamani, J.; Porras-jorge, R.; Saravia-navarro, D.; Herrera, J.; Chavez-galarza, J. Prediction of Biometric Variables through Multispectral Images Obtained from UAV in Beans (*Phaseolus Vulgaris* L .) during Ripening Stage. **2021**, doi:10.20944/preprints202106.0139.v1.
 27. Tisot, D.A. Modelos de Transferência Radiotiva No Estudo Da Concentração de Clorofila Em Cana-de-Açúcar, Utilizando Dados Hiperespectrais, 2009.
 28. Javed, A.; Ahmad, N.; Ahmed, J.; Hameed, A.; Ashraf, M.A.; Zafar, S.A.; Maqbool, A.; Al-Amrah, H.; Alatawi, H.A.; Al-Harbi, M.S.; et al. Grain Yield, Chlorophyll and Protein Contents of Elite Wheat Genotypes under Drought Stress. *J. King Saud Univ. - Sci.* **2022**, *34*, 102279, doi:10.1016/j.jksus.2022.102279.
 29. Jewan, S.Y.Y.; Pagay, V.; Billa, L.; Tyerman, S.D.; Gautam, D.; Sparkes, D.; Chai, H.H.; Singh, A. The Feasibility of Using a Low-Cost near-Infrared, Sensitive, Consumer-Grade Digital Camera Mounted on a Commercial UAV to Assess Bambara Groundnut Yield. *Int. J. Remote Sens.* **2022**, *43*, 393–423, doi:10.1080/01431161.2021.1974116.
 30. Gitelson, A.A.; Kaufman, Y.J.; Merzlyak, M.N. Use of a Green Channel in Remote Sensing of Global Vegetation from EOS- MODIS. *Remote Sens. Environ.* **1996**, *58*, 289–298, doi:10.1016/S0034-4257(96)00072-7.
 31. Shaul, O. Magnesium Transport and Function in Plants: The Tip of the Iceberg. *BioMetals* **2002**, *15*, 309–323.
 32. Plaza, J.; Criado, M.; Sánchez, N.; Pérez-Sánchez, R.; Palacios, C.; Charfolé, F. Uav Multispectral Imaging Potential to Monitor and Predict Agronomic Characteristics of Different Forage Associations. *Agronomy* **2021**, *11*, 1–22, doi:10.3390/agronomy11091697.
 33. Schmitz, P.K.; Kandel, H.J. Using Canopy Measurements to Predict Soybean Seed Yield. *Remote Sens.* **2021**, *13*, doi:10.3390/rs13163260.
 34. Ji, Y.; Chen, Z.; Cheng, Q.; Liu, R.; Li, M.; Yan, X.; Li, G.; Wang, D.; Fu, L.; Ma, Y.; et al. Estimation of Plant Height and Yield Based on UAV Imagery in Faba Bean (*Vicia Faba* L.). *Plant Methods* **2022**, *18*, 1–13, doi:10.1186/s13007-022-00861-7.
 35. Spies, G.; Botelho, F.; Campos, S.C.; Poltronieri, K.C.; Ruffato, S. Efeito Do Espaçamento de Plantio e o Teor de Água Na Massa Específica e Massa de Mil Grãos Dos Grãos de Soja. In Proceedings of the Quinto Congresso de la Soja del Mercosur; 2011; pp. 1–5.
 36. Qi, H.; Zhu, B.; Kong, L.; Yang, W.; Zou, J.; Lan, Y.; Zhang, L. Hyperspectral Inversion Model of Chlorophyll Content in Peanut Leaves. *Appl. Sci.* **2020**, *10*, doi:10.3390/app10072259.
 37. Prudente, V.H.R.; Mercante, E.; Johann, J.A.; Souza, C.H.W. de; Cattani, C.E.V.; Mendes, I.S.; Caon, I.L. Use of Terrestrial Remote Sensing to Estimate Soybeans and Beans Biophysical Parameters. *Geocarto Int.* **2021**, *36*, 773–790, doi:10.1080/10106049.2019.1624982.
 38. Hussain, S.; Gao, K.; Din, M.; Gao, Y.; Shi, Z.; Wang, S. Assessment of UAV-Onboard Multispectral Sensor for

- Non-Destructive Site-Specific Rapeseed Crop Phenotype Variable at Different Phenological Stages and Resolutions. *Remote Sens.* **2020**, *12*, 1–19, doi:10.3390/rs12030397.
39. Din, M.; Zheng, W.; Rashid, M.; Wang, S.; Shi, Z. Evaluating Hyperspectral Vegetation Indices for Leaf Area Index Estimation of *Oryza Sativa* L. at Diverse Phenological Stages. *Front. Plant Sci.* **2017**, *8*, 1–17, doi:10.3389/fpls.2017.00820.
40. Zhao, Y.; Potgieter, A.B.; Zhang, M.; Wu, B.; Hammer, G.L. Predicting Wheat Yield at the Field Scale by Combining High-Resolution Sentinel-2 Satellite Imagery and Crop Modelling. *Remote Sens.* **2020**, *12*, doi:10.3390/rs12061024.
41. García-Berná, J.A.; Ouhbi, S.; Benmouna, B.; García-Mateos, G.; Fernández-Alemán, J.L.; Molina-Martínez, J.M. Systematic Mapping Study on Remote Sensing in Agriculture. *Appl. Sci.* **2020**, *10*, doi:10.3390/app10103456.