



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE SERGIPE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA E BIODIVERSIDADE**

**FENOTIPAGEM POR VANT E APRENDIZADO DE
MÁQUINA PARA PREDIÇÃO DA PRODUTIVIDADE DE
MILHO EM AMBIENTES CONTRASTANTES DE
NITROGÊNIO EM REGIÃO SEMIÁRIDA**

BARBARA NASCIMENTO SANTOS



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE SERGIPE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA E BIODIVERSIDADE**

BARBARA NASCIMENTO SANTOS

**FENOTIPAGEM POR VANT E APRENDIZADO DE MÁQUINA PARA PREDIÇÃO
DA PRODUTIVIDADE DE MILHO EM AMBIENTES CONTRASTANTES DE
NITROGÊNIO EM REGIÃO SEMIÁRIDA**

Dissertação apresentada à Universidade Federal de Sergipe, como parte das exigências do Curso de Mestrado em Agricultura e Biodiversidade, área de concentração em Agricultura e Biodiversidade, para obtenção do título de “Mestre em Ciências”.

Orientador
Prof. Dr. Gustavo Hugo Ferreira de Oliveira

SÃO CRISTÓVÃO
SERGIPE – BRASIL
2026

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE**

S237f Santos, Barbara Nascimento.
Fenotipagem por Vant e aprendizado de máquina para predição da produtividade de milho em ambientes contrastantes de nitrogênio em região semiárida / Barbara Nascimento Santos; orientador Gustavo Hugo Ferreira de Oliveira. – São Cristóvão, SE, 2026.
62 f.: il.

Dissertação (mestrado em Agricultura e Biodiversidade) – Universidade Federal de Sergipe, 2026.

1. Agrobiodiversidade. 2. Milho – Melhoramento genético. 3. Produtividade agrícola. 4. Plantas – Efeitos do nitrogênio. I. Oliveira, Gustavo Hugo Ferreira de orient. II. Título.

CDU: 663.15

BARBARA NASCIMENTO SANTOS

**FENOTIPAGEM POR VANT E APRENDIZADO DE MÁQUINA PARA PREDIÇÃO
DA PRODUTIVIDADE DE MILHO EM AMBIENTES CONTRASTANTES DE
NITROGÊNIO EM REGIÃO SEMIÁRIDA**

Dissertação apresentada à Universidade Federal de Sergipe, como parte das exigências do Curso de Mestrado em Agricultura e Biodiversidade, área de concentração em Agricultura e Biodiversidade, para obtenção do título de “Mestre em Ciências”.

APROVADA em 26 de janeiro de 2026.

Dr. José Jairo Florentino Cordeiro Junior (UFS)

Dr. Tiago Olivoto (UFSC)

Prof. Dr. Gustavo Hugo Ferreira de Oliveira
(Orientador)

SÃO CRISTÓVÃO
SERGIPE – BRASIL

*Aos meus pais, irmãos e sobrinhos, por todos
os sorrisos genuínos que me fortaleceram a
cada passo trilhado*
Dedico

AGRADECIMENTOS

“Deus faz mais do que pedimos ou imaginamos” (Ef 3:20).

Agradeço primeiramente a **Deus** por me conceder força, saúde e sabedoria para chegar até aqui. Em minhas orações, sempre roguei proteção à minha família e discernimento para os estudos e Deus ouviu as minhas preces. Por isso, hoje concluo minha pós-graduação em nível de mestrado com o coração repleto de gratidão.

Chegar a este momento só foi possível porque, ao meu lado, sempre estiveram meu pai, **João Virginio**, e minha mãe, **Josefa Fontes**. A vocês, minha eterna gratidão por tudo. Junto a eles, agradeço às minhas irmãs **Marta**, **Silvanete**, **Ivanilda**, **Vanuza** e **Ivaneide**, exemplos de força e coragem enquanto mulheres, e aos meus irmãos **Fábio**, **Edivan**, **Gidelvan**, **Vanildo** e **Ivan** (*in memoriam*), pelo apoio e incentivo ao longo dessa caminhada. Ao meu namorado, **Erivelton**, pelo companheirismo, pelo carinho e por sempre me apoiar em todos os momentos, sejam eles felizes ou difíceis.

Agradeço ao meu orientador, Prof. Dr. **Gustavo Hugo Ferreira de Oliveira**, que, desde o início da minha graduação, acreditou em mim e me proporcionou inúmeras oportunidades de crescimento profissional. Sua orientação foi fundamental para a minha formação, sempre me incentivando a pensar “fora da caixinha”, de forma crítica e inovadora, buscando conhecimento além do óbvio.

Aos membros atuais e egressos do **Grupo de Estudos em Melhoramento Vegetal do Semiárido (GEMS)**, agradeço pela convivência, aprendizado e amadurecimento profissional. Estar no campo com vocês, dividindo responsabilidades e aprendizados, foi uma satisfação.

Às meninas da pós-graduação, **Jaci** e **Carla**, por todo apoio e conhecimento compartilhado nesse período. Agradeço em especial à **Nartênia** por dividir as aflições da pós e tornar essa caminhada mais leve. Foi um ano de convivência intenso, marcado por uma amizade que tenho grande afeto.

A todos que participaram, de forma direta ou indireta, para a realização deste trabalho, expresso minha mais profunda gratidão, em particular, aos membros da banca avaliadora, Prof. Dr. **Jairo Cordeiro** e Prof. Dr. **Tiago Olivoto**, pelas valiosas contribuições. Agradeço à **Universidade Federal de Sergipe (UFS)** e à **Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)** pelo suporte institucional, acadêmico e financeiro, que viabilizou a execução desta pesquisa.

BIOGRAFIA

Barbara Nascimento Santos, nascida em 28 de abril de 1999, no município de Paripiranga, Bahia, filha de João Virginio de Jesus Santos e Josefa Fontes do Nascimento Santos, possui graduação em Engenharia Agrônômica pela Universidade Federal de Sergipe (UFS), Campus do Sertão, concluída no período de 2019 a 2024. Durante a graduação, atuou como bolsista de Iniciação Tecnológica (PIBITI) nos anos de 2020 e 2022 e de Iniciação Científica (PIBIC) em 2021, desenvolvendo pesquisas na área de Melhoramento Vegetal, com ênfase na cultura do milho em condições semiáridas, e participando ativamente da condução de experimentos de campo, bem como da coleta e da análise de dados agronômicos. Em 2023, realizou estágio no Núcleo de Estudos em Genética e Melhoramento de Milho, da Faculdade de Ciências Agrárias e Veterinárias (FCAV/UNESP), em Jaboticabal-SP, sob a orientação do Prof. Dr. Gustavo Vitti Môro. Em 2024, ingressou no Programa de Pós-Graduação em Agricultura e Biodiversidade (PPGAGRI/UFS), nível mestrado, como bolsista, sob a orientação do Prof. Dr. Gustavo Hugo Ferreira de Oliveira. Ao longo da trajetória acadêmica, participou de diversos eventos científicos e cursos de formação complementar, e publicou artigos científicos, capítulos de livros e trabalhos em anais de congressos, com destaque para estudos envolvendo melhoramento genético de plantas, estatística experimental, análise multivariada e fenotipagem baseada em imagens. Recebeu premiações acadêmicas em eventos regionais, nacionais e internacionais, o que evidencia a relevância e a qualidade de suas pesquisas na área de Ciências Agrárias.

SUMÁRIO

	Página
LISTA DE FIGURAS	i
LISTA DE TABELAS	iii
LISTA DE ABREVIATURAS, SÍMBOLOS E SIGLAS	iv
RESUMO	v
ABSTRACT	vi
1. INTRODUÇÃO GERAL	1
2. REVISÃO DE LITERATURA	3
2.1 Cultivo do milho em região semiárida	3
2.2 Nitrogênio na cultura do milho	3
2.3 Eficiência no uso de nitrogênio (EUN) no milho	4
2.4 Fenotipagem de alto rendimento no melhoramento do milho	5
3. REFERÊNCIAS BIBLIOGRÁFICAS	8
4. ARTIGO 1.....	13
Resumo.....	13
4.1. Introdução	13
4.2. Material e Métodos	15
4.2.1 Material genético, descrição da área e delineamento experimental	15
4.2.2 Obtenção e processamento das imagens	17
4.2.3 Índices de vegetação	18
4.2.4 Análises estatísticas	20
4.3. Resultados.....	21
4.3.1 Desempenho dos modelos de regressão na predição da produtividade de grãos	21
4.3.2 Dispersão entre produtividade observada e predita	23
4.3.3 Avaliação dos modelos Linear e LASSO.....	28
4.3.4 Avaliação dos modelos GBM e Cforest	31
4.3.5 Avaliação da produtividade predita dos genótipos em cada modelo	35
4.3.6 Eficiência agrônômica no uso de nitrogênio (EAN) e responsividade produtiva dos genótipos.....	37
4.4. Discussão	38
4.5. Conclusões	40
4.6. Referências Bibliográficas	40
5. CONSIDERAÇÕES FINAIS	46
ANEXOS	47

LISTA DE FIGURAS

ARTIGO 1

Figura	Página
1	16
2	16
3	18
4	19
5	22
6	23
7	24
8	24
9	25
10	26
11	26
12	27
13	27

	regressão na área experimental de Graccho Cardoso, com altura de voo de 80 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) cforest e (d) GBM.....	
14	Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Graccho Cardoso, com altura de voo de 80 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) cforest e (d) GBM.....	28
15	Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 60 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.....	29
16	Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 80 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.....	29
17	Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 60 metros na área de Graccho Cardoso em baixo e alto nitrogênio.....	30
18	Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 80 metros na área de Graccho Cardoso em baixo e alto nitrogênio.....	31
19	Importância dos índices de vegetação pelo modelo GBM na área experimental de Nossa Senhora da Glória sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio.....	32
20	Importância dos índices de vegetação pelo modelo Cforest na área experimental de Nossa Senhora da Glória sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio.....	32
21	Importância dos índices de vegetação pelo modelo GBM na área experimental de Graccho Cardoso sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio.....	33
22	Importância dos índices de vegetação pelo modelo Cforest na área experimental de Graccho Cardoso sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio.....	33
23	Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo GBM em Nossa Senhora da Glória. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio.....	34
24	Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo CFOREST em Nossa Senhora da Glória. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio.....	34
25	Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo GBM em Graccho Cardoso. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio.....	35
26	Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo CFOREST em Graccho Cardoso. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio.....	35
27	Avaliação dos genótipos dentro de cada modelo em 60 metros na área de Nossa	36

	Senhora da Glória em baixo e alto nitrogênio.....	
28	Avaliação dos genótipos dentro de cada modelo em 80 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.	36
29	Avaliação dos genótipos dentro de cada modelo em 60 metros na área de Graccho Cardoso em baixo e alto nitrogênio.....	37
30	Avaliação dos genótipos dentro de cada modelo em 80 metros na área de Graccho Cardoso em baixo e alto nitrogênio.....	37
31	Avaliação da eficiência agrônômica e responsividade dos genótipos na área de Nossa Senhora da Glória.....	37
32	Avaliação da eficiência agrônômica e responsividade dos genótipos na área de Graccho Cardoso.....	38

LISTA DE TABELAS

ARTIGO 1

Tabela		Página
1	Resumo dos parâmetros de aquisição, processamento e métricas de qualidade fotogramétrica das imagens obtidas por VANT nas áreas experimentais, no primeiro voo, a 60 metros de altura.....	18
2	Descrição dos índices de vegetação multispectrais utilizados no estudo.....	19
3	Classificação e finalidade dos modelos utilizados para predição da produtividade de grãos baseada em índices de vegetação multispectrais	21

LISTA DE ABREVIATURAS, SÍMBOLOS E SIGLAS

VANT	Veículo Aéreo Não Tripulado
LASSO	Least Absolute Shrinkage and Selection Operator
LM	Linear
Cforest	Floresta Condicional
GBM	Gradient Boosting Machine
DAP	Dias Após Plantio
EAN	Eficiência Agronômica no uso de Nitrogênio
EUN	Eficiência no uso de Nitrogênio

RESUMO

SANTOS, Barbara Nascimento. **Fenotipagem por VANT e aprendizado de máquina para predição da produtividade de milho em ambientes contrastantes de nitrogênio em região semiárida**. São Cristóvão: UFS, 2026. 62p. (Dissertação– Mestrado em Agricultura e Biodiversidade).*

A fenotipagem de alto rendimento tem contribuído substancialmente para os avanços na agricultura e nos programas de melhoramento de plantas. Sua aplicação, por meio de veículos aéreos não tripulados (VANTs), possibilitou a aquisição rápida de dados fenotípicos com alta confiabilidade e resolução espacial, promovendo sua adoção em diversos contextos agrícolas. Apesar desses avanços, diversas limitações metodológicas permanecem insuficientemente exploradas, particularmente quando essa abordagem é aplicada em condições de estresse ambiental e de alta homogeneidade espectral. Este estudo teve como objetivo avaliar a acurácia preditiva de quatro modelos preditivos, utilizando métodos de regressão e de aprendizado de máquina para estimar a produtividade de grãos de progênies de meios-irmãos de milho cultivadas sob condições contrastantes de nitrogênio, utilizando imagens multiespectrais obtidas por VANT. Os experimentos foram conduzidos durante a safra de 2024, em duas áreas experimentais localizadas nos municípios de Nossa Senhora da Glória e de Graccho Cardoso, Sergipe, Brasil. Adotou-se o delineamento experimental em blocos casualizados, com parcelas subdivididas e três repetições, no qual os níveis de nitrogênio (alto e baixo) foram atribuídos às parcelas principais e as progênies de meios-irmãos, às subparcelas. Imagens multiespectrais de drone foram adquiridas durante três voos a alturas de 60 e 80 m ao longo do ciclo da cultura, correspondentes a diferentes estágios fenológicos. Quatorze índices de vegetação multiespectral associados à estrutura do dossel, ao teor de clorofila e ao estado nutricional das plantas foram calculados. Quatro abordagens preditivas foram avaliadas: um modelo linear clássico, um modelo de regressão penalizada (LASSO) e dois algoritmos baseados em árvores de decisão, Floresta Condicional (cforest) e Máquina de Impulso Gradiente (GBM). O desempenho dos modelos foi avaliado utilizando o erro quadrático médio (RMSE) e o erro absoluto médio (MAE), além de análises diagnósticas das premissas do modelo linear e das avaliações da importância das variáveis e dos valores SHAP para os modelos GBM e cforest. Em ambas as áreas experimentais e em ambas as condições de nitrogênio, os modelos cforest e GBM apresentaram consistentemente maior acurácia preditiva do que as abordagens lineares. De modo geral, as imagens adquiridas a 60 m resultaram em desempenho superior dos modelos, destacando a importância de uma resolução espacial mais alta para aumentar a sensibilidade à variabilidade fisiológica dentro do dossel. As análises de importância das variáveis e dos valores SHAP indicaram que as contribuições preditivas se concentraram em um subconjunto limitado de índices de vegetação, particularmente aquelas sensíveis à estrutura do dossel e ao teor de clorofila. Além disso, observaram-se respostas preditivas distintas entre os genótipos, dependendo da abordagem de modelagem e das condições ambientais. Esses resultados sugerem que a aquisição e o processamento de dados espectrais podem ser otimizados priorizando índices de vegetação específicos e estágios fenológicos estrategicamente selecionados. Para a predição da produtividade de grãos de milho, recomenda-se o uso combinado dos modelos cforest e GBM com índices de vegetação como TCARI, MCARI e MSAVI2. Para aumentar a robustez e a extrapolação desses resultados, estudos futuros devem avaliar o desempenho desses índices em uma gama mais ampla de níveis de nitrogênio, genótipos e condições edafoclimáticas.

Palavras-chave: Ambientes semiáridos, progênies de meios-irmãos, resposta espectral, melhoramento de plantas, *Zea mays* L.

* Comitê Orientador: Gustavo Hugo Ferreira de Oliveira – UFS (Orientador).

ABSTRACT

SANTOS, Barbara Nascimento. **UAV phenotyping and machine learning for predicting corn productivity in contrasting nitrogen environments in a semi-arid region.** São Cristóvão: UFS, 2026. 62p. (Dissertation – Master of Science in Agriculture and Biodiversity).*

High-throughput phenotyping has contributed substantially to advances in agriculture and plant breeding programs. By using unmanned aerial vehicles (UAVs), its application has enabled the rapid acquisition of phenotypic data with high reliability and spatial resolution, promoting its adoption across diverse agricultural contexts. Despite these advances, several methodological limitations remain insufficiently explored, particularly when this approach is applied under conditions of environmental stress and high spectral homogeneity. This study aims to evaluate the accuracy of four predictive models, using regression and machine learning approaches to estimate the grain yield of maize half-sib progenies grown under contrasting nitrogen conditions, based on multispectral images obtained by UAV. The experiments were conducted during the 2024 growing season in two experimental areas located in the municipalities of Nossa Senhora da Glória and Graccho Cardoso, Sergipe, Brazil. A randomized block design with split plots and three replications was adopted, in which nitrogen levels (high and low) were assigned to the main plots and the half-sib progenies to the subplots. Multispectral drone images were acquired during three flights at heights of 60 and 80m throughout the crop cycle, corresponding to different phenological stages. Fourteen multispectral vegetation indices associated with canopy structure, chlorophyll content, and plant nutritional status were calculated. Four predictive approaches were evaluated: a classical linear model, a penalized regression model (LASSO), and two decision tree-based algorithms, Conditional Forest (Cforest) and Gradient Boosting Machine (GBM). Model performance was evaluated using the root mean square error (RMSE) and the mean absolute error (MAE), in addition to diagnostic analyses of the linear model assumptions and assessments of variable importance and SHAP values for the GBM and Cforest models. In both experimental areas and nitrogen conditions, the Cforest and GBM models consistently showed higher predictive accuracy than the linear approaches. Overall, images acquired at 60m resulted in superior model performance, highlighting the importance of higher spatial resolution for increased sensitivity to physiological variability within the canopy. Analyses of variable importance and SHAP values indicated that predictive contributions were concentrated in a limited subset of vegetation indices, particularly those sensitive to canopy structure and chlorophyll content. Furthermore, distinct predictive responses were observed among genotypes, depending on the modeling approach and environmental conditions. These results suggest that the acquisition and processing of spectral data can be optimized by prioritizing specific vegetation indices and strategically selected phenological stages. For predicting maize grain yield, the combined use of the Cforest and GBM models with vegetation indices such as TCARI, MCARI, and MSAVI2 is recommended. To increase the robustness and generalizability of these findings, future studies should evaluate the performance of such indices across a broader range of nitrogen levels, genotypes, and edaphoclimatic conditions.

Key-words: Semi-arid environments; half-sib progenies; spectral response; plant breeding; *Zea mays* L.

* Guidance Committee: Gustavo Hugo Ferreira de Oliveira (Advisor).

1. INTRODUÇÃO GERAL

O milho (*Zea mays* L.) é uma das culturas mais relevantes em nível global. Sua alta variabilidade genética permitiu que se tornasse um modelo para diversos programas de melhoramento vegetal, possibilitando uma ampla adaptabilidade em diferentes condições edafoclimáticas (Santos *et al.*, 2025; Feitosa *et al.*, 2025; Preciado-Ortiz *et al.*, 2022). Esse desempenho explica sua crescente disseminação mundial e importância socioeconômica, sendo utilizado como base para a alimentação humana e animal, além de apresentar uso industrial nos setores têxtil, cosmético e de biocombustíveis.

No Brasil, um dos países megadiversos do mundo, a cultura do milho está bem estabelecida e é cultivada em praticamente todo o território nacional. No entanto, nas regiões semiáridas do Nordeste brasileiro, a produtividade ainda é limitada. O clima dessas áreas é caracterizado por altas temperaturas e distribuição pluviométrica irregular, o que pode impor restrições ao desenvolvimento das plantas. Soma-se a isso uma utilização ineficaz de nutrientes, particularmente do nitrogênio (N), elemento fundamental para o crescimento do milho, mas frequentemente escasso ou mal aproveitado sob condições adversas (Anaya-Salgado *et al.*, 2025; Li *et al.*, 2026).

Embora o milho seja uma planta C4, com elevada eficiência fotossintética e boa adaptação a ambientes de altas temperaturas, a falta de água e a escassez de N durante as fases críticas de desenvolvimento comprometem significativamente seu rendimento final (Ortiz *et al.*, 2022). Em geral, a adubação nitrogenada é feita em duas etapas: na semeadura, utilizando adubos de fundação (normalmente NPK), e em cobertura, entre os estádios fenológicos V4 e V6 (quatro e seis folhas completamente desenvolvidas, respectivamente), com a aplicação de fertilizantes como ureia ($\text{CO}(\text{NH}_2)_2$) e sulfato de amônio ($(\text{NH}_4)_2\text{SO}_4$). Contudo, a eficiência dessa adubação pode ser comprometida devido às perdas por lixiviação e volatilização, particularmente em períodos de escassez hídrica (Modesto *et al.*, 2017).

Dessa forma, a implementação de ferramentas que auxiliem em uma avaliação precisa, ágil e não destrutiva torna-se crucial para a seleção de plantas com uso eficiente de nitrogênio e tolerância ao estresse hídrico. A fenotipagem de alto rendimento, por meio de veículos aéreos não tripulados (VANTs), tem se mostrado promissora para essa finalidade. Esta abordagem permite a obtenção de imagens espectrais, disponibilizando assim informações em tempo real sobre as características morfofisiológicas das plantas, as quais podem ser associadas à sua saúde nutricional (Zhang e Zhu, 2023).

Com as imagens capturadas por VANTs, torna-se viável calcular índices de vegetação que utilizam diferentes bandas espectrais, o que possibilita a avaliação indireta de características ligadas à estrutura do dossel, ao teor de clorofila e à condição nutricional das plantas (Dos Santos, Padolfi e Ramaldes, 2018; Resende *et al.*, 2024). Contudo, para interpretar essas informações espectrais, são necessários métodos estatísticos que consigam correlacionar os índices de vegetação com variáveis agronômicas de importância, como a produtividade de grãos e a eficiência no uso de nitrogênio. Tradicionalmente, essa relação tem sido analisada por meio de modelos de regressão linear, que pressupõem relações lineares e suposições estatísticas que nem sempre são totalmente atendidas em dados espectrais, os quais possuem alta dimensionalidade e multicolinearidade.

Nesse cenário, técnicas de aprendizado de máquina vêm ganhando destaque como opções promissoras em relação aos modelos estatísticos tradicionais, pois oferecem maior flexibilidade para representar relações complexas não lineares entre os índices de vegetação e a produtividade. Com base no que foi apresentado, esta dissertação evidencia a importância de utilizar ferramentas e metodologias de relevância para avaliar dados complexos em diferentes situações. Hipotetiza-se que a resposta espectral das progênies e a capacidade preditiva dos modelos variam em função das condições de disponibilidade de nitrogênio e que algoritmos de aprendizado de máquina apresentam desempenho superior na predição do que os modelos

de regressão linear tradicionais na estimativa da produtividade de grãos a partir de índices de vegetação.

Portanto, o objetivo deste estudo foi avaliar quatro modelos preditivos, incluindo métodos de regressão e algoritmos de aprendizado de máquina, para a predição da produtividade de grãos de progênies de meios-irmãos de milho sob ambientes contrastantes de nitrogênio, empregando imagens multiespectrais obtidas por VANTs como ferramenta de fenotipagem de alto rendimento.

2. REVISÃO DE LITERATURA

2.1 Cultivo do milho em região semiárida

Com os avanços tecnológicos e o progresso das pesquisas ao longo dos anos, o cultivo do milho (*Zea mays* L.) em regiões semiáridas vem apresentando resultados promissores. No entanto, essas áreas ainda representam um grande desafio para a maximização do potencial produtivo da cultura, em razão das condições climáticas adversas, principalmente da precipitação pluviométrica irregular e das elevadas temperaturas, fatores que resultam em elevada variabilidade interanual da produtividade.

No Brasil, a estimativa de produção total de milho, considerando as três safras, é de 138,9 milhões de toneladas, o que representa uma redução de 1,5% em comparação à safra anterior, segundo a Companhia Nacional de Abastecimento (CONAB, safra 2025/26). Para o Nordeste brasileiro, estima-se uma área plantada de 10.385,4 mil hectares, com produção de aproximadamente 32,7 milhões de toneladas, destacando a importância da cultura para a região, apesar de estar fortemente condicionada às restrições climáticas predominantes. Entre os estados do Nordeste, Sergipe destaca-se pela maior produtividade média, com uma estimativa de 5.985 kg ha⁻¹, demonstrando o potencial produtivo do estado e sua contribuição para o desempenho regional da cultura do milho (CONAB, safra 2025/26).

Em regiões semiáridas, as perdas associadas às condições climáticas não afetam somente a diminuição da produtividade, mas também a qualidade do que é produzido. De acordo com o terceiro levantamento da CONAB para a safra 2025/26, no estado de Sergipe, onde a produção de milho ocorre predominantemente sob regime de sequeiro, a ocorrência de chuvas mal distribuídas durante o ciclo da cultura resultou em perdas qualitativas estimadas em aproximadamente 5% da produção total, devido à presença de grãos ardidos.

O estresse causado pelo déficit hídrico compromete significativamente o desenvolvimento do milho, causando redução da expansão foliar e, conseqüentemente, diminuição do consumo de carbono e de energia, formação de um sistema radicular superficial, encurtamento do comprimento dos internódios, além de impactar a formação dos componentes de rendimento, como menor número de grãos por espiga e de fileiras de grãos (Silva *et al.*, 2021; Fancelli, 1988).

Conforme estudo realizado por Fancelli (2015), a disponibilidade insuficiente de água durante o estágio fenológico VT (pendoamento) pode resultar em perdas de aproximadamente 50% da produtividade do milho. As regiões semiáridas do Brasil e do mundo enfrentam o desafio não apenas do déficit hídrico, mas também de outros fatores limitantes, como o manejo nutricional e, especialmente, a deficiência de nitrogênio no solo (Mata *et al.*, 2024; Ayangbenro e Babalola, 2021).

Nesse contexto, evidencia-se a necessidade de aprofundar pesquisas sobre essas restrições e destaca-se o papel fundamental do melhoramento genético para o desenvolvimento de materiais mais adaptados a essas condições adversas. Em países como o México e a África do Sul, avanços no melhoramento genético têm expressado aumento da produtividade mesmo sob estresse abiótico, como visto nas pesquisas de Noperi-Mosqueda *et al.* (2024) e Preciado-Ortiz *et al.* (2022). Esses autores evidenciaram comportamentos distintos entre os genótipos de milho avaliados, permitindo a seleção de materiais mais adequados às condições locais.

No semiárido brasileiro, os estudos realizados por Santos *et al.* (2025) e Feitosa *et al.* (2025) demonstraram diferentes comportamentos produtivos dos materiais, com seleção de materiais superiores e indicados para a região. Dessa forma, reforça-se a importância de programas de melhoramento específicos e contínuos, orientados para a realidade de cada região semiárida.

2.2 Nitrogênio na cultura do milho

O nitrogênio (N) é o nutriente exigido em maior quantidade pelo milho, participando de processos fisiológicos essenciais como a síntese de aminoácidos, proteínas, clorofila e enzimas envolvidas no metabolismo energético e fotossintético (Taiz *et al.*, 2017; Vieira, 2017). Sua deficiência acarreta sintomas evidentes, como o amarelecimento das folhas mais velhas, podendo evoluir para clorose em situações mais graves, redução do crescimento e antecipação do florescimento (Taiz *et al.*, 2017).

Durante o desenvolvimento da cultura, a máxima demanda por N ocorre nos estádios vegetativos iniciais, particularmente entre V4 e V8, fases em que há intensa expansão foliar e definição de componentes ligados ao rendimento, como o número de espigas por planta e o número de fileiras de grãos por espiga (Fancelli, 2015). Assim, deficiências nesses períodos comprometem drasticamente seu desenvolvimento, podendo alterar a duração das fases fenológicas e, conseqüentemente, diminuir o rendimento final.

No Nordeste do Brasil, o manejo do nitrogênio na cultura do milho tem características significativas devido às condições edafoclimáticas predominantes. A irregularidade das chuvas, combinada com solos que geralmente possuem baixa matéria orgânica e capacidade reduzida de retenção de nutrientes, compromete a eficácia da absorção e utilização do nitrogênio aplicado, especialmente em sistemas de sequeiro (Marengo *et al.*, 2022). Nessas circunstâncias, a presença de déficit hídrico pode diminuir consideravelmente a absorção do nutriente pelas plantas, mesmo com a aplicação de doses apropriadas.

A adubação nitrogenada na cultura do milho é geralmente realizada em duas etapas. A primeira ocorre no momento da semeadura, por meio da aplicação de adubos de fundação, comumente combinados com fósforo e potássio (NPK). A segunda etapa corresponde à adubação de cobertura, aplicada entre os estádios fenológicos V4 e V6, período em que há um alto acúmulo de matéria seca (Fancelli, 2015).

Pesquisas conduzidas em regiões semiáridas do Nordeste brasileiro demonstram que o parcelamento da adubação nitrogenada pode constituir uma estratégia viável para o aumento da produtividade do milho. Aragão *et al.* (2022) observaram resultados promissores no norte do estado do Ceará, em sistema de sequeiro, com aplicação do nitrogênio em seis doses. Entretanto, é importante destacar que, em áreas semiáridas, a eficácia dessa técnica depende bastante da presença de chuvas próximas ao momento da aplicação, fazendo com que o parcelamento e a adequação do manejo sejam estratégias essenciais para minimizar perdas.

Alguns estudos voltados para adubação foliar de nitrogênio destacam a responsividade no desempenho produtivo da cultura com a aplicação desse método, podendo ser uma alternativa suplementar de manejo (Fernandes, Campos, Ventura, 2025; Brankov *et al.*, 2020). De modo geral, a eficácia do manejo nutricional depende de interações entre tipo de solo, características genéticas da cultivar utilizada, clima e práticas culturais adotadas, justificando a necessidade de recomendações regionais e adaptadas a cada sistema produtivo.

A aplicação adequada de N é essencial não apenas para alcançar altas produtividades, mas também para a mitigação dos impactos ambientais. O uso excessivo de fertilizantes nitrogenados pode resultar em lixiviação, contaminação de corpos d'água e de lençóis freáticos, bem como na liberação de gases de efeito estufa, como o óxido nitroso (N₂O) (Adeoluwa *et al.*, 2022; Cassim *et al.*, 2022; Tyagi, Ahmad, Malik, 2022; Cameron, Di, Moir, 2013).

Dessa forma, estratégias como a utilização desse elemento orientada por recomendações técnicas contribuem tanto para a sustentabilidade ambiental quanto para a eficiência produtiva da cultura. Adicionalmente, convém ressaltar que tanto a época de aplicação, a sincronização com a necessidade nutricional da planta e o uso de fertilizantes com liberação lenta/controlada devem ser levados em consideração como alternativas para minimizar os riscos de possíveis perdas, sobretudo em ambientes semiáridos (Fancelli e Munhoz, 2015; Almeida, Sanches, 2012).

2.3 Eficiência do uso de nitrogênio (EUN) no milho

A eficiência no uso de nitrogênio (EUN) pode ser compreendida como a capacidade da planta de absorver e remobilizar esse nutriente de forma eficaz, resultando em maior produtividade por unidade de nitrogênio aplicado (Moll *et al.*, 1982). Existe uma complexidade envolvida em sua avaliação, pois essa característica é altamente afetada por fatores ambientais e genéticos, sendo um dos principais desafios enfrentados no cultivo do milho.

Pesquisas apontam que a eficiência global de uso do N na agricultura continua baixa, e estratégias de manejo e genética são fundamentais para melhorar tanto a produtividade quanto a sustentabilidade ambiental (Ciampitti e Lemaire, 2022; Gheith *et al.*, 2022).

A EUN é geralmente representada pela quantidade de grãos produzidos por unidade de nitrogênio utilizada. Em sistemas de cultivo de milho, altos valores de EUN não estão necessariamente ligados a grandes quantidades de fertilizante, mas principalmente à habilidade do genótipo em sustentar níveis adequados de produtividade em condições de baixa oferta de nitrogênio. Nesse sentido, do ponto de vista do melhoramento genético, os genótipos eficientes são aqueles que apresentam boa produtividade mesmo com menores quantidades de N aplicadas.

Pesquisas indicam que a EUN tende a ser maior em ambientes com baixas doses de nitrogênio, enquanto sua eficiência diminui gradualmente à medida que a dose de N aumenta, devido ao efeito de diluição do fertilizante. Por exemplo, Adeoluwa *et al.* (2022) registraram valores de EUN próximos a 0,20 kg de grãos por kg de fertilizante nitrogenado em linhagens de milho expostas à aplicação de 30 kg N ha⁻¹. Em contrapartida, valores inferiores a 0,05 kg ha⁻¹ foram observados sob doses mais altas de 120 kg N ha⁻¹. Esses resultados mostram que a alta EUN está relacionada à eficiência fisiológica e genética dos materiais em condições de baixa disponibilidade de nitrogênio.

Resultados semelhantes foram observados por Arisede *et al.* (2020) e Gheith *et al.* (2022). Esses estudos mostraram que genótipos considerados eficientes conseguem manter uma produtividade relativamente alta com baixos níveis de nitrogênio, exibindo maior eficiência na absorção, assimilação e remobilização desse nutriente. Dessa forma, o conhecimento sobre os mecanismos fisiológicos que estão relacionados com essa eficiência é crucial para que se possa otimizar os recursos disponíveis e selecionar materiais superiores.

Entre os fatores fisiológicos, destacam-se enzimas como a redutase do nitrato (RN) e a glutamina sintetase (GS) (Sahay *et al.*, 2021). A RN desempenha papel central na assimilação do nitrato, convertendo o nitrato em nitrito e regulando simultaneamente o fluxo nitrogenado e a produção de óxido nítrico (NO), uma molécula sinalizadora especialmente importante em situações de estresse. A GS age em etapa posterior, incorporando o amônio originado da assimilação em glutamina, evitando toxicidade e fornecendo compostos nitrogenados para a síntese de aminoácidos e metabolitos. No entanto, Oliveira *et al.* (2013) demonstraram que a RN não possibilitou a identificação de genótipos eficientes em condições de baixo nitrogênio, já a GS apresentou-se como uma possível alternativa de seleção indireta de genótipos com EUN.

De acordo com a clássica proposta de Moll *et al.* (1992), a eficiência no uso de nitrogênio (EUN) pode ser avaliada mediante a quantidade de grãos produzidos por unidade de nitrogênio disponível no solo, sendo expressa como Gw/Ns, onde Gw representa a produção de grãos e Ns a quantidade de nitrogênio aplicado à planta. Os mesmos autores demonstraram que a EUN envolve outros fatores, obtidos a partir de diferentes parâmetros fisiológicos, como a eficiência de absorção (Nt/Ns), que indica a capacidade de absorver o nutriente, e a eficiência de utilização (Gw/Nt), que representa a eficiência da conversão do nitrogênio em biomassa produtiva. Assim, a sua expressão é dada pela equação: $Gw/Ns = (Nt/Ns)(Gw/Nt)$, onde Nt é a quantidade de nitrogênio presente na planta durante a maturidade.

Por fim, o melhoramento genético tem papel crucial na busca por maior EUN, possibilitando identificar genótipos superiores e utilizá-los em programas específicos (Wani

et al., 2021; Asibi, Chai e Coulter, 2019; DeBruin *et al.*, 2017). Essa seleção é realizada por meio da observação direta em experimentos, avaliação de parâmetros fisiológicos e agronômicos.

2.4 Fenotipagem de alto rendimento no melhoramento do milho

A fenotipagem de alto rendimento é uma ferramenta amplamente empregada tanto nos campos de produção agrícola quanto em programas de melhoramento genético. A sua utilização tem estimulado o crescimento de várias culturas devido à rapidez e acuracidade no fornecimento de dados em tempo real. Esses benefícios tornam a fenotipagem uma ferramenta crucial para programas de melhoramento genético do milho. No entanto, em condições de estresse abiótico ou diferentes condições de nitrogênio, a fenotipagem baseada em sensores ópticos pode enfrentar limitações significativas, como saturação espectral e a diminuição da capacidade de discriminação entre genótipos (Valencia-Ortiz *et al.*, 2025; Casanova, Epema e Goudriaan, 1998). Essa restrição dificulta a detecção de variações genéticas sutis e representa um desafio fundamental para a utilização da fenotipagem por imagem em programas de melhoramento com nitrogênio limitado.

Dentre as plataformas disponíveis para a fenotipagem de alto rendimento, destaca-se o uso de veículos aéreos não tripulados (VANTs). Estes dispositivos, equipados com sensores acoplados, possibilitam a obtenção de imagens com alta resolução de forma rápida e em tempo real (Zhang e Zhu, 2023). Esta tecnologia permite o acompanhamento das culturas ao longo de todo o ciclo fenológico ou em fases específicas de crescimento, representando um benefício considerável em comparação com as imagens obtidas por satélites, que geralmente apresentam uma resolução espacial inferior e uma frequência de captura mais baixa (Pinto *et al.*, 2023; Zhang, Marzougui, Sankaran, 2020). Entretanto, apesar dessas vantagens operacionais, a eficácia dos dados espectrais coletados por VANTs depende consideravelmente da capacidade dos índices em registrar variações fisiológicas significativas, o que nem sempre é possível em situações de estresse nutricional.

No contexto do melhoramento do milho, a fenotipagem por imagem permitiu uma diminuição significativa no tempo de avaliação, além de reduzir os erros ligados ao desgaste físico durante as coletas manuais. Shepard *et al.* (2025) comprovaram que a avaliação do florescimento por meio de imagens demonstrou elevada precisão e confiabilidade em relação à abordagem convencional, que envolve a determinação manual do instante em que 50% das plantas da parcela estão liberando pólen e com estigmas receptivos, procedimento trabalhoso e suscetível a falhas. A pesquisa também destacou a relevância de efetuar voos regulares, particularmente durante a época de florescimento, para assegurar a precisão das informações.

De forma semelhante, Resende *et al.* (2024) aplicaram a fenotipagem por imagem para analisar os componentes da espiga do milho, obtendo resultados que se assemelham aos da fenotipagem manual, indicando a confiabilidade da tecnologia. Adicionalmente, outras pesquisas enfatizaram a eficácia da fenotipagem por imagens no monitoramento das plantas, predição da produtividade e seleção de genótipos promissores (Xiao *et al.*, 2023; Alcântara *et al.*, 2023; Maciel *et al.*, 2022; Su *et al.*, 2019). Apesar desses avanços, ainda existe uma lacuna sobre o uso da fenotipagem por imagem em ambientes contrastantes de nitrogênio, principalmente em regiões de clima desafiador como o semiárido.

O desenvolvimento de ferramentas específicas para análise de imagens obtidas por VANT e criação de shapefiles como o FIELDImageR (Matias *et al.*, 2020) e pliman (Olivoto, 2022) tem democratizado a obtenção de dados em nível de parcelas experimentais em programas de melhoramento vegetal. A consolidação dessas ferramentas fortalece o uso de imagens dentro dos programas de melhoramento.

Entre os índices mais utilizados em estudos com imagens para avaliar vegetação, pode-se citar o Índice de Vegetação por Diferença Normalizada (NDVI), criado por Rouse *et al.* (1974), que possibilita a avaliação da saúde vegetal através da análise das bandas espectrais do infravermelho próximo (NIR) e do vermelho (Red), sendo calculado a partir da

equação: $NDVI = (NIR - Red) / (NIR + Red)$. Neste índice, os valores podem variar entre 1.0 e -1.0, em que valores próximos a 1.0 indicam vegetação verde e saudável, enquanto valores inferiores ou negativos indicam estresse ou escassez de vegetação.

Outro índice que tem apresentado resultados promissores é o Índice de Vegetação por Diferença Normalizada da Borda Vermelha (NDRE), que apresenta alta correlação com a produtividade e a biomassa no milho (Macedo *et al.*, 2023). Por utilizar a região espectral da borda vermelha, esse índice surge como uma alternativa mais sensível às variações fisiológicas da vegetação.

3. REFERÊNCIAS BIBLIOGRÁFICAS

- ADEOLUWA, O.O.; MUTENGWA, C.S.; CHIDUZA, C.; TANDZI, N.L. Nitrogen use efficiency of quality protein maize (*Zea mays* L.) genotypes. **Agronomy**, v. 12, n. 5, p. 1118, 2022. 10.3390/agronomy12051118
- ALCÂNTARA, J.F.D.; SANTOS, R.G.D.; BAILO, F.H.R.; SILVA, C.A.D.; TEODORO, P.E.; TEODORO, L.P.R. High-throughput phenotyping as an auxiliary tool in the selection of corn hybrids for agronomic traits. **Revista Ceres**, v. 70, n. 1, p. 106-113, 2023. 10.1590/0034-737X202370010012
- ANAYA-SALGADO, A.; QUEVEDO-NOLASCO, A.; BOLAÑOS-GONZÁLEZ, M. A.; FLORES-VELÁZQUEZ, J.; REYES-GONZÁLEZ, A.; SANTANA-ESPINOZA, S.; MALTOS-BUENDIA, J.; SÁNCHEZ-DUARTE, J. I.; MALDONADO-JAQUEZ, J. A. The Water Efficiency and Productivity of Forage Maize (*Zea mays* L.) in a Semi-Arid Region Under Different Humidity, Nitrogen, and Substrate Levels. **Crops**, v. 6, n. 1, p. 1, 2025. 10.3390/crops6010001
- ARAGÃO, M.F.; TAVARES, R.; SANTOS, M.D.F.N.D.; LIMA, J.S.; PINHEIRO NETO, L.G. Nitrogen fertilization split in green corn under rainfed system. **Revista Ceres**, v. 69, p. 668-677, 2022. 10.1590/0034-737X202269060005
- ARISEDE, C.; MAINASSARA, Z.A.; JILL, C.; AMSAL, T.; COSMOS, M.; BISH, D.; BENHILDAH, M.; MIKE, O.; MARUTHI, P.B. Low-N stress tolerant maize hybrids have higher fertilizer N recovery efficiency and reduced N-dilution in the grain compared to susceptible hybrids under low N conditions. **Plant Production Science**, v. 23, n. 4, p. 417-426, 2020. 10.1080/1343943X.2020.1746188
- ASIBI, A.E.; CHAI, Q.; COULTER, J. A. Mechanisms of nitrogen use in maize. **Agronomy**, v. 9, n. 12, p. 775, 2019. 10.3390/agronomy9120775
- AYANGBENRO, A.S.; BABALOLA, O.O. Reclamation of arid and semi-arid soils: The role of plant growth-promoting archaea and bacteria. **Current Plant Biology**, v. 25, p. 100173, 2021. 10.1016/j.cpb.2020.100173
- BRANKOV, M.; SIMIĆ, M.; DOLIJANOVIĆ, Ž.; RAJKOVIĆ, M.; MANDIĆ, V.; DRAGIČEVIĆ, V. The response of maize lines to foliar fertilizing. **Agriculture**, v. 10, n. 9, p. 365, 2020. 10.3390/agriculture10090365
- CAMERON, K. C.; DI, H. J.; MOIR, J.L. Nitrogen losses from the soil/plant system: a review. **Annals of Applied Biology**, v. 162, n. 2, p. 145-173, 2013. 10.1111/aab.12014
- CASANOVA, D.; EPEMA, G.F.; GOUDRIAAN, J. Monitoring rice reflectance at field level for estimating biomass and LAI. **Field Crops Research**, v. 55, n. 1-2, p. 83-92, 1998. [https://doi.org/10.1016/S0378-4290\(97\)00064-6](https://doi.org/10.1016/S0378-4290(97)00064-6)
- CASSIM, B.M.A.R.; BESEN, M.R.; KACHINSKI, W.D.; MACON, C.R.; DE ALMEIDA JUNIOR, J.H.V.; SAKURADA, R.; INOUE, T.T.; BATISTA, M.A. Nitrogen fertilizers technologies for corn in two yield environments in South Brazil. **Plants**, v. 11, n. 14, p. 1890, 2022. 10.3390/plants11141890

CIAMPITTI, I.A.; LEMAIRE, G. From use efficiency to effective use of nitrogen: a dilemma for maize breeding improvement. **Science of the Total Environment**, v. 826, p. 154125, 2022. 10.1016/j.scitotenv.2022.154125

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Acompanhamento da safra brasileira: 3º levantamento safra 2025/26**, dezembro de 2025. v. 13, n. 3. Disponível em: <https://www.gov.br/conab/pt-br/atuacao/informacoes-agropecuarias/safras/safra-de-graos/boletim-da-safra-de-graos/3o-levantamento-safra-2025-26/3o-levantamento-safra-2025-26>. Acesso em: 03 jan. 2026

DE ALMEIDA, R.F.; SANCHES, B.C. Fertilizantes nitrogenados com liberação lenta e estabilizada na agricultura. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 7, n. 5, p. 4, 2012.

DEBRUIN, J.L.; SCHUSSLER, J.R.; MO, H.; COOPER, M. Grain yield and nitrogen accumulation in maize hybrids released during 1934 to 2013 in the US Midwest. **Crop Science**, v. 57, n. 3, p. 1431-1446, 2017. 10.2135/cropsci2016.08.0704

DE OLIVEIRA, L.R.; MIRANDA, G.V.; DELIMA, R.O.; FRITSCHÉ-NETO, R.; GALVÃO, J.C.C. Eficiência de absorção e utilização de nitrogênio e atividade enzimática em genótipos de milho. **Revista Ciência Agronômica**, v. 3, p. 614, 2013. 10.1590/S1806-66902013000300025

DOS SANTOS, O.L.; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v. 14, n. 1, p. 145-165, 2018. 10.5008/1809.7367.143

FANCELLI, A.L. **Fenologia do milho**. Piracicaba: ESALQ/USP, 1988.

FANCELLI, A.L. Cultivo racional e sustentável requer maior conhecimento sobre planta do milho. **Visão Agrícola**, v. 13, n. 9, p. 20-23, 2015.

FANCELLI, A.L.; MUNHOZ, R. Programa racional para fertilizantes deve considerar fatores que afetam cultivo. **Visão Agrícola**, v. 13, n. 13, p. 52-57, 2015.

FEITOSA, D.A.; FERREIRA, K.P.F.; ARAGÃO, N.S.C.; SANTOS, B.N.; OLIVEIRA, J.D.S.; SILVA, R.D.J.; SANTOS, J.F.S.; BRITO, M.E.B.; CORDEIRO JUNIOR, J.J.F.; DE OLIVEIRA, G.H.F. Performance of maize hybrids grown in a semi-arid region under rainfed and wastewater irrigation systems. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 29, p. e281710, 2025. 10.1590/1807-1929/agriambi.v29n5e281710

FERNANDES, D.B.; CAMPOS, L.V.; VENTURA, M.V.A. Desempenho da aplicação foliar de nitrogênio na cultura do milho: eficiência e resposta fisiológica. **Research, Society and Development**, v. 14, n. 6, p. e7714649069, 2025. 10.33448/rsd-v14i6.49069.

GHEITH, E.M.S.; EL-BADRY, O.Z.; LAMLAM, S.F.; ALI, H.M.; SIDDIQUI, M.H.; GHAREEB, R.Y.; EL-SHEIKH, M.H.; JEBRIL, J.; ABDELSALAM, N.R.; KANDIL, E.E. Maize (*Zea mays* L.) productivity and nitrogen use efficiency in response to nitrogen application levels and time. **Frontiers in Plant Science**, v. 13, p. 941343, 2022. 10.3389/fpls.2022.941343

LI, Y.; NIE, W.; WAN, Y.; DANG, X.; LI, J.; WANG, H.; BAI, Q. Optimizing water and nitrogen management for enhanced spring maize productivity and resource use efficiency under drip irrigation in arid and semi-arid regions. **Journal of the Science of Food and Agriculture**, v. 106, n. 2, p. 1034-1049, 2026. <https://doi.org/10.1002/jsfa.70229>

MACEDO, F.L.; NÓBREGA, H.; DE FREITAS, J.G.R.; RAGONEZI, C.; PINTO, L.; ROSA, J.; PINHEIRO DE CARVALHO, M.A.A. Estimation of productivity and above-ground biomass for corn (*Zea mays*) via vegetation indices in Madeira Island. **Agriculture**, v. 13, n. 6, p. 1115, 2023. <https://doi.org/10.3390/agriculture13061115>

MACIEL, G.M.; GALLIS, R.; BARBOSA, R.L.; CARNEIRO, V.Q.; REZENDE, W.S.; SIQUIEROLI, A.C.S. High-throughput phenotyping by RGB and multispectral imaging analysis of genotypes in sweet corn. **Horticultura Brasileira**, v. 40, p. 92-98, 2022. <http://dx.doi.org/10.1590/s01020536-2022012>

MARENGO, J.A.; GALDOS, M.V.; CHALLINOR, A.; CUNHA, A.P.; MARIN, F.R.; VIANNA, M.D.S.; ALVALA, R.C.S.; ALVES, L.M.; MORAES, O.L.; BENDER, F. Drought in Northeast Brazil: A review of agricultural and policy adaptation options for food security. **Climate Resilience and Sustainability**, v. 1, p. 1-22, 2022. <https://doi.org/10.1002/cli2.17>

MATA, D.A.da; SILVA, T.B.da; SILVA, J.F.da; SILVA, G.deF.da; PAIVA, J.H.S.; MACENA, R.A.; NASCIMENTO, R.R.A.; ARAÚJO, J.V.dos S.; PEREIRA, F.M.; LIMA, A.D. da C.; SILVA, F.G.da; SOARES, J.V.; SILVA, B.O.T. da; MARTINS, A.H.P. da C.; MATA, D.A.da. Fertilidade do solo no semiárido: características e desafios. **Revista de Gestão e Secretariado**, [S. l.], v. 15, n. 9, p. e4278, 2024. 10.7769/gesec.v15i9.4278. Disponível em: <https://ojs.revistagesec.org.br/secretariado/article/view/4278>. Acesso em: 23 nov. 2025.

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

MODESTO, V.C.; SOUZA, H.D.; CAVALCANTE, A.C.R.; SALLES, H.O.; LIMA, A. R.; DIAS, C.T.S.; NATALE, W. Nitrogen fertilization regarding maize crop in a semi-arid region. **Científica**, v. 45, n. 4, p. 443-452, 2017. <https://doi.org/10.15361/1984-5529.2017v45n4p443-452>

MOLL, R.H.; KAMPRATH, E.J.; JACKSON, W.A. Analysis and interpretation of factors which contribute to efficiency of nitrogen utilization. **Agronomy Journal**, v. 74, n. 3, p. 562-564, 1982. 10.2134/agronj1982.00021962007400030037x

NOPERI-MOSQUEDA, L.C.; ALVAREZ-HOLGUIN, A.; OCHOA-RIVERO, J.M.; VILLAREAL-GUERRERO, F.; RUIZ-ÁLVAREZ, O.; DELGADO-SÁNCHEZ, P.; NAVARRO-LEÓN, ELOY; PONCE-GARCÍA, O.C. Production and Photosynthetic Indicators of Maize Hybrids (*Zea mays* L.) Under Drought Conditions in a Semi-Arid Region. **Journal of Plant Growth Regulation**, p. 1-17, 2024. <https://doi.org/10.1007/s00344-024-11477-7>

OLIVOTO, T. Lights, camera, pliman! An R package for plant image analysis. **Methods in Ecology and Evolution**, v. 13, n. 4, p. 789-798, 2022. <https://doi.org/10.1111/2041-210X.13803>

ORTEZ, O.A.; MCMECHAN, A.J.; HOEGEMEYER, T.; CIAMPITTI, I.A.; NIELSEN, R.; THOMISON, P.R.; ELMORE, R.W. Abnormal ear development in corn: A review. **Agronomy Journal**, v. 114, n. 2, p. 1168-1183, 2022. <https://doi.org/10.1002/agj2.20986>

PINTO, F.; ZAMAN-ALLAH, M.; REYNOLDS, M.; SCHULTHESS, U. Satellite imagery for high-throughput phenotyping in breeding plots. **Frontiers in Plant Science**, v. 14, p. 1114670, 2023. 10.3389/fpls.2023.1114670

PRECIADO-ORTIZ, R.E.; OCHOA-CENTENO, N.J.; VÁZQUEZ-CARRILLO, M.G.; SANTIAGO-RAMOS, D.; TERRÓN-IBARRA, A.D. Grain yield, physical and pasting properties, and anthocyanins of non-conventional pigmented corn hybrids for pozole end-use adapted to subtropical regions. **Applied Food Research**, v. 2, n. 2, p. 100180, 2022. <https://doi.org/10.1016/j.afres.2022.100180>

RESENDE, E.L.; BRUZI, A.T.; CARDOSO, E.D.S.; CARNEIRO, V.Q.; PEREIRA DE SOUZA, V.A.; FROIS CORREA BARROS, P.H.; PEREIRA, R.R. High-throughput phenotyping: application in maize breeding. **AgriEngineering**, v. 6, n. 2, p. 1078-1092, 2024. <https://doi.org/10.3390/agriengineering6020062>

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. **Monitoring vegetation systems in the Great Plains with ERTS**. Washington, DC: NASA, 1974. (NASA Special Publication, 351, 309).

SAHAY, S.; ROBLEDO-ARRATIA, L.; GLOWACKA, K.; GUPTA, M. Root NRT, NiR, AMT, GS, GOGAT and GDH expression levels reveal NO and ABA mediated drought tolerance in Brassica juncea L. **Scientific Reports**, v. 11, n. 1, p. 7992, 2021. 10.1038/s41598-021-86401-0

SANTOS, A.M.; FEITOSA, D.A.S.; SANTOS, B.N.; CORDEIRO JUNIOR, J.J.F.; OLIVEIRA, G.H.F. Estabilidade Produtiva de Genótipos de Milho no Alto Sertão Sergipano. **Revista Eletrônica Competências Digitais para Agricultura Familiar**, v. 11, n. 1, p. e1101201, 2025. Disponível em: <https://owl.tupa.unesp.br/recodaf/index.php/recodaf/article/view/201>. Acesso em: 23 nov. 2025

SHEPARD, N.R.; DESALVIO, A.J.; ARIK, M.; ADAK, A.; MURRAY, S.C.; VARELA, J.I. Deep learning-based high-throughput detection of flowered maize (*Zea mays* L.) plots from UAS imagery across environments. **The Plant Phenome Journal**, v. 8, n. 1, p. e70021, 2025. <https://doi.org/10.1002/ppj2.70021>

SILVA, S.; DA PAZ SOUSA, A.C.; DA SILVA, C.S.; RODRIGUES ARAÚJO, E.; DA SILVA SOARES, M.A.; TEODORO, I. Parâmetros produtivos do milho sob déficit hídrico em diferentes fases fenológicas no semiárido brasileiro. **Irriga**, [S. l.], v. 1, n. 1, p. 30–41, 2021. 10.15809/irriga.2021v1n1p30-41. Disponível em: <https://revistas.fca.unesp.br/index.php/irriga/article/view/4254>. Acesso em: 23 nov. 2025.

SU, W.; ZHANG, M.; BIAN, D.; LIU, Z.; HUANG, J.; WANG, W., WU, J.; GUO, H. Phenotyping of corn plants using unmanned aerial vehicle (UAV) images. **Remote Sensing**, v. 11, n. 17, p. 2021, 2019. <https://doi.org/10.3390/rs11172021>

TAIZ, L.; ZEIGER, E.; MOLLER, I. M.; MURPHY, A. **Fisiologia e desenvolvimento vegetal**. 6. ed. Porto Alegre: Artmed, 2017. p. 731.

TYAGI, J.; AHMAD, S.; MALIK, M. Nitrogenous fertilizers: impact on environment sustainability, mitigation strategies, and challenges. **International Journal of Environmental Science and Technology**, v. 19, n. 11, p. 11649-11672, 2022. 10.1007/s13762-022-04027-9

VALENCIA-ORTIZ, M.; MCGEE, R.J.; CARTER, A. H.; SANKARAN, S. Variability in vegetation indices as a function of unmanned aerial vehicle flight altitudes and other factors for crop monitoring applications. **Agricultural Engineering International: CIGR Journal**, v. 27, n. 2, 2025.

WANI, S.H.; VIJAYAN, R.; CHOUDHARY, M.; KUMAR, A.; ZAID, A.; SINGH, V.; KUMAR, P.; YASIN, J. K. Nitrogen use efficiency (NUE): elucidated mechanisms, mapped genes and gene networks in maize (*Zea mays* L.). **Physiology and Molecular Biology of Plants**, v. 27, n. 12, p. 2875-2891, 2021. 10.1007/s12298-021-01113-z

XIAO, J.; SUAB, S.A.; CHEN, X.; SINGH, C.K.; SINGH, D.; AGGARWAL, A.K.; KOROM, A.; WIDYATMANTI, W.; MOLLAH, T.H.; MINH, H.V.T.; KHEDHER, K.M.; AVTAR, R. Enhancing assessment of corn growth performance using unmanned aerial vehicles (UAVs) and deep learning. **Measurement**, v. 214, p. 112764, 2023. <https://doi.org/10.1016/j.measurement.2023.112764>

ZHANG, C.; MARZOUGUI, A.; SANKARAN, S. High-resolution satellite imagery applications in crop phenotyping: An overview. **Computers and Electronics in Agriculture**, v. 175, p. 105584, 2020. 10.1016/j.compag.2020.105584

ZHANG, Z.; ZHU, L. A review on unmanned aerial vehicle remote sensing: Platforms, sensors, data processing methods, and applications. **Drones**, v. 7, n. 6, p. 398, 2023. <https://doi.org/10.3390/drones7060398>

4. ARTIGO 1

MODELOS DE APRENDIZADO DE MÁQUINA COM ÍNDICES DE VEGETAÇÃO OBTIDOS POR VANT PARA PREDIÇÃO DA PRODUTIVIDADE DE MILHO EM AMBIENTES CONTRASTANTES DE NITROGÊNIO

Artigo formatado de acordo com as normas do periódico The Journal of Agricultural Science

B. N. Santos¹, N. S. C. Aragão¹, J. F.S. Santos¹, C. N. S. Lima¹, T. R. A. Oliveira², J. J. F. C. Junior², G. H. F. Oliveira², W. G. Vale³

¹ *Programa de Pós-Graduação em Agricultura e Biodiversidade, Universidade Federal de Sergipe, Avenida Marechal Rondon Jardim, s/n. 49100-000, Rosa Elze, São Cristóvão, Sergipe, Brasil.*

² *Departamento de Engenharia Agrônômica do Sertão, Universidade Federal de Sergipe, Avenida Vinte e Seis de Setembro, 1126. 49680-000, Nova Esperança, Nossa Senhora da Glória, Sergipe, Brasil.*

³ *Departamento de Engenharia Agrícola, Universidade Federal de Sergipe, Avenida Marechal Rondon Jardim, s/n. 49100-000, Rosa Elze, São Cristóvão, Sergipe, Brasil.*

***Autor correspondente:** B. N. Santos, Email: barbaranascimento2804@gmail.com

RESUMO

No milho (*Zea mays* L.), a produtividade de grãos está intimamente relacionada à utilização eficiente do nitrogênio, tornando crucial o desenvolvimento de métodos que permitam sua predição para otimizar o tempo de avaliação. Objetivou-se avaliar modelos de regressão e aprendizado de máquina na predição da produtividade de grãos de progênies de meios-irmãos de milho em ambientes contrastantes de nitrogênio. Os experimentos foram conduzidos em duas áreas experimentais, nos municípios de Nossa Senhora da Glória e de Graccho Cardoso, em 2024, em delineamento em blocos casualizados, com esquema de parcela subdividida, replicado três vezes. Os níveis de nitrogênio (alto e baixo) constituíram as parcelas, e as progênies de meios-irmãos de milho as subparcelas. As imagens multiespectrais foram obtidas durante três voos em duas alturas (60 e 80 m). Foram testados quatro modelos preditivos: linear, penalizado e baseados em árvores. Em ambas as áreas experimentais e nas condições de nitrogênio, os modelos cforest e GBM apresentaram maior acurácia, com menores valores de RMSE e MAE e ajuste mais adequado entre os valores observados e preditos. As análises de importância das variáveis e dos valores SHAP aplicadas aos modelos GBM e cforest revelaram que um conjunto reduzido de índices de vegetação concentrou a maior contribuição preditiva. Verificou-se comportamento preditivo diferenciado entre os genótipos em função dos algoritmos avaliados. Recomenda-se o uso dos modelos cforest e GBM associados a índices de vegetação como TCARI, MCARI e MSAVI2 para a predição da produtividade de grãos em milho. Estudos adicionais são necessários para avaliar o desempenho desses índices em mais níveis de nitrogênio.

Palavras-chave: Baixo nitrogênio; Drone, Fenotipagem de alto rendimento; *Zea mays* L.

4.1. Introdução

A produtividade de grãos do milho (*Zea mays* L.) é um dos fatores agronômicos mais importantes para a segurança alimentar global, bem como para o planejamento agrícola dos sistemas de produção, particularmente em áreas de variabilidade ambiental como as regiões

semiáridas (Feitosa *et al.*, 2025; Wu *et al.*, 2024; Nogueira *et al.*, 2023; Rahimi Jahangirlou *et al.*, 2021).

O rendimento final da cultura é o resultado da combinação de vários processos fisiológicos, como a expansão da área foliar, a eficiência fotossintética, a assimilação e a redistribuição de nutrientes, duração das etapas no ciclo fenológico, especialmente as que definem o potencial produtivo (Ren *et al.*, 2023; Welcker *et al.*, 2022; Fancelli, 1988). Esses processos são amplamente afetados pelas condições edafoclimáticas e pelo manejo aplicado durante o ciclo da cultura.

Dentre os fatores nutricionais, o nitrogênio (N) é o nutriente que mais limita a produtividade do milho, pois está diretamente ligado à produção de clorofila, proteínas e enzimas que participam do metabolismo do carbono e da fotossíntese (Sun *et al.*, 2025; Gheith *et al.*, 2022; Asibi, Chai e Coulter, 2019; Taiz *et al.*, 2017). A falta de nitrogênio afeta o crescimento vegetativo, diminui a absorção da radiação fotossintética e restringe o acúmulo de biomassa, resultando em uma redução na quantidade e no peso dos grãos, apresentando como principal sintoma o amarelecimento das folhas mais velhas (Wani *et al.*, 2021; Xing *et al.*, 2021; Taiz *et al.*, 2017).

Em contrapartida, o uso excessivo de N pode levar a uma baixa eficiência, aumento dos custos de produção e impactos ambientais (Tyagi, Ahmad e Malik, 2022; Bashir *et al.*, 2013). Isso evidencia a necessidade de ferramentas que possibilitem o monitoramento do estado nutricional das plantas e a previsão do desempenho produtivo da cultura.

Comumente, a estimativa da produtividade do milho é realizada somente no encerramento total do ciclo, mediante a colheita e pesagem dos grãos. Isso impede que se façam intervenções de manejo durante o desenvolvimento da cultura. Nesse contexto, a fenotipagem por imagem vem se estabelecendo como uma opção promissora para a avaliação não destrutiva do crescimento e do estado fisiológico das plantas, possibilitando a estimativa do potencial produtivo mesmo em estágios intermediários do ciclo (Bagum *et al.*, 2025; Santos *et al.*, 2025; Resende *et al.*, 2024).

Notavelmente, os avanços nos veículos aéreos não tripulados (VANTs) equipados com sensores multiespectrais permitiram a captura de imagens com elevada resolução espacial, superando restrições observadas em imagens de satélites, que apresentam resolução espacial reduzida e interferência atmosférica (Pinto *et al.*, 2023).

Quando comparados a sensores orbitais, como o Sentinel-2, os VANTs proporcionam uma resolução espacial e uma flexibilidade temporal superiores, permitindo aquisições em estádios fenológicos específicos e sob condições controladas, o que é especialmente importante para experimentos de campo e ambientes heterogêneos (Li *et al.*, 2022; Bollas, Kokinou e Polychronos, 2021). Em contrapartida, as imagens de satélite oferecem uma cobertura espacial mais ampla e custos operacionais mais baixos (Pádua *et al.*, 2020; Segarra *et al.*, 2020). Nesse caso, a seleção entre plataformas aéreas e orbitais deve levar em conta o propósito da pesquisa, a escala de análise e o grau de detalhamento necessário.

Com base nas imagens capturadas pelos VANTs, é possível calcular diversos índices de vegetação usando bandas do visível, do infravermelho próximo e, em certas situações, da região do red-edge (Dos Santos, Padolfi e Ramaldes, 2018; Shiratsuchi *et al.*, 2014). Isso aumenta a sensibilidade para detectar variações fisiológicas do milho em diferentes estádios fenológicos e condições nutricionais.

Dessa maneira, o uso dos VANTs na fenotipagem agrícola oferece vantagens significativas em relação aos métodos tradicionais, que demandam intensivamente mão de obra, tempo e recursos, principalmente em experimentos com um grande número de genótipos (Smith, Potgieter e Chapman, 2021; Omari *et al.*, 2020; Vasseur *et al.*, 2017). Embora o investimento inicial em plataformas aéreas e sensores espectrais possa ser elevado, o retorno costuma ser significativo, pois essas tecnologias possibilitam um maior detalhamento sobre a lavoura, além de gerarem dados com elevada acuracidade.

Na perspectiva da aplicação prática, os progressos em softwares dedicados ao processamento fotogramétrico e à extração de índices de vegetação têm sido fundamentais para a ampla utilização da fenotipagem por imagem. Nesse cenário, sobressaem-se plataformas de código aberto, como QGIS e WebODM, que disponibilizam ferramentas robustas para ortorretificação, criação de mosaicos de imagens e cálculo de índices espectrais, além dos softwares de código fechado, como Agisoft Metashape e Pix4D, amplamente empregados em pesquisas agrícolas por conta de sua elevada automação, estabilidade e eficiência em fluxos de trabalho fotogramétricos complexos (Kostrzewa *et al.*, 2025).

Diversos estudos têm demonstrado relações significativas entre índices de vegetação e a produtividade de grãos do milho (Santos *et al.*, 2025; Resende *et al.*, 2024; Burns *et al.*, 2022; Silva *et al.*, 2022). No entanto, muitos desses estudos se baseiam em análises de correlação simples ou modelos lineares, que nem sempre conseguem capturar a relação não linear entre variáveis espectrais e rendimento final, especialmente em ambientes com diferentes níveis de disponibilidade de nitrogênio.

Ademais, os estudos que combinam de maneira sistemática múltiplos índices de vegetação, variados estágios de desenvolvimento da cultura e modelos preditivos mais avançados, como os fundamentados em aprendizado de máquina, associados a uma interpretação fisiológica coerente dos resultados, ainda são escassos.

Por fim, é essencial analisar a capacidade dos índices de vegetação obtidos por VANTs em prever a produtividade do milho, levando em conta ambientes contrastantes de nitrogênio e métodos estatísticos que possam lidar com as complexas interações entre variáveis. Dessa forma, o objetivo deste estudo foi analisar a acurácia de modelos lineares e *machine learning* na predição da produtividade de grãos de progênies de meios-irmãos de milho cultivadas em condições contrastantes de nitrogênio, utilizando índices de vegetação multispectrais obtidos por drones.

4.2. Material e Métodos

4.2.1. Material genético, descrição da área e delineamento experimental

As progênies de meios-irmãos avaliadas foram provenientes de uma variedade de polinização aberta (PopTol2), caracterizada por tolerância ao déficit hídrico. Para a obtenção das progênies, foi instalado um campo de polinização no município de Nossa Senhora da Glória, Sergipe (10°13'06" S 37° 25'13" O e 291 m), durante a safra de 2023. O campo foi implantado a uma distância de 200 metros de outras áreas com plantio de milho, a fim de evitar contaminação por pólen externo. Utilizou-se espaçamento de 0,8 m entre linhas e 0,2 m entre plantas, com linhas de 10 m.

As progênies foram avaliadas e selecionadas com base nos critérios de bom desempenho de sanidade de espiga e componentes de produtividade (diâmetro de espiga, número de fileiras de grãos, número de grãos na fileira, comprimento de espiga). Inicialmente, foram semeadas manualmente as mesmas 50 progênies em cada ambiente experimental, nos municípios de Nossa Senhora da Glória e Graccho Cardoso, Sergipe (10°13'42" S 37° 12'9" O e 225 m), no ano agrícola de 2024.

Após a condução dos experimentos, colheita e obtenção dos dados fenotípicos, procedeu-se com o pré-processamento dos dados de cada local de forma independente. Esse pré-processamento incluiu a verificação da consistência dos dados, identificação de outliers e exclusão de parcelas perdidas. Como resultado desse controle de qualidade, foram consideradas para as análises estatísticas dados de 33 progênies no ambiente de Nossa Senhora da Glória e 27 progênies no ambiente de Graccho Cardoso. As duas regiões apresentam clima do tipo 'tr**neb' (Novais & Machado, 2023) e solo classificado como argissolo. As informações referentes à precipitação e temperatura dos experimentos estão demonstradas nas Figuras 1 e 2.




Figura 1. Precipitação pluviométrica diária (mm) e variação da temperatura do ar - máxima (Tmax), média (Tmed) e mínima (Tmin) — ao longo dos dias após o plantio (DAP) na área experimental de Nossa Senhora da Glória, SE. As linhas verticais tracejadas indicam os estádios fenológicos V7/V8, VT e R1 do milho.




Figura 2. Precipitação pluviométrica diária (mm) e variação da temperatura do ar - máxima (Tmax), média (Tmed) e mínima (Tmin) — ao longo dos dias após o plantio (DAP) na área experimental de Graccho Cardoso, SE. As linhas verticais tracejadas indicam os estádios fenológicos V7, VT e R1 do milho.

Em ambos os locais, os experimentos foram conduzidos em delineamento em blocos casualizados (DBC), em esquema de parcela subdividida, com três repetições. A adubação de fundação foi realizada de acordo com as recomendações para a cultura do milho, sendo aplicados, em Nossa Senhora da Glória, 181,8 kg ha⁻¹ de MAP, 30 kg ha⁻¹ de P₂O₅ e 100 kg ha⁻¹ de KCl, e, em Graccho Cardoso, 181,8 kg ha⁻¹ de MAP, 141 kg ha⁻¹ de P₂O₅ e 133 kg ha⁻¹ de KCl. Adicionalmente, foram aplicados 20 kg ha⁻¹ de nitrogênio na adubação de fundação em ambos os locais.

Os níveis de nitrogênio constituíram as parcelas, sendo definidos dois tratamentos: alto nitrogênio (140 kg ha⁻¹ de N, aplicado em cobertura de forma parcelada, com 60% da dose no primeiro parcelamento e 40% no segundo) e baixo nitrogênio (sem adubação nitrogenada em cobertura). As subparcelas foram compostas pelas progênies de meios-irmãos. Cada

subparcela consistiu de duas linhas de três metros de comprimento, espaçadas em 0,70 m entre linhas e 0,20 m entre plantas, contabilizando 30 plantas por subparcela, o que corresponde a uma população de aproximadamente 71.425 plantas ha⁻¹.

4.2.2. *Obtenção e processamento das imagens*

As imagens foram capturadas utilizando um veículo aéreo não tripulado (VANT) DJI Mavic 3 Multispectral, equipado com câmera multispectral composta por quatro bandas espectrais (4 × 5 MP: Green, Red, RedEdge e NIR) e uma câmera RGB de 20 MP (sensor 4/3 CMOS), sendo equipado com RTK (Real-Time Kinematic), utilizado para garantir precisão geométrica no posicionamento das imagens. As bandas da câmera multispectral compreendiam os comprimentos de onda: Verde (G) 560 nm ± 16 nm; Vermelho (R) 650 nm ± 16 nm; Borda vermelha (RE) 730 nm ± 16 nm e Infravermelho próximo (NIR) 860 nm ± 26 nm (Tecnodrones, 2025)

O aplicativo DroneDeploy foi utilizado para delimitação da área de voo, alturas de voo (60 e 80 metros ao nível do solo) e sobreposição frontal e lateral (80%) das imagens. Foram realizados três voos em cada área experimental, com horários mantidos entre 11h00 e 13h00, em condições de pleno sol. Durante a aquisição, a correção automática do sensor multispectral foi empregada, realizando ajustes internos de exposição e ganho, com o objetivo de reduzir variações radiométricas decorrentes das condições de iluminação.

O processamento das imagens foi efetuado no software Agisoft Metashape Professional®, seguindo um fluxo padrão de fotogrametria, aplicado separadamente para cada área experimental, altura de voo e data de voo. As etapas do processamento são ilustradas na Figura 3 e compreendem: 1) importação das imagens; 2) correção das coordenadas; 3) alinhamento das imagens; 4) otimização dos parâmetros das câmeras; 5) criação da nuvem de pontos densa; 6) construção do modelo tridimensional; 7) aplicação de textura; 8) criação do modelo em mosaico; 9) construção do modelo digital de elevação (DEM); e 10) criação do orthomosaico.

As características da câmera multispectral utilizada, bem como os parâmetros de aquisição, processamento e qualidade fotogramétrica das imagens, estão apresentadas na Tabela 1. Para a área experimental de Nossa Senhora da Glória, foram utilizadas 300 imagens, enquanto para Graccho Cardoso foram utilizadas 296 imagens. A resolução espacial (GSD), o erro de reprojeção e o erro espacial horizontal (erro XY) indicaram adequada qualidade dos orthomosaicos para as análises subsequentes de índices de vegetação.




Figura 3. Etapas do processamento das imagens para obtenção dos orthomosaicos.

Tabela 1. Resumo dos parâmetros de aquisição, processamento e métricas de qualidade fotogramétrica das imagens obtidas por VANT nas áreas experimentais, no primeiro voo, a 60 metros de altura.

	Área experimental	
	Graccho Cardoso	Nossa Senhora da Glória
Número de imagens	300	296
Resolução da câmera (px)	2592x1944	2592x1944
Distância focal (mm)	4,34	4,34
GSD (cm pixel ⁻¹)	2,81	2,78
Erro de reprojeção (px)	1,31	1,18
Erro XY (mm)	6	5,7

Notas: GSD = ground sampling distance. O erro de reprojeção refere-se ao ajuste interno do modelo fotogramétrico, enquanto o erro XY representa o erro espacial horizontal dos orthomosaicos após o processamento

4.2.3. Índices de vegetação

A extração dos índices de vegetação foi realizada a partir dos orthomosaicos utilizando os pacotes *pliman* e *plimanshiny* (Olivoto, 2022) no software R 4.3.3 (R Core Team, 2024). Inicialmente, as bandas espectrais foram organizadas de modo a garantir a correspondência radiométrica e espacial entre as camadas. Em seguida, foi criada uma camada vetorial no formato *shapefile* (shp), considerando o número de colunas, linhas e tamanho das subparcelas experimentais. Posteriormente, realizou-se a seleção dos índices de vegetação a serem avaliados, contemplando combinações espectrais baseadas nas bandas Red, Green, RE e NIR.

Para remoção do solo exposto e cálculo dos índices de vegetação considerando apenas a vegetação, a opção *segment plot* do *plimanshiny* foi marcada. Para essa etapa, utilizou-se o índice de vegetação por diferença normalizada (NDVI). Feito isso, foram extraídos os valores

médios dos índices de vegetação para cada subparcela experimental. A Figura 4 apresenta um pipeline com as etapas do processamento realizadas no *plimanshiny*.

A seleção dos índices de vegetação empregados neste estudo foi fundamentada em critérios fisiológicos e espectrais, baseados na capacidade empírica de representar atributos relevantes do dossel do milho, como biomassa verde, cobertura do solo e conteúdo relativo de clorofila, fatores diretamente relacionados ao potencial produtivo da cultura. Ao todo, foram computados 14 índices de vegetação multispectrais (Tabela 2).




Figura 4. Pipeline para obtenção dos índices de vegetação multispectrais.

Tabela 2. Descrição dos índices de vegetação multispectrais utilizados no estudo.

Índice	Fórmula	Referência
Chlorophyll vegetation index (CVI)	$(NIR * R) / G^2$	(Vincini <i>et al.</i> , 2008)
Green difference vegetation index (GDVI)	$NIR - G$	(Tucker, 1979)
Green optimal soil adjusted vegetation index (GOSAVI)	$(1 + 0.16)(NIR - G) / (NIR + G + 0.16)$	(Rondeaux <i>et al.</i> , 1996)
Green ratio vegetation index (GRVI)	NIR / G	(Buschmann and Nagel, 1993)
Green soil adjusted vegetation index (GSAVI)	$1.5((NIR - G) / (NIR + G + 0.5))$	(Sripada <i>et al.</i> , 2006)
Infrared percentage vegetation index (IPVI)	$NIR / (NIR + R)$	(Crippen, 1990)
Modified chlorophyll absorption in reflectance index 1 (MCARI1)	$[(NIR - RE) - 0.2 * (NIR - G)] * (NIR / RE)$	(Daughtry <i>et al.</i> , 2000)
Modified chlorophyll absorption	$(1.5(NIR - RE) - 1.3(NIR$	(Haboudane <i>et al.</i> ,

in reflectance index 2(MCARI2)	$\frac{-G + \sqrt{(2NIR + 1)^2 - (6NIR - 5RE) - 0.5}}{2}$	(2004)
Modified Vegetation Index (MSAVI)	$0.5 [2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}]$	(Qi <i>et al.</i> , 1994)
Normalized difference vegetation index (NDVI)	$(NIR - R)/(NIR + R)$	(Tucker, 1979)
Red Edge Simple Ratio (RESR)	RE/R	(Erdle <i>et al.</i> , 2011)
Ratio vegetation index (RVI)	NIR/R	(Jordan, 1969)
Transformed Chlorophyll Absorption in Reflectance Index (TCARI)	$3((RE - R) - 0.2(RE - G) * (RE / R))$	(Haboudane <i>et al.</i> , 2002)
Triangular vegetation index (TVI)	$0.5 * (120 * (NIR - G) - 200 * (R - G))$	(Broge and Leblanc, 2001)

Notas: R, G, NIR e RE representam os valores das bandas presentes na imagem para vermelho, verde, infravermelho próximo e de borda vermelha, respectivamente.

4.2.4. Análises estatísticas

Todas as análises estatísticas foram realizadas utilizando o software R 4.3.3 (R Core Team, 2024), com pacotes para modelagem preditiva e aprendizado de máquina. A base de dados foi composta pela produtividade de grãos de milho e por índices de vegetação multispectrais derivados de imagens aéreas.

Os índices de vegetação foram organizados no formato wide, em que cada variável representou a combinação entre o índice espectral e a respectiva data de voo, expressa em dias após o plantio. Dessa forma, a informação temporal associada às datas de voo foi incorporada diretamente às variáveis preditoras.

Para o desenvolvimento dos modelos de regressão, os dados foram divididos em dois subconjuntos: treino (80%) e teste (20%), de forma estratificada, considerando exclusivamente a variável resposta, produtividade de grãos. Esse procedimento teve como objetivo assegurar a representatividade dos dados em ambos os subconjuntos e minimizar o viés na análise do desempenho preditivo. O particionamento foi realizado utilizando a função *createDataPartition* do pacote *caret*, assegurando reprodutibilidade com *set.seed(123)*.

Antes do ajuste dos modelos, as funções *step_normalize*, *step_corr* e *step_zv* do pacote *recipes* foram utilizadas, respectivamente, para padronizar todos os preditores (média = 0; sd = 1), remover variáveis com correlação superior a 0,95 e remover variáveis com ausência de variação.

Os modelos de regressão foram treinados sob um mesmo esquema de validação, empregando validação cruzada repetida (20 folds × 5 repetições). Esse método foi implementado para diminuir a variabilidade das estimativas de desempenho e fortalecer a comparação entre algoritmos. A seleção desse esquema é especialmente importante em pesquisas com dados agrícolas, em que a variabilidade ambiental pode ter um impacto significativo nos resultados.

Foram avaliados diferentes algoritmos de regressão, contemplando abordagens lineares, penalizadas e baseadas em árvores de decisão, conforme descrito na Tabela 3. A diversidade de modelos permitiu tratar a alta dimensionalidade e a redundância espectral, que são características típicas dos dados de sensoriamento remoto.

Tabela 3. Classificação e finalidade dos modelos utilizados para predição da produtividade de grãos baseada em índices de vegetação multispectrais.

Modelo	Tipo	Descrição
--------	------	-----------

Linear model	Regressão linear	Modelo paramétrico que estima a relação linear entre as variáveis.
LASSO	Regressão penalizada	Regressão linear com penalização L1, promovendo seleção automática de variáveis.
cforest	Árvores condicionais	Floresta aleatória baseada em árvores de inferência condicional.
GBM	Boosting de árvores	Modelo aditivo baseado em árvores de decisão sequenciais que minimizam o erro residual

Para os modelos Linear e LASSO, as pressuposições de normalidade, homoscedasticidade e independência dos resíduos foram avaliadas por meio de gráficos de resíduos versus valores ajustados, gráficos Q-Q plot e scale-location. A interpretabilidade dos modelos Cforest e GBM foi avaliada por meio de *Feature importance rankings* das variáveis e valores SHAP (*SHapley Additive exPlanations*). Todas as análises foram realizadas separadamente para cada ambiente experimental, nível de nitrogênio e altura de voo.

As métricas de erro quadrático médio (em inglês RMSE: *Root Mean Square Error*) e erro absoluto médio (em inglês MAE: *Mean Absolute Error*) foram empregadas para comparar o desempenho dos modelos, com base nas previsões feitas nos conjuntos de treino e teste. Adicionalmente, os genótipos foram avaliados em rankings dentro de cada modelo com base no RMSE. As equações utilizadas para calcular as métricas foram:

Erro quadrático médio:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_{obs}^i - V_{pred}^i)^2} \quad (1)$$

Erro absoluto médio:

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_{obs}^i - V_{pred}^i| \quad (2)$$

Onde, V_i obs é o valor observado, V_i pred é a predição do modelo, e n é o número de valores observados.

A Eficiência Agronômica no uso de nitrogênio (EAN) foi calculada com base na metodologia descrita por Moll *et al.* (1982), sendo expressa pela seguinte equação:

$$EAN = Gw / Ns$$

Onde, Gw é o valor da produção de grãos, e Ns é a quantidade de nitrogênio aplicado à planta.

4.3. Resultados

4.3.1. Desempenho dos modelos de regressão na predição da produtividade de grãos

De maneira geral, os modelos de regressão avaliados exibiram desempenho distinto entre as áreas experimentais, refletindo a influência das condições ambientais, do nível de nitrogênio e da resolução espacial das imagens na capacidade dos índices de vegetação em explicar variações da produtividade de grãos. Em ambos os ambientes, os algoritmos baseados em aprendizado de máquina (GBM, Cforest) exibiram desempenho superior em comparação aos modelos linear e LASSO, com menores valores de RMSE e MAE, independentemente do nível de nitrogênio e da altura de voo (Figuras 5 e 6), evidenciando maior acurácia preditiva e melhor capacidade de generalização.

Na área experimental de Nossa Senhora da Glória (Figura 5), sob baixo nitrogênio e altura de voo de 60 m, as diferenças entre os algoritmos foram mais evidentes, com valores de RMSE variando entre 1.700 e 2.200 kg ha⁻¹, enquanto os valores de MAE variaram entre 1.200 e 1.700 kg ha⁻¹, com destaque para os modelos Cforest e GBM, que apresentaram valores de RMSE de aproximadamente 1.900 kg ha⁻¹ e MAE variando em torno de 1.400 kg ha⁻¹. Esse comportamento sugere que os modelos não lineares têm maior habilidade em capturar variação fisiológica do dossel, característica marcante em ambientes sob estresse nutricional.




Figura 5. Desempenho dos modelos de regressão para a área de Nossa Senhora da Glória em condições de baixo e alto nitrogênio, nas duas alturas de voo (60 e 80 metros).

Por outro lado, sob alto nitrogênio, notou-se um aumento geral dos erros e uma diminuição das diferenças entre os modelos, o que indica uma limitação do contraste espectral em ambientes mais homogêneos, especialmente nas imagens obtidas a 80 metros. Resultados que evidenciam a influência negativa da redução da resolução espacial sobre a capacidade preditiva dos modelos.

Na área experimental de Graccho Cardoso (Figura 6), os valores de erro foram, em geral, menores do que os registrados em Nossa Senhora da Glória. Foi observada, de modo geral, uma variação de RMSE entre 500 e 1.000 kg ha⁻¹ e MAE entre 400 e 800 kg ha⁻¹, indicando maior estabilidade preditiva. Em ambos os ambientes, os menores erros concentraram-se nos modelos baseados em aprendizado de máquina, sobretudo nas imagens obtidas a 60 m.




Figura 6. Desempenho dos modelos de regressão para a área de Graccho Cardoso em condições de baixo e alto nitrogênio, nas duas alturas de voo (60 e 80 metros).

4.3.2 Dispersão entre produtividade observada e predita

Os gráficos de dispersão entre a produtividade observada e predita corroboram os padrões identificados pelas métricas de desempenho. Em Nossa Senhora da Glória (Figura 7), sob baixo nitrogênio e altura de voo de 60 m, observou-se menor dispersão dos pontos e melhor alinhamento à linha de identidade para os modelos baseados em árvores, indicando maior acurácia preditiva.

Entretanto, ao comparar os coeficientes de determinação entre os conjuntos de treinamento e teste, verifica-se redução substancial no desempenho preditivo, evidenciando limitações na capacidade de generalização dos modelos. Nesse cenário, os modelos lineares e LASSO apresentaram maior dispersão dos pontos e baixos valores de R^2 no conjunto de teste (0,10 e 0,20, respectivamente), indicando baixa capacidade de capturar a relação entre os índices espectrais e a produtividade.




Figura 7. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Nossa Senhora da Glória, com altura de voo de 60 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.




Figura 8. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Nossa Senhora da Glória, com altura de voo de 60 m em alto nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.

No conjunto de treinamento, os modelos baseados em aprendizado de máquina apresentaram elevados coeficientes de determinação. Para o modelo Cforest, os valores de R^2 sob baixo nitrogênio foram de 0,80 e 0,76 nas alturas de voo de 60 e 80 m, respectivamente, enquanto os valores no conjunto de teste foram reduzidos para 0,41 e 0,31 (Figuras 7 e 9c). De forma semelhante, o modelo GBM apresentou R^2 de 0,82 e 0,66 no treinamento, mas com redução para 0,31 e 0,26 no teste nas mesmas alturas de voo (Figuras 7 e 9d), indicando perda de desempenho preditivo quando aplicado a dados não utilizados no ajuste do modelo.

Sob alto nitrogênio (Figura 8), observou-se maior variabilidade no desempenho dos algoritmos. Para o modelo linear, os valores de R^2 foram semelhantes entre treinamento (0,56) e teste (0,50), sugerindo maior estabilidade do modelo. Em contraste, os algoritmos baseados em aprendizado de máquina apresentaram diferenças mais pronunciadas entre treino e teste. O

modelo Cforest apresentou R^2 de 0,64 no treinamento e 0,22 no teste, enquanto o GBM apresentou R^2 de 0,69 no treinamento e apenas 0,02 no teste, indicando possível sobreajuste aos dados de treinamento.

Com o aumento da altura de voo para 80 m (Figuras 9 e 10), observou-se maior dispersão entre os valores observados e preditos em todos os algoritmos avaliados. Embora os modelos baseados em árvores tenham mantido desempenho semelhante ou superior aos modelos lineares em alguns cenários, verificou-se redução ou instabilidade no desempenho preditivo em determinados níveis de nitrogênio. Sob baixo nitrogênio, os valores de R^2 no conjunto de teste variaram entre 0,26 e 0,34, enquanto sob alto nitrogênio os melhores resultados foram obtidos pelos modelos GBM ($R^2 = 0,41$) e Cforest ($R^2 = 0,34$), indicando maior capacidade de generalização nesses cenários. Esses resultados evidenciam que tanto o nível de nitrogênio quanto a altura de voo influenciam diretamente o desempenho preditivo dos modelos.




Figura 9. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Nossa Senhora da Glória, com altura de voo de 80 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.




Figura 10. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Nossa Senhora da Glória, com altura de voo de 80 m em alto nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.

Na área experimental de Graccho Cardoso (Figuras 11 e 12), os gráficos de dispersão apresentaram, de modo geral, menor variabilidade comparativamente a Nossa Senhora da Glória, especialmente para a altura de voo de 60 m. Os modelos Cforest e GBM mantiveram maior alinhamento à linha de identidade com ajuste mais adequado dos modelos, enquanto os modelos lineares apresentaram maior dispersão dos pontos. Para o algoritmo Cforest, os coeficientes de determinação de treinamento sob baixo nitrogênio foram de 0,64 e 0,61 a 60 e 80 m, respectivamente (Figuras 11 e 13c), enquanto sob alto nitrogênio foram de 0,68 e 0,63 (Figuras 12 e 14c). O modelo GBM apresentou coeficientes de determinação de treinamento entre 0,76 e 0,74 sob baixo nitrogênio (Figuras 11 e 13d) e entre 0,77 e 0,69 sob alto nitrogênio, nas alturas de 60 e 80 m, respectivamente (Figuras 12 e 14d).




Figura 11. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Graccho Cardoso, com altura de voo de 60 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.




Figura 12. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Graccho Cardoso, com altura de voo de 60 m em alto nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.

Em contrapartida, nas imagens capturadas a 80 m (Figuras 13 e 14), verificou-se aumento da dispersão dos pontos, assim como foi visto na área experimental de Nossa Senhora da Glória, independentemente do nível de nitrogênio. Esse resultado demonstra que a combinação entre a perda da resolução espacial e a elevada disponibilidade de nitrogênio compromete a eficiência dos índices espectrais e, consequentemente, a habilidade preditiva dos algoritmos.




Figura 13. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Graccho Cardoso, com altura de voo de 80 m em baixo nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.




Figura 14. Gráfico de dispersão da produtividade observada versus prevista dos modelos de regressão na área experimental de Graccho Cardoso, com altura de voo de 80 m em alto nitrogênio. Modelos avaliados: (a) Linear model; (b) LASSO Regression; (c) Cforest e (d) GBM.

4.3.3. Avaliação dos modelos Linear e LASSO

As análises diagnósticas dos modelos LM e LASSO indicaram que as pressuposições clássicas de normalidade e homocedasticidade foram parcialmente atendidas, evidenciando as limitações presentes nesses métodos para a modelagem preditiva a partir de índices multiespectrais.

Na altura de voo de 60 metros, sob baixo nitrogênio, o modelo LASSO apresentou leve redução da variância residual em comparação ao modelo linear, embora padrões estruturais ainda fossem observados (Figura 15). Os gráficos scale-location confirmaram a não constância da variância dos resíduos, principalmente para maiores valores ajustados, enquanto os Q-Q plots indicaram que os resíduos se aproximaram da normalidade na região central, porém com desvios evidentes nas caudas. Diante do aumento da altura de voo para 80 metros (Figura 16), observou-se intensificação das violações das pressuposições em ambos os modelos, evidenciado pelo crescimento da dispersão dos resíduos e maior variabilidade da variância dos valores ajustados.




Figura 15. Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 60 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.




Figura 16. Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 80 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.

Na área experimental de Graccho Cardoso (Figura 17), a 60 metros de altura, os gráficos diagnósticos indicaram melhor adequação geral dos modelos LM e LASSO em comparação à área de Nossa Senhora da Glória, comportamento também observado em 80 metros (Figura 18). No geral, os resíduos apresentaram menor dispersão e menor evidência de padrões sistemáticos, especialmente sob alto nitrogênio. Os gráficos scale-location apontaram uma variância relativamente mais uniforme, ao passo que os Q-Q plots exibiram resíduos na região central próximos da normalidade, com desvios moderados nas extremidades. Esses resultados refletem a maior estabilidade ambiental da área, embora limitações estruturais dos modelos lineares ainda sejam observadas.




Figura 17. Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 60 metros na área de Graccho Cardoso em baixo e alto nitrogênio.




Figura 18. Avaliação dos modelos LASSO e LM para resíduos, scale-location e Q-Q plot em 80 metros na área de Graccho Cardoso em baixo e alto nitrogênio.

4.3.4 Avaliação dos modelos GBM e Cforest

A análise da importância das variáveis nos modelos GBM e Cforest revelou que a contribuição dos índices de vegetação para a predição da produtividade não ocorreu de forma uniforme entre as condições experimentais. Em todas as situações avaliadas, observou-se que pequenos conjuntos de índices concentram a maior parte da contribuição preditiva. Esse comportamento é crucial do ponto de vista operacional, pois facilita a escolha direcionada de índices mais informativos, o que reduz os custos computacionais e a complexidade na obtenção e no processamento dos dados espectrais.

Na área experimental de Nossa Senhora da Glória, observou-se que os índices MCARI1, TCARI e NDVI apresentaram maior relevância no modelo GBM, com destaque para avaliações realizadas aos 61 e 96 dias após o plantio (DAP), variando conforme a altura de voo e a condição de nitrogênio (Figura 19). Em particular, sob alto nitrogênio, a 60 m, destacaram-se TCARI e NDVI aos 61 e 96 DAP, enquanto, sob baixo nitrogênio, a 60 m, houve maior contribuição de MCARI1, TCARI e MSAVI. Para as avaliações a 80 m, os índices MCARI1, MCARI2 e CVI apresentaram maior importância no modelo.

Padrões semelhantes foram parcialmente observados no modelo cforest, no qual os índices MCARI2, MCARI1 e TCARI apresentaram elevada contribuição preditiva em diferentes condições experimentais (Figura 20). Destaca-se ainda a relevância do NDVI nas avaliações realizadas a 61 e 96 DAP em algumas combinações de altura de voo e disponibilidade de nitrogênio.




Figura 19. Importância dos índices de vegetação pelo modelo GBM na área experimental de Nossa Senhora da Glória sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio




Figura 20. Importância dos índices de vegetação pelo modelo Cforest na área experimental de Nossa Senhora da Glória sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio

Em Graccho Cardoso, verificou-se comportamento de importância das variáveis, com destaque para o índice MSAVI no modelo GBM aos 54 DAP, período que coincide com o estágio de V7, sob baixo nitrogênio e em ambas as alturas de voo (Figura 21). Sob alto nitrogênio, notou-se uma maior variedade de índices com alta contribuição preditiva aos 89 DAP, incluindo GDVI, CVI e NDVI, tanto em condições de baixo quanto de alto nitrogênio (Figura 21). Esse padrão indica que, em condições de dossel mais homogêneo, diferentes índices passam a registrar variações discretas relacionadas à densidade foliar e à eficiência da fotossíntese. Com o modelo Cforest, notou-se a permanência dos índices GDVI, MSAVI e NDVI entre os mais relevantes aos 54 e 89 DAP (Figura 22).




Figura 21. Importância dos índices de vegetação pelo modelo GBM na área experimental de Graccho Cardoso sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio




Figura 22. Importância dos índices de vegetação pelo modelo Cforest na área experimental de Graccho Cardoso sob condições de alto e baixo nitrogênio, em 60 e 80 metros. DAP= Dias após plantio

De forma geral, os resultados obtidos por meio da análise SHAP também apresentaram poucos índices concentrando os maiores impactos positivos na predição da produtividade em ambos os algoritmos avaliados e nas condições experimentais, em particular para os ambientes de baixo nitrogênio.

Em Nossa Senhora da Glória, de modo geral, tanto o GBM quanto o Cforest apresentaram índices com maior aumento da predição aos 96 DAP (Figuras 23 e 24). Sob baixo nitrogênio, a 60 m, o índice TACRI destacou-se em ambos os modelos, enquanto sob alto nitrogênio destacou-se o índice GDVI. Já na altura de 80 m, observou-se comportamento distinto, com maior recorrência do índice TCARI em todas as condições avaliadas, especialmente aos 75 DAP (Figuras 23 e 24).




Figura 23. Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo GBM em Nossa Senhora da Glória. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio




Figura 24. Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo Cforest em Nossa Senhora da Glória. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio

Na área de Graccho Cardoso, observou-se maior consistência dos índices que promoveram aumento da predição em todas as situações avaliadas e em ambos os modelos, especialmente aos 89 DAP, destacando-se MCARI2 e MCARI1 sob baixo nitrogênio, e CVI e NDVI (Figuras 25 e 26). Novamente, o índice MSAVI apresentou papel relevante aos 54 DAP, reforçando sua importância na captura de variações do dossel em períodos

intermediários.




Figura 25. Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo GBM em Graccho Cardoso. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio




Figura 26. Avaliação dos valores SHAP dos índices de vegetação utilizados na predição da produtividade de grãos pelo modelo CFOREST em Graccho Cardoso. (a) Baixo nitrogênio (60 metros), (b) Alto nitrogênio (60 metros), (c) Baixo nitrogênio (80 metros) e (d) Alto nitrogênio (80 metros). DAP= Dias após plantio

4.3.5. Avaliação da produtividade predita dos genótipos em cada modelo

A avaliação da produtividade predita dos genótipos pelos diferentes algoritmos permitiu identificar materiais com maior estabilidade preditiva sob distintas condições ambientais, evidenciada por menores valores de RMSE. Na área experimental de Nossa Senhora da Glória, o genótipo G31 apresentou-se de forma consistente entre os materiais com menores erros de predição em diferentes modelos, nível de nitrogênio e altura de voo (Figuras 27 e 28), indicando elevada estabilidade do desempenho produtivo estimado particularmente sob condições de baixo nitrogênio.




Figura 27. Avaliação dos genótipos dentro de cada modelo em 60 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.




Figura 28. Avaliação dos genótipos dentro de cada modelo em 80 metros na área de Nossa Senhora da Glória em baixo e alto nitrogênio.

Em condições de alto nitrogênio, observaram-se menores erros de predição para os genótipos G11, G27 e G1, dependendo do modelo ajustado, com destaque para os algoritmos GBM, cforest e LASSO (Figura 27). Na altura de 80 m, sob baixo nitrogênio, os menores valores de RMSE foram observados principalmente para os genótipos G28, G31 e G6, variando conforme o algoritmo utilizado. Já sob alto nitrogênio, os genótipos G27, G31, G1 e G25 apresentaram os menores erros de predição em diferentes modelos, com maior frequência nos algoritmos GBM, Cforest, LM e LASSO (Figura 28).

Na área experimental de Graccho Cardoso, observou-se, de modo geral, maior consistência entre os genótipos com menores erros de predição, refletindo maior estabilidade espectral e fisiológica do dossel. Em ambas as alturas de voo, o genótipo G17 apresentou baixos valores de RMSE em todos os algoritmos sob baixo nitrogênio (Figuras 29 e 30), indicando elevada robustez preditiva nesse ambiente. Além disso, o genótipo G4 destacou-se sob baixo nitrogênio a 60 m, enquanto o genótipo G2 apresentou os menores erros sob alto nitrogênio a 60 m, comportamento que se manteve nos modelos GBM e Cforest a 80 m (Figura 30).




Figura 29. Avaliação dos genótipos dentro de cada modelo em 60 metros na área de Graccho Cardoso em baixo e alto nitrogênio.




Figura 30. Avaliação dos genótipos dentro de cada modelo em 80 metros na área de Graccho Cardoso em baixo e alto nitrogênio.

4.3.6. Eficiência agrônômica no uso de nitrogênio (EAN) e responsividade produtiva dos genótipos

Os genótipos considerados superiores em termos de eficiência agrônômica e responsividade produtiva nos dois ambientes experimentais são mostrados nas Figuras 31 e 32. Na área experimental de Nossa Senhora da Glória (Figura 31), as produtividades médias gerais foram de 4.569,57 kg ha⁻¹ sob alto nitrogênio e 3.500,67 kg ha⁻¹ sob baixo nitrogênio, evidenciando resposta positiva da cultura à adubação nitrogenada, embora com expressiva variabilidade entre os genótipos.




Figura 31. Avaliação da eficiência agrônômica e responsividade dos genótipos na área de Nossa Senhora da Glória.

Os genótipos G42, G50, G20 e G4 destacaram-se como superiores quanto à eficiência agrônômica e responsividade produtiva, apresentando valores de EAN de 0,70; 0,65; 0,62 e 0,58, respectivamente. Esses materiais exibiram produtividades acima da média geral do ambiente, tanto sob baixo quanto sob alto nitrogênio. Sob baixo N, esses genótipos alcançaram produtividades entre 3.818 e 4.703 kg ha⁻¹, superando a média do ambiente, enquanto sob alto N apresentaram valores entre 4.574 e 5.698 kg ha⁻¹, indicando elevada capacidade de resposta ao incremento da disponibilidade do nutriente. Esses genótipos demonstram alta produtividade em condições limitantes e uma resposta expressiva quando há maior oferta de nitrogênio.

Na área experimental de Graccho Cardoso (Figura 32), as produtividades médias gerais foram consideravelmente inferiores às observadas em Nossa Senhora da Glória, com valores de 1.717,82 kg ha⁻¹ sob alto nitrogênio e 1.289,09 kg ha⁻¹ sob baixo nitrogênio, refletindo condições ambientais mais restritivas ao desenvolvimento da cultura. Nesse ambiente, observou-se um maior número de genótipos classificados como eficientes e responsivos, destacando-se G31, G2, G27, G42, G26, G40 e G50, com valores de EAN variando de 0,60 a 0,82, sendo o maior valor registrado para o genótipo G31 (0,82). Esses genótipos apresentaram produtividades superiores à média do ambiente em ambas as condições de nitrogênio. Sob baixo N, os valores variaram de 1.477 a 2.016 kg ha⁻¹, enquanto sob alto N atingiram produtividades entre 1.791 e 1.913 kg ha⁻¹.




Figura 32. Avaliação da eficiência agrônômica e responsividade dos genótipos na área de Graccho Cardoso.

Além do desempenho agrônômico, nota-se uma convergência entre os genótipos considerados eficientes e responsivos e aqueles que demonstraram maior estabilidade preditiva nos diversos modelos de predição. Os genótipos G4 e G2, que foram superiores para EAN, também estiveram entre os que apresentaram os menores erros de predição.

4.4. Discussão

O desempenho superior dos modelos baseados em imagens obtidas a 60 m pode estar associado à melhoria da relação sinal-ruído, uma vez que a maior resolução espacial reduz a mistura espectral e potencializa a captura de informações relacionadas à variabilidade do dossel (Liu *et al.*, 2022; Kennedy, Garruccio e Cussen, 2021). Em altitudes mais elevadas, a diminuição da resolução espacial tende a comprometer a resposta espectral e aumentar o ruído radiométrico, enfraquecendo a relação entre os índices espectrais e a produtividade de grãos. Esses resultados destacam a relevância de estabelecer corretamente os parâmetros de voo para otimizar a capacidade preditiva dos modelos baseados em imagens de VANTs.

Além das condições de aquisição das imagens, o desempenho dos modelos foi fortemente influenciado pelo algoritmo empregado. A superioridade observada nos modelos GBM e Cforest sugere que a relação entre os índices de vegetação e a produtividade do milho é predominantemente não linear, especialmente sob condições de estresse nutricional. Nesses ambientes, as diferenças fisiológicas entre genótipos tornam-se mais evidentes, favorecendo o desempenho de algoritmos capazes de modelar interações complexas e padrões não lineares (Khan *et al.*, 2025; Barboza *et al.*, 2023; Liakos *et al.*, 2018). Dessa forma, os resultados confirmam que as abordagens baseadas em aprendizado de máquina são adequadas para prever a produtividade em sistemas agrícolas diversos.

Em contraste, a menor variabilidade observada nos ambientes de alto nitrogênio pode estar relacionada à saturação dos índices espectrais. Nessas condições, o aumento do teor de clorofila e o rápido fechamento do dossel reduzem o contraste fisiológico entre as subparcelas, levando à saturação espectral, sobretudo em índices baseados nas bandas do vermelho e do infravermelho próximo (Valencia-Ortiz *et al.*, 2025; Guo *et al.*, 2022; Casanova, Epema e Goudriaan, 1998). Esse efeito limita a capacidade discriminatória dos índices e reduz a variabilidade explicada pelos modelos preditivos.

As características intrínsecas dos dados espectrais também contribuem para a compreensão da violação pontual das suposições observadas nos modelos LM e LASSO. Esse comportamento é frequentemente relatado em estudos que utilizam variáveis espectrais naturalmente correlacionadas para estimar características agrônômicas complexas, como a produtividade de grãos (Liakos *et al.*, 2018; Zhao *et al.*, 2018). A ligeira superioridade do LASSO pode ser atribuída à penalização L1, que promove a regularização dos coeficientes e reduz os efeitos da multicolinearidade, comum em conjuntos de índices espectrais (Adhikary e Bora, 2024; Rasmussen e Bro, 2012). No entanto, essa penalização atua apenas sobre a magnitude dos coeficientes, não sendo capaz de capturar relações não lineares nem de corrigir a heterocedasticidade presente nos dados, o que reforça a complexidade das interações entre reflectância, estrutura do dossel e produtividade.

O desempenho dos modelos também foi significativamente afetado pelo espaço temporal das coletas. Assim, foram observados que os períodos correspondentes a 61 e 96 dias após o plantio (DAP) foram superiores para todos os modelos preditivos. Esses períodos coincidem, respectivamente, com os estádios fenológicos V7–V8 e R1 para cultivares de milho de ciclo normal a tardio (Borella, Leschewitz e Trautenmüller, 2019). A recorrência verificada dos índices MCARI2 e MSAVI durante estes períodos pode estar associada à elevada sensibilidade desses índices à estrutura do dossel e ao teor de clorofila, especialmente durante as fases intermediárias do desenvolvimento vegetativo e o início do estágio reprodutivo (Zhao *et al.*, 2018; Haboudane *et al.*, 2004; Qi *et al.*, 1994). No estágio V7–V8 ocorre intenso acúmulo de biomassa e elevada demanda por nitrogênio, fatores que influenciam diretamente o desempenho fisiológico das plantas no estágio R1, marcado pela floração (Fancelli, 1988).

As análises de importância e valores SHAP para os modelos GBM e Cforest permitiram identificar os pequenos conjuntos de índices que foram priorizados por ambos os algoritmos, indicando uma predominância de variáveis relacionadas à estrutura do dossel (bandas do infravermelho próximo) e à avaliação nutricional, com destaque para índices baseados nas bandas do vermelho e red-edge. Esses índices são amplamente reconhecidos por sua sensibilidade ao estado nutricional das plantas e à dinâmica do crescimento vegetativo. Em conjunto, esses resultados sugerem que a coleta e o processamento de dados espectrais podem ser otimizados, concentrando-se em índices específicos e estádios fenológicos estratégicos, sem comprometer a precisão das predições.

Essa abordagem está alinhada a estudos recentes que empregam métodos explicáveis de aprendizado de máquina para identificar variáveis dominantes em modelos preditivos complexos, ampliando aplicações operacionais na fenotipagem por imagens de VANTs (Abdullah e Mustafa, 2025; Guo *et al.*, 2024). Em ambientes com maior heterogeneidade,

como sob baixo nitrogênio, os modelos passam a depender mais fortemente de índices específicos para explicar as diferenças na produtividade, enquanto em ambientes de alto nitrogênio a uniformização do dossel reduz o efeito individual dos índices e limita a discriminação espectral.

Entre os índices frequentemente selecionados pelos modelos, MCARI2 e TCARI estão diretamente associados à absorção de clorofila e à densidade do dossel, características fortemente relacionadas ao desempenho produtivo no início do estágio reprodutivo (Zhang *et al.*, 2021). Dessa forma, os resultados indicam que é possível simplificar a coleta de dados espectrais, selecionando índices-chave, sem comprometer a robustez das previsões. Essa estratégia otimiza aplicações operacionais em programas de melhoramento genético baseados em fenotipagem por imagens de VANTs.

A avaliação da produtividade predita dos genótipos em cada modelo sugere que materiais com maior uniformidade espectral e fisiológica tendem a apresentar respostas mais consistentes aos índices de vegetação, favorecendo a acurácia das previsões (Zeng *et al.*, 2022). Esses resultados reforçam a importância de avaliar o desempenho genotípico sob diferentes níveis de disponibilidade de nitrogênio, uma vez que genótipos produtivos em ambientes de alto N nem sempre mantêm desempenho superior sob condições de limitação nutricional (Lammerts van Bueren e Struik, 2017).

Nesse contexto, a eficiência agrônômica do uso do nitrogênio (EAN), definida como o incremento na produtividade de grãos por unidade de N aplicada (Moll *et al.*, 1982), constitui um critério fundamental para a identificação de genótipos eficientes e responsivos. A manutenção de produtividades elevadas sob baixo N indica maior eficiência fisiológica na absorção, assimilação e remobilização do nutriente, enquanto a resposta positiva sob alto N reflete elevado potencial produtivo e plasticidade fisiológica (Gheith *et al.*, 2022).

Nesse sentido, a seleção para eficiência no uso do nitrogênio tende a ser mais expressiva em ambientes mais restritivos, como visto na área experimental de Graccho Cardoso, uma vez que as diferenças fisiológicas entre os materiais são ampliadas. Esses resultados corroboram evidências da literatura de que a eficiência no uso do nitrogênio é geralmente maior sob baixa disponibilidade do nutriente, diminuindo progressivamente à medida que as doses de N aumentam (Adeoluwa *et al.*, 2022; Han *et al.*, 2015).

Por fim, o bom desempenho dos genótipos G4 e G2 nos modelos de predição indica que materiais com maior eficiência agrônômica no uso do nitrogênio tendem a apresentar respostas espectrais mais estáveis ao longo do ciclo, facilitando a detecção das variações produtivas por meio dos índices de vegetação. Assim, a integração de modelos preditivos baseados em imagens de VANTs mostra-se uma ferramenta promissora para a identificação antecipada de genótipos superiores em programas de melhoramento voltados à eficiência no uso de nutrientes.

4.5. Conclusões

Modelos baseados em árvores (GBM e Cforest) apresentaram maior precisão e estabilidade preditiva em comparação aos modelos lineares. A predição da produtividade foi dependente de um conjunto reduzido de índices de vegetação, cuja importância variou conforme o ambiente, a disponibilidade de nitrogênio e o estágio fenológico da cultura.

Entre os índices avaliados, MSAVI, MCARI2 e TCARI destacaram-se como os mais consistentes. Genótipos com maior eficiência no uso do nitrogênio e maior estabilidade produtiva apresentaram padrões espectrais mais consistentes e menores erros de predição, com destaque para G31 e G27.

Os resultados também indicam que os modelos desenvolvidos apresentam caráter especialista, refletindo as condições ambientais e experimentais utilizadas em seu treinamento. Assim, a ampliação dos bancos de dados pode contribuir para o desenvolvimento de modelos mais robustos e com maior capacidade de generalização e acurácia preditiva.

4.6. Referências Bibliográficas

- Abdullah MH and Mustafa YT** (2025) Machine learning and SHAP-based analysis of deforestation and forest degradation dynamics along the Iraq–Turkey border. *Earth* **6**, 49. <https://doi.org/10.3390/earth6020049>
- Adeoluwa OO, Mutengwa CS, Chiduza C, Tandzi NL** (2022) Nitrogen use efficiency of quality protein maize (*Zea mays* L.) genotypes. *Agronomy* **12**, 1118. <https://doi.org/10.3390/agronomy12051118>
- Adhikary MK and Bora A** (2024) Material informatics and impact of multicollinearity on regression model for fatigue strength of steel. *International Journal of Fracture* **246**, 37-46. <https://doi.org/10.1007/s10704-024-00765-8>
- Asibi AE, Chai Q, Coulter JA** (2019) Mechanisms of nitrogen use in maize. *Agronomy* **9**, 775. <https://doi.org/10.3390/agronomy9120775>
- Bagum SA, Islam MU, Uddin MS, Sikder S, Gaber A, Hossain A** (2025) Integrating morphological and digital traits to optimize nitrogen use e efficiency in maize hybrids. *International Journal of Botany (Phyton)* **94**. <https://doi.org/10.32604/phyton.2025.065607>
- Barboza TOC, Ardiguieri M, Souza GFC, Ferraz MAJ, Gaudencio JRF, Santos AFD** (2023) Performance of vegetation indices to estimate green biomass accumulation in Common Bean. *AgriEngineering* **5**, 840-854.
- Bashir MT, Ali S, Ghauri M, Adris A, Harun R** (2013) Impact of excessive nitrogen fertilizers on the environment and associated mitigation strategies. *Asian J. Microbiol. Biotechnol. Environ. Sci* **15**, 213-221.
- Bollas N, Kokinou E, Polychronos V** (2021) Comparison of sentinel-2 and UAV multispectral data for use in precision agriculture: An application from northern Greece. *Drones* **5**, 35. <https://doi.org/10.3390/drones5020035>
- Borella J, Leschewitz R, Trautenmüller JW** (2019) Arquitetura foliar em populações de milho de ciclos contrastantes. *Revista Brasileira de Engenharia de Biosistemas* **13**, 168-177. <https://doi.org/10.18011/bioeng2019v13n2p168-177>
- Broge NH and Leblanc E** (2001) Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment* **76**, 156-172. [https://doi.org/10.1016/S0034-4257\(00\)00197-8](https://doi.org/10.1016/S0034-4257(00)00197-8)
- Burns BW, Green VS, Hashem AA, Massey JH, Shew AM, Adviento-Borbe MAA, Milad M** (2022) Determining nitrogen deficiencies for maize using various remote sensing indices. *Precision Agric* **23**, 791–811. <https://doi.org/10.1007/s11119-021-09861-4>
- Buschmann C and Nagel E** (1993) In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing* **14**, 711-722. <https://doi.org/10.1080/01431169308904370>
- Casanova D, Epema GF, Goudriaan J** (1998) Monitoring rice reflectance at field level for estimating biomass and LAI. *Field Crops Research* **55**, 83-92. [https://doi.org/10.1016/S0378-4290\(97\)00064-6](https://doi.org/10.1016/S0378-4290(97)00064-6)
- Crippen RE** (1990) Calculating the vegetation index faster. *Remote Sensing of Environment* **34**, 71-73.
- Daughtry CS, Walthall CL, Kim MS, De Colstoun EB, McMurtrey Iii JE** (2000) Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment* **74**, 229-239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- Dos Santos OL, Padolfi AS, Ramaldes GP** (2018) Análise de índice de vegetação através de imagens obtidas por VANT. *Revista Científica FAESA* **14**, 145-165. [10.5008/1809.7367.143](https://doi.org/10.5008/1809.7367.143)

- Erdle K, Mistele B, Schmidhalter U** (2011) Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research* **124**, 74-84. <https://doi.org/10.1016/j.fcr.2011.06.007>
- Fancelli AL** (1988) *Fenologia do milho*. ESALQ/USP.
- Feitosa DA, Ferreira KP, Aragão NS, Santos BN, Oliveira JDS, Silva RDJ, Santos JFS, Brito MEB, Junior JJFC, De Oliveira GHF** (2025) Performance of maize hybrids grown in a semi-arid region under rainfed and wastewater irrigation systems. *Revista Brasileira de Engenharia Agrícola e Ambiental* **29**, e281710. [10.1590/1807-929/agriambi.v29n5e281710](https://doi.org/10.1590/1807-929/agriambi.v29n5e281710)
- Gheith EMS, El-Badry OZ, Lamloom SF, Ali HM, Siddiqui MH, Ghareeb RY, El-Sheikh MH, Jebril J, Abdelsalam NR and Kandil EE** (2022) Maize (*Zea mays* L.) productivity and nitrogen use efficiency in response to nitrogen application levels and time. *Frontiers in Plant Science* **13**, 941343. doi: 10.3389/fpls.2022.941343
- Guo R, Yang B, Guo Y, Li H, Li Z, Zhou B, ... and Wang F** (2024) Machine learning-based prediction of outdoor thermal comfort: Combining Bayesian optimization and the SHAP model. *Building and Environment* **254**, 111301. <https://doi.org/10.1016/j.buildenv.2024.111301>
- Guo Y, Zhang X, Chen S, Wang H, Jayavelu S, Cammarano D, Fu Y** (2022) Integrated UAV-based multi-source data for predicting maize grain yield using machine learning approaches. *Remote Sensing* **14**, 6290. <https://doi.org/10.3390/rs14246290>
- Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB** (2004) Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment* **90**, 337-352.
- Haboudane D, Miller JR, Tremblay N, Zarco-Tejada PJ, Dextraze L** (2002) Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment* **81**, 416-426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)
- Han M, Okamoto M, Beatty PH, Rothstein SJ, Good AG** (2015) The genetics of nitrogen use efficiency in crop plants. *Annual Review of Genetics* **49**, 269-289. <https://doi.org/10.1146/annurev-genet-112414-055037>
- Jordan CF** (1969) Derivation of leaf-area index from quality of light on the forest floor. *Ecology* **50**, 663-666. <https://doi.org/10.2307/1936256>
- Kennedy J, Garruccio S, Cussen K** (2021) Modelling and mitigation of drone noise. *Vibroengineering Procedia* **37**, 60-65. <https://doi.org/10.21595/vp.2021.21988>
- Khan SN, Iqbal J, Khan MR, Malik NA, Khan FA, Khan K, ... and Wahab A** (2025) Using remotely sensed vegetation indices and multi-stream deep learning improves county-level corn yield predictions. *European Journal of Agronomy* **164**, 127496. <https://doi.org/10.1016/j.eja.2024.127496>
- Kostrzewa A, Platek-Żak A, Banat P, Wilk Ł** (2025) Open-Source vs. Commercial Photogrammetry: Comparing Accuracy and Efficiency of OpenDroneMap and Agisoft Metashape. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* **48**, 65-72. <https://doi.org/10.5194/isprs-archives-XLVIII-1-W4-2025-65-2025>
- Lammerts van Bueren ET, Struik PC** (2017) Diverse concepts of breeding for nitrogen use efficiency. A review. *Agronomy for Sustainable Development* **37**, 50. <https://doi.org/10.1007/s13593-017-0457-3>
- Liakos KG, Busato P, Moshou D, Pearson S, Bochtis D** (2018) Machine learning in agriculture: A review. *Sensors* **18**, 2674. <https://doi.org/10.3390/s18082674>
- Li M, Shamshiri RR, Weltzien C, Schirrmann M** (2022) Crop monitoring using Sentinel-2 and UAV multispectral imagery: A comparison case study in Northeastern Germany. *Remote Sensing* **14**, 4426. <https://doi.org/10.3390/rs14174426>

- Liu S, Yin D, Feng H, Li Z, Xu X, Shi L, Jin X** (2022) Estimating maize seedling number with UAV RGB images and advanced image processing methods. *Precision Agriculture* **23**, 1604-1632. <https://doi.org/10.1007/s11119-022-09899-y>
- Moll RH, Kamprath EJ, Jackson WA** (1982) Analysis and interpretation of factors which contribute to efficiency of nitrogen utilization. *Agronomy Journal* **74**, 562-564. 10.2134/agronj1982.00021962007400030037x
- Nogueira DB, da Silva AO, Girollo AB, da Silva AP, Costa BR** (2023) Dry spells in a semi-arid region of Brazil and their influence on maize productivity. *Journal of Arid Environments* **209**, 104892. <https://doi.org/10.1016/j.jaridenv.2022.104892>
- Olivoto T** (2022) Lights, camera, pliman! An R package for plant image analysis. *Methods in Ecology and Evolution* **13**, 789-798. <https://doi.org/10.1111/2041-210X.13803>
- Omari MK, Lee J, Faqeerzada MA, Joshi R, Park E, Cho BK** (2020) Digital image-based plant phenotyping: a review. *Korean Journal of Agricultural Science* **47**, 119-130. <https://doi.org/10.7744/kjoas.2020004>
- Pádua L, Guimarães N, Adão T, Sousa A, Peres E, Sousa JJ** (2020) Effectiveness of sentinel-2 in multi-temporal post-fire monitoring when compared with UAV imagery. *ISPRS International Journal of Geo-Information* **9**, 225. <https://doi.org/10.3390/ijgi9040225>
- Pinto F, Zaman-Allah M, Reynolds M, Schulthess U** (2023) Satellite imagery for high-throughput phenotyping in breeding plots. *Frontiers in Plant Science* **14**, 1114670. 10.3389/fpls.2023.1114670
- Qi J, Chehbouni A, Huete AR, Kerr YH, Sorooshian S** (1994) A modified soil adjusted vegetation index. *Remote Sensing of Environment* **48**, 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rahimi Jahangirlou M, Akbari GA, Alahdadi I, Soufizadeh S, Kumar U, Parsons D** (2021) Phenotypic traits, grain yield and yield components of maize cultivars under combinations of management practices in semi-arid conditions of Iran. *International Journal of Plant Production* **15**, 459-471. <https://doi.org/10.1007/s42106-021-00151-7>
- Rasmussen MA, Bro R** (2012) Um tutorial sobre a abordagem Lasso para modelagem esparsa. *Chemometrics and Intelligent Laboratory Systems* **119**, 21-31. <https://doi.org/10.1016/j.chemolab.2012.10.003>
- R Core Team** (2024). R: A Language and Environment for Statistical Computing. Vienna, Austria: R Foundation for Statistical Computing. <<https://www.R-project.org/>>.
- Ren Y, Li Q, Du X, Zhang Y, Wang H, Shi G, Wei M** (2023) Analysis of corn yield prediction potential at various growth phases using a process-based model and deep learning. *Plants* **12**, 446. <https://doi.org/10.3390/plants12030446>
- Resende EL, Bruzi AT, Cardoso EDS, Carneiro VQ, Pereira de Souza VA, Frois Correa Barros PH, Pereira RR** (2024) High throughput phenotyping: application in maize breeding. *AgriEngineering* **6**, 1078-1092. <https://doi.org/10.3390/agriengineering6020062>
- Rondeaux G, Steven M, Baret F** (1996) Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment* **55**, 95-107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Santos BN, Aragão NSC, Santos MRD, Oliveira TRAD, Cordeiro JJF, Oliveira GHF** (2025) Aerial imaging for early assessment of yield potential in maize. *Revista Ceres* **72**, e72038. <https://doi.org/10.71252/217734912025720038>
- Segarra J, Buchailot ML, Araus JL, Kefauver SC** (2020) Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy* **10**, 641. <https://doi.org/10.3390/agronomy10050641>
- Shiratsuchi LS, Brandão ZN, Vicente LE, Victoria DDC, Ducati JR, Oliveira RD, Vilela MDF** (2014) Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: Bernardi, A. C. C.; Naime, J. M.; Resende, A. V.; Bassoi, L. H.; Inamasu, R. Y. (Ed.). *Agricultura de precisão: resultados de um novo olhar*. Embrapa.

- Silva MFE, Maciel GM, Gallis RB, Barbosa RL, Carneiro VQ, Rezende WS, Siquieroli ACS** (2022) High-throughput phenotyping by RGB and multispectral imaging analysis of genotypes in sweet corn. *Horticultura Brasileira* **40**, 92-98. <http://dx.doi.org/10.1590/s01020536-2022012>
- Smith DT, Potgieter AB, Chapman SC** (2021) Scaling up high-throughput phenotyping for abiotic stress selection in the field. *Theoretical and Applied Genetics* **134**, 1845-1866. <https://doi.org/10.1007/s00122-021-03864-5>
- Sripada RP, Heiniger RW, White JG, Meijer AD** (2006) Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal* **98**, 968-977. <https://doi.org/10.2134/agronj2005.0200>
- Sun X, Zhao Q, Gao J, Liu Z** (2025) The physiological mechanisms and hurdles of efficient water–nitrogen utilization in maize production: a review. *Plants* **14**, 1899. <https://doi.org/10.3390/plants14131899>
- Taiz L, Zeiger E, Moller IM, Murphy A** (2017) *Fisiologia e desenvolvimento vegetal* (6th ed.). Artmed.
- Tecnodrones** (2025) Drone DJI Mavic 3 Multispectral. Disponível em: <https://www.tecnodrones.com.br/drone-dji-mavic-3-multispectral>. Acesso em 20 out. 2025
- Tucker CJ** (1979) Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* **8**, 127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Tyagi J, Ahmad S and Malik M** (2022) Nitrogenous fertilizers: Impact on environment sustainability, mitigation strategies, and challenges. *International Journal of Environmental Science and Technology* **19**, 11649-11672. <https://doi.org/10.1007/s13762-022-04027-9>
- Valencia-Ortiz M, McGee RJ, Carter AH, Sankaran S** (2025) Variability in vegetation indices as a function of unmanned aerial vehicle flight altitudes and other factors for crop monitoring applications. *Agricultural Engineering International: CIGR Journal* **27**.
- Vasseur F, Wang G, Bresson J, Schwab R, Weigel D** (2017) Image-based methods for phenotyping growth dynamics and fitness in large plant populations. *BioRxiv*. <https://doi.org/10.1101/208512>
- Vincini M, Frazzi E, D'Alessio P** (2008) A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture* **9**, 303-319. <https://doi.org/10.1007/s11119-008-9075-z>
- Wani SH, Vijayan R, Choudhary M, Kumar A, Zaid A, Singh V, ... and Yasin JK** (2021) Nitrogen use efficiency (NUE): elucidated mechanisms, mapped genes and gene networks in maize (*Zea mays* L.). *Physiology and Molecular Biology of Plants* **27**, 2875-2891. <https://doi.org/10.1007/s12298-021-01113-z>
- Welcker C, Spencer NA, Turc O, Granato I, Chapuis R, Madur D, ... and Tardieu, F** (2022) Physiological adaptive traits are a potential allele reservoir for maize genetic progress under challenging conditions. *Nature Communications* **13**, 3225. <https://doi.org/10.1038/s41467-022-30872-w>
- Wu X, Li Z, Li W, Xue X, Yang L, Xu J, ... and Han Q** (2024) Reducing fertilization with high planting density increases maize yield stability and nitrogen use efficiency in semi-arid areas. *European Journal of Agronomy* **159**, 127223. <https://doi.org/10.1016/j.eja.2024.127223>
- Xing H, Zhou W, Wang C, Li L, Li X, Cui N, ... and Wang Y** (2021) Excessive nitrogen application under moderate soil water deficit decreases photosynthesis, respiration, carbon gain and water use efficiency of maize. *Plant Physiology and Biochemistry* **166**, 1065-1075. <https://doi.org/10.1016/j.plaphy.2021.07.014>
- Zeng Y, Hao D, Huete A, Dechant B, Berry J, Chen JM, ... and Chen M** (2022) Optical vegetation indices for monitoring terrestrial ecosystems globally. *Nature Reviews Earth & Environment* **3**, 477-493. <https://doi.org/10.1038/s43017-022-00298-5>

- Zhao X, Nie G, Yao Y, Ji Z, Gao J, Wang X, Jiang Y** (2020) Natural variation and genomic prediction of growth, physiological traits, and nitrogen-use efficiency in perennial ryegrass under low-nitrogen stress. *Journal of Experimental Botany* **71**, 6670-6683.
<https://doi.org/10.1093/jxb/eraa388>
- Zhao B, Duan A, Ata-Ul-Karim ST, Liu Z, Chen Z, Gong Z, ... and Ning D** (2018) Exploring new spectral bands and vegetation indices for estimating nitrogen nutrition index of summer maize. *European Journal of Agronomy* **93**, 113-125.
<https://doi.org/10.1016/j.eja.2017.12.006>
- Zhang J, Qiu X, Wu Y, Zhu Y, Cao Q, Liu X, Cao W** (2021) Combining texture, color, and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods. *Computers and Electronics in Agriculture* **185**, 106138. <https://doi.org/10.1016/j.compag.2021.106138>

5. CONSIDERAÇÕES FINAIS

Os índices de vegetação apresentaram comportamentos distintos entre os ambientes contrastantes de nitrogênio, evidenciando a influência da disponibilidade de nitrogênio sobre a resposta espectral.

Observou-se que a qualidade da resolução espacial das imagens multiespectrais está diretamente associada ao desempenho dos modelos preditivos, bem como ao padrão de agrupamento dos índices de vegetação, refletindo maior sensibilidade na detecção de variações fisiológicas das plantas.

O uso de imagens multiespectrais capturadas por veículos aéreos não tripulados, atrelado a modelos de análise preditiva, mostrou-se uma estratégia eficiente e promissora para aplicação em programas de melhoramento genético, especialmente em ambientes com baixa disponibilidade de nitrogênio.

No entanto, é importante destacar que os resultados deste estudo podem não ser reproduzidos em outros contextos devido à alta complexidade dos dados espectrais e à variação na resposta fisiológica das plantas em ambientes com diferentes níveis de nitrogênio.

Assim, recomenda-se a adição de mais níveis de nitrogênio e a realização de voos em diferentes estádios fenológicos, com o objetivo de avaliar como o comportamento espectral muda ao longo do ciclo da cultura e de melhorar a precisão dos modelos preditivos.

ANEXOS

TABELAS

TABELA 1A. Valores da eficiência agronômica e produtividade média dos genótipos na área de Nossa Senhora da Glória.

Código	Baixo nitrogênio (Kg ha ⁻¹)	Alto nitrogênio (Kg ha ⁻¹)	EAN
G1	2718.888215	4035.580861	0.507811911
G10	3777.327043	3794.251239	0.750371081
G11	3945.941435	3967.237008	0.749687161
G14	2211.613272	3915.525671	0.425732393
G15	3974.645497	4468.643932	0.670409613
G16	3814.185658	4242.839371	0.677583502
G17	3474.308023	4684.817779	0.55897605
G19	3783.735217	5234.382116	0.54484491
G2	3288.294811	5517.845325	0.449178344
G20	3818.394466	4574.333958	0.629173625
G21	3412.45007	4627.812331	0.555786702
G22	3783.927948	5184.673903	0.550096646
G23	3449.361203	5105.852972	0.509199483
G24	3459.738701	4728.467463	0.551493603
G25	3745.250189	3959.161208	0.713009364
G27	3734.069706	4154.852871	0.677398696
G28	2506.908425	4171.410127	0.452973884
G29	3327.758766	3682.598802	0.681106482
G3	3338.615351	4966.978711	0.506630897
G31	3673.482254	4085.353195	0.677744375
G32	3396.245783	4045.524394	0.63276416
G34	4311.213457	6520.233065	0.498372409
G4	4413.649085	5697.774158	0.583861924
G40	1891.992861	3461.387701	0.411990149
G41	3146.777592	5454.550692	0.153471328
G42	4702.903114	5034.221836	0.704127437
G44	3331.400492	3797.117462	0.661287629
G47	3631.621193	4333.098424	0.631712648
G48	2885.093686	4030.615427	0.539518253
G5	3509.623446	6099.674975	0.433682016
G50	4532.95954	5208.759187	0.655941559
G6	3426.522259	4038.033179	0.639589402
G8	3103.310807	3972.106831	0.588873401

EAN: eficiência agronômica no uso de nitrogênio.

TABELA 2A. Valores da eficiência agronômica e produtividade média dos genótipos na área de Graccho Cardoso.

Código	Baixo nitrogênio (Kg ha ⁻¹)	Alto nitrogênio (Kg ha ⁻¹)	EAN
G1	992.0874838	1375.46204	0.544598245
G10	1158.33153	1346.7241	0.649425179
G11	673.6536146	1405.900238	0.361790381
G14	886.5078935	1643.692305	0.407227372
G15	1195.37145	2007.393697	0.449619563
G17	1452.077955	1980.504832	0.553590849
G19	1071.013705	2020.630573	0.400205437
G2	1799.524921	1790.62949	0.758799453
G20	753.4838019	1500.991347	0.379027402
G21	1740.875316	1671.11997	0.786565538
G24	741.4426893	1386.707672	0.403708176
G25	883.3576417	883.8731449	0.754608179
G26	1558.088247	1798.31621	0.654185432
G27	1708.543619	1899.698966	0.679072527
G28	1066.327904	1565.986175	0.51413566
G29	1480.599238	1617.046707	0.691337052
G31	2016.098631	1842.542606	0.826169413
G32	1557.425535	2555.251938	0.460201936
G37	653.7351708	1385.255509	0.356325449
G4	1337.829108	2439.295848	0.41410554
G40	1581.085691	1912.523336	0.62419968
G41	1328.962518	1432.57353	0.700439592
G42	1645.471237	1876.300765	0.662159655
G48	1787.236287	1681.239091	0.802652145
G50	1476.762497	1830.07111	0.609280903
G6	1012.032913	1772.276579	0.431159555
G8	1247.526966	1759.261122	0.535419905

EAN: eficiência agronômica no uso de nitrogênio.