

UNIVERSIDADE FEDERAL DE VIÇOSA

**SELEÇÃO DE PROGÊNIES DE SOJA VIA TÉCNICAS DE GEOESTATÍSTICA E
AEROFOTOGRAMETRIA**

Uilton Pereira da Cunha
Magister Scientiae

**VIÇOSA - MINAS GERAIS
2024**

UILTON PEREIRA DA CUNHA

**SELEÇÃO DE PROGÊNIES DE SOJA VIA TÉCNICAS DE GEOESTATÍSTICA E
AEROFOTOGRAMETRIA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Magister Scientiae*.

Orientador: Felipe Lopes da Silva

Coorientadores: Lucas de Paula Corredo
Luiz A Peternelli
Domingos S M Valente

**VIÇOSA - MINAS GERAIS
2024**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

C972s
2024
Cunha, Uilton Pereira da, 1995-
Seleção de progênies de soja via técnicas de geoestatística e
aerofotogrametria / Uilton Pereira da Cunha. – Viçosa, MG,
2024.

1 dissertação eletrônica (58 f.): il. (algumas color.).

Inclui anexos.

Orientador: Felipe Lopes da Silva.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Agronomia, 2024.

Referências bibliográficas: f. 47-53.

DOI: <https://doi.org/10.47328/ufvbbt.2024.587>

Modo de acesso: World Wide Web.

1. *Glycine max.* 2. Soja - Seleção. 3. Krigagem. 4. Análise
de covariância. 5. Fertilidade do solo. I. Silva, Felipe Lopes da,
1981-. II. Universidade Federal de Viçosa. Departamento de
Agronomia. Programa de Pós-Graduação em Genética e
Melhoramento. III. Título.

CDD 22. ed. 633.342

UILTON PEREIRA DA CUNHA

**SELEÇÃO DE PROGÊNIES DE SOJA VIA TÉCNICAS DE GEOESTATÍSTICA E
AEROFOTOGRAMETRIA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Magister*

APROVADA: 28 de agosto de 2024.

Assentimento:

Uilton Pereira da Cunha
Autor

Felipe Lopes da Silva
Orientador

Essa dissertação foi assinada digitalmente pelo autor em 28/10/2024 às 08:44:25 e pelo orientador em 04/11/2024 às 11:58:13. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **I7CQ.CLDS.APM3** e clique no botão 'Validar documento'.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Agradeço à CAPES pela concessão da bolsa de estudos.

Agradeço primeiramente a Deus, por conceder a oportunidade de chegar até aqui com saúde, paz e amadurecimento. Aos meus pais, Cleide e Ailton, expresso minha profunda gratidão pela educação, amizade, amor, proteção e apoio incondicional ao longo de toda a minha vida. Aos meus avós, Maria da Glória e João Pereira, meus verdadeiros tesouros.

À Universidade Federal de Viçosa e ao Programa de Pós-Graduação em Genética e Melhoramento, manifesto minha gratidão pela oportunidade concedida e pela excelência do ensino proporcionado, além do apoio constante dos professores. Ao meu orientador, Professor Felipe Lopes da Silva, expresso minha sincera admiração e agradecimento pela orientação, confiança e dedicação em cada etapa deste trabalho.

À técnica de laboratório, Edna Mayer, sou grato pelos conselhos, motivações e "puxões de orelha" que foram fundamentais durante a minha passagem pelo Programa Soja.

Aos membros da banca, agradeço por aceitarem o convite e por contribuírem com suas sugestões para enriquecer este trabalho.

Aos amigos especiais que conheci em Viçosa, tanto durante a graduação quanto no mestrado, dedico minha sincera gratidão pelo apoio e companheirismo ao longo dessa jornada.

Aos colegas do Programa Soja, agradeço pela amizade, pelos momentos compartilhados e pela valiosa colaboração no desenvolvimento deste trabalho. Por fim, agradeço a todos que, de alguma forma, contribuíram para a realização deste trabalho, seja por meio de apoio moral, incentivo ou colaboração direta.

RESUMO

CUNHA, Uilton Pereira da, M.Sc., Universidade Federal de Viçosa, agosto de 2024. **SELEÇÃO DE PROGÊNIES DE SOJA VIA TÉCNICAS DE GEOESTATÍSTICA E AEROFOTOGRAMETRIA.** Orientador: Felipe Lopes da Silva. Coorientadores: Lucas de Paula Corredo, Luiz Alexandre Peternelli e Domingos Sarvio Magalhaes Valente.

A soja [*Glycine max* (L.) Merrill] é a principal commodity agrícola do Brasil, destacando-se por sua importância econômica e ampla gama de aplicações industriais. Em resposta a essa relevância, os programas de melhoramento genético buscam continuamente desenvolver cultivares mais adaptadas e produtivas. No entanto, a seleção de linhagens superiores pode ser influenciada por diversos fatores, como a disponibilidade de nutrientes no solo. Este estudo teve como objetivo incorporar informações dos atributos químicos do solo e índices de vegetação como covariáveis para ajustar o ranqueamento das progênies de soja na geração $F_{3:5}$. Os experimentos foram realizados em duas áreas da Universidade Federal de Viçosa durante a safra 2022/2023: o Ensaio-1, na UEPE-Vale da Agronomia, com 500 progênies, e o Ensaio-2, na UEPE-Horta Nova, com 264 progênies. Ambos os ensaios seguiram um delineamento em blocos aumentados, com parcelas compostas por três linhas de 1,5 m de comprimento, espaçadas em 0,50 m, e uma densidade de plantio de 17 sementes por metro. Foram coletadas 39 amostras de solo no Ensaio-1 e 30 no Ensaio-2 para análise química, além de realizar imageamento aéreo com VANT. A partir das imagens RGB e dos dados de fertilidade do solo, foram extraídos índices de vegetação e gerados mapas de fertilidade. Esses dados foram integrados como covariáveis nos modelos experimentais, cuja adequação foi avaliada pelo Logaritmo da Verossimilhança, Critério de Informação Akaike (AIC), Critério de Informação Bayesiano (BIC) e herdabilidade (h^2). A inclusão dos atributos do solo e índices de vegetação como covariáveis impactou o ranqueamento das progênies, destacando sua relevância na seleção. No entanto, os teores de nutrientes mostraram-se mais influentes na seleção do que os índices de vegetação.

Palavras-chave: *glycine max* (L.) merrill; krigagem; delineamentos

aumentados; análise de covariâncias; fertilidade do solo

ABSTRACT

CUNHA, Uilton Pereira da, M.Sc., Universidade Federal de Viçosa, August, 2024. **SELECTION OF SOYBEAN PROGENIES USING GEOSTATISTICS AND PHOTOGRAMMETRY TECHNIQUES.** Adviser: Felipe Lopes da Silva. Co-advisers: Lucas de Paula Corredo, Luiz Alexandre Peternelli and Domingos Sarvio Magalhaes Valente.

Soybean [*Glycine max* (L.) Merrill] is the leading agricultural commodity in Brazil, standing out for its economic importance and wide range of industrial applications. In response to this significance, breeding programs continuously strive to develop more adaptable and productive cultivars. However, the selection of superior lines can be influenced by various factors, such as nutrient availability in the soil. This study aimed to incorporate soil chemical attributes and vegetation indices as covariates to adjust the ranking of soybean progenies in the $F_{3:5}$ generation. The experiments were conducted in two areas of the Federal University of Viçosa during the 2022/2023 growing season: Experiment-1 at UEPE-Vale da Agronomia, with 500 progenies, and Experiment-2 at UEPE-Horta Nova, with 264 progenies. Both trials followed an augmented block design, with plots consisting of three rows, each 1.5 m long, spaced 0.50 m apart, and a planting density of 17 seeds per meter. A total of 39 soil samples were collected in Experiment-1 and 30 in Experiment-2 for chemical analysis, in addition to aerial imaging with UAV. From the RGB images and soil fertility data, vegetation indices were extracted, and fertility maps were generated. These data were integrated as covariates in the experimental models, whose fit was evaluated using the Logarithm of Likelihood, Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and heritability (h^2). The inclusion of soil attributes and vegetation indices as covariates impacted the ranking of f progenies, highlighting their relevance in selection. However, nutrient levels proved to be more influential in the selection process than the indices.

Keywords: *glycine max* (l.) merril; kriging; augmented designs; covariance analysis; soil fertility

LISTA DE ILUSTRAÇÕES

Figura 1. Localização geográfica do município de Viçosa, Minas Gerais, destacando as áreas onde foram realizados o Ensaio-1 (UEPE - Vale da Agronomia) e o Ensaio-2 (UEPE - Horta Nova).....	16
Figura 2. Representação dos planos de voo gerados pelo aplicativo Pix4D Capture para as áreas de estudo.....	17
Figura 3. Visualização do Ground Control Point (GCP) na área experimental do Ensaio-2 (UEPE – Horta Nova).....	18
Figura 4. Grade Shapefile utilizada na extração dos dados de índice de vegetação e fertilidade por parcela no Ensaio-1 e Ensaio-2.....	20
Figura 5. Mapa de distribuição espacial dos micronutrientes para o Ensaio-1 (UEPE-Vale da Agronomia).	33
Figura 6. Mapa de distribuição espacial dos macronutrientes para o Ensaio-1 (UEPE-Vale da Agronomia).	34
Figura 7. Mapa de distribuição espacial dos micronutrientes para o Ensaio-2 (UEPE-Horta Nova): A – Boro; B – Cobre; C – Ferro; D – Manganês; E – Zinco.	35
Figura 8. Mapa de distribuição espacial dos macronutrientes para o Ensaio-2 (UEPE-Horta Nova): A – Cálcio; B – Magnésio; C – Fósforo; D – Potássio.....	36
Figura 9. Mapas de índices de vegetação para o Ensaio-1 (vale da Agronomia).	42
Figura 10. Mapas de índices de vegetação para o Ensaio-2 (Horta Nova).....	43

LISTA DE TABELAS

Tabela 1 - Índices de vegetação utilizados no estudo	21
Tabela 2. Estatística descritiva das características de fertilidade do solo na profundidade de 0-0,20m para o ensaio conduzido na UEPE-Vale da Agronomia, considerado nesse estudo como Ensaio-1.....	28
Tabela 3 - Estatística descritiva das características de fertilidade do solo na profundidade de 0-0,20m para o ensaio conduzido na UEPE- Horta Nova, considerado nesse estudo como Ensaio-2.....	29
Tabela 4. Parâmetros dos semivariogramas para as variáveis de análise do solo para o Ensaio -1 (UEPE-Vale da Agronomia).....	31
Tabela 5. Parâmetros dos semivariogramas para as variáveis de análise do solo para o Ensaio - 2 (UEPE-Horta Nova).....	31
Tabela 6. Desempenho dos modelos com e sem inclusão de macro e micronutrientes na produtividade dos genótipos de soja avaliados no Ensaio-1 (UEPE-Vale da Agronomia) e no Ensaio-2 (UEPE-Horta Nova).....	37
Tabela 7 - Comparação da similaridade entre os modelos com covariáveis (nutrientes do solo) e o modelo sem covariáveis em relação à seleção percentual das melhores progênies nos Ensaio 1 e 2.....	40
Tabela 8 - Desempenho dos modelos com e sem inclusão de índice de vegetação na produtividade dos genótipos de soja avaliados no Ensaio-1 (UEPE-Vale da Agronomia) e no Ensaio-2 (UEPE-Horta Nova).....	44
Tabela 9. Comparação da similaridade entre os modelos com covariáveis (índices de vegetação) e o modelo sem covariáveis em relação à seleção percentual das melhores progênies nos Ensaio 1 e 2.	45

SUMÁRIO

1.	INTRODUÇÃO	11
2.	MATERIAIS E MÉTODOS.....	14
2.1	MATERIAL VEGETAL, DESCRIÇÃO DO LOCAL, PLANTIO E COLETA DE DADOS DE CAMPO	14
2.2	AERONAVE, PLANO DE VOO, DISTRIBUIÇÃO E GEORREFERENCIAMENTO DOS GROUND CONTROL POINTS	16
2.3	PROCESSAMENTO DOS ORTOMOSAICOS, CRIAÇÃO DO GRADE SHAPEFILE E EXTRAÇÃO DOS ÍNDICES DE VEGETAÇÃO.....	19
2.4	COLETA, PREPARO DAS AMOSTRAS DE SOLO E DETERMINAÇÃO DOS INDICADORES DO SOLO	22
2.5	ELABORAÇÃO DOS MAPAS DE KRIGAGEM E EXTRAÇÃO DOS VALORES MÉDIOS DOS ATRIBUTOS QUÍMICOS DO SOLO A NÍVEL DE PARCELA	22
2.6	ANÁLISE ESTATÍSTICA	23
3.	RESULTADOS E DISCUSSÃO	26
4.	CONCLUSÕES	47
5.	REFERÊNCIAS	47
	ANEXO.....	53

1. INTRODUÇÃO

A soja [*Glycine max* (L.) Merrill] destaca-se como uma das principais commodities no cenário agrícola nacional, desempenhando um papel fundamental na produção de óleo vegetal e proteína destinada à alimentação humana e animal (NEVARA *et al.*, 2023; PHUAH *et al.*, 2022). O Brasil reafirma sua posição como líder mundial na produção e exportação de grãos de soja, registrando uma produção de 154,6 milhões de toneladas, cultivadas em aproximadamente 44 milhões de hectares e exportando expressivos 96,7 milhões de toneladas (CONAB, 2023; MENEGON *et al.*, 2024). No entanto, com a crescente demanda por alimentos e os desafios ambientais e climáticos, é imperativo desenvolver genótipos cada vez mais superiores (AJEESH KRISHNA *et al.*, 2021). Nesse contexto, o melhoramento genético de plantas emerge como um recurso fundamental para potencializar a produtividade, adaptabilidade e resistência das cultivares de soja (MILIOLI *et al.*, 2022).

Os programas de melhoramento genético da soja concentram-se no desenvolvimento de novas cultivares que apresentem melhorias em características agronômicas essenciais, como aumento da produtividade, resistência a pragas e doenças, maior adaptação a diferentes condições ambientais e maior tolerância a adversidades climáticas (SEDIYAMA *et al.*, 2005). Para atingir tais objetivos, o processo de melhoramento genético é meticuloso e envolve ciclos iterativos de cruzamentos, seleções e testes (KAISER *et al.*, 2020). Inicialmente, são desenvolvidas populações segregantes por meio de hibridação artificial, sendo então conduzidas por diversas gerações até se alcançar um nível adequado de homozigose genética. Posteriormente, plantas de gerações avançadas são selecionadas para testes de progênies e a escolha de linhagens com características agronômicas desejáveis (ALMEIDA *et al.*, 1999).

Nas fases iniciais dos programas de melhoramento genético é comum enfrentar limitações que afetam a precisão dos experimentos, como o grande número de linhagens a serem testadas, restrições na quantidade de material genético disponível e limitações no tamanho da área experimental. Conseqüentemente, nem todas as linhagens podem ser replicadas em cada bloco experimental, o que pode comprometer a precisão das estimativas dos parâmetros fenotípicos e genotípicos (SANTOS, 2023). Para superar esses desafios, é fundamental planejar

adequadamente os experimentos. A utilização de delineamentos apropriados permite um controle mais eficaz das variáveis ambientais, melhorando a precisão das estimativas dos valores genéticos (HALLAUER, 2011). Um exemplo de delineamento particularmente eficiente nessas circunstâncias é o Delineamento de Blocos Aumentados (DBA), proposto por Walter T. Federer em 1955.

O DBA é um tipo de delineamento experimental que inclui duas classes de tratamentos: os comuns, também chamados de testemunhas, que são repetidos no experimento, e os tratamentos adicionais, conhecidos como regulares, que são introduzidos aleatoriamente sem a necessidade de repetição (LESTERI & ANSHORI, 2022). Dessa forma, a seleção de genótipos baseia-se no desempenho dos tratamentos regulares em comparação com as testemunhas mais próximas. Além disso, as testemunhas são essenciais para corrigir os efeitos genotípicos dos tratamentos regulares, minimizando variações não genotípicas (SABA *et al.*, 2017). A flexibilidade do DBA, ao permitir a avaliação de um grande número de genótipos sem a obrigatoriedade de repetir tratamentos regulares, torna-o particularmente útil nas fases iniciais do programa de melhoramento, especialmente para a triagem preliminar de progênies promissoras (SALUCI *et al.*, 2020). Ademais, sua eficiência em termos de recursos, como terra, insumos e mão de obra, reforça sua utilidade (KHOKHAR *et al.*, 2022).

Apesar das vantagens inerentes ao uso do DBA nos programas de melhoramento genético, é essencial reconhecer suas limitações. Um desafio significativo surge quando o número de tratamentos a serem testados é extenso, resultando em blocos potencialmente grandes e heterogêneos (ESHETIE, 2011). Essa heterogeneidade dos blocos pode comprometer a precisão experimental, especialmente devido à falta de ajuste para variações no ambiente, como a fertilidade do solo, que é crucial para a obtenção de estimativas precisas dos valores genotípicos dos tratamentos (LIN & POUSHINSKY, 1983).

A fertilidade do solo resulta da interação complexa entre fatores naturais e antropogênicos (PIVELLO *et al.*, 2021). Essa condição exerce uma influência direta sobre o crescimento, desenvolvimento e produtividade das plantas, afetando características como porte, vitalidade e resistência a doenças (SALEEM *et al.*, 2023). Em ambientes experimentais, onde a fertilidade do solo pode variar com concentrações excessivas ou insuficientes de nutrientes, as respostas das plantas aos

tratamentos podem ser obscurecidas ou distorcidas, dificultando a identificação e a seleção dos genótipos mais promissores (ELTAHER *et al.*, 2021).

Para mitigar a influência da fertilidade do solo na seleção das linhagens de soja, a aplicação de modelos estatísticos emerge como uma estratégia promissora (ALVARADO, 2020). Os modelos lineares mistos podem incluir efeitos aleatórios para representar a variação genética entre as linhagens de soja testadas, enquanto também consideram efeitos fixos para fatores ambientais, como a fertilidade do solo (MADIAS *et al.*, 2021). Ao integrar dados da fertilidade de solo nesses modelos, é possível normalizar e ajustar informações, isolando esse fator ambiental.

Por meio da análise de solos, os atributos químicos são quantificados, permitindo avaliar os níveis de deficiência, suficiência ou excesso de nutrientes (MOURSY *et al.*, 2022). Uma abordagem complementar a essa técnica é a krigagem, que se baseia na correlação espacial entre os pontos de amostragem para estimar valores desconhecidos em locais não amostrados (LIU *et al.*, 2021). A integração da krigagem à análise de solos resulta na produção de mapas representativos da distribuição espacial da fertilidade do solo, capturando assim a variação espacial dos nutrientes em uma determinada área e permitindo sua incorporação aos modelos estatísticos.

Embora a análise química do solo seja essencial para compreender as condições nutricionais em uma área agrícola, avanços tecnológicos estão rapidamente introduzindo métodos digitais que têm o potencial de complementar ou até mesmo substituir essa prática (KAMILARIS *et al.*, 2017). Nesse contexto, imagens RGB (Red, Green e Blue) de veículos aéreos não tripulados (VANTs) equipados com sensores emergem como uma alternativa ágil, eficiente e flexível (YANG, 2017). Analisando as cores e padrões dessas imagens, é possível extrair índices de vegetação. Esses índices fornecem uma avaliação quantitativa da densidade, saúde e vitalidade da vegetação. Isso permite identificar condições de estresse, como deficiências nutricionais nas plantas (SULAIMAN *et al.*, 2024), que se manifestam por mudanças na coloração das folhas e na refletância espectral (SHARIFI, 2020).

Diante da complexidade envolvida no processo de seleção de indivíduos no melhoramento genético, é essencial buscar constantemente por metodologias que facilitem e aprimorem esse processo. Atualmente, ao selecionar indivíduos, levamos em consideração diversos fatores, incluindo os efeitos de repetição, genotípicos

individuais e famílias. No entanto, uma lacuna a ser abordada é a integração das informações do solo nesse processo. Uma abordagem promissora é a incorporação das características da fertilidade do solo e de índices de vegetação como covariáveis no modelo de delineamento experimental. Neste sentido, o objetivo do trabalho foi avaliar e comparar métodos de ranqueamento de progênies de soja utilizando Geoestatística e Aerofotogrametria. Mais especificamente, buscamos demonstrar a importância de considerar os efeitos do solo ao classificar as progênies de soja com base na produtividade e investigar a viabilidade de usar índices derivados de imagens RGB como alternativa à análise tradicional da fertilidade do solo.

2. MATERIAIS E MÉTODOS

2.1 MATERIAL VEGETAL, DESCRIÇÃO DO LOCAL, PLANTIO E COLETA DE DADOS DE CAMPO

Durante a safra 2022/23, foram realizados dois ensaios para testar progênies de soja na geração F_{3:5} desenvolvidas pelo Programa de Melhoramento de Soja da Universidade Federal de Viçosa (UFV). O Ensaio-1 ocorreu na Unidade de Ensino, Pesquisa e Extensão (UEPE) Vale da Agronomia (latitude 20°46'04" S, longitude 42°52'11" W, 660 m de altitude), enquanto o Ensaio-2 foi realizado na UEPE Horta Nova (latitude 20°45'45" S, longitude 42°49'27" W, 647 m de altitude) (Figura 1).

No Ensaio-1, implantado em 28/10/2022, foram semeadas 500 progênies de soja na geração F_{3:5} originadas de 84 populações, as quais derivaram de oito cultivares comerciais e sete linhagens do Banco de Germoplasma do Programa de Melhoramento de Soja da UFV. Como testemunhas, foram incluídos cinco cultivares comerciais: BRASMAX Cromo TF IPRO, M5838 IPRO, NEO610 IPRO, M6410 IPRO e DM 66I68 IPRO. As progênies e as testemunhas foram distribuídas aleatoriamente em dez blocos, totalizando 550 parcelas experimentais.

No Ensaio-2, implantado em 23/11/2022, foram semeadas 264 progênies de soja na geração F_{3:5} originadas de 15 populações, obtidas por meio de um dialelo completo envolvendo seis cultivares comerciais. Como testemunhas, foram utilizados seis cultivares comerciais: BRASMAX Cromo TF IPRO, Apolo RR, M5838 IPRO,

NS5909, TMG 7262RR e TMG 7363 RR. As progênies e as testemunhas foram distribuídas aleatoriamente em seis blocos, totalizando 300 parcelas experimentais.

Ambos os ensaios adotaram o DBA, onde cada parcela experimental foi composta por três linhas de 1,5 m de comprimento, espaçadas em 0,50 m, resultando em 2,25 m² de área experimental por parcela. A densidade de plantio foi de 17 sementes por metro.

O preparo do solo nas áreas experimentais incluiu uma aração seguida por duas gradagens. A aração teve como objetivo principal a descompactação do solo, promovendo aeração e melhorando as condições para o desenvolvimento das raízes da cultura. Após a aração, foram realizadas duas gradagens para nivelar e refinar o solo. A adubação foi feita de forma localizada, aplicando 286 kg/ha da formulação 6-30-6 (N-P-K), que contém 6% de nitrogênio (N), 30% de fósforo (P₂O₅) e 6% de potássio (K₂O). Esse fertilizante foi colocado diretamente no sulco de plantio. Durante todo o período dos ensaios, foi realizado um monitoramento semanal para identificar e controlar pragas e doenças, garantindo um ambiente saudável para as plantas. Todas as práticas de manejo foram executadas conforme recomendações específicas para a cultura da soja, levando em consideração as necessidades individuais de cada área de cultivo.

A variável avaliada foi a produtividade, determinada a partir da massa dos grãos colhidos das três linhas de cada parcela experimental. Para a avaliação da produtividade, as parcelas experimentais foram colhidas individualmente e manualmente. Em seguida, as plantas foram submetidas a uma trilhadeira estacionária com sistema rotativo de debulha, permitindo a extração dos grãos. Os grãos extraídos foram então pesados em uma balança de precisão. Para garantir a precisão na comparação entre os diferentes genótipos, o percentual de umidade dos grãos foi ajustado para um padrão de 13%, utilizando o Medidor de Umidade de Grãos John Deere GT5300.

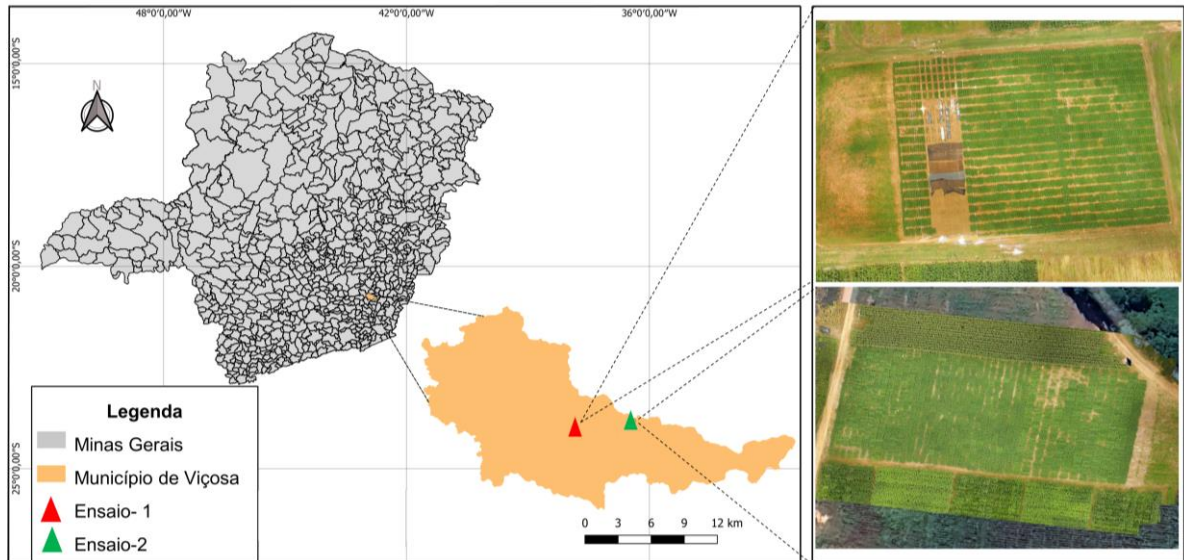


Figura 1. Localização geográfica do município de Viçosa, Minas Gerais, destacando as áreas onde foram realizados o Ensaio-1 (UEPE - Vale da Agronomia) e o Ensaio-2 (UEPE - Horta Nova).

2.2 AERONAVE, PLANO DE VOO, DISTRIBUIÇÃO E GEORREFERENCIAMENTO DOS GROUND CONTROL POINTS

O levantamento aéreo foi realizado utilizando um VANT do tipo RPA (Remotely Piloted Aircraft), modelo Phantom 3 Professional da DJI. O veículo é equipado com uma câmera Sony EXMOR de 1/2,3 polegadas, permitindo a captura de imagens no formato RGB (Red, Green, Blue) com uma resolução de 12,4 megapixels. A lente da câmera tem um campo de visão de 94° e uma distância focal de 20 mm, com abertura óptica de F/2,8.

Para cada ensaio, foi elaborado um plano de voo utilizando o aplicativo Pix4D Capture®, versão 4.11.0, disponível gratuitamente na Google Play Store (Figura 2). Os parâmetros de voo configurados incluíram uma altitude de 20 metros acima do nível do solo, uma velocidade média de voo de 1,8 m/s, ajuste do ângulo da câmera para 90° e uma sobreposição frontal e lateral de 85% entre as imagens. Essas configurações resultaram em uma GSD (Ground Sample Distance) de 0,5 cm por pixel.



Figura 2. Representação dos planos de voo gerados pelo aplicativo Pix4D Capture para as áreas de estudo. A - Plano de voo elaborado para o Ensaio-1 (UEPE – Vale da Agronomia); B - Plano de voo elaborado para o Ensaio-2 (UEPE - Horta Nova).

Os voos foram programados para ocorrer entre 11:00 e 13:00 horas, afim de aproveitar as condições ideais de iluminação e evitar a presença de sombras durante a captura das imagens. Adicionalmente, todas as operações foram conduzidas no modo Visual Line-of-Sight (VLOS), ou seja, dentro do campo de visão direta do operador. Essas medidas foram adotadas para assegurar a qualidade das imagens capturadas, bem como a segurança das operações de voo.

Em cada ensaio, foram instalados Ground Control Points (GCPs). Esses pontos são marcadores físicos no terreno com coordenadas geográficas conhecidas, essenciais para o georreferenciamento da área de estudo e o alinhamento das imagens durante o pré-processamento (ZHENG *et al.*, 2022). Cada GCP foi confeccionado em lona front light, com dimensões de 0,30 m x 0,30 m, apresentando um padrão xadrez em preto e branco para facilitar a identificação durante a captura das imagens (Figura 3). No Ensaio-1, sete GCPs foram estrategicamente posicionados, enquanto no Ensaio-2, oito GCPs foram distribuídos pela área experimental.

No Ensaio-1, os GCPs foram georreferenciados utilizando um receptor GNSS RTK Topomap TPS T10. Este equipamento oferece alta precisão no levantamento de pontos, utilizando a técnica de Real Time Kinematic (RTK), que corrige os sinais GNSS em tempo real, proporcionando coordenadas precisas. Para o Ensaio-2, o georreferenciamento dos GCPs foi realizado com um receptor GNSS JAVAD, modelo TRIUMPH 1. Este receptor permaneceu posicionado em cada ponto por 30 minutos, coletando dados suficientes para garantir a precisão necessária.

No pós-processamento dos dados obtidos pelo GNSS, foi adotado o método do Posicionamento de Ponto Preciso (PPP), oferecido pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Este serviço é "on-line" e gratuito, e permite a obtenção de coordenadas com alta precisão no Sistema de Referência Geocêntrico para as Américas (SIRGAS 2000).




Figura 3. Visualização do Ground Control Point (GCP) na área experimental do Ensaio-2 (UEPE – Horta Nova). A – Representação gráfica do GCP; B - Vista aérea identificando o GCP na área do Ensaio-2; C - Detalhe da escala do GCP.

Ao longo do ciclo de desenvolvimento da soja, foram realizados 15 voos no Ensaio-1 e 18 voos no Ensaio-2. No entanto, para a elaboração do ortomosaico utilizado na análise dos índices de vegetação, foram selecionadas as imagens capturadas no dia 24/01/2023 para o Ensaio-1 e no dia 14/02/2023 para o Ensaio-2. Essas datas correspondem ao estágio fenológico R5 das plantas em cada ensaio, que se refere à fase de desenvolvimento de vagens e enchimento de grãos (FEHR & CAVINESS., 1977). Durante esse período, a demanda por macro e micronutrientes é significativamente maior (SOUZA *et al.*, 2022). Dessa forma, é possível capturar

mudanças na coloração das folhas e na refletância espectral devido a deficiências nutricionais, caso estejam presentes, durante a análise.

2.3 PROCESSAMENTO DOS ORTOMOSAICOS, CRIAÇÃO DO GRADE SHAPEFILE E EXTRAÇÃO DOS ÍNDICES DE VEGETAÇÃO

De posse das imagens, foi gerado um ortomosaico para cada ensaio utilizando o software Agisoft™ MetaShape Professional Edition, versão 1.7.1. As imagens obtidas durante os voos foram importadas para o software através do comando "Add Photos". Para garantir um alinhamento preciso entre as imagens, o sistema de coordenadas de referência foi ajustado para o Datum WGS 84, zona 23S, um passo essencial para assegurar a correspondência exata entre elas.

Após a importação e o ajuste do sistema de coordenadas, o processo de alinhamento das imagens foi iniciado com o comando "Align Photos", utilizando o parâmetro "medium" na caixa de diálogo do software. Durante essa fase, o programa identificou automaticamente pontos de correspondência entre as imagens, promovendo seu alinhamento de maneira precisa.

As coordenadas geográficas dos GCPs foram então integradas ao projeto, com cada marcador verificado minuciosamente e ajustado conforme necessário para garantir a precisão das imagens. Com os ajustes concluídos, procedeu-se à geração de uma nuvem densa de pontos utilizando o comando "Build Dense Cloud", com o parâmetro "medium" selecionado para proporcionar uma representação detalhada da topografia tridimensional das áreas de interesse.

Com a nuvem densa de pontos disponível, o próximo passo foi a construção da malha poligonal através do comando "Build Mesh". Essa malha consiste em uma rede de triângulos interligados que aproximam a superfície do terreno. Cada vértice da malha representa um ponto na superfície capturada, proporcionando uma representação visual detalhada.

Posteriormente, foi criado um Modelo Digital de Elevação (DEM) utilizando o comando "Build DEM". Este modelo oferece uma representação precisa e detalhada da superfície das áreas estudadas. Através do comando "Build Orthomosaic", foi produzida uma imagem ortográfica georreferenciada correspondendo à área experimental, no formato GeoTIFF.

Os ortomosaicos gerados foram importados para o software QGIS Desktop, versão 3.28.12 'Firenze', como camadas raster. Com os ortomosaicos carregados, foram criadas grades em formato shapefile para os ensaios 1 e 2, que foram utilizadas na extração dos valores dos índices de vegetação.

Para criar a grade, no menu principal do QGIS, selecionou-se a opção 'Vetor' e, em seguida, 'Criar Grade'. Na janela que se abriu, foram configurados os parâmetros da grade da seguinte forma: o tipo de grade foi definido como "Polígono Retangular". Para o Ensaio-1, foi configurada uma grade com 550 polígonos, e para o Ensaio-2, uma grade com 300 polígonos. O tamanho de cada polígono foi estabelecido como 2,0 metros na horizontal e 1,50 metros na vertical. Após a configuração, a grade foi gerada, adicionada ao projeto como uma nova camada e salva como shapefile. Sobrepondo a camada raster, cada polígono da grade foi cuidadosamente posicionado sobre uma parcela experimental, conforme ilustrado na Figura 4.



Figura 4. Grade Shapefile utilizada na extração dos dados de índice de vegetação e fertilidade por parcela no Ensaio-1 e Ensaio-2: A - Grade Shapefile para o Ensaio-1 (UEPE – Vale da Agronomia); B - Grade Shapefile para o Ensaio-2 (UEPE – Horta Nova).

A partir da camada raster, foram calculados nove índices de vegetação utilizando a "Calculadora Raster" do QGIS (Tabela 1). Esses índices foram obtidos por meio de operações algébricas entre as bandas espectrais R, G e B do ortomosaico. Após o cálculo, os valores médios de cada índice para cada parcela experimental foram extraídos com a ferramenta "Estatísticas Zonais" no QGIS. Essa ferramenta calcula estatísticas dos dados raster para cada região delimitada pelos polígonos.

Tabela 1 - Índices de vegetação utilizados no estudo

Índice de Vegetação	Descrição	Equação	Referência
ExG (Excess Green)	Mede o excesso de verde nas folhas, sendo útil para identificar áreas de alta densidade de clorofila.	$ExG=2*(G-R-B)$	Woebbecke <i>et al.</i> , 1995
GLI (Green Leaf Index)	Avalia a intensidade do verde das folhas, diferenciando vegetação saudável de estressada.	$GLI=(G-R)+(G-B)/(G+R+G+B)$	Louhaichi <i>et al.</i> , 2001
GRRI (Green Red Ratio Index)	Utiliza a razão entre o verde e o vermelho para monitorar a saúde da vegetação.	$GRRI=G/R$	Gamon & Surfus, 1999
MGRVI (Modified Green Red Vegetation Index)	Modifica o GRRI para melhorar a sensibilidade em diferentes condições de vegetação.	$MGRVI=(G^2-R^2)/(G^2+R^2)$	Bendig <i>et al.</i> , 2015
MVARI (Modified VARI)	Índice modificado para uma melhor distinção entre vegetação e solo.	$MVARI=(G-B)/(G+R-B)$	Gitelson <i>et al.</i> , 2002
NGRDI (Normalized Difference Green Red Index)	Calculado pela diferença normalizada entre verde e vermelho para avaliar a vegetação.	$NGRDI=(G-R)/(G+R)$	Hunt <i>et al.</i> , 2005
RGBVI (Red Green Blue Vegetation Index)	Índice baseado nas bandas vermelha, verde e azul para estimar a quantidade de vegetação.	$RGBVI=(G^2-(R*B))/(G^2+(R*B))$	Bendig <i>et al.</i> , 2015
TGI (Triangular Greenness Index)	Baseado na análise de pixels em um espaço de cor triangular para estimar o verde da vegetação.	$TGI=G-(0,39*R)-(0,61*B)$	Hunt <i>et al.</i> , 2011
VARI (Visible Atmospheric Resistant Index)	Resistente a variações atmosféricas, é utilizado para avaliar a vegetação visível.	$VARI=(G- R)/(G+R-B)$	Gitelson <i>et al.</i> , 2002

R = Red; G = Green; B = Blue.

2.4 COLETA, PREPARO DAS AMOSTRAS DE SOLO E DETERMINAÇÃO DOS INDICADORES DO SOLO

Na área do Ensaio-1, foram coletadas 39 amostras simples de solo, enquanto no Ensaio-2 foram coletadas 30 amostras. Cada amostra consistiu em aproximadamente 300 g de solo retirado da camada de 0-20 cm utilizando um trado holandês. Posteriormente, as amostras foram devidamente embaladas, identificadas e enviadas para o laboratório de análises de solo a fim de quantificar as seguintes características: potencial hidrogeniônico (pH), fósforo (P), potássio (K), cálcio (Ca), magnésio (Mg), alumínio (Al), acidez potencial (H+Al), ferro (Fe), zinco (Zn), cobre (Cu), manganês (Mn), boro (B), fósforo remanescente (P-rem), matéria orgânica (M.O.), soma de bases trocáveis (SB), capacidade de troca catiônica efetiva (t), capacidade de troca catiônica a pH 7,0 (T), índice de saturação de bases (V) e índice de saturação de alumínio (m). Essas análises foram realizadas conforme o Manual de Métodos de Análises de Solos (EMBRAPA, 2017).

Para a extração de P, K, Fe, Zn, Mn e Cu, empregou-se o extrator Mehlich 1, enquanto para Ca, Mg e Al, utilizou-se o extrator KCl a 1 mol/L. A acidez potencial (H+Al) foi extraída com acetato de cálcio 0,5 mol/L a pH 7, enquanto o B foi extraído com água quente. A capacidade de troca catiônica a pH 7,0 (T) foi determinada considerando todos os cátions permutáveis presentes no solo (Ca^{2+} , Mg^{2+} , K^+ , H^+ e Al^{3+}). A capacidade de troca catiônica efetiva (t) foi estimada pela soma dos cátions Ca^{2+} , Mg^{2+} , K^+ e Al^{3+} , e a soma de bases trocáveis (SB) foi obtida pela soma dos cátions Ca^{2+} , Mg^{2+} e K^+ . Os índices de saturação de bases (V) e de saturação de alumínio (m) foram calculados com base nos valores de SB, T, t e Al.

2.5 ELABORAÇÃO DOS MAPAS DE KRIGAGEM E EXTRAÇÃO DOS VALORES MÉDIOS DOS ATRIBUTOS QUÍMICOS DO SOLO A NÍVEL DE PARCELA

A partir dos resultados da análise química do solo, foram elaborados os mapas de fertilidade de cada nutriente avaliado nos Ensaios 1 e 2. Os dados das análises de solo foram importados para o software QGIS e, em seguida, utilizando a extensão Smart-Map (PEREIRA *et al.*, 2022), foi feita a Krigagem Ordinária para cada nutriente.

Com a extensão Smart-Map ativada no QGIS, procedeu-se à seleção e interpolação das variáveis de nutrientes. No comando “Dados” da extensão, selecionou-se a variável de interesse (por exemplo, fósforo, potássio, cálcio, etc.). No comando “Grid”, definiu-se o tamanho da grade para a interpolação, determinando a resolução da malha interpolada. Também foi selecionada a camada de contorno da área de estudo para restringir a interpolação aos limites da área experimental.

No comando “Interpolação” do Smart-Map, foram calculados os semivariogramas das variáveis selecionadas. O software ajustou automaticamente um modelo teórico de semivariograma, escolhendo entre os modelos disponíveis (linear, linear com patamar, exponencial, esférico e gaussiano). Para cada modelo, foram determinados os coeficientes de efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), coeficiente de determinação (R^2) e o erro médio quadrático da raiz (RMSE).

Para a análise do índice de dependência espacial (IDE) dos atributos químicos do solo, utilizou-se a relação $C_1/(C_0+C_1)$. A classificação da dependência espacial foi realizada conforme ZIMBACK (2001): forte dependência para IDE > 75%, dependência moderada para IDE entre 25% e 75% e baixa dependência para IDE < 25%.

Comprovada a dependência espacial, procedeu-se à interpolação por krigagem ordinária. No comando “Interpolação” da extensão, selecionou-se a opção de krigagem e realizou-se a interpolação, gerando mapas estimativos dos valores dos nutrientes em locais não medidos.

A partir dos mapas resultantes da krigagem, foram extraídos os valores médios de cada atributo químico do solo utilizando a ferramenta "Zonal Statistics". Essa extração foi realizada para cada uma das 550 parcelas do Ensaio-1 e para as 300 parcelas do Ensaio-2. Os valores extraídos foram transferidos para uma tabela do Excel para análises estatísticas posteriores.

2.6 ANÁLISE ESTATÍSTICA

Com o objetivo de verificar a eficiência da predição de valores genotípicos das progênies, modelos estatísticos que incluíam covariáveis de fertilidade do solo e índices de vegetação foram comparados com modelos que não as incluíam. A análise foi realizada utilizando uma abordagem de modelos lineares mistos (BLUP/REML) no

software estatístico R, versão 4.2.1, com o auxílio do pacote Asreml, versão 4.2.0.302. Os modelos estatísticos empregados foram estruturados da seguinte forma:

Modelo sem covariável (DBA):

$$Y = X\beta + Zg + Wb + e \quad (1)$$

onde:

Y é o vetor de observações do ensaio;

β é o vetor de efeitos fixos relacionados com os tratamentos comuns do ensaio, com matriz de incidência X;

g é o vetor de efeitos aleatórios correspondentes às progênies avaliadas, com $g \sim N(0, \sigma g^2)$ e matriz de incidência Z;

b é o vetor de efeitos aleatórios dos blocos, com $b \sim N(0, \sigma b^2)$ e matriz de incidência W;

e é vetor de erros aleatórios.

Modelo com nutrientes do solo com covariáveis:

Para a análise da influência dos nutrientes sobre a produtividade das progênies de soja, foram elaborados diferentes modelos estatísticos que incorporaram covariáveis associadas aos nutrientes do solo.

- Modelo individual para cada nutriente como covariável: Foram criados modelos separados para cada macronutriente e micronutriente, totalizando quatro modelos para os macronutrientes e cinco para os micronutrientes. Cada modelo incluiu uma única covariável correspondente ao nutriente específico, com a fórmula geral:

$$Y = X\beta + COV_i + Zg + Wb + e \quad (2)$$

onde: COV_i é o vetor da covariável para o nutriente i ;

- Modelo com macronutrientes como covariáveis: Neste modelo, os efeitos individuais de cada macronutriente são incluídos separadamente como covariáveis.

$$Y = X\beta + \sum_{i=1}^n \text{COV macro}_i + Zg + Wb + e \quad (3)$$

Onde: $\sum_{i=1}^n \text{COV macro}_i$ representa o somatório dos efeitos de todos os macronutrientes, tratados individualmente.

- Modelo com micronutrientes como covariável: Neste modelo, os efeitos individuais de cada micronutriente são incluídos separadamente como covariáveis.

$$Y = X\beta + \sum_{i=1}^n \text{COV micro}_i + Zg + Wb + e \quad (4)$$

Onde: $\sum_{i=1}^n \text{COV micro}_i$ representa o somatório dos efeitos de todos os micronutrientes, tratados individualmente.

- Modelo com macro e micronutrientes como covariável: Neste modelo, os efeitos individuais de cada macronutriente e micronutriente são incluídos separadamente como covariáveis.

$$Y = X\beta + \sum_{i=1}^n \text{COV nutriente}_i + Zg + Wb + e \quad (5)$$

Onde: $\sum_{i=1}^n \text{COV nutriente}_i$ representa o somatório dos efeitos de todos os Macronutrientes e micronutrientes, tratados individualmente.

Modelos com índices de vegetação como covariáveis:

Foram testados individualmente nove índices de vegetação como covariáveis. Cada índice foi avaliado em um modelo separado para investigar sua influência na produtividade das progênes. A fórmula geral para cada modelo é:

$$Y = X\beta + \text{COVindex}_i + Zg + Wb + e \quad (6)$$

Onde: COVindex_i representa o vetor da covariável para o índice de vegetação i .

A significância e ajuste dos modelos foram avaliados com base no logaritmo verossimilhança, no Critério de Informação de Akaike (AIC) (AKAIKE, 1973), e no Critério de Informação Bayesiano (BIC) (SCHWARZ,1978). Além disso, a herdabilidade (h^2) foi calculada como a razão entre a variância genética e a variância fenotípica estimadas pelos modelos.

Os parâmetros do logaritmo da verossimilhança, AIC e BIC, são medidas que avaliam o quão bem o modelo estatístico se ajustou aos dados, ou seja, quão eficiente o modelo foi em "explicar" o fenômeno biológico, representado neste caso pela variável produção por parcela. A escolha do melhor modelo baseia-se na comparação desses critérios, buscando aquele que apresenta o menor valor de AIC e BIC, indicando um melhor ajuste do modelo aos dados observados (ALBAHLI & YAR, 2022). As equações para o cálculo desses critérios são apresentadas a seguir:

Critério de Informação Akaike:

$$AIC = - 2L + 2K \quad (7)$$

onde:

L: é a função de verossimilhança do modelo;

K: é o número de parâmetros estimados no modelo.

Critério de Informação Bayesiano:

$$BIC = -2 L + K \log(n) \quad (8)$$

Onde: n: é o número de observações no conjunto de dados.

A herdabilidade (h^2) é dada por:

$$h^2 = \sigma^2_g / \sigma^2_f \quad (9)$$

Onde: σ^2_g é a variância genética e σ^2_f é a variância fenotípica.

Os melhores modelos que incorporam covariáveis foram usados para corrigir os valores de produção de grãos de cada progênie nos dois ensaios. Esses ajustes

visam compensar variações externas, como condições ambientais, oferecendo uma estimativa mais precisa do desempenho genético das progênies. A partir desses modelos corrigidos, as progênies mais promissoras foram selecionadas com intensidades de 20%, 50% e 70%.

Simultaneamente, uma seleção de indivíduos foi realizada usando um modelo que não considerava covariáveis, aplicando as mesmas intensidades de seleção. Para comparar os métodos, foi calculado o percentual de similaridade entre os indivíduos selecionados pelos modelos com e sem covariáveis. Esse cálculo envolveu a comparação das progênies escolhidas por cada modelo e a determinação da proporção de progênies comuns entre elas.

Essa análise permite avaliar o grau de concordância entre os métodos de seleção. Um alto percentual de similaridade indicaria que os modelos com e sem covariáveis levaram à escolha de progênies semelhantes, sugerindo que as variações nos teores de nutrientes tiveram pouca influência nas decisões de seleção. Por outro lado, um baixo percentual de similaridade mostraria que o uso das covariáveis afetou de forma significativa a escolha das progênies, evidenciando a importância de ajustar os valores de produção para fatores externos e, assim, garantir que a seleção seja mais precisa e focada no potencial genético real.

3. RESULTADOS E DISCUSSÃO

3.1 ATRIBUTOS QUÍMICOS DO SOLO

De acordo com as Classes de Interpretação de Fertilidade do Solo apresentadas na quinta aproximação (GOMES *et al.*, 1999), constatou-se que ambas as áreas exibiam valores médios consistentes com características de solo adequadas para cultivo, apresentando variações sutis entre elas. A classificação revelou que os valores de SB, CTC total e CTC efetiva foram considerados adequados em ambas as áreas. A M.O e a V (%) foram avaliadas como de nível médio. O H+AL foi classificado como médio para o Ensaio-1 e bom para o Ensaio-2. O pH do solo em ambas as áreas foi ligeiramente ácido, porém dentro da faixa considerada adequada para a maioria das culturas, conforme a classificação agrônômica.

As Tabelas 2 e 3 apresentam a estatística descritiva dos atributos químicos dos solos para os Ensaios 1 e 2. No Ensaio-1, observou-se que os coeficientes de variação

(CV%) para Cu, Fe, Zn, Mn e Mg foram elevados, indicando uma maior variação nos dados. Os CV% para P, K e B foram extremamente altos. Em contraste, pH, P-rem e CTC (T) exibiram CV% baixos, sugerindo uma dispersão relativa. Já CTC (t), V%, M.O, Ca, H+Al e S.B apresentaram CV% médios.

No Ensaio-2, a M.O, pH, P-rem e CTC (T) apresentaram baixo CV (%). Os teores de P e Mn, por outro lado, mostraram valores altos de CV%. Para Ca, Mg, H+Al, S.B, CTC (t), V (%), Cu, Fe e Zn, os CV (%) foram classificados como médios, enquanto o CV (%) para B e K foram considerados muito altos (DALCHIAVON *et al.*, 2012).

Tabela 2. Estatística descritiva das características de fertilidade do solo na profundidade de 0-0,20m para o ensaio conduzido na UEPE-Vale da Agronomia, considerado nesse estudo como Ensaio-1.

Variável	Média	Mínimo	Máximo	DP	Variância	CV (%)	Curtose	Assimetria
M.O	2,72	2	3,4	0,28	0,08	10,43	-0,06	-0,02
pH	5,96	5,4	6,8	0,31	0,1	5,19	0,34	0,7
P rem	26,52	20,1	30,7	2,6	6,77	9,81	-0,86	-0,4
P	21,29	11,5	46,2	8,31	69,1	39,04	0,78	1,1
K	85,77	41	170	28,37	804,66	33,07	1,08	0,99
Ca	3,35	2,96	3,77	0,45	0,21	13,52	-0,42	0
Mg	1,13	0,72	2,25	0,31	0,1	27,47	2,47	1,38
H+Al	4,07	2,64	5,28	0,58	0,34	14,33	0,12	-0,22
SB	4,7	3,21	6,86	0,77	0,59	16,28	0,04	0,57
T	8,77	7,5	9,6	0,52	0,27	5,88	-0,27	-0,75
t	4,7	3,21	6,86	0,76	0,58	16,21	0,06	0,58
V	53,45	41,3	72,2	6,97	48,53	13,03	-0,11	0,53
B	0,34	0,2	0,4	0,12	0,01	35,2	2,98	1,32
Cu	3,49	2,1	5,2	0,78	0,61	22,36	-0,88	0,08
Fe	60,98	54	89,9	14,41	207,66	23,63	-0,71	0,18
Zn	6,98	4,2	11,3	1,84	3,37	26,3	-0,24	0,61
Mn	41,77	25,5	63,1	9,31	86,66	22,29	-0,47	0,38

DP: desvio padrão; CV (%): coeficiente de variação.

M.O: matéria orgânica (dag/kg); pH: potencial hidrogeniônico em água; P- rem: fósforo remanescente (mg/L); P: fósforo (mg/dm³); K: potássio (mg/dm³); Ca: cálcio (cmol_c/dm³); Mg: magnésio (cmol_c/dm³); H+Al: acidez potencial (cmol_c/dm³); SB: soma de bases trocáveis (cmol_c/dm³); T: capacidade de troca catiônica a pH 7,0 (cmol_c/dm³); t: capacidade de troca catiônica efetiva (cmol_c/dm³); V: índice de saturação por base (%); B: boro (mg/dm³); Cu: cobre (mg/dm³); Fe: ferro (mg/dm³); Zn: zinco (mg/dm³); Mn: manganês (mg/dm³).

Tabela 3 - Estatística descritiva das características de fertilidade do solo na profundidade de 0-0,20m para o ensaio conduzido na UEPE- Horta Nova, considerado nesse estudo como Ensaio-2.

Variável	Média	Mínimo	Máximo	DP	Variância	CV (%)	Curtose	Assimetria
M.O	2,89	2,40	3,20	0,17	0,03	6,02	0,10	-0,57
pH	5,70	5,30	6,30	0,28	0,08	5,00	-1,03	0,18
P rem	31,49	28,10	34,70	1,68	2,82	5,33	-0,92	-0,22
P	72,02	38,30	98,20	18,17	330,04	25,23	-1,16	-0,50
K	139,93	50,00	310,00	65,59	4302,13	46,87	0,93	1,18
Ca	3,69	2,51	4,59	0,57	0,32	15,35	-0,98	-0,18
Mg	0,80	0,48	1,22	0,15	0,02	18,37	0,69	0,44
H+Al	5,03	3,30	6,27	0,80	0,64	15,96	-1,02	-0,36
SB	4,84	3,34	6,18	0,74	0,54	15,24	-0,79	-0,19
T	9,87	8,68	11,19	0,59	0,34	5,95	-0,43	0,02
t	4,87	3,44	6,18	0,70	0,49	14,39	-0,73	-0,13
V	49,12	35,50	63,80	7,37	54,34	15,01	-0,92	-0,01
B	0,37	0,20	1,00	0,17	0,03	46,05	4,06	1,67
Cu	2,29	1,70	3,00	0,33	0,11	14,35	-0,74	0,16
Fe	33,59	21,40	38,80	5,77	33,35	17,19	-0,01	0,53
Zn	7,87	5,70	10,90	1,32	1,74	16,78	-0,69	0,35
Mn	60,79	41,20	91,20	13,12	172,03	21,58	-0,34	0,66

DP: desvio padrão; CV (%): coeficiente de variação.

M.O: matéria orgânica (dag/kg); pH: potencial hidrogeniônico em água; P- rem: fósforo remanescente (mg/L); P: fósforo (mg/dm³); K: potássio (mg/dm³); Ca: cálcio (cmol_c/dm³); Mg: magnésio (cmol_c/dm³); H+Al: acidez potencial (cmol_c/dm³); SB: soma de bases trocáveis (cmol_c/dm³); T: capacidade de troca catiônica a pH 7,0 (cmol_c/dm³); t: capacidade de troca catiônica efetiva (cmol_c/dm³); V: índice de saturação por base (%); B: boro (mg/dm³); Cu: cobre (mg/dm³); Fe: ferro (mg/dm³); Zn: zinco (mg/dm³); Mn: manganês (mg/dm³).

Os atributos de solo exibiram uma distribuição assimétrica, tanto positiva quanto negativa, com variações na curtose abrangendo ambos os extremos. A curtose positiva indica maior presença de valores discrepantes em relação à média, enquanto a curtose negativa indica menos valores extremos comparados a uma distribuição normal (BAHTIAR *et al.*, 2020). No que diz respeito à assimetria, valores positivos indicam uma inclinação para a direita na distribuição dos dados, com uma maior concentração de valores abaixo da média, incluindo alguns extremamente altos. Em contraste, valores negativos sugerem uma inclinação para a esquerda na distribuição, com uma maior incidência de valores acima da média e possivelmente alguns extremamente baixos (LONDERO *et al.*, 2020).

Assim, a presença de variação nos valores de curtose e assimetria, bem como valores altos de coeficiente de variação, evidencia que os atributos do solo não

seguem uma distribuição normal. Em vez disso, apresentam diferentes graus de concentração e dispersão em torno da média. Essa diversidade nos atributos do solo reflete variações significativas nas áreas onde os ensaios foram conduzidos, sugerindo uma heterogeneidade nesses ambientes.

3.2 MAPAS DE KRIGAGEM

A análise geoestatística das amostras de solo, realizada por meio da modelagem de semivariogramas, identificou dependência espacial dos macronutrientes e micronutrientes nos Ensaio 1 e 2. Os parâmetros dos semivariogramas ajustados e o índice de dependência espacial (IDE) para essas variáveis estão apresentados na Tabela 4 para o Ensaio-1 e na Tabela 5 para o Ensaio-2.

No Ensaio-1, quatro variáveis foram melhor explicadas pelo modelo linear com patamar (P, K, Cu e Fe), quatro pelo modelo linear (Ca, Mg, B e Zn) e uma pelo modelo esférico (Mn). No Ensaio2, seis das nove variáveis foram melhor explicadas pelo modelo linear com patamar (P, K, Ca, Mg, Mn e Fe), duas pelo modelo linear (Cu e B) e uma pelo modelo exponencial (P).

Quanto ao IDE, de acordo com a classificação de ZIMBACK (2001), ambos os ensaios mostraram predominância de dependência espacial moderada ($25\% < IDE < 75\%$), com seis variáveis incluídas nesse intervalo, enquanto as demais foram classificadas como alta dependência espacial ($IDE > 75\%$). Assim, conforme GUIMARÃES (2013), pode-se concluir que a dependência espacial foi bem capturada pela malha de amostragem utilizada em cada ensaio.

Tabela 4. Parâmetros dos semivariogramas para as variáveis de análise do solo para o Ensaio -1 (UEPE-Vale da Agronomia).

Variável	Modelo	C ₀	C ₁	Alcance (m)	IDE (%)	R ²	Classe
P	Lin. Pat.	28,818	54,418	18,862	0,654	0,875	Moderado
K	Lin. Pat.	174,95	524,146	24,378	0,750	0,995	Alto
Ca	Lin	0,128	0,201	25,033	0,611	0,867	Moderado
Mg	Lin	0,028	0,065	25,258	0,699	0,872	Moderado
B	Lin	0,007	0,010	26,817	0,588	0,554	Moderado
Cu	Lin. Pat.	0,182	0,792	32,806	0,813	0,874	Alto
Fe	Lin. Pat.	197,51	210,479	26,876	0,516	0,650	Moderado
Zn	Lin	0,567	3,913	28,019	0,873	0,978	Alto
Mn	Esf	45,762	86,575	19,102	0,654	0,603	Moderado

IDE: Índice de dependência espacial ($C_1/C_0 + C_1$); C₀:efeito pepita; C₀+C₁: Patamar; Lin. Pat.: modelo linear com patamar; Lin: modelo linear; ESF: modelo esférico; P: fósforo (mg/dm³); K: potássio (mg/dm³); Ca: cálcio (cmol_c/dm³); Mg: magnésio (cmol_c/dm³); B: boro (mg/dm³); Cu: cobre (mg/dm³); Fe: ferro (mg/dm³); Zn: zinco (mg/dm³); Mn: manganês (mg/dm³).

Tabela 5. Parâmetros dos semivariogramas para as variáveis de análise do solo para o Ensaio - 2 (UEPE-Horta Nova).

Variável	Modelo	C ₀	C ₁	Alcance (m)	IDE (%)	R ²	Classe
P	Exp	74,596	357,198	17,348	0,827	0,929	Alto
K	Lin. Pat.	109,87	257,092	17,552	0,701	0,993	Moderado
Ca	Lin. Pat.	0,012	0,422	21,459	0,972	0,954	Alto
Mg	Lin. Pat.	0,006	0,016	17,373	0,727	0,760	Moderado
B	Lin	0,014	0,012	17,323	0,462	0,640	Moderado
Cu	Lin	0,118	0,096	17,487	0,449	0,950	Moderado
Fe	Lin. Pat.	30,737	20,788	21,758	0,403	0,448	Moderado
Zn	Lin. Pat.	0,43	1,814	14,368	0,808	0,983	Alto
Mn	Lin. Pat.	78,301	179,206	15,867	0,696	0,987	Moderado

IDE: Índice de dependência espacial ($C_1/C_0 + C_1$); C₀:efeito pepita; C₀+C₁: Patamar; Lin. Pat.: modelo linear com patamar; Lin: modelo linear; Exp: modelo exponencial; P: fósforo (mg/dm³); K: potássio (mg/dm³); Ca: cálcio (cmol_c/dm³); Mg: magnésio (cmol_c/dm³); B: boro (mg/dm³); Cu: cobre (mg/dm³); Fe: ferro (mg/dm³); Zn: zinco (mg/dm³); Mn: manganês (mg/dm³).

Com base na identificação da dependência espacial, foi possível realizar a interpolação dos dados e gerar mapas de krigagem para cada nutriente analisado. Nos mapas de distribuição espacial dos micronutrientes para o Ensaio-1 (Figura 5), observa-se que o B apresentou predominantemente teores baixos (0,16 - 0,35 mg/dm³) em 59,45% das parcelas, enquanto 40,55% exibiram teores médios (0,36 - 0,60). Em contraste, os teores de Cu foram elevados (> 1,8 mg/dm³) em todas as

parcelas avaliadas, assim como os de Fe ($> 45 \text{ mg/dm}^3$), Mn ($> 12 \text{ mg/dm}^3$) e Zn ($> 2,2 \text{ mg/dm}^3$) (GOMES *et al.*, 1999).

Nos mapas de distribuição espacial dos macronutrientes (Figura 6), o Ca foi considerado bom ($2,41 - 4,00 \text{ cmolc/dm}^3$) em todas as parcelas. Para o Mg, a maioria das parcelas (91,45%) apresentou teores bons ($0,91 - 1,50 \text{ cmolc/dm}^3$), com 4,18% mostrando teores médios ($0,46 - 0,90 \text{ cmolc/dm}^3$) e 4,37% teores muito bons ($> 1,50 \text{ cmolc/dm}^3$). Quanto ao K, 66,9% das parcelas apresentaram teores bons ($71 - 120 \text{ mg/dm}^3$), 25,8% teores médios ($41 - 70 \text{ mg/dm}^3$) e 7,3% teores muito bons ($> 120 \text{ mg/dm}^3$). Em relação ao P, 61,27% das parcelas apresentaram teores bons ($15,9 - 24,0 \text{ mg/dm}^3$), 25,28% teores muito bons ($> 24 \text{ mg/dm}^3$) e 13,45% teores médios ($11,5 - 15,8 \text{ mg/dm}^3$), considerando sua interpretação baseada em P-rem ($19 - 30 \text{ mg/l}$) (GOMES *et al.*, 1999).

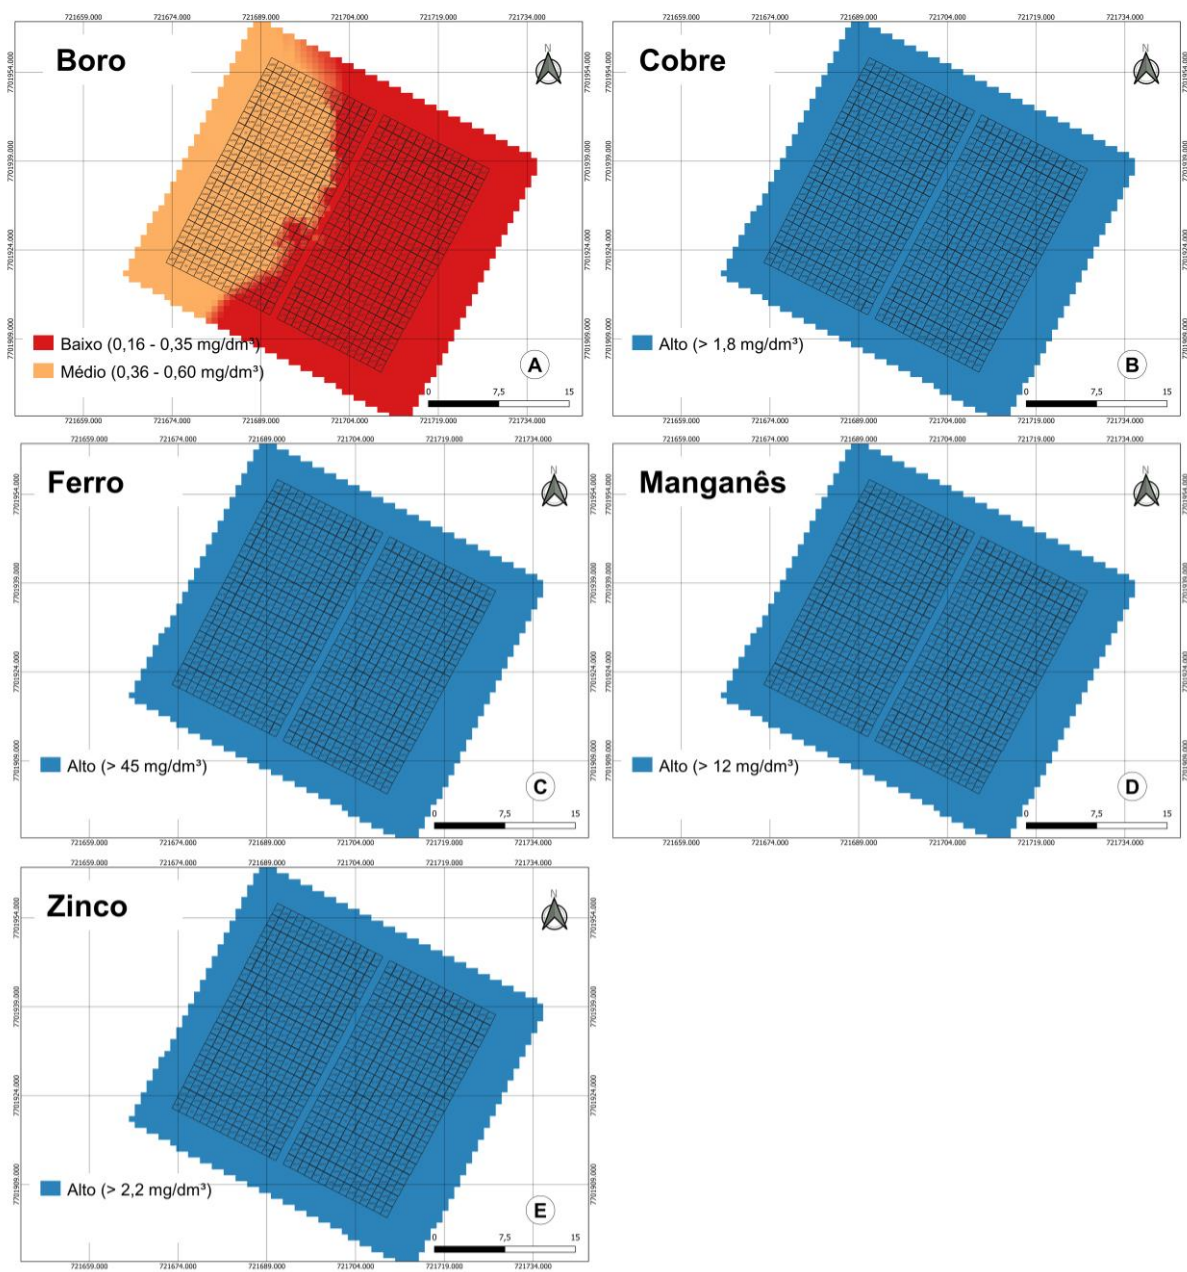


Figura 5. Mapa de distribuição espacial dos micronutrientes para o Ensaio-1 (UEPE-Vale da Agronomia): A – Boro; B – Cobre; C – Ferro; D – Manganês; E – Zinco.

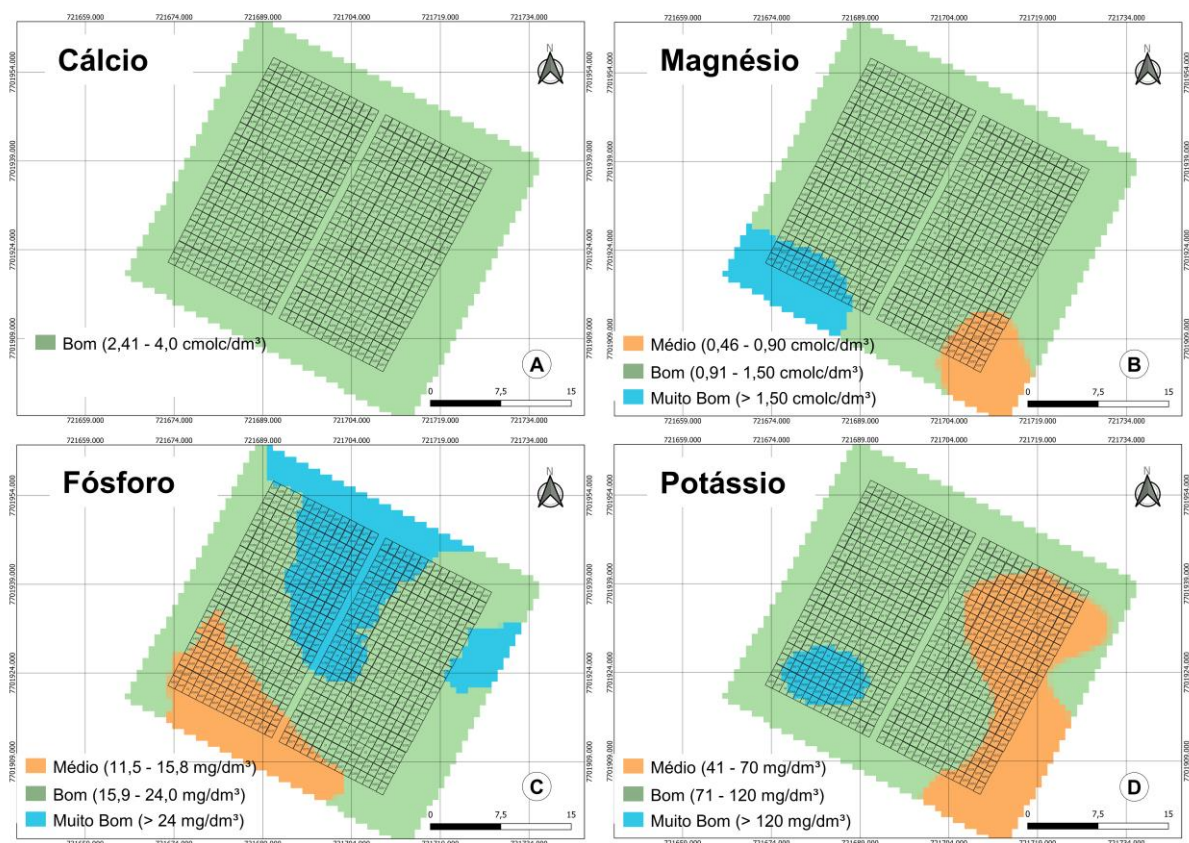


Figura 6. Mapa de distribuição espacial dos macronutrientes para o Ensaio-1 (UEPE-Vale da Agronomia): A – Cálcio; B – Magnésio; C – Fósforo; D – Potássio.

Nos mapas de distribuição espacial dos micronutrientes do Ensaio-2 (Figura 7), observa-se que o B apresentou predominantemente teores baixos em 44,66% das parcelas, enquanto 49,68% mostraram teores médios, e 5,66% apresentaram teores bons (0,61 – 0,90 mg/dm³). Em contrapartida, o Cu foi encontrado em teores elevados em todas as parcelas experimentais, assim como o Mn e Zn. O Fe foi encontrado em teor médio (19 – 30 mg/dm³) em apenas 0,3% das parcelas, enquanto 99,7% apresentaram teores bons (31 – 45 mg/dm³) (GOMES *et al.*, 1999).

Nos mapas de distribuição espacial dos macronutrientes do Ensaio-2 (Figura 8), o Ca foi considerado bom em 69,3% das parcelas e muito bom (> 4,00 cmolc/dm³) em 30,7% das parcelas. No que tange ao Mg, a maioria das parcelas (90,03%) apresentou teores médios, com 9,97 % apresentando teores bons. Em relação ao K, 31,33% das parcelas mostraram teores bons e 68,67% teores muito bons. Quanto ao P, 100% das parcelas apresentaram teores muito bons (> 33 mg/dm³), considerando sua interpretação baseada em P-rem (30 – 44 mg/l) (GOMES *et al.*, 1999).

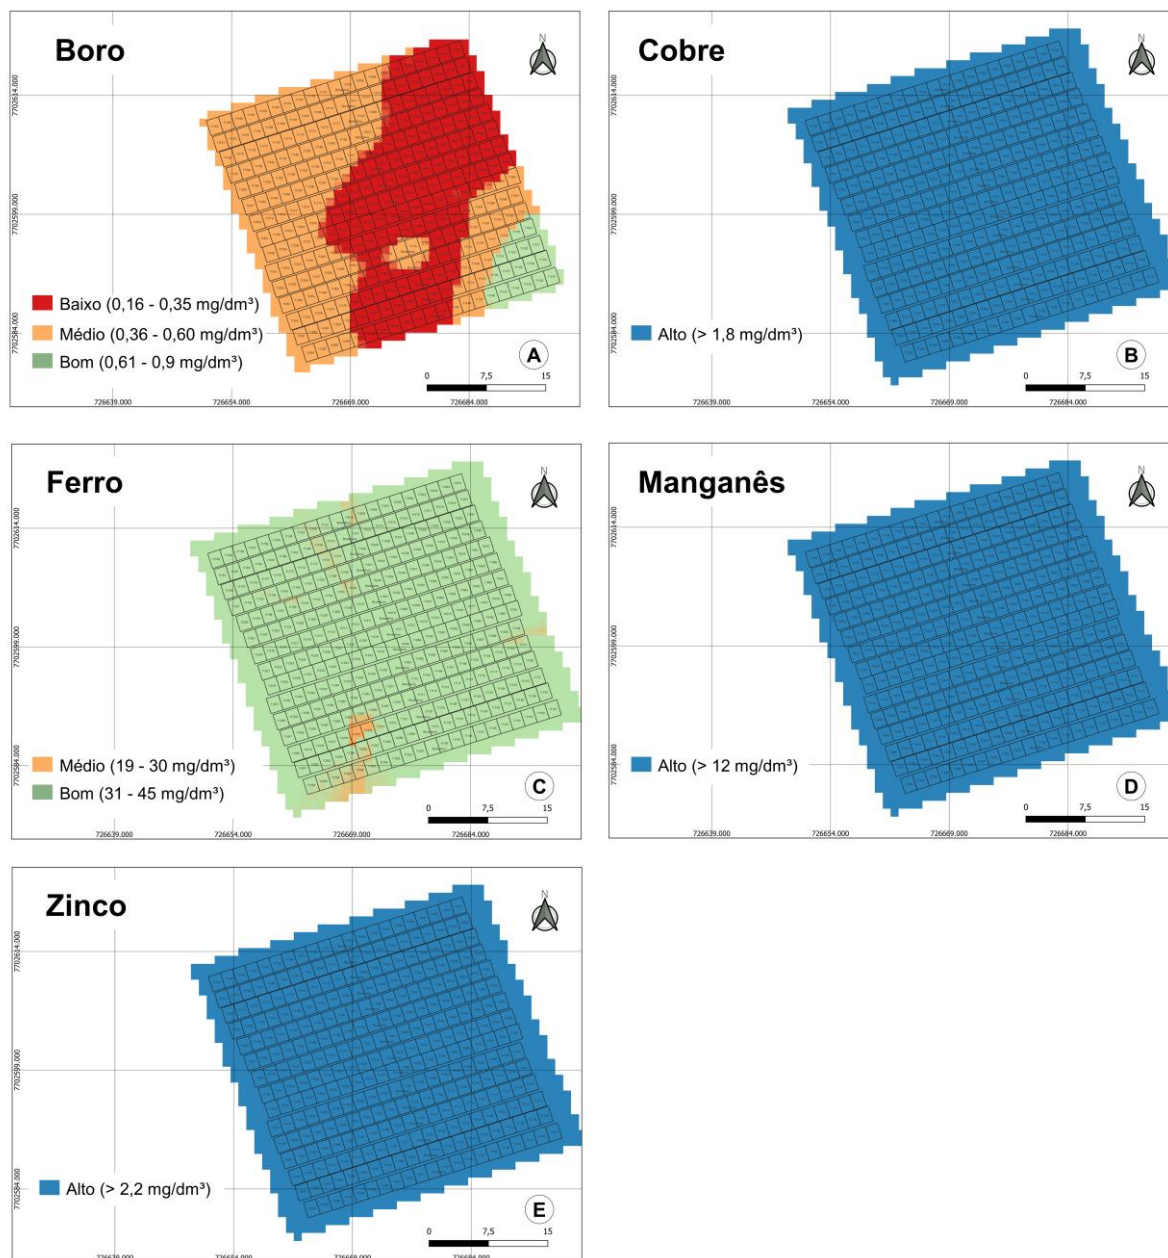


Figura 7. Mapa de distribuição espacial dos micronutrientes para o Ensaio-2 (UEPE-Horta Nova): A – Boro; B – Cobre; C – Ferro; D – Manganês; E – Zinco.

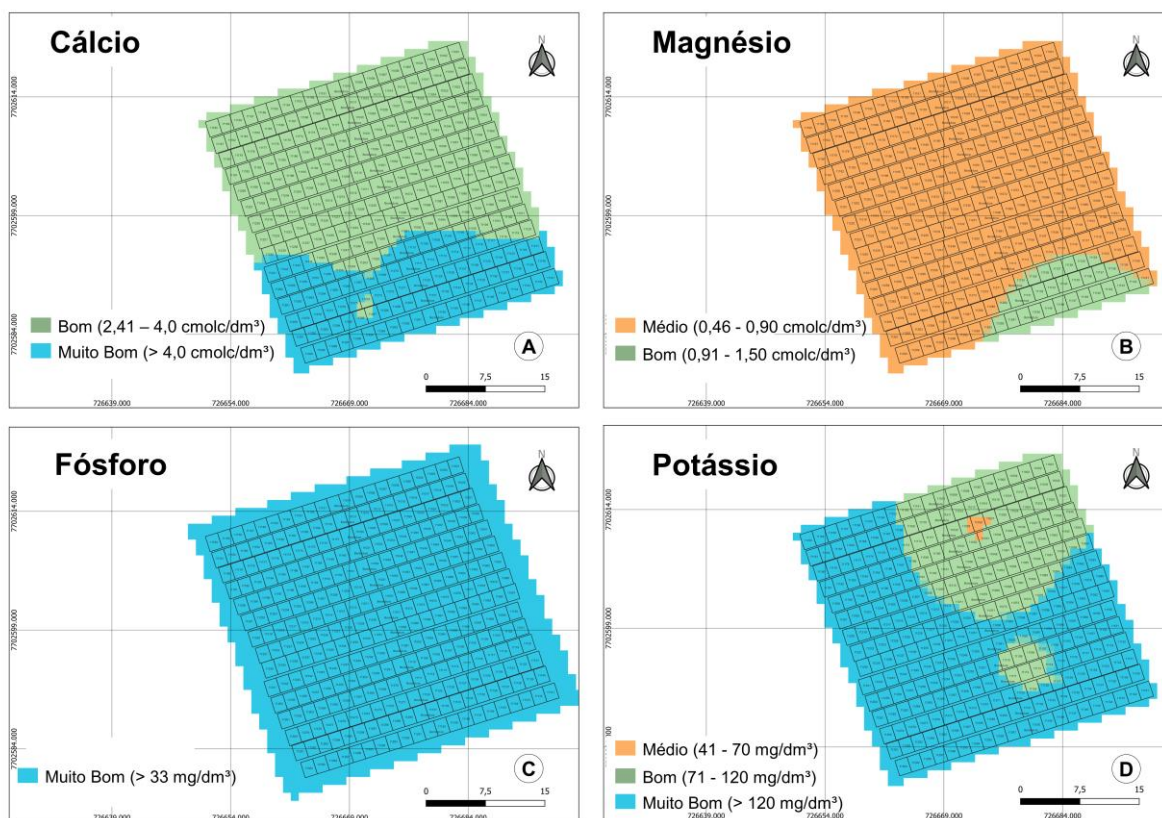


Figura 8. Mapa de distribuição espacial dos macronutrientes para o Ensaio-2 (UEPE-Horta Nova): A – Cálcio; B – Magnésio; C – Fósforo; D – Potássio.

3.3 MODELOS ESTATÍSTICOS E RANQUEAMENTO DAS PROGÊNIES DE SOJA

A Tabela 4 compara os valores de AIC, BIC e o logaritmo da verossimilhança para os modelos testados nos ensaios 1 e 2, com e sem covariáveis. Os critérios de AIC e BIC são amplamente utilizados para avaliar a qualidade de modelos estatísticos. Modelos com valores mais baixos de AIC e BIC são geralmente considerados melhores, indicando um ajuste mais adequado aos dados. O logaritmo da verossimilhança, por sua vez, quantifica a adequação do modelo aos dados, com valores mais altos sugerindo um ajuste superior (ALBAHLI & YAR, 2022).

Nos dois ensaios, os modelos com covariáveis demonstraram desempenho superior em comparação ao modelo sem covariáveis. Especificamente, os modelos que incluíram todos os macros e micronutrientes, apenas os micronutrientes, e apenas os macronutrientes se destacaram como os mais adequados entre os testados, apresentando os valores mais baixos de AIC e BIC, além de um maior valor de logaritmo da verossimilhança.

Tabela 6. Desempenho dos modelos com e sem inclusão de macro e micronutrientes na produtividade dos genótipos de soja avaliados no Ensaio-1 (UEPE-Vale da Agronomia) e no Ensaio-2 (UEPE-Horta Nova).

Modelo	Ensaio-1				Ensaio-2			
	h ²	lnL	AIC	BIC	h ²	lnL	AIC	BIC
Sem Covariável	0,69	-3.280,26	6.566,52	6.579,39	0,28	-1.815,44	3.636,87	3.647,89
Com Covariáveis								
Boro	0,70	-3.273,83	6.553,66	6.566,52	0,28	-1.809,61	3.625,21	3.636,22
Cobre	0,71	-3.276,00	6.557,99	6.570,86	0,28	-1.810,14	3.626,27	3.637,28
Ferro	0,69	-3.279,14	6.564,28	6.577,14	0,29	-1.812,31	3.630,62	3.641,63
Manganês	0,70	-3.278,99	6.563,98	6.576,84	0,29	-1.805,58	3.617,15	3.628,16
Zinco	0,69	-3.278,31	6.562,62	6.575,49	0,28	-1.810,81	3.627,61	3.638,62
Cálcio	0,69	-3.275,85	6.557,70	6.570,56	0,29	-1.809,57	3.625,14	3.636,15
Magnésio	0,69	-3.276,00	6.558,00	6.570,87	0,28	-1.805,58	3.617,15	3.628,16
Fósforo	0,69	-3.279,23	6.564,46	6.577,32	0,28	-1.811,43	3.628,87	3.639,88
Potássio	0,70	-3.280,23	6.566,46	6.579,32	0,29	-1.811,99	3.629,98	3.640,99
Todos os Macronutrientes	0,70	-3.268,49	6.542,98	6.555,83	0,29	-1.797,51	3.601,01	3.611,99
Todos os Micronutrientes	0,71	-3.262,69	6.531,39	6.544,23	0,28	-1.794,73	3.595,46	3.606,43
Todos os Macronutrientes e Micronutrientes	0,70	-3.248,86	6.503,71	6.516,53	0,28	-1.776,82	3.559,64	3.570,57

h²: herdabilidade; lnL: logaritmo da verossimilhança; AIC: Critério de Informação de Akaike; BIC: Critério de Informação Bayesiano.

O desempenho superior dos modelos com covariáveis pode ser atribuído à capacidade desses modelos de capturar de maneira mais precisa os efeitos das variáveis relacionadas à fertilidade do solo sobre a produtividade dos genótipos de soja. Os macros e micronutrientes desempenham papéis cruciais no metabolismo, na divisão celular, na síntese de proteínas e na regulação hormonal das plantas, todos essenciais para o desenvolvimento vegetal adequado e a maximização da produtividade (PANDEY *et al.*, 2020). A ausência ou deficiência desses nutrientes pode resultar em crescimento atrofiado, menor resistência a estresses abióticos e bióticos e, conseqüentemente, em uma redução significativa no rendimento das plantas (KUMARI *et al.*, 2022).

Em ambos os ensaios conduzidos, foi observado que o teor de B no solo estava abaixo do recomendado para a cultura da soja na maioria das parcelas experimentais. Esse micronutriente desempenha um importante papel no desenvolvimento das plantas. Além da sua função estrutural nas células, esse nutriente está envolvido em uma variedade de processos metabólicos, incluindo o metabolismo de ácidos nucléicos, do fenol, compostos nitrogenados e açúcares, síntese de proteínas, metabolismo do fósforo e regulação hormonal, entre outros (GARCÍA-SÁNCHEZ *et al.*, 2020). Sua deficiência pode afetar diversos processos, como o crescimento da raiz, a translocação de açúcares, o metabolismo dos carboidratos e a síntese de ácidos nucléicos, influenciando diretamente na produtividade das plantas (GARCÍA-SÁNCHEZ *et al.*, 2020).

Além disso, as interações entre os nutrientes podem influenciar significativamente a produtividade das plantas, uma vez que a presença ou deficiência de certos nutrientes pode afetar a absorção e a utilização de outros. Por exemplo, quantidades excessivas de P podem reduzir a absorção de micronutrientes catiônicos como Fe, Mn, Zn e Cu (MALVI, 2011). O excesso de K pode diminuir a absorção de Mg e Ca (ARAÚJO *et al.*, 2012). Teores altos de Fe podem inibir a absorção de Zn, enquanto quantidades excessivas de Zn podem reduzir a absorção de Mn (MOUSAVI *et al.*, 2012). Teores altos de Ca podem diminuir a absorção de Fe (BURSTROM, 1968). Teores ideais de Cu e B podem melhorar a absorção de N pelas plantas (AHMED *et al.*, 2011; CUI *et al.*, 2022). Da mesma forma, teores adequados de Ca e Zn podem aumentar a absorção de P e K, e teores ideais de Mn aumentam a absorção de Cu (MALVI, 2011).

Portanto, a inclusão de covariáveis nos modelos estatísticos reflete de maneira mais fiel as variações na produtividade, ao considerar os efeitos complexos dos nutrientes. Em contrapartida, modelos que desconsideram essas variáveis tendem a negligenciar essas interações importantes, levando à subestimação ou superestimação das variações na produtividade, comprometendo a acurácia dos resultados.

O Ensaio-2 apresentou uma herdabilidade inferior em comparação com o Ensaio-1. A herdabilidade representa a proporção da variabilidade total de uma característica que é atribuída a fatores genéticos em relação aos fatores ambientais (ZHU & ZHOU, 2020). Assim, a discrepância nos valores de herdabilidade entre esses dois ensaios pode ser atribuída a diversas razões, como as condições experimentais específicas de cada estudo, a variação ambiental e possíveis diferenças nas origens genéticas das progênies avaliadas (ADHIKARI *et al.*, 2018; LUSTRU *et al.*, 2021; TESFAYE *et al.*, 2021).

A avaliação da qualidade experimental dos ensaios foi realizada com base no Coeficiente de Variação (CV%), que mede a variação dos dados em relação à média. Observou-se que o CV% foi bastante semelhante entre os dois ensaios, com valores de 25,25% para o Ensaio-1 e 26,44% para o Ensaio-2. Esses valores indicam uma variação consistente dos dados em ambos os ensaios, sugerindo uma qualidade experimental comparável.

A diferença na herdabilidade entre os ensaios, portanto, pode ser melhor compreendida ao considerar a variabilidade genética das progênies. No Ensaio-1, foram avaliadas progênies provenientes de 84 populações, com a participação de 15 genitores no processo de cruzamento. Em contraste, no Ensaio-2, as progênies originaram-se de apenas 15 populações, envolvendo apenas 6 genitores nos cruzamentos.

No estudo conduzido por BARROSO *et al.* (2017) com progênies de feijão-caupi na geração F_{3:6}, foi destacada uma associação entre variabilidade genética e herdabilidade. Os pesquisadores observaram uma alta herdabilidade, o que foi atribuído à significativa variância genotípica presente entre as progênies analisadas. Essa relação foi corroborada por CASCÃO *et al.* (2023) em sua investigação sobre diferentes populações de milho. Ao observarem uma elevada variabilidade genética entre as progênies estudadas, os pesquisadores também identificaram uma maior

estimativa de herdabilidade, especialmente em relação a atributos relevantes como massa de grãos e peso da espiga sem palha.

Além disso, o estudo conduzido por VIEIRA *et al.* (2021) sobre programas de seleção recorrente em milho fornece evidências adicionais dessa relação. Ao longo dos ciclos de seleção, eles observaram um aumento progressivo na herdabilidade, o que foi atribuído ao acúmulo de alelos favoráveis e ao conseqüente aumento na variabilidade genética das populações analisadas.

Na Tabela 7, são apresentados os valores de similaridade entre os três melhores modelos com covariáveis em relação ao modelo sem covariável. Para o Ensaio-1, considerando taxas de seleção de 20%, 50% e 70% dos melhores genótipos. Observa-se que a similaridade entre o modelo sem covariável e o modelo que considera todos os macronutrientes e micronutrientes foi de 92%, 93% e 97%, respectivamente. Em relação ao modelo que incorporou apenas os micronutrientes, a similaridade foi de 93%, 95% e 96%. Para o modelo que incluiu todos os macronutrientes, a similaridade foi de 93%, 95% e 97%.

Para o Ensaio 2, a similaridade entre o modelo sem covariável e o modelo que inclui tanto macronutrientes quanto micronutrientes como covariáveis foi de 95%, 96% e 97%. Para o modelo que considerou apenas os micronutrientes, a similaridade foi de 97%, 98% e 98% para as respectivas intensidades de seleção. Enquanto isso, o modelo que incorporou todos os macronutrientes mostrou uma similaridade de 97%, 97% e 98% em relação ao modelo sem covariável.

Tabela 7 - Comparação da similaridade entre os modelos com covariáveis (nutrientes do solo) e o modelo sem covariáveis em relação à seleção percentual das melhores progênies nos Ensaio 1 e 2.

	Ensaio-1			Ensaio-2		
	Modelo sem covariável vs			Modelo sem covariável vs		
Melhores genótipos	Macro e Micro	Micro	Macro	Macro e Micro	Micro	Macro
20%	92%	93%	93%	95%	97%	97%
50%	93%	95%	95%	96%	98%	97%
70%	97%	96%	96%	97%	98%	98%

Macro e Micro: modelo estatístico que incluiu todos os macros e micronutrientes como covariáveis; Micro: modelo estatístico que incluiu apenas os micronutrientes como covariáveis; Macro: modelo estatístico que incluiu apenas os macronutrientes como covariáveis.

Apesar dos modelos com covariáveis terem apresentado melhor adequação dos dados em comparação ao modelo sem covariáveis, observou-se uma grande coincidência entre os melhores genótipos selecionados para esses modelos. Uma possível explicação pode estar nas condições químicas do solo nas áreas onde os ensaios foram conduzidos, as quais apresentavam fertilidade adequada para o cultivo da soja. Isso sugere que a fertilidade do solo não foi um fator estritamente limitante nas produtividades dos genótipos avaliados.

No estudo conduzido por FERREIRA (2020), com o objetivo de corrigir o ranqueamento das famílias de cana-de-açúcar durante o processo de seleção, foram incorporadas informações dos atributos do solo como covariáveis no modelo de delineamento experimental. O autor constatou que a concordância entre os modelos variou significativamente de acordo com a intensidade de seleção aplicada: iniciando em 83,33% para a seleção das 20% melhores famílias, elevando-se para 90% para as 50% melhores famílias, chegando a 95% para as 70% melhores famílias. No entanto, ao longo do estudo, foi constatado que a área onde o ensaio foi conduzido não era adequada para o cultivo da cana-de-açúcar, com as propriedades químicas do solo atuando como um fator limitante para uma produção elevada, o que justifica a menor concordância entre os modelos para uma intensidade de seleção de 20%.

3.4 ÍNDICES DE VEGETAÇÃO

Nos Ensaios 1 e 2, nove índices de vegetação foram empregados como covariáveis no modelo estatístico com o intuito de aprimorar a seleção das progênies de soja. No Ensaio-1, os resultados revelaram que o índice GRII variou de 0,09 a 31, o RGBVI de -0,34 a 1,0, o NGRDI de -0,83 a 1,0, e o TGI de -20,01 a 118,03. Adicionalmente, o MGRVI variou de -0,98 a 1,0, o EXG de -95 a 209, e o GLI de -0,7 a 1,0. Os índices VARI e MVARI tiveram variações entre -0,83 a 2,0, e entre -2 a 1,0, respectivamente. Para o Ensaio-2, foram observadas variações semelhantes, embora com sutis diferenças em relação ao Ensaio-1. O GRII variou de 0,14 a 40, o RGBVI de -0,53 a 1,0, o NGRDI de -0,74 a 1,0, e o TGI de -33,11 a 137,83. Igualmente, o MGRVI variou de -0,95 a 1,0, o EXG de -77 a 244, e o GLI de -0,54 a 1,0. Os índices VARI e MVARI demonstraram variações de -0,74 a 1,3 e de -1,19 a 1,0, respectivamente.

As Figuras 9 e 10 apresentam os mapas de índice de vegetação MVARI e GLI para o Ensaio-1, e os mapas dos índices TGI e ExG para o Ensaio-2, respectivamente.

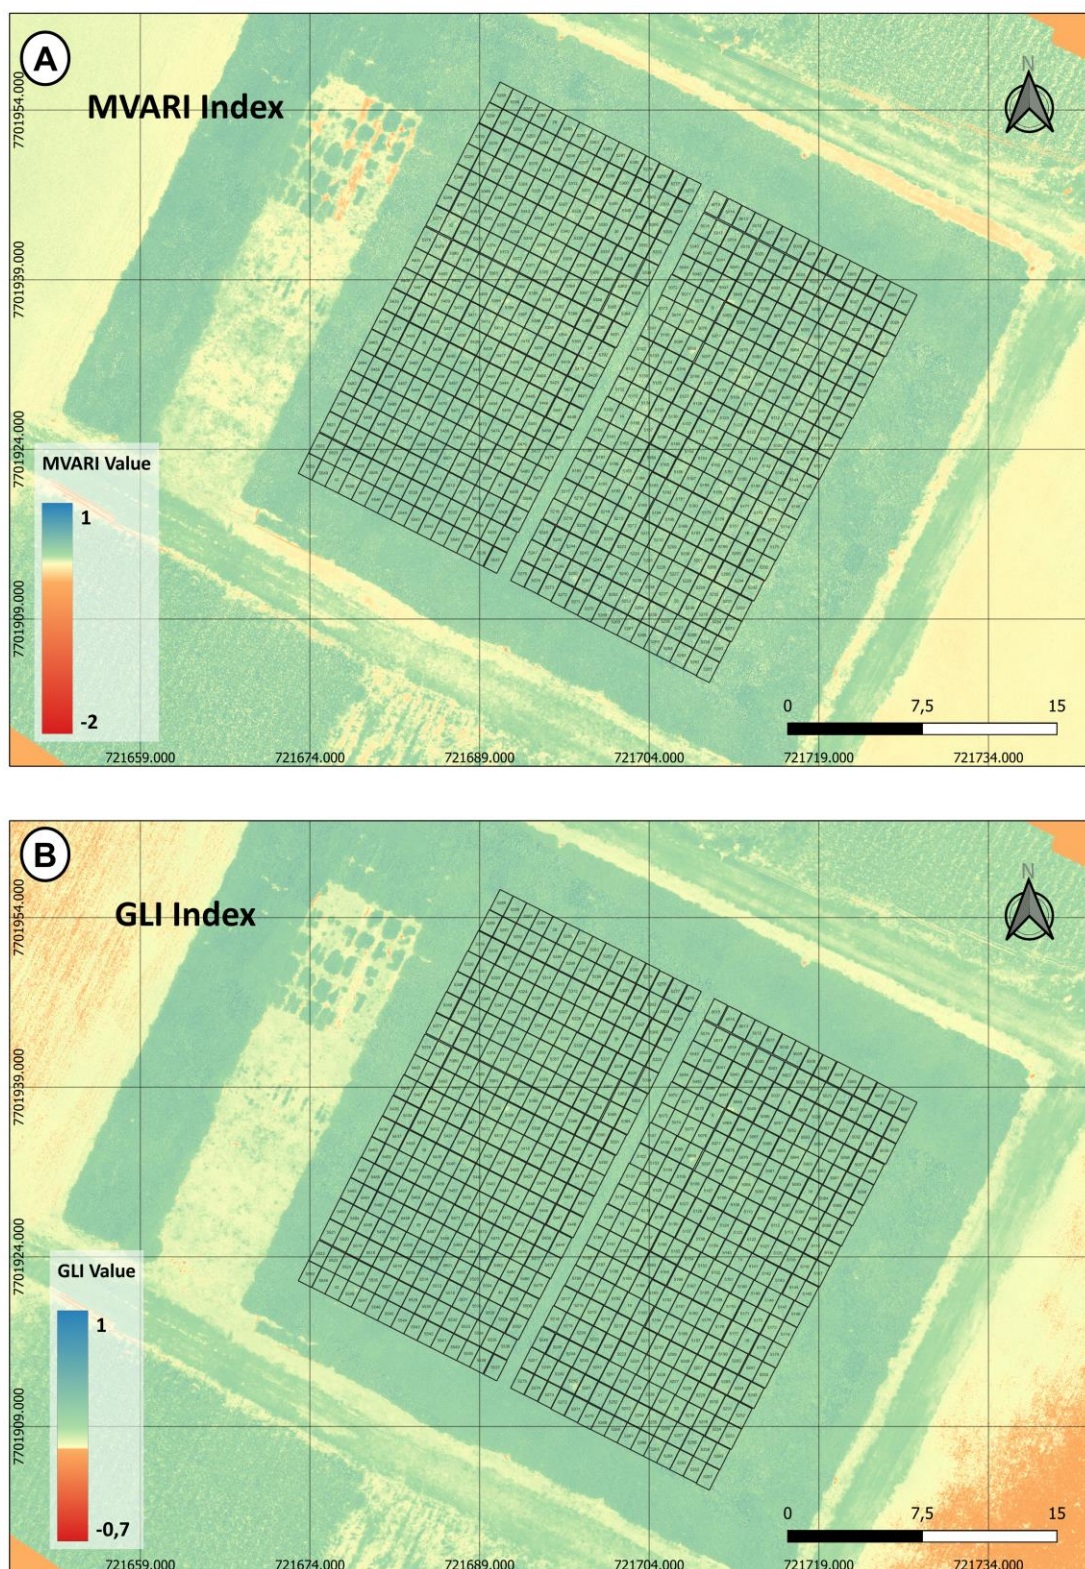


Figura 9. Mapas de índices de vegetação para o Ensaio-1 (vale da Agronomia). A – Mapa para índices MVARI (Modified VARI); B – Mapa para índice GLI (Green Leaf Index).





Figura 10. Mapas de índices de vegetação para o Ensaio-2 (Horta Nova). A – Mapa para TGI (Triangular Greenness Index); B – Mapa o índice ExG (Excess Green);

Na Tabela 8, são apresentados os valores do logaritmo da verossimilhança, AIC e BIC dos modelos correspondentes, tanto com covariáveis quanto sem, para os

Ensaio 1 e 2. Ao analisar os diversos índices de vegetação empregados, nota-se que alguns demonstram um desempenho ligeiramente superior em termos de ajuste do modelo. Entretanto, as disparidades entre os índices não são substanciais, uma vez que todos os modelos com covariáveis exibem valores de AIC e BIC, bem como do logaritmo da verossimilhança, relativamente próximos. Apesar disso, a inclusão das covariáveis resultou na diminuição nos valores de AIC e BIC e um aumento no valor do logaritmo de verossimilhança em comparação com o modelo sem covariável.

Para o Ensaio-1, os modelos que incorporaram os índices de vegetação MVARI e GLI demonstraram um ajuste superior ao modelo sem covariáveis, apresentando valores menores de AIC e BIC e um logaritmo da verossimilhança maior, além de um valor de herdabilidade superior em relação ao modelo sem covariáveis. No Ensaio-2, os melhores modelos foram aqueles que incorporaram os índices de vegetação ExG e TGI. O TGI apresentou uma herdabilidade superior, enquanto o ExG mostrou uma herdabilidade semelhante à do modelo sem covariáveis.

Tabela 8 - Desempenho dos modelos com e sem inclusão de índice de vegetação na produtividade dos genótipos de soja avaliados no Ensaio-1 (UEPE-Vale da Agronomia) e no Ensaio-2 (UEPE-Horta Nova).

Modelo	Ensaio-1				Ensaio-2			
	h ²	lnL	AIC	BIC	h ²	lnL	AIC	BIC
Sem Covariável	0,69	-3.280,3	6.566,5	6.579,4	0,28	-1.815,4	3.636,9	3.647,9
Com Covariáveis								
ExG	0,71	-3.278,2	6.562,5	6.575,3	0,28	-1.807,3	3.620,7	3.631,7
GLI	0,71	-3.273,8	6.553,6	6.566,4	0,27	-1.808,4	3.622,7	3.633,7
GRRI	0,69	-3.274,2	6.554,3	6.567,2	0,25	-1.808,3	3.622,6	3.633,6
MGRVI	0,69	-3.273,9	6.553,7	6.566,6	0,26	-1.808,0	3.621,9	3.632,9
MVARI	0,71	-3.273,5	6.553,1	6.566,0	0,27	-1.808,4	3.622,7	3.633,7
NGRDI	0,69	-3.273,2	6.552,4	6.565,3	0,26	-1.814,1	3.634,2	3.645,2
RGBVI	0,71	-3.274,2	6.554,4	6.567,3	0,28	-1.809,0	3.624,0	3.635,1
TGI	0,71	-3.277,6	6.561,2	6.574,1	0,29	-1.807,3	3.620,6	3.631,6
VARI	0,69	-3.273,3	6.552,5	6.565,4	0,26	-1.813,3	3.632,6	3.643,7

h²: herdabilidade; lnL: logaritmo da verossimilhança; AIC: Critério de Informação de Akaike; BIC: Critério de Informação Bayesiano; ExG - Excess Green; GLI - Green Leaf Index; GRRI - Green Red Ratio Index; MGRVI - Modified Green Red Vegetation Index; MVARI - Modified VARI; NGRDI - Normalized Difference Green Red Index; RGBVI - Red Green Blue Vegetation Index; TGI - Triangular Greenness Index; VARI - Visible Atmospheric Resistant Index.

Na Tabela 9, são apresentados os valores de similaridade entre os dois melhores modelos com covariáveis em comparação ao modelo sem covariável para

cada ensaio, considerando taxas de seleção de 20%, 50% e 70% dos melhores genótipos. Para o Ensaio-1, observa-se que a similaridade entre o modelo sem covariável e o modelo que incluiu o MVARI foi de 99% em todas as taxas de seleção. Em relação ao modelo que incorporou o índice GLI, a similaridade foi de 100% em todas as taxas de seleção. Para o Ensaio-2, a similaridade entre o modelo sem covariável e o modelo que utilizou o índice de vegetação ExG como covariável foi de 97%, 98% e 99%. Para o modelo que considerou o índice de vegetação TGI, a similaridade foi de 98%, 98% e 99%.

Tabela 9. Comparação da similaridade entre os modelos com covariáveis (índices de vegetação) e o modelo sem covariáveis em relação à seleção percentual das melhores progênies nos Ensaio 1 e 2.

	Ensaio-1		Ensaio-2	
	Modelo sem covariável vs		Modelo sem covariável vs	
Melhores genótipos	MVARI	GLI	ExG	TGI
20%	99%	100%	97%	98%
50%	99%	100%	98%	98%
70%	99%	100%	99%	99%

MVARI - Modified VARI; GLI - Green Leaf Index; ExG - Excess Green; TGI - Triangular Greenness Index.

Para cada ensaio, observou-se que os melhores modelos, ao incluir índices de vegetação como covariáveis, diferiram entre si. Essas variações podem ser atribuídas tanto à diversidade genética das progênies de soja quanto às condições ambientais específicas de cada ensaio. A interação entre os genótipos e o ambiente pode resultar em variações na refletância da luz, afetando os valores dos índices de vegetação (ZHANG *et al.*, 2023). Fatores ambientais, como intensidade de luz, temperatura, umidade e disponibilidade de água, desempenham um papel crucial no desenvolvimento das plantas e em suas características fisiológicas, impactando diretamente a saúde, o vigor das plantas e, conseqüentemente, a forma como cada índice de vegetação captura os dados de refletância (SKENDŽIĆ *et al.*, 2023).

Genótipos distintos podem apresentar diferenças notáveis em características morfológicas, como distribuição, arquitetura, tamanho, forma e densidade da folhagem. Essas diferenças afetam diretamente a refletância da luz capturada pelos sensores e, conseqüentemente, os valores obtidos pelos índices de vegetação

(KATSOULAS *et al.*, 2016). Além disso, a resistência dos genótipos a estresses bióticos e abióticos pode variar, o que influencia a saúde e o vigor das plantas, refletindo-se nos índices de vegetação (COELHO *et al.*, 2020). A quantidade e o tipo de pigmentos presentes nas folhas também variam entre os genótipos; esses pigmentos são essenciais para a absorção e reflexão da luz em comprimentos de onda específicos, formando a base para muitos índices de vegetação (FILIMON *et al.*, 2016).

A comparação entre os modelos com e sem covariáveis na seleção de progênies de soja revelou uma alta similaridade. Essa concordância pode ser atribuída às condições nutricionais das áreas experimentais, que atenderam plenamente às necessidades das plantas no estágio fenológico em que foram avaliadas. Com uma nutrição apropriada, as variações no estado nutricional e na saúde das plantas foram minimizadas, resultando em uma refletância espectral relativamente estável nas populações de plantas de cada ensaio. Conseqüentemente, os índices de vegetação derivados da refletância nas bandas visíveis capturaram poucas variações. Dessa forma, a correção aplicada pelos modelos com covariáveis teve um impacto reduzido, tornando os modelos com e sem covariáveis bastante semelhantes.

Deficiências nutricionais normalmente têm um impacto na região visível devido a mudanças na pigmentação, e o amarelecimento das folhas, característico dessas deficiências, leva a um aumento da refletância nas regiões verde-vermelha (LI *et al.*, 2020). Estudos de PEÑUELAS *et al.* (1994) demonstram que folhas de *Helianthus annuus* estressadas, especialmente aquelas com deficiência de nitrogênio, apresentavam refletâncias significativamente maiores nos comprimentos de onda visíveis e menores no infravermelho próximo, em comparação com folhas bem nutridas. De maneira semelhante, LASSALLE (2021) observou que a necrose associada a deficiências de nutrientes aumentava a refletância nas áreas necrosadas das folhas, enquanto nas regiões saudáveis, essa refletância diminuía. Essas observações ressaltam como deficiências nutricionais podem afetar a refletância espectral e, portanto, influenciar os índices de vegetação, o que explica por que, em condições de nutrição adequada, a correção pelos modelos com covariáveis teve um impacto reduzido.

Diante desses resultados, onde a coincidência entre os modelos com e sem covariável é alta para todas as intensidades de seleção, pode-se inferir que a inclusão

dessas covariáveis proporcionou uma vantagem discernível na predição do comportamento do modelo. Nesse cenário, torna-se questionável a utilização dessas covariáveis, especialmente se sua inclusão não resultar em ganhos substanciais em termos de precisão ou confiabilidade do modelo. Assim, pode ser mais eficiente e simplificado adotar o modelo base sem covariáveis, evitando a complexidade desnecessária associada à inclusão das covariáveis.

4. CONCLUSÕES

Os resultados demonstraram que a metodologia proposta melhorou o modelo tradicional ao incorporar covariáveis relacionadas aos nutrientes do solo. A inclusão de todos os macronutrientes e micronutrientes, apenas micronutrientes ou apenas macronutrientes teve um efeito significativo no ranqueamento das progênies de soja quanto à produção por parcela. No entanto, os índices de vegetação como covariáveis apresentaram efeitos menos pronunciados, com resultados de seleção similares ao modelo tradicional, sugerindo que sua contribuição na melhoria do modelo pode ser limitada.

5. REFERÊNCIAS

- ADHIKARI, B. N., JOSHI, B. P., SHRESTHA, J., & BHATTA, N. R. Genetic variability, heritability, genetic advance and correlation among yield and yield components of rice (*Oryza sativa* L.). **Journal of Agriculture and Natural Resources**, v. 1, n. 1, p. 149-160, 2018.
- AHMED, N., ABID, M., AHMAD, F., ULLAH, M. A., JAVAID, Q., & ALI, M. A. Impact of boron fertilization on dry matter production and mineral constitution of irrigated cotton. **Pak. J. Bot.**, v. 43, n. 6, p. 2903-2910, 2011.
- AJEESH KRISHNA, T. P., MAHARAJAN, T., IGNACIMUTHU, S., & ANTONY CEASAR, S. Genomic-assisted breeding in finger millet (*Eleusine Coracana* (L.) Gaertn.) for abiotic stress tolerance. **Genomic designing for abiotic stress resistant cereal crops**, p. 291-317, 2021.
- AKAIKE, H. Information theory as an extension of the maximum likelihood principle. In: Petrov, B.N., Csaksi, F. (Eds.), 2nd **International Symposium on Information Theory**. Akademiai Kiado, Budapest, Hungary, p. 267-281, 1973.
- ALBAHLI, S., & YAR, G. N. A. H. Defect Prediction Using Akaike and Bayesian Information Criterion. **Comput. Syst. Sci.**, v. 41, n. 3, p. 1117-1127, 2022.

ALMEIDA, L. A.; KIIHL, R. A. S.; MIRANDA, M. A. C.; CAMPELO, J. G. A. Melhoramento da soja para regiões de baixa latitudes. **Recursos genéticos e melhoramento de plantas para o nordeste brasileiro**, 1999.

ALVARADO, G., RODRIGUEZ, FM, PACHECO, A., BURGUEÑO, J., CROSSA, J., VARGAS, M., ... & LOPEZ-CRUZ, MA. META-R: A software to analyze data from multi-environment plant breeding trials. **The Crop Journal**, v. 8, n. 5, p. 745-756, 2020.

ARAÚJO, H. S., QUADROS, B. R. D., CARDOSO, A. I. I., & CORRÊA, C. V. Doses de potássio em cobertura na cultura da abóbora. **Pesquisa Agropecuária Tropical**, v. 42, p. 469-475, 2012.

BAHTIAR, A., SYAMSUDDIN, A., & AKIB, I. Description of mathematical communication skills, logical thinking and its influence on the ability of mathematical literacy for students of grade v elementary school. **International Journal of Scientific and Technology Research**, v. 9, n. 4, p. 1075-1078, 2020.

BARROSO, A. M., MATOS, R. F. D., PINHEIRO, M. D. S., BERTINI, C. H. C. D., & DOVALE, J. C. Genetic variability and selection of extra-early cowpea progenies. **Revista Caatinga**, v. 30, p. 698-707, 2017.

BENDIG, J., YU, K., AASEN, H., BOLTEN, A., BENNERTZ, S., BROSCHEIT, J., ... & BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.

BURSTROM, H. G. Calcium and plant growth. **Biological Reviews**, v. 43, n. 3, p. 287-316, 1968.

CASCÃO, L. M., SANTANA, P. N. D., COSTA, N. V., CRISPIM FILHO, A. J., RESENDE, M. P. M., & MELO, P. G. S. Inbreeding depression and genetic variability of populations for green maize production. **Revista Ceres**, v. 69, p. 709-719, 2023.

COELHO, W. S. S., OLIVEIRA, G. M., DOS SANTOS, C. B., DA SILVA, W. O., BARROS, J. R. A., SIMÕES, W. L., ... & ANGELOTTI, F. The combination of abiotic stresses influences the physiological responses and production of *Macroptilium* genotypes. **Plant Physiology Reports**, v. 29, n. 1, p. 105-115, 2024.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da safra brasileira: grãos, safra 2022/23, **12º levantamento**, v. 10, n. 12, 2023. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 01 fevereiro 2024.

CUI, X., HE, H., HU, S., ZHANG, B., & CAI, H. Synergistic interaction between copper and nitrogen-uptake, translocation, and distribution in rice plant. **Plants**, v. 11, n. 19, p. 2612, 2022.

DALCHIAVON, F. C., CARVALHO, M. D. P., ANDREOTTI, M., & MONTANARI, R. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho

Distroférico sob Sistema Plantio Direto. **Revista Ciência Agronômica**, v. 43, p. 453-461, 2012.

ELTAHER, S., BAENZIGER, P. S., BELAMKAR, V., EMARA, H. A., NOWER, A. A., SALEM, K. F., ... & SALLAM, A. GWAS revealed effect of genotype × environment interactions for grain yield of Nebraska winter wheat. **BMC genomics**, v. 22, n. 1, p. 1-14, 2021.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Manual de métodos de análise de solo**. 3. ed. Distrito Federal: Embrapa Solos, p. 574, 2017.

ESHETIE, A. **Construction and analysis of augmented and modified augmented designs**. Master of Science Thesis. Addis Ababa University, School of Graduate Students, College of Natural Sciences, Department of Statistics, Addis Ababa, Ethiopia, 2011.

FEDERER, W. T. Augmented designs, "Hawaiian Planters". **Record**, v. 55, p. 191-208, 1956.

FEHR, W. R.; CAVINESS, C. E.; VORST, J. J. Response of Indeterminate and Determinate Soybean Cultivars to Defoliation and Half-plant Cut-off 1. **Crop Science**, v. 17, n. 6, p. 913-917, 1977.

FERREIRA, M. D. P. **Geoestatística e aerofotogrametria aplicadas à seleção de famílias de cana-de-açúcar**. 2020 Tese (Doutorado em Estatística Aplicada e Biometria) - Universidade Federal de Viçosa, Viçosa, MG, 2020.

FILIMON, R. V.; ROTARU, L.; FILIMON, R. M. Quantitative investigation of leaf photosynthetic pigments during annual biological cycle of *Vitis vinifera* L. table grape cultivars. **South African Journal of Enology and Viticulture**, v. 37, n. 1, p. 1-14, 2016.

GAMON, J. A.; SURFUS, J. S. Assessing leaf pigment content and activity with a reflectometer. **The New Phytologist**, v. 143, n. 1, p. 105-117, 1999.

GARCÍA-SÁNCHEZ, F., SIMÓN-GRAO, S., MARTÍNEZ-NICOLÁS, J. J., ALFOSEA-SIMÓN, M., LIU, C., CHATZISSAVVIDIS, C., ... & CÁMARA-ZAPATA, J. M. Multiple stresses occurring with boron toxicity and deficiency in plants. **Journal of Hazardous Materials**, v. 397, p. 122713, 2020.

GITELSON, A. A., KAUFMAN, Y. J., STARK, R., & RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.

GOMES, L. A. A.; SILVA, E. C. DA; FAQUIN, V. Recomendações de adubação para cultivos em ambiente protegido. In: RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ, V.H. (Ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5a aproximação**. Viçosa - MG: UFV, p.99-110. 1999.

GUIMARÃES, W.D. Geoestatística para o mapeamento da variabilidade espacial de atributos físicos do solo. 2013. 60p. Tese (Doutorado em Engenharia Civil) – Universidade Federal de Viçosa, Viçosa, MG.

HALLAUER, A. R. Evolution of plant breeding. **Crop breeding and applied biotechnology**, v. 11, p. 197-206, 2011.

HUNT JR, E. R., DAUGHTRY, C. S. T., EITEL, J. U., & LONG, D. S. Remote sensing leaf chlorophyll content using a visible band index. **Agronomy journal**, v. 103, n. 4, p. 1090-1099, 2011.

HUNT, E. R., CAVIGELLI, M., DAUGHTRY, C. S., MCMURTREY, J. E., & WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, p. 359-378, 2005.

KAISER, N., DOUCHES, D., DHINGRA, A., GLENN, K. C., HERZIG, P. R., STOWE, E. C., & SWARUP, S. The role of conventional plant breeding in ensuring safe levels of naturally occurring toxins in food crops. **Trends in Food Science & Technology**, v. 100, p. 51-66, 2020.

KAMILARIS, A., KARTAKOULLIS, A., & PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, p. 23-37, 2017.

KATSOULAS, N., ELVANIDI, A., FERENTINOS, K. P., KACIRA, M., BARTZANAS, T., & KITTAS, C. Crop reflectance monitoring as a tool for water stress detection in greenhouses: A review. **Biosystems Engineering**, v. 151, p. 374-398, 2016.

KHOKHAR, E. S., LOZADA, D. N., NANKAR, A. N., HERNANDEZ, S., COON, D., KAUR, N., & NOURBAKHS, S. S. High-throughput Characterization of Fruit Phenotypic Diversity among New Mexican Chile Pepper (*Capsicum spp.*) Using the Tomato Analyzer Software. **HortScience**, v. 57, n. 12, p. 1507-1517, 2022.

KUMARI, V. V., BANERJEE, P., VERMA, V. C., SUKUMARAN, S., CHANDRAN, M. A. S., GOPINATH, K. A., ... & AWASTHI, N. K. Plant nutrition: An effective way to alleviate abiotic stress in agricultural crops. **International Journal of Molecular Sciences**, v. 23, n. 15, p. 8519, 2022.

LASSALLE, G. Monitoring natural and anthropogenic plant stressors by hyperspectral remote sensing: Recommendations and guidelines based on a meta-review. **Science of the Total Environment**, v. 788, p. 147758, 2021.

LESTERI, E., YUNITA, R., & ANSHORI, M. Selection and validation of m4 soybean mutant lines through multi-characters approach. **Sabrao journal of breeding and genetics**, v. 54, n. 5, p. 1077-1089, 2022.

LI, D., LI, C., YAO, Y., LI, M., & LIU, L. Modern imaging techniques in plant nutrition analysis: A review. **Computers and Electronics in Agriculture**, v. 174, p. 105459, 2020.

- LIN, C. S., & POUSHINSKY, G. A modified augmented design for an early stage of plant selection involving a large number of test lines without replication. **Biometrics**, p. 553-561, 1983.
- LIU, J., LIU, J., LI, Z., HOU, X., & DAI, G. Estimating CPT Parameters at Unsampled Locations Based on Kriging Interpolation Method. **Applied Sciences**, v. 11, n. 23, p. 11264, 2021.
- LONDERO, R., DE OLIVEIRA, R. B., DO NASCIMENTO, J. M., ARCOVERDE, S. N. S., & SECRETTI, M. L. Dependência espacial da fertilidade do solo sob plantio direto e suas relações com a produtividade da soja. **Caderno de Ciências Agrárias**, v. 12, p. 1-8, 2020.
- LOUHAICHI, M., BORMAN, M. M., & JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65-70, 2001.
- LUSTRU, E. A., SIQUEIRA, W. J., AZEVEDO FILHO, J. A. D., VIANNA, S. A., & COLOMBO, C. A. Estimates of genetic parameters for juvenile traits in macaw palm. **Bragantia**, v. 80, p. e2821, 2021.
- MADIAS, A., DI MAURO, G., VITANTONIO-MAZZINI, L. N., GAMBIN, B. L., & BORRÁS, L. Environment quality, sowing date, and genotype determine soybean yields in the Argentinean Gran Chaco. **European Journal of Agronomy**, v. 123, p. 126217, 2021.
- MALVI, U. R. Interaction of micronutrients with major nutrients with special reference to potassium. **Karnataka Journal of Agricultural Sciences**, v. 24, n. 1, 2011.
- MENEGON, A. H. M., de LIMA, S. F., ALVES, V. C. D., CONTARDI, L. M., CORDEIRO, M. A. S., VENDRUSCOLO, E. P., ... & NOGUEIRA, A. R. F. Soybean Population Management Seeking Greater Grain Productivity. **Revista De Gestão Social e Ambiental**, v. 18, n. 2, 2024.
- MILIOLI, A. S., MEIRA, D., PANHO, M. C., MADELLA, L. A., WOYANN, L. G., TODESCHINI, M. H., ... & BENIN, G. Genetic improvement of soybeans in Brazil: South and Midwest. **Crop Science**, v. 62, n. 6, p. 2276-2293, 2022.
- MOURSY, A. R.; HASSAN, M. N.; ELHEFNY, T. M. Sampling and analysis of soil and water: A review. **Int. J. Geogr. Geol. Environ**, v. 4, p. 34-41, 2022.
- MOUSAVI, S.R., GALAVI, M., & REZAEI, M. The interaction of zinc with other elements in plants: a review. **International Journal of Agriculture and Crop Sciences**, v. 4, n. 24, p. 1881-1884, 2012.
- NEVARA, G. A., GIWA IBRAHIM, S. A., SYED MUHAMMAD, S. K., ZAWAWI, N., MUSTAPHA, N. A., & KARIM, R. Oilseed meals into foods: An approach for the valorization of oilseed by-products. **Critical Reviews in Food Science and Nutrition**, v. 63, n. 23, p. 6330-6343, 2023.

PANDEY, M.; SHRESTHA, J.; SUBEDI, S.; SHAH, K. K. Role of nutrients in wheat: A review. **Tropical Agrobiodiversity**, v. 1, n. 1, p. 18-23, 2020.

PEÑUELAS, J., GAMON, J. A., FREDEEN, A. L., MERINO, J., & FIELD, C. B. Reflectance indices associated with physiological changes in nitrogen-and water-limited sunflower leaves. *Remote sensing of Environment*, v. 48, n. 2, p. 135-146, 1994.

PEREIRA, G. W., VALENTE, D. S. M., QUEIROZ, D. M. D., COELHO, A. L. D. F., COSTA, M. M., & GRIFT, T. Smart-map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. **Agronomy**, v. 12, n. 6, p. 1350, 2022.

PHUAH, E.T., YAP, J. W.L., LAU, C.W., LEE, Y.-Y., & TANG, T.K. Vegetable Oils and Animal Fats: Sources, Properties and Recovery. In **Recent Advances in Edible Fats and Oils Technology: Processing, Health Implications, Economic and Environmental Impact**, p. 1-26, 2022.

PIVELLO, V. R., VIEIRA, I., CHRISTIANINI, A. V., RIBEIRO, D. B., DA SILVA MENEZES, L., BERLINCK, C. N., ... & OVERBECK, G. E. Understanding Brazil's catastrophic fires: Causes, consequences and policy needed to prevent future tragedies. **Perspectives in Ecology and Conservation**, v. 19, n. 3, p. 233-255, 2021.

SABA, I., SOFI, P. A., ZEERAK, N. A., MIR, R. R., & GULL, M. Using augmented design for evaluation of common bean (*Phaseolus vulgaris* L.) germplasm. **International Journal of Current Microbiology and Applied Science**, v. 6, n. 7, p. 246-254, 2017.

SALEEM, S., MUSHTAQ, N. U., RASOOL, A., SHAH, W. H., TAHIR, I., & REHMAN, R. U. Plant nutrition and soil fertility: physiological and molecular avenues for crop improvement. In *Sustainable Plant Nutrition*. p. 23-49, 2023.

SALUCI, J. C. G., VIVAS, M., DE ALMEIDA, R. N., DUTRA, I. P., CARLOS, M. C., DO AMARAL JÚNIOR, A. T., & SCAPIM, C. A. Potential of popcorn s4 lines for resistance to southern corn leaf blight. **Functional Plant Breeding Journal**, v. 2, n. 2, 2020.

SANTOS, D. P. D. **Delineamentos ótimos para experimentos multi-ambientais de melhoramento genético de plantas**. Tese (Doutorado em Estatística e Experimentação Agronômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, SP. 75 f, 2023.

SEDIYAMA, T.; TEIXEIRA, R. C.; REIS, M. S. Melhoramento da soja. In: BOREM, A. **Melhoramento de espécies cultivadas**. Viçosa: UFV, 2005. p. 553 – 602.

SCHWARZ, G. Estimating the dimension of a model. **The Annals of Statistics**, p. 461-464, 1978.

SHARIFI, A. Remotely sensed vegetation indices for crop nutrition mapping. **Journal of the Science of Food and Agriculture**, v. 100, n. 14, p. 5191-5196, 2020.

SKENDŽIĆ, S., ZOVKO, M., LEŠIĆ, V., PAJAČ ŽIVKOVIĆ, I., & LEMIĆ, D. Detection and evaluation of environmental stress in winter wheat using remote and proximal sensing methods and vegetation indices—a review. **Diversity**, v. 15, n. 4, p. 481, 2023.

SULAIMAN, P. S., KHALID, F., Azman, A., & Hanafi, M. Reviewing Vegetation Indices for Mobile Application: Potentials and Challenges. **Journal of Advanced Research in Applied Sciences and Engineering Technology**, v. 35, n. 2, p. 33-46, 2024.

TESFAYE, D., ABAKEMAL, D., & HABTE, E. Genetic variability, heritability and genetic advance estimation of highland adapted maize (*Zea mays* L.) genotypes in Ethiopia. **Journal of Current Opinion in Crop Science**, v. 2, n. 2, p. 184-191, 2021.

VIEIRA, P. M. H., BÁEZ, O. E. O., ALMEIDA, B. K. D. S., MENDES, M. H. S., & SOUZA, J. C. D. Number of progenies and repetitions for reciprocal full-sib recurrent selection programs in maize. **Ciência e Agrotecnologia**, v. 45, p. e030420, 2021.

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

YANG, G., LIU, J., ZHAO, C., LI, Z., HUANG, Y., YU, H., ... & YANG, H. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. **Frontiers in plant science**, v. 8, p. 1111, 2017.

ZHANG, J., HAN, M., WANG, L., CHEN, M., CHEN, C., SHEN, S., ... & YAN, X. Study of genetic variation in bermuda grass along longitudinal and latitudinal gradients using spectral reflectance. **Remote Sensing**, v. 15, n. 4, p. 896, 2023.


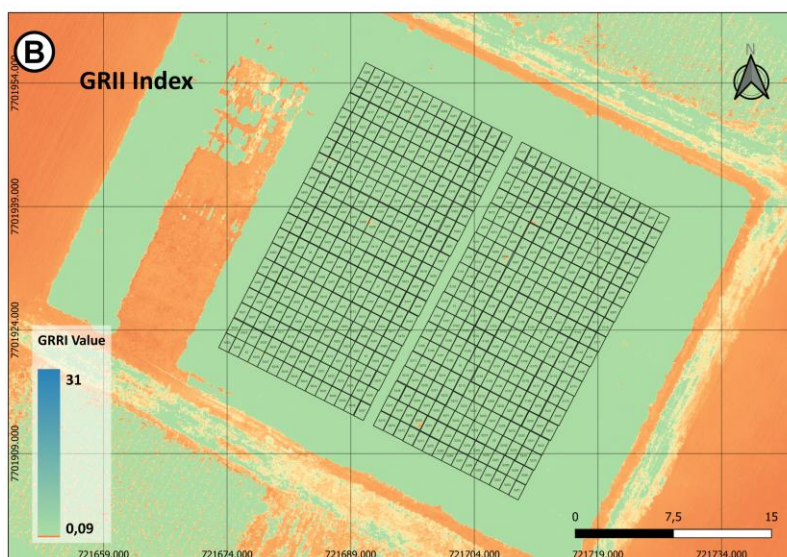

ZHENG, C., ABD-ELRAHMAN, A., WHITAKER, V., DALID, C. Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods. **Remote Sens**, v. 14, n. 18, p. 4511, 2022.

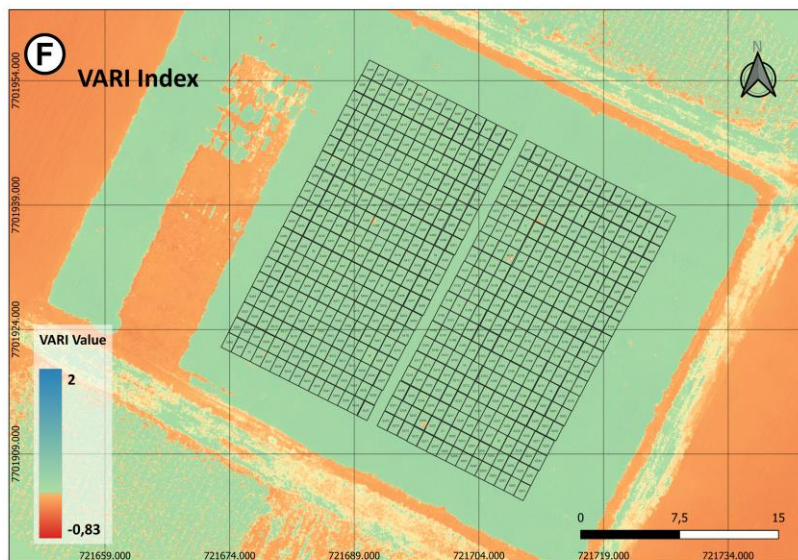


ZHU, H., & ZHOU, X. Statistical methods for SNP heritability estimation and partition: A review. **Computational and Structural Biotechnology Journal**, 18, 1557-1568.


ZIMBACK, C.R.L. **Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade do solo**. Tese (Livre-Docência) -Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, SP. 114 f, 2001.

Anexo

ANEXO A - Mapas de índices de vegetação para o Ensaio-1. A – índice NGRDI; B - índice GRII; C- índice MGRVI; D - índice ExG; E - índice TGI; F - índice VARI; G – RGBVI.







ANEXO B - Mapas de índices de vegetação para o Ensaio-2. A – índice GRII; B - índice NGRDI; C- índice MVARI; D - índice VARI; E - índice RGBVI; F - índice GLI; G – MGRVI.

