

**MONITORAMENTO DA RESPOSTA DO CAPIM-MULATO II AO NITROGÊNIO POR
IMAGENS RGB E MODELAGEM PREDITIVA****Gabriel Alecsander Aparecido Leite¹;**¹Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/3329609119004461>**Isabel Felizardo Chambingo²;**²Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/2218141957764650>**Ronilson Martins Silva³;**³Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/2905929579262261>**Matheus de Godoi Bertin⁴;**⁴Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/0408257540774009>**Fernanda de Fátima da Silva Devecchio⁵;**⁵Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/2167811056562057>**Lilian Elgalise Techio Pereira⁶;**⁶Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/6228828702565216>**Adriano Rogério Bruno Tech⁷.**⁷Universidade de São Paulo (USP), Pirassununga, São Paulo.<http://lattes.cnpq.br/8768632680429517>

RESUMO: O presente estudo avaliou o potencial de imagens RGB obtidas por Aeronave Remotamente Pilotada (ARP) para caracterizar a resposta espectral do Capim-Mulato II submetido a diferentes doses de nitrogênio. O experimento foi conduzido em 16 parcelas submetidas aos tratamentos N0, N20, N40 e N60, correspondentes às doses de 0, 20, 40 e 60 kg N ha⁻¹, respectivamente. Foram realizados 40 voos ao longo de dois ciclos experimentais, com aquisição das imagens no pré-corte da forrageira. O processamento computacional permitiu a extração dos índices ExG, GLI, VARI e NGRDI e a aplicação de análises estatísticas e modelos preditivos. VARI e NGRDI apresentaram as maiores correlações com as doses aplicadas. Entre os modelos avaliados, ElasticNet apresentou o maior R² (0,8016), enquanto Lasso apresentou os menores valores de RMSE (8,4456 kg ha⁻¹) e MAE (6,1307 kg ha⁻¹). Os resultados demonstram o potencial das imagens RGB para caracterizar diferenças na resposta espectral da forrageira e estimar a dose associada aos tratamentos experimentais, embora sejam necessárias validações independentes para ampliar a capacidade de generalização dos modelos.

PALAVRAS-CHAVE: Sensoriamento remoto. Índices de vegetação. Adubação nitrogenada.

MONITORING MULATO II GRASS RESPONSE TO NITROGEN USING RGB IMAGERY AND PREDICTIVE MODELING

ABSTRACT: This study evaluated the potential of RGB images acquired by a Remotely Piloted Aircraft (RPA) to characterize the spectral response of Mulato II grass subjected to different nitrogen rates. The experiment was conducted in 16 plots subjected to N0, N20, N40, and N60 treatments, corresponding to 0, 20, 40, and 60 kg N ha⁻¹, respectively. Forty flights were conducted over two experimental cycles, with images acquired during the pre-cutting stage. Computational processing enabled the extraction of ExG, GLI, VARI, and NGRDI vegetation indices and the application of statistical analyses and predictive models. VARI and NGRDI showed the highest correlations with the applied nitrogen rates. Among the evaluated models, ElasticNet presented the highest R² (0.8016), whereas Lasso showed the lowest RMSE (8.4456 kg ha⁻¹) and MAE (6.1307 kg ha⁻¹). The results demonstrate the potential of RGB imagery to characterize differences in forage spectral response and estimate nitrogen rates associated with the experimental treatments, although independent validation is required to improve the generalization capacity of the models.

KEYWORDS: Remote sensing. Vegetation indices. Nitrogen fertilization.

INTRODUÇÃO

A produção pecuária brasileira está fortemente associada ao uso de pastagens, cuja produtividade e sustentabilidade dependem, entre outros fatores, do manejo adequado dos nutrientes. Nesse contexto, o nitrogênio desempenha papel fundamental no crescimento e desenvolvimento das gramíneas forrageiras (Dias-Filho, 2014; Dias-Filho, 2023).

Entre as forrageiras tropicais, o Capim-Mulato II (*Urochloa* híbrida) destaca-se pela qualidade nutricional, capacidade de rebrota e adaptação às condições tropicais, características que favorecem sua utilização em sistemas de produção animal (Argel et al., 2007). Entretanto, sua resposta à disponibilidade de nutrientes pode variar, tornando relevante o desenvolvimento de métodos rápidos e não destrutivos para o monitoramento da vegetação.

A avaliação das pastagens pode envolver métodos de campo que demandam coleta de material vegetal, mão de obra e tempo para processamento das amostras. Embora forneçam informações importantes, essas abordagens podem limitar avaliações frequentes e espacialmente abrangentes, favorecendo o emprego de métodos não destrutivos e de sensoriamento remoto (Fernandes et al., 2023).

O uso de Aeronaves Remotamente Pilotadas (ARPs) ampliou a aquisição de imagens de alta resolução espacial para o monitoramento agrícola. Associadas ao processamento digital, imagens RGB permitem extrair atributos relacionados às características e ao vigor da vegetação (Jorge et al., 2011; Olson; Anderson, 2021; Santos et al., 2024).

Entre os atributos derivados de imagens RGB, destacam-se índices de vegetação como ExG, GLI, VARI e NGRDI, obtidos por diferentes combinações dos canais vermelho, verde e azul e utilizados para caracterizar variações na resposta da vegetação (Woebbecke et al., 1995; Louhaichi et al., 2001; Gitelson et al., 2002; Tucker, 1979).

A integração desses índices com métodos estatísticos e modelos preditivos permite investigar associações entre a resposta espectral da vegetação e variáveis agrônômicas, ampliando as possibilidades de monitoramento de sistemas produtivos.

Diante desse contexto, torna-se relevante avaliar se índices de vegetação derivados de imagens RGB são capazes de caracterizar diferenças na resposta espectral do Capim-Mulato II submetido a diferentes doses de nitrogênio e se esses atributos apresentam potencial para estimar os tratamentos nitrogenados nas condições experimentais avaliadas.

OBJETIVO

O objetivo deste estudo foi avaliar o potencial de imagens RGB obtidas por Aeronave Remotamente Pilotada, associadas ao processamento digital e à extração de índices de vegetação, para caracterizar a resposta espectral do Capim-Mulato II submetido a diferentes classes de adubação nitrogenada.

Especificamente, buscou-se: (i) extrair os índices ExG, GLI, VARI e NGRDI das imagens RGB; (ii) avaliar a resposta desses índices às classes N0, N20, N40 e N60, correspondentes às doses de 0, 20, 40 e 60 kg N ha⁻¹; (iii) analisar a associação entre os índices de vegetação e os tratamentos nitrogenados; e (iv) desenvolver e comparar modelos preditivos para estimar as doses de nitrogênio associadas à resposta espectral dos tratamentos experimentais.

METODOLOGIA


O estudo foi realizado em uma área experimental composta por 16 parcelas de 20 m² (5 × 4 m), cultivadas com Capim-Mulato II (*Urochloa* híbrida) e submetidas a quatro doses de nitrogênio: 0, 20, 40 e 60 kg N ha⁻¹, denominadas N0, N20, N40 e N60, respectivamente, com quatro parcelas por tratamento. Utilizou-se sulfato de amônio como fonte de nitrogênio, aplicado manualmente após cada rebaixamento da forrageira. As avaliações foram conduzidas em dois ciclos experimentais, entre novembro de 2024 e abril de 2025 e novembro de 2025 e abril de 2026.

O desenvolvimento da forrageira foi acompanhado até o doss atingir aproximadamente 30 cm de altura, condição estabelecida para o pré-corte. As imagens RGB foram obtidas um dia antes de cada rebaixamento, utilizando uma Aeronave Remotamente Pilotada DJI Mavic 2 Pro, em voos realizados entre 07h00 e 09h00, a aproximadamente 25 m de altura. Foram realizados 40 voos, sendo 20 em cada ciclo experimental. Em cada avaliação, uma única cena abrangendo as 16 parcelas foi utilizada para extração dos atributos espectrais, sem emprego de sobreposição longitudinal ou lateral das imagens.

Após a aquisição, as imagens foram processadas por meio de um fluxo computacional

desenvolvido em Python, conforme apresentado na Figura 1.

Figura 1: Fluxograma das etapas do processamento digital desenvolvido.



Fonte: Própria Autoria.

Inicialmente, foram selecionados manualmente os quatro vértices da área experimental, seguida da correção de perspectiva e segmentação da vegetação. A partir da máscara obtida, as parcelas foram identificadas e numeradas automaticamente de acordo com sua posição espacial. O processamento foi desenvolvido principalmente com as bibliotecas *OpenCV*, *NumPy*, *Pandas* e *Matplotlib*, permitindo a automatização das etapas após a definição inicial da área de interesse.

Para cada parcela, foram calculados os índices Excess Green Index (ExG), Green Leaf Index (GLI), Visible Atmospherically Resistant Index (VARI) e Normalized Green-Red Difference Index (NGRDI), a partir dos canais vermelho (R), verde (G) e azul (B) das imagens. Para o cálculo do ExG, os canais RGB foram previamente normalizados conforme as Equações 1 a 3:

$$r = \frac{R}{R + G + B} \quad (1)$$

$$g = \frac{G}{R + G + B} \quad (2)$$

$$b = \frac{B}{R + G + B} \quad (3)$$

em que R, G e B correspondem aos valores dos canais vermelho, verde e azul, respectivamente, e r, g e b aos respectivos valores normalizados.

Os índices de vegetação foram calculados conforme as Equações 4 a 7:

$$ExG = 2g - r - b \quad (4)$$

$$GLI = \frac{2g - r - b}{2g + r + b} \quad (5)$$

$$VARI = \frac{g - r}{g + r - b} \quad (6)$$

$$GRDI = \frac{g - r}{g + r} \quad (7)$$

As formulações utilizadas seguiram Woebbecke et al. (1995) para o ExG, Louhaichi et al. (2001) para o GLI, Gitelson et al. (2002) para o VARI e Tucker (1979) para o NGRDI. Para cada parcela, foram obtidos os valores médios dos índices, além da mediana, desvio-padrão e valores mínimo e máximo.

A associação entre os índices de vegetação e as doses de nitrogênio aplicadas foi avaliada pelo coeficiente de correlação de Pearson, considerando os tratamentos N0, N20, N40 e N60. Essa análise permitiu avaliar a intensidade e a direção das relações lineares entre os atributos espectrais e as doses aplicadas.

Para investigar o potencial preditivo dos atributos espectrais, foram avaliados os modelos Regressão Linear, Ridge, Lasso, ElasticNet, Random Forest e Support Vector Regression (SVR), utilizando os índices de vegetação como variáveis explicativas e as doses aplicadas (0, 20, 40 e 60 kg N ha⁻¹) como variável resposta. O desempenho foi comparado por meio do coeficiente de determinação (R²), raiz do erro quadrático médio (RMSE) e erro absoluto médio (MAE), empregando validação cruzada K-Fold com cinco subdivisões (k = 5).

Após a comparação dos modelos, o algoritmo selecionado foi aplicado aos atributos espectrais das parcelas para estimar a dose de nitrogênio associada à resposta espectral observada. As estimativas foram posteriormente comparadas aos quatro tratamentos experimentais (N0, N20, N40 e N60) e utilizadas para a geração de tabelas e mapas temáticos.

Ao final do processamento, as informações espectrais, estatísticas e preditivas foram organizadas e os resultados foram gerados automaticamente pelo sistema desenvolvido.

Dessa forma, após a seleção inicial da área experimental, o fluxo computacional permitiu executar de maneira padronizada as etapas de processamento das imagens, cálculo dos índices de vegetação, análise estatística, aplicação do modelo preditivo e geração das estimativas de nitrogênio, mapas temáticos, tabelas e relatório técnico.

RESULTADOS E DISCUSSÃO

Os índices de vegetação derivados das imagens RGB apresentaram diferentes níveis de associação com as doses de nitrogênio aplicadas ao Capim-Mulato II. Entre os índices avaliados, o VARI apresentou a maior correlação linear positiva com as doses de nitrogênio ($r = 0,9233$), seguido pelo NGRDI ($r = 0,8774$). O GLI apresentou correlação positiva moderada ($r = 0,4299$), enquanto o ExG apresentou correlação negativa moderada ($r = -0,5070$). Esses resultados indicam maior associação do VARI e do NGRDI com as variações nas doses de nitrogênio nas condições experimentais avaliadas (Tabela 1).

Tabela 1: Coeficientes de correlação de Pearson (r) entre os índices de vegetação e as doses de nitrogênio.

Índice	Correlação de Pearson (r)	Interpretação
ExG	-0,5070	Negativa moderada
GLI	0,4299	Positiva moderada
VARI	0,9233	Positiva muito forte
NGRDI	0,8774	Positiva forte

Fonte: Própria Autoria.

A resposta observada para os índices RGB está de acordo com estudos que demonstram o potencial de imagens obtidas por aeronaves não tripuladas para caracterizar alterações no dossel associadas à disponibilidade de nitrogênio. Zheng et al. (2018) verificaram que índices derivados de imagens RGB, incluindo o NGRDI, apresentaram potencial para estimar o acúmulo de nitrogênio em arroz. Da mesma forma, estudos com imagens RGB obtidas por UAV demonstraram a aplicabilidade do VARI no monitoramento da condição e do desenvolvimento de culturas (Gerardo; de Lima, 2023). Entretanto, índices baseados exclusivamente nas bandas do visível são influenciados por características do dossel e pelas condições de aquisição das imagens, especialmente variações de iluminação, o que deve ser considerado em avaliações realizadas ao longo do tempo (Rasmussen et al., 2016).

Com base nos resultados, foram desenvolvidos modelos de regressão utilizando os índices de vegetação como variáveis explicativas e a dose de nitrogênio como variável resposta. Foram avaliados os modelos ElasticNet, Lasso, Regressão Linear, Random Forest, Ridge e Support Vector Regression (SVR).

Tabela 2: Desempenho médio dos modelos obtido pela validação cruzada *K-Fold* ($k = 5$).

Modelo	R ²	RMSE	MAE
ElasticNet	0,8016	8,5192	6,4336
Lasso	0,7958	8,4456	6,1307
Linear	0,7852	8,6119	6,2568
Random Forest	0,6774	9,4217	6,5400
Ridge	0,1513	17,5029	15,2417
SVR	-1,0494	27,2218	23,1335

Fonte: Própria Autoria.

Os modelos ElasticNet, Lasso e Regressão Linear apresentaram os melhores desempenhos entre os métodos avaliados (Tabela 2). O ElasticNet obteve o maior R^2 médio (0,8016), enquanto o Lasso apresentou os menores valores de RMSE (8,4456 kg ha⁻¹) e MAE (6,1307 kg ha⁻¹). A Regressão Linear apresentou desempenho próximo, com R^2 de 0,7852, indicando que, nas condições avaliadas, os modelos lineares apresentaram melhor desempenho preditivo que Random Forest, Ridge e SVR.

O Random Forest apresentou desempenho intermediário ($R^2 = 0,6774$), enquanto Ridge e SVR apresentaram os menores desempenhos, com R^2 de 0,1513 e -1,0494, respectivamente. O valor negativo observado para o SVR indica desempenho preditivo inferior ao obtido utilizando a média da variável resposta como referência. Considerando conjuntamente R^2 , RMSE e MAE, o Lasso foi adotado como modelo de referência para as estimativas subsequentes.

A partir do modelo selecionado, as estimativas foram incorporadas ao sistema computacional desenvolvido, permitindo gerar valores individualizados para as parcelas experimentais (Tabela 3).

Tabela 3: Estimativas das doses de nitrogênio pelo modelo Lasso e doses aplicadas nas parcelas experimentais.


Parcela	N estimado (kg ha ⁻¹)	Tratamento	Dose aplicada (kg ha ⁻¹)
1	11,8	N0	0
2	57,3	N60	60
3	38,2	N40	40
4	41,8	N40	40
5	42,0	N40	40
6	15,9	N20	20
7	15,0	N20	20
8	26,1	N0	0
9	19,8	N20	20
10	1,2	N0	0
11	56,0	N60	60
12	57,2	N60	60
13	58,6	N60	60
14	31,6	N40	40
15	0,0	N0	0
16	11,3	N20	20

Fonte: Própria Autoria.

As estimativas obtidas pelo modelo Lasso apresentaram diferentes níveis de aproximação em relação às doses efetivamente aplicadas (Tabela 3). Em grande parte das parcelas submetidas aos tratamentos N20, N40 e N60, os valores estimados permaneceram próximos às respectivas doses experimentais. Entretanto, foram observadas discrepâncias em algumas parcelas, especialmente no tratamento N0, evidenciando variabilidade da

resposta espectral mesmo entre unidades submetidas ao mesmo tratamento. A Figura 2 apresenta os resultados obtidos pela aplicação do modelo preditivo a uma imagem RGB adquirida em 1º de fevereiro de 2026. A partir do processamento da imagem, foram estimadas as doses de nitrogênio associadas à resposta espectral de cada parcela, possibilitando a comparação entre os valores estimados pelo modelo e as doses efetivamente aplicadas nos respectivos tratamentos.

Figura 2: Distribuição espacial das doses de nitrogênio estimadas pelo modelo Lasso nas parcelas experimentais de Capim-Mulato II.



Fonte: Própria Autoria.

A representação espacial permitiu visualizar a variabilidade das estimativas de nitrogênio entre as parcelas experimentais (Figura 2). A comparação com os tratamentos N0, N20, N40 e N60 evidenciou diferentes níveis de aproximação entre os valores estimados pelo modelo e as doses efetivamente aplicadas. Dessa forma, o mapa constitui uma representação espacial da resposta predita a partir dos atributos espectrais, não devendo ser interpretado como uma recomendação de adubação nitrogenada.

A integração entre o processamento das imagens RGB, os índices de vegetação e a modelagem preditiva permitiu caracterizar diferenças na resposta espectral do Capim-Mulato II submetido aos tratamentos N0, N20, N40 e N60. Entre os índices avaliados, VARI e NGRDI apresentaram as maiores associações com as doses aplicadas, enquanto os modelos ElasticNet, Lasso e Regressão Linear apresentaram os melhores desempenhos preditivos nas condições experimentais avaliadas.

Os resultados demonstram o potencial das imagens RGB obtidas por ARP para o

monitoramento da resposta da forrageira a diferentes níveis de adubação nitrogenada. Entretanto, as estimativas geradas pelo modelo representam associações entre os atributos espectrais e os tratamentos experimentais, não constituindo recomendações de fertilização. Além disso, considerando que as mesmas parcelas foram avaliadas repetidamente ao longo dos ciclos experimentais, estudos futuros devem considerar explicitamente a dependência temporal das observações e avaliar o desempenho dos modelos em áreas e ciclos independentes.

CONSIDERAÇÕES FINAIS

As imagens RGB obtidas por Aeronave Remotamente Pilotada mostraram potencial para caracterizar a resposta espectral do Capim-Mulato II submetido aos tratamentos N0, N20, N40 e N60. Entre os índices avaliados, VARI e NGRDI apresentaram as maiores associações com as doses de nitrogênio aplicadas, indicando maior associação com as variações nas doses de nitrogênio nas condições experimentais avaliadas.

Na modelagem preditiva, ElasticNet, Lasso e Regressão Linear apresentaram os melhores desempenhos, com maior R^2 para o ElasticNet e menores RMSE e MAE para o Lasso. A integração entre processamento das imagens, índices de vegetação e modelagem permitiu estimar a dose associada à resposta espectral e representar espacialmente os resultados das parcelas.

Entretanto, as estimativas obtidas devem ser interpretadas como associações entre os atributos espectrais e os tratamentos experimentais, não constituindo recomendação de adubação nitrogenada. Considerando ainda as avaliações repetidas das mesmas parcelas ao longo dos dois ciclos experimentais, estudos futuros devem incorporar estratégias de validação que considerem a dependência temporal das observações e avaliar os modelos em áreas e ciclos independentes, visando ampliar sua robustez e capacidade de generalização.

REFERÊNCIAS

- ARGEL, P. J.; MILES, J. W.; GUIOT GARCÍA, J. D.; CUADRADO CAPELLA, H.; LASCANO, C. E. *Cultivar Mulato II (Brachiaria híbrido CIAT 36087): gramínea de alta qualidade e produção forrageira, resistente às cigarrinhas e adaptada a solos tropicais ácidos*. Cali: Centro Internacional de Agricultura Tropical (CIAT), 2007.
- DIAS-FILHO, M. B. *Diagnóstico das pastagens no Brasil*. Belém, PA: Embrapa Amazônia Oriental, 2014. 36 p. (Documentos, 402).
- DIAS-FILHO, M. B. *Degradação de pastagens: conceitos, processos e estratégias de recuperação e de prevenção*. Belém, PA: Ed. do Autor, 2023. 59 p. ISBN 978-65-00-73154-5.
- FERNANDES, A. M. et al. Non-destructive methods used to determine forage mass and nutritional condition in tropical pastures. *AgriEngineering*, v. 5, n. 3, p. 1614-1629, 2023. DOI: 10.3390/agriengineering5030100.

GERARDO, R.; DE LIMA, I. P. Applying RGB-based vegetation indices obtained from UAS imagery for monitoring the rice crop at the field scale: a case study in Portugal. *Agriculture*, v. 13, n. 10, art. 1916, 2023. DOI: 10.3390/agriculture13101916.

GITELSON, A. A.; STARK, R.; GRITS, U.; RUNDQUIST, D.; KAUFMAN, Y.; DERRY, D. Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing*, v. 23, n. 13, p. 2537-2562, 2002. DOI: 10.1080/01431160110107806.

JORGE, L. A. C.; INAMASU, R. Y.; CARMO, R. B. Desenvolvimento de um VANT totalmente configurado para aplicação em agricultura de precisão no Brasil. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. *Anais [...]*. São José dos Campos: INPE, 2011. p. 399-406.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, v. 16, n. 1, p. 65-70, 2001. DOI: 10.1080/10106040108542184.

OLSON, D. O.; ANDERSON, J. A. Review on unmanned aerial vehicles, remote sensors, imagery processing, and their applications in agriculture. *Agronomy Journal*, v. 113, n. 2, p. 971-992, 2021. DOI: 10.1002/agj2.20595.

RASMUSSEN, J.; NTAKOS, G.; NIELSEN, J.; SVENSGAARD, J.; POULSEN, R. N.; CHRISTENSEN, S. Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, v. 74, p. 75-92, 2016. DOI: 10.1016/j.eja.2015.11.026.

SANTOS, W. M. dos et al. Use of unmanned aerial vehicles for monitoring pastures and forages in agricultural sciences: a systematic review. *Drones*, v. 8, n. 10, art. 585, 2024. DOI: 10.3390/drones8100585.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127-150, 1979. DOI: 10.1016/0034-4257(79)90013-0.

WOEBBECKE, D. M.; MEYER, G. E.; VON BARGEN, K.; MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, v. 38, n. 1, p. 259-269, 1995.

ZHENG, H. et al. Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. *Remote Sensing*, v. 10, n. 6, art. 824, 2018. DOI: 10.3390/rs10060824.