

**UNIVERSIDADE ESTADUAL PAULISTA (UNESP)
FACULDADE DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
CAMPUS DE DRACENA**

João Vitor Braga Visioli

**USO DE FENOTIPAGEM DE ALTO RENDIMENTO E
TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO
DA PRODUTIVIDADE DE *Glycine max* SUBMETIDAS A
ADUBAÇÃO FOLIAR**

Dracena

2024

**UNIVERSIDADE ESTADUAL PAULISTA (UNESP)
FACULDADE DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
CAMPUS DE DRACENA**

João Vitor Braga Visioli

**USO DE FENOTIPAGEM DE ALTO RENDIMENTO E
TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO
DE *Glycine max* SUBMETIDAS A ADUBAÇÃO FOLIAR**

Trabalho de Conclusão de Curso apresentado à Faculdade de Ciências Agrárias e Tecnológicas – Unesp, Campus de Dracena como parte das exigências para graduação em Engenharia Agrônoma.

Orientador: Prof. Dr. Rafael Simões Tomaz

Co-orientador: Prof. Dr^a. Ronaldo Cintra Lima

Dracena

2024

Certificado de aprovação



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Dracena



UNIVERSIDADE ESTADUAL PAULISTA
"JULIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
UNESP – CÂMPUS DE DRACENA

CERTIFICADO DE APROVAÇÃO

Título: "USO DE FENOTIPAGEM DE ALTO RENDIMENTO E TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO DA PRODUTIVIDADE DE *Glycine max* SUBMETIDAS A ADUBAÇÃO FOLIAR"

Modalidade: Trabalho de **Atividades de pesquisa**

Autor: **João Vitor Braga Visioli**

Orientador (a): PROF. DR. Rafael Simões Tomaz

Co-orientador(es): PROF. DR. Ronaldo Cintra Lima

Número de Créditos: 12

Data da aprovação e correção de acordo com as sugestões da Banca: 28/05/2024

Dr. Rafael Simões Tomaz

Dr. Cosme Damião Cruz

Dr. Daniel Pedrosa Alves

DEDICATÓRIA

A minha esposa Angélica Maria Barboza Braga e minha mãe Solange Braga Bacaro, que me possibilitaram mais essa conquista, exemplos de vida fundamentais para a minha vida pessoal e profissional.

AGRADECIMENTOS

A Deus principalmente, que sempre esteve comigo e me deu capacidade e disciplina necessária para realização desse trabalho.

A toda minha família e amigos por todo apoio concedido.

Ao meu orientador Prof. Dr. Rafael Simões Tomaz, pela atenção, disponibilidade e ensinamentos.

Aos técnicos Alan, Rodrigo e Oscar, que me auxiliaram na condução desse trabalho.

Ao Prof. Dr. Cosme Damiano Cruz e Dr. Daniel Pedrosa Alves, pelo tempo dedicado, pelas avaliações e conhecimentos que foram compartilhados que acrescentaram muito ao trabalho.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP). Processo 2022/02526-9.

“A verdadeira viagem de descobrimento não consiste em procurar novas paisagens, mas em ter novos olhos”. (Marcel Proust)

RESUMO

A soja [*Glycine max* (L.) Merrill] é a principal cultura leguminosa do mundo, sendo, respectivamente o Brasil, USA e Argentina os seus principais produtores. A utilização

do grão da soja na dieta humana e animal em vários países decorre de seu valor nutricional, principalmente pelo alto conteúdo proteico, com cerca de 40%. No Brasil, muito do sucesso da cultura decorre do uso de variedades melhoradas, mais adaptadas às condições edafoclimáticas da região e em melhorias no sistema de produção. A utilização de tecnologias como o uso de fertilizantes foliares aliado ainda a tecnologia de análise mais atuais como a fenotipagem de alto rendimento por meio de drones, e o uso de inteligência artificial na análise de dados tem permitido nos últimos anos um aumento na produtividade da cultura. Com o intuito de avaliar os fatores citados no desenvolvimento de produtividade da cultura da soja, foram realizados, dois experimentos em delineamento de blocos casualizados, com três repetições, em esquema fatorial, considerando, variedades e níveis de tratamento com fertilizante foliar. Os experimentos foram implantados na área experimental irrigada do FCAT UNESP – Campus de Dracena, nas safras agrícolas de 2021/2022 e 2022/2023. Foram avaliadas características agronômicas de desenvolvimento da cultura, e atributos de produtividade, sendo realizada, adicionalmente, a fenotipagem de alto rendimento com o drone Mavic 2 Pro. Foram realizados voos periódicos na cultura com o intuito de coletar imagens e realizar a associação destas com as características agronômicas mensuradas, fazendo uso de redes neurais artificiais do tipo perceptron multicamada. Os resultados permitiram identificar fonte de variação relativo tanto às variedades, quanto aos tratamentos foliares. Ainda, as redes construídas permitiram com sucesso a modelagem da produtividade da cultura por meio das imagens coletadas com o drone.

Palavras-chave: *Glycine max*, Inteligência Artificial, Biometria.

ABSTRACT

Soybean [*Glycine max* (L.) Merrill] is the world's principal legume crop, with Brazil, the USA, and Argentina being its main producers. The use of soybean grain in human and animal diets in various countries is due to its nutritional value, particularly its high protein content of about 40%. In Brazil, much of the crop's success is attributed to the use of improved varieties that are better adapted to the region's soil and climatic conditions, as well as improvements in the production system. The utilization of technologies such as foliar fertilizers, alongside the latest technology in analysis like high-throughput phenotyping through UAV - Unmanned Aerial Vehicle –, and the use of artificial intelligence in data analysis, has enabled an increase in crop productivity in recent years. In order to evaluate the mentioned factors in the development of soybean crop productivity, two experiments were conducted using a randomized block design with three replications, in a factorial scheme considering varieties and levels of foliar fertilizer treatment. The experiments were carried out in the irrigated experimental area of FCAT UNESP – Dracena Campus, during the 2021/2022 and 2022/2023 agricultural seasons. Agronomic characteristics of crop development and productivity attributes were evaluated, with additional high-throughput phenotyping performed using the Mavic 2 Pro drone. Periodic flights over the crop were conducted to collect images and associate them with measured agronomic characteristics, using multilayer perceptron artificial neural networks. The results identified sources of variation related to both the varieties and foliar treatments. Furthermore, the constructed networks successfully modeled crop productivity through the images collected with the UAV.

Keywords: *Glycine max*, Artificial Intelligence, Biometrics.

LISTA DE FIGURAS

Figura 1 - Orthomosaico construído a partir de 232 imagens de vôo realizado em 30/02/2022, representando parcelas experimentais do experimento da safra 2021/2022.	35
Figura 2 - ANN do tipo PMC para predição da produtividade das variedades de soja utilizadas no experimento da safra 2021-2022.	38
Figura 3 - Métricas RMSE (A) e R2 (B) das ANN construídas para predição da produtividade.	39
Figura 4 - Orthomosaico construído a partir de 238 imagens de voo realizado em 07/02/2023, representando parcelas experimentais do experimento da safra 2022/2023.	40
Figura 5 - Estimativas do índice de vegetação BGI para variedades de soja e tratamento foliar.	42
Figura 6 - Estimativas do índice de vegetação SI para variedades de soja e tratamento foliar.	42

LISTA DE TABELAS

Tabela 1 - Índices de vegetação.....	20
Tabela 2 - Análise de solo utilizada para o experimento 2021-2022.....	25
Tabela 3 - Análise de solo utilizada para o experimento 2022-2023.....	25
Tabela 4 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2021-2022.	29
Tabela 5 - Teste de comparação de média das características avaliadas para o fator tratamento foliar da safra 2021-2022.....	29
Tabela 6 - Teste de comparação de média das características avaliadas para o fator Variedade da safra 2021-2022	29
Tabela 7 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2022-2023.	33
Tabela 8 - Teste de comparação de média das características avaliadas para o fator tratamento foliar da safra 2022-2023.....	33
Tabela 9 - Teste de comparação de média das características avaliadas para o fator Variedade da safra 2022-2023.....	34
Tabela 10 - Resumo da ANOVA para as características de índices de vegetação considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2021-2022.....	37
Tabela 11 - Métricas das etapas de treinamento da melhor ANN construída para predição da produtividade da safra 2021-2022.	40
Tabela 12 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2022-2023.	43
Tabela 13 - Métricas das etapas de treinamento da melhor ANN construída para predição da produtividade da safra 2022-2023.	44

LISTAS DE ABREVIATURAS E SIGLAS

Co	Cobalto
Mo	Molibdênio
Fe	Ferro
MoO ₄ ²⁻	Molibdato
NO ³⁻	Nitrato
N ₂	Gás Nitrogênio
$F = G + A$	Fenótipo igual genótipo mais ambiente
VANT	Veículo aéreo não tripulado
ANN	Redes Neurais Artificiais
ETo	Evapotranspiração de referência
Kc	Coeficiente da cultura
BI	Brightness Index
GLI	Green Leaf Index
HI	Primary Colors Hue Index
NGRDI	Normalized Green Red Difference Index
SI	Spectral Slope Saturation Index
VARI	Visible Atmospherically Resistant Index
BGI	Blue Green Pigment Index
RMSE	Root Mean Squared Error
kg ha ⁻¹	Quilos por hectare
cm	Centímetros

SUMÁRIO

1 INTRODUÇÃO	14
2 REVISÃO DE LITERATURA.....	16
2.1. A cultura da soja.....	16
2.2. Importância do cobalto e do molibdênio na soja.....	16
2.3 Importância do Ferro na soja.....	17
2.4. Fenotipagem de alto rendimento com Drone	19
2.5. Redes Neurais Artificiais (ANN).....	21
3 MATERIAL E MÉTODOS	24
3.1. Área experimental, material genético e características avaliadas	24
3.2. Fenotipagem de alto Rendimento e redes neurais artificiais	26
4. RESULTADOS E DISCUSSÃO	27
4.1. Experimentação – Ano Agrícola de 2021/2022.....	28
4.2. Experimentação – Ano Agrícola de 2022-2023	30
4.3. Fenotipagem de alto Rendimento - Ano Agrícola de 2021-2022	35
4.4. Fenotipagem de alto Rendimento – Ano Agrícola de 2022-2023	40
5. CONCLUSÕES.....	45
REFERÊNCIAS.....	46

1 INTRODUÇÃO

A cultura da soja [*Glycine max* (L.) Merr.] possui ampla adaptação nas diferentes latitudes brasileiras, além de alto teor proteico e lipídico. A safra atual apresentou aumento na área plantada de 6,2% em relação à anterior (CONAB, 2023), com aumento na produtividade em cerca de 15,9%. O aumento na produção está aliado, além do clima favorável, a variedades adaptadas às diversas regiões, à disponibilidade de tecnologias no setor produtivo e a utilização de insumos agrícolas, que influenciam no desenvolvimento da planta por meio do estímulo dos mecanismos de fixação biológica do nitrogênio, muito em decorrência do estímulo à produção de enzimas específicas no desenvolvimento dos pelos radiculares, nódulos ou na formação de hormônios vegetais (ZUFFO et al., 2015). Neste estudo enfatizaremos os efeitos de alguns nutrientes sobre características importantes da soja. Também abordaremos a predição da produtividade por medições diretas ou preditas por modelagem fundamentada em redes neurais artificiais. De acordo com Gris et al. (2005), tem sido relatado que o cobalto (Co) e o molibdênio (Mo) são os responsáveis por respostas positivas sobre a produção de grãos e de proteína, atuando ainda como coadjuvantes no desenvolvimento do sistema radicular das plantas. Conseqüentemente, fertilizantes foliares com base nesses dois nutrientes são potencialmente capazes de melhorar as condições de cultivo e estimular a maior produtividade na cultura.

O ferro (Fe) é o micronutriente em maior quantidade na crosta terrestre, podendo chegar até 5% em massa. Em solos tropicais brasileiros, com alto grau de intemperização, os teores de Fe podem ser ainda mais elevados, porém alimentos produzidos nestas condições podem possuir baixos teores de Fe. A justificativa está no efeito de diluição nutricional que ocorre nas plantas, face aos crescentes aumentos de produtividade das culturas na redução da absorção pelas plantas, provocada pela baixa disponibilidade do Fe em condições de alcalinidade do solo, característica geralmente encontrada em solos do semiárido brasileiro. Tecnologias como a biofortificação agrônômica podem elevar os teores de Fe nos alimentos (OLIVEIRA, 2019; CECCHERINI, 2022).

No contexto da avaliação da produtividade, aliado às tecnologias da lavoura, outras tecnologias visando avaliação e análise de dados, tem proporcionado

grandes avanços na determinação das melhores condições de cultivo ou na avaliação do desempenho da lavoura e do desempenho genético de cultivares. Dentre estas, as Redes Neurais Artificiais, como método de análise (MARTINS et al., 2016), e a fenotipagem de alto rendimento por meio de drones, como método preciso, de baixo custo e não destrutivo, tem se mostrado como tecnologias que podem auxiliar bastante a avaliação da lavoura (FRITSCHÉ-NETO; BORÉM, 2016).

Considerando o exposto, este trabalho teve três enfoques: agrônômico, tecnológico e biométrico. O enfoque agrônômico visou avaliar cultivares de soja, tratados e não tratados com fertilizante foliar visando recomendação para a região da Nova Alta Paulista. Já o enfoque tecnológico, visou avaliar a fenotipagem de alto rendimento com drone visando a predição da produtividade da cultura. Por fim o enfoque biométrico visou realizar a modelagem da produtividade por meio de métodos estatísticos tradicionais de análise univariada e por meio de Redes Neurais Artificiais (ANN).

2 REVISÃO DE LITERATURA

2.1. A cultura da soja

A soja [*Glycine max* (L.) Merrill] é a principal cultura leguminosa do mundo (BORNHOFEN et al., 2015), sendo, respectivamente o Brasil, USA e Argentina os seus principais produtores. A utilização do grão da soja na dieta humana e animal em vários países decorre de seu valor nutricional, principalmente pelo alto conteúdo proteico, com cerca de 40% (VIEIRA et al., 1999), além de ser fonte de vitaminas, fosfolípido, mineral e de compostos bioativos (ACHOURI, et al., 2005; KIM, et al., 2012). Ainda, o grão da soja, tem outros destinos no mercado mundial, como a produção de óleo vegetal, biocombustíveis, farinha, formulação de rações, entre outros (PIMENTEL e PATZEK, 2005; VIANNA et al., 2013). Esta cultura foi domesticada a partir da soja silvestre (*Glycine soja* Sieb. & Zucc.), na China há 5.000 anos e, posteriormente, introduzida na Coreia e Japão há cerca de 2.000 anos. Por volta de 1765, chegou a América do Norte e, logo após, durante a primeira metade do século passado, chegou à América Central e do Sul (ZHOU et al., 2015). Por fim, no ano de 1919, começou a apresentar participação efetiva na produção mundial de grãos (SCHAUB et al., 1988). Atualmente, no Brasil, a soja movimenta grande parte do agronegócio, sua área de cultivo corresponde a mais de 50% de toda área cultivada com grãos no país, sendo o maior produtor. Na safra de (2022/2023) a produção nacional foi de 154,6 milhões de toneladas em uma área de 44 milhões de hectares com produtividade média de 3508 kg ha⁻¹ (CONAB, 2023).

2.2. Importância do cobalto e do molibdênio na soja

De acordo com Sfredo & Oliveira (2010), pesquisas feitas em diversas regiões do Brasil demonstraram efeitos diversos associados de toxicidade ou deficiência, a nutrientes como Mo e Co, que são elementos importantes em solos de cerrado, capazes de afetar as espécies cultivadas nesta região. Na soja, o Mo é um micronutriente que é exigido em pouca quantidade, cerca de 9,0 g ha⁻¹ (SFREDO & OLIVEIRA, 2010), mas é de grande importância para o crescimento e desenvolvimento das plantas. A sua principal função é atuar no metabolismo do nitrogênio, pois ele participa como um cofator de enzimas, sendo assim um nutriente

de grande importância no desenvolvimento e rendimento da cultura da soja (MORAES, 2006). A falta de Mo e/ou de Co, se manifesta como uma clorose, relacionada de forma indireta com a deficiência de N (SFREDO & OLIVEIRA, 2010). Segundo os autores, quando o valor do pH do solo é igual ou maior que 5,0, o Mo, que é móvel nas plantas, é absorvido predominantemente como MoO_4^{2-} e mobilizado para ser utilizado como cofator nas enzimas nitrogenase, nitrato redutase e oxidase do sulfeto, as quais estão intimamente relacionadas com o transporte de elétrons das reações bioquímicas. De acordo com Gris et al. (2005), em condições adequadas de fixação biológica de N, pode ser marcante a influência do Mo, que atua na redutase do nitrato, que é o responsável pela redução do NO_3^- para ser assimilado pela planta. Dessa forma, sua deficiência está altamente relacionada à diminuição da produtividade da cultura. O Co, por sua vez, é essencial para a fixação do N_2 , pois participa na síntese de cobamida e da leghemoglobina nos nódulos. Sua deficiência pode acarretar deficiência de N na soja, devido à baixa fixação biológica de N, causando uma clorose total, seguida de necrose nas folhas mais velhas, devido à deficiência de nitrogênio. O excesso de Co diminui a absorção de Fe, motivo pelo qual os sintomas de toxicidade de Co são semelhantes aos de deficiência de ferro, com folhas cloróticas na parte superior das plantas e atrofiamento. Indiretamente, o Mo e/ou o Co são os responsáveis por respostas positivas sobre a produção de grãos e de proteína, atuando ainda como coadjuvantes no desenvolvimento do sistema radicular das plantas, tornando as plantas menos suscetíveis aos estresses bióticos e abióticos (GRIS et al., 2005).

Segundo ZIBIANI et al. (2023), Ferreira et al. (2022) quando comparado a aplicação via sulco de plantio, a aplicação foliar de Co e Mo apresentou maiores médias nos componentes de produtividade

2.3 Importância do Ferro na soja

Na soja, o Fe desempenha um papel crucial nos processos metabólicos, incluindo na produção de clorofila e a respiração celular, fundamentais para a fotossíntese da planta. Quando há deficiência desse nutriente, os sintomas começam a se manifestar entre as nervuras das folhas, que adquirem uma

coloração amarelada. À medida que a deficiência se agrava, as nervuras também se tornam amarelas e, por fim, toda a folha fica quase branca (BORKERT et al., 1994).

O Fe desempenha diversas funções enzimáticas, sendo catalisadas por diferentes enzimas, como a catalase, responsável pela degradação do peróxido de hidrogênio, uma substância tóxica para as plantas. Além disso, participa em processos catalisados pela peroxidase, que elimina superóxidos; nitrogenase, responsável pela redução do N_2 à amônia; leghemoglobina, que se liga ao oxigênio e, em excesso, inativa a nitrogenase; e ferredoxina, atuando como carreador de elétrons para reduzir o $NADP^+$ a $NADPH$ no fotosistema I. A deficiência de Fe resulta em menor quantidade de RNA e taxa reduzida de síntese de proteínas. Como aproximadamente 75% do ferro está nos cloroplastos, essa deficiência causa clorose nas folhas jovens devido à diminuição da concentração de cloroplastos e do teor de clorofila. (SFREDO e BORKERT, 2004).

A redução na absorção de ferro pelas plantas pode ser atribuída à competição desse micronutriente com outros nutrientes pelos mecanismos de transporte celular. (KABATA-PENDIAS, 2011).

No corpo humano, o ferro desempenha papéis essenciais na biossíntese de ácidos nucleicos, no crescimento e desenvolvimento celular, na cadeia respiratória e em diversos processos enzimáticos e metabólicos (COMBS, 2001). A deficiência de ferro pode resultar em várias doenças, sendo a anemia a mais comum, além de comprometer a capacidade imunológica do organismo, tornando os indivíduos mais susceptíveis a doenças (CAKMAK, 2008).

Técnicas como a biofortificação podem elevar os teores de Fe ou de outros nutrientes nos grãos. Os alimentos biofortificados representam uma abordagem complementar viável, sustentável e econômica para auxiliar as populações carentes. Esses alimentos podem ser produzidos de duas maneiras, primeiramente geneticamente, que por meio do melhoramento genético de plantas busca aumentar os níveis de um nutriente específico, ou por meio da biofortificação agrônômica, que envolve o aumento da fertilização do solo, aplicação de nutrientes via foliar e/ou tratamento direto das sementes para aumento do teor de nutrientes (OLIVEIRA, 2019).

2.4. Fenotipagem de alto rendimento com Drone

A fenotipagem de plantas tem como base o tripé genótipo, o ambiente e o fenótipo. O genótipo é entendido como a constituição genética de organismo, neste caso a planta, considerando-se uma, ou mais de uma, característica para estudo (Sadras et al., 2013). Os fenótipos, por sua vez, são as particularidades apresentadas por um conjunto de características da planta, tais como valores ou classes associadas a arquitetura, forma, tamanho e cor, resistência à patógenos, tolerância a estresses, produtividade, etc., distinguíveis por inspeção visual direta ou por métodos refinados de análise (WALTER et al., 2015).

Fenotipagem é o ato de determinar os valores qualitativos ou quantitativos das características em estudo e relacioná-las ao desempenho de um genótipo em determinado ambiente (DHONDT et al., 2013). No modelo genético básico dado por $F = G + A$, considera-se ambiente, todo o fator externo, conhecido ou desconhecido que não o genótipo, mas que influencia este, de forma a proporcionar um fenótipo.

O processo de fenotipagem de alto desempenho tem se mostrado uma alternativa promissora, pois é capaz de aliar rapidez, alta precisão e baixo custo na obtenção de informações fenotípicas ao decorrer do ciclo da cultura, de modo não destrutivo e em grande quantidade de indivíduos (FRITSCHÉ-NETO; BORÉM, 2016). De acordo com Araus e Cairns (2014), a disponibilidade de tecnologias do sensoriamento remoto impulsionou uma variada gama de pesquisas no domínio da agricultura de precisão. Considerando que a primeira se preocupa com mensurações em escalas muito grandes, adaptações tiveram que ser realizadas com o intuito de suprir as necessidades das aplicações relacionadas ao melhoramento genético.

Devido a isso, a utilização dos produtos do sensoriamento remoto é restringida pela distância de amostragem do solo, o que implica na utilização de sensores proximais, como os utilizados plataformas terrestres ou em VANT's. Nesse sentido, o uso de câmeras de alta resolução, tais como as câmeras 4K de drones utilizados para tais fins, que tem sido capazes de permitir a avaliação de caracteres morfofisiológicos e agrônômicos de centenas ou milhares de plantas em um curto intervalo de tempo e com baixa exigência de mão de obra. Roth et al. (2018) pontuaram ainda que tal ferramenta como altamente escalável, isto é, capazes de suportar o aumento da demanda de trabalho visando a captura de dados de alta qualidade; desde que operada por profissionais qualificados, principalmente no

planejamento de vôos. Tais abordagens têm sido de extrema importância para o melhoramento genético vegetal, visando a seleção de genótipos desejáveis.

A seleção por meio da fenotipagem de alto rendimento tem lançado mão de índices espectrais para verificar aos atributos de qualidade e sanidade da lavoura, os quais por sua vez estão associados às características de interesse do melhorista (FRITSCHÉ-NETO; BORÉM, 2016). Na cultura da soja, o processo de fenotipagem associado a imagens digitais tem sido empregado para avaliação da cobertura do dossel vegetativo da cultura, além da radiação solar interceptada, tendo apresentado boa precisão e eficiência quando comparada com outros métodos (GASPAR & CONLEY, 2015, XAVIER et al, 2017, FIORANI et al, 2012). Matias et al. (2020), desenvolveram uma ferramenta computacional disponibilizada gratuitamente, na forma de um pacote para ser utilizado no software R. Essa ferramenta possibilita a investigação de diversos índices de vegetação, tais quais apresentados na Tabela 1. Essa tabela incluindo os índices que foram utilizados no trabalho e constitui uma versão simplificada da apresentada pelo autor na página do github (<https://github.com/OpenDroneMap/FIELDImageR>) da ferramenta. As letras R, G e B remetem às camadas de cores vermelho, verde e azul, de uma imagem RGB, na etapa de processamento da imagem.

Tabela 1 - Índices de vegetação.

Índice	Fórmula	Características relacionadas
BI	$\sqrt{(R^2+G^2+B^2)/3}$	Cobertura vegetal, conteúdo de água
GLI	$(2*G-R-B)/(2*G+R+B)$	Clorofila
HI	$(2*R-G-B)/(G-B)$	Solo, coloração do solo
NGRDI	$(G-R)/(G+R)$	Clorofila, biomassa, conteúdo de água
SI	$(R-B)/(R+B)$	Solo
VARI	$(G-R)/(G+R-B)$	Altura do dossel, biomassa, clorofila
BGI	B/G	clorofila

Fonte: Elaborado pelo autor.

Os desafios relatados na literatura são diversos, principalmente quando são relativos à experimentação realizada em um único ano e local. Dois casos de sucesso, no entanto, podem ser citados: Xavier et al. (2017), avaliando características de arquitetura de plantas de soja, por meio da avaliação do dossel com VANT; e Yu et al. (2016), avaliando grau de maturidade de plantas de soja. No trabalho de Xavier et al (2017), os autores utilizaram câmeras RGB convencionais e

VANT para obtenção de imagens de parcelas de um experimento de soja. A abordagem analítica relativa às imagens coletadas envolveu contagem de pixels das imagens e análise estatística por meio de métodos tradicionais. O trabalho de Yu et al. (2016), por sua vez, também utilizou plataforma terrestre e aérea para obtenção de imagens, na cultura da soja. Mas, além da análise por meio da contagem de pixel, os autores utilizam abordagem de inteligência artificial, especificamente um método de Randon Forest visando mensurar e classificar características geométricas das parcelas avaliadas. A abordagem analítica, por sua vez, constitui um outro problema, relatado por Herrero-Huerta et al. (2020). Os pesquisadores relataram um severo overfitting no processo de ajuste de características associadas à biomassa em soja. Tal fato reflete na dificuldade em se construir um modelo de machine learning capaz de generalizar resultados relativos a um experimento.

2.5. Redes Neurais Artificiais (ANN)

De acordo com Russell et al. (1995) as ANNs – Artificial Neural Networks – ou redes neurais artificiais podem ser interpretadas como um modelo matemático para a representação das operações do cérebro, sendo que os elementos aritméticos da computação representam os neurônios e a rede corresponde à coleção de neurônios interconectados. As ANNs são constituídas de unidades de processamento simples, denominadas neurônio artificial, sendo este composto por: um conjunto de conexões, cada uma delas com um peso; um elemento somatório capaz de somar as informações de entrada; e uma função de ativação com o intuito de restringir a amplitude da resposta, e disparar uma saída associada ao neurônio (BRAGA et al., 2000).

O neurônio artificial é a unidade básica de processamento das ANNs (HAYKIN, 2008), sendo uma estrutura projetada para funcionar de forma análoga ao neurônio biológico, apresentando as mesmas características e possuindo a capacidade de adquirir conhecimento. O termo rede neural, de acordo com Hastie, Tibshirani e Friedman (2008), tem sido utilizado para englobar um grande conjunto de modelos e métodos de aprendizagem que envolvem normalmente modelos estatísticos não lineares.

Uma rede neural constitui-se de uma regressão em dois estágios (“two-stage regression”) ou um modelo de classificação, normalmente representado em um diagrama de rede. Essa categoria de rede pode ser utilizada para modelar uma ou múltiplas variáveis quantitativas, categóricas, ou combinações destas. Özçelik et al. (2010) relataram que as ANNs são normalmente referidas como uma caixa preta (“black-box”), dado ao fato de seus coeficientes ou pesos não serem interpretáveis, e devido às suas propriedades tais como: a existência de camadas ocultas de neurônios e a utilização de funções não lineares para tratamento da informação. Os autores ressaltam ainda que em embora na prática a ANN constitua-se de uma metodologia de modelagem matemática, não compreendemos ao certo como elas aprendem a solução de um problema particular, e como elas são capazes de extrapolar conclusões.

A dinâmica de um estudo baseado em ANN exige que, para cada problema, tenhamos que ajustar uma arquitetura de rede com número variável de camadas intermediárias ocultas, com quantidade de neurônios e funções de ativação específicas. Redes dessa natureza são referenciadas como redes neurais artificiais profundas, ou por meio do termo “Deep Learning” (GOODFELLOW et al., 2016), o qual, para fim de simplificação, será referenciada no texto simplesmente como ANN. Essas, algumas vezes são bastante simples, mas que dependendo do tipo de problema podem se tornar muito complexas. Sua utilização prática envolve processos de treinamento, aprendizado e validação; devendo-se considerar a arquitetura planejada anteriormente (SILVA et al., 2010). Uma das propriedades que torna as ANNs atraentes é a habilidade de detectar implicitamente relações não lineares dos dados sem a necessidade de especificação prévia de um modelo (MARTINS et al., 2016), diferindo da abordagem por regressão.

Com relação à aplicação das ANNs, diversos autores tem relatado sucesso de sua aplicação. Prado (2015) relatou o uso de ANNs como classificadores de índice de doenças por meio da interpretação de características espectrais no feijão comum. Seu objetivo foi realizar a detecção precoce de antracnose e da murcha-de-fusário, por meio de uma variada gama e índices multiespectrais e hiperespectrais. O autor concluiu que o uso de determinados comprimentos de onda, associados a determinados índices espectrais permitiu a detecção precoce das duas doenças da cultura do feijão.

Carneiro et al. (2018) investigou a respeito da ferramenta da lógica Fuzzy em estudo de estabilidade e adaptabilidade em feijão comum. Embora não seja uma ANN propriamente dita, ela constitui uma ferramenta de Inteligência Artificial. Os resultados obtidos pelos autores foram bastante promissores com respeito à tomada de decisão, após realizada uma análise comparativa com o método tradicional de Eberhart and Russell (1966). Rosado et al. (2020), descreve o uso de ANN para predição do mérito genético de características de florescimento em cultivares de feijão. Os autores concluíram que as ANNs modeladas apresentaram resultados equivalentes aos proporcionados por metodologia tradicional – BLUP. Outros casos de sucesso da aplicação de ANN na cultura do feijão são descritos na literatura (CARNEIRO et al., 2017).

3 MATERIAL E MÉTODOS

3.1. Área experimental, material genético e características avaliadas

O experimento foi realizado na Área Experimental irrigada da Faculdade de Ciências Agrárias e Tecnológicas da UNESP, Campus de Dracena, SP, nas coordenadas geográficas 51°32' Latitude Oeste e 21°29' Longitude Sul, localizada a 396 m de altitude. O clima local, conforme classificação de Koppen é do tipo Cw, caracterizados pelas estações de clima quente e inverno seco. As médias anuais de temperatura e precipitação são, respectivamente, 24°C e 1300 mm, com temperatura média máxima de 31°C e média mínima de 19°C.

Foram considerados dois experimentos, um instalado em novembro de 2021, com colheita realizada em abril de 2022; e sua repetição, ocorrida na safra de 2022-2023, instalada em campo na segunda quinzena do mês de novembro de 2022, e colhida em abril de 2023.

O solo da região é classificado como Argissolo Vermelho Amarelo distrófico (SANTOS et al., 2013). A coleta de solo foi realizada na profundidade de 0-0,20 m, proporcionando uma amostra uniforme do horizonte A do Argissolo, destorroada, homogeneizada, seca ao ar e peneirada com malha de quatro milímetros de abertura. Os atributos físicos e químicos foram determinados conforme descrito por Raj et al. (2001). Foi realizada calagem em área total, pelo método de saturação por base, segundo Quaggio et al. (1985). Foi realizada incorporação de calcário, elevando a saturação por bases para 70%, em toda a área em fevereiro de 2021, para avaliação da fertilidade do solo foram realizadas coleta e análise de solo para o experimento do ano 2021-2022 (Tabela 2) e para o experimento do ano 2022-2023 (Tabela 3), a correção de fósforo e potássio foram feitas seguindo recomendações do Boletim 100 (Raj et al,1997). Para preparo do solo, no ano de 2021 e no ano de 2022 foram feitas a operação de aração e gradagem do solo. O experimento do ano 2021-2022 foi conduzido em sistema convencional, já para o experimento 2022-2023, após o preparo do solo foi semeado a lanço uma mistura de *Urochloa brizantha* com *Crotalaria ochroleuca*, e após três meses foi dessecado e um mês depois foi feita a semeadura em sistema plantio direto.

Tabela 2 - Análise de solo utilizada para o experimento 2021-2022.

pH	g/dm ³	mg/dm ³	mmolc/dm ³							V%	m%	mg/dm ³					
CaCl ₂	MO	P	K	Ca	Mg	Al	H+Al	SB	T			S	Fe	Mn	Zn	Cu	B
5,4	8	15	1,7	15	6	0	11	22,7	33,7	67	0	3	8,8	11,8	0,9	1,1	0,1

Tabela 3 - Análise de solo utilizada para o experimento 2022-2023.

pH	g/dm ³	mg/dm ³	mmolc/dm ³							V%	m%	mg/dm ³					
CaCl ₂	MO	P	K	Ca	Mg	Al	H+Al	SB	T			S	Fe	Mn	Zn	Cu	B
5,2	10	14	1,8	14	6	0	13	21,8	34,8	63	0	3	13,6	17	0,8	1,4	0,09

O experimento da safra de 2021-2022 foi instalado em campo sob delineamento de blocos casualizados com três repetições, em esquema fatorial duplo 4 x 3, considerando quatro variedades: ICS TORO, ICS RODEO, ICS 1332 e ICS 7019; todas as variedades cedidas pela empresa Intellicrops Genética Vegetal do Grupo Inquima. Adicionalmente, foram considerados níveis do fator tratamento com fertilizante foliar: Nível D1, controle sem adubação foliar; nível D2, com aplicação de adubação foliar à base de Mo e Co; e nível D3, com aplicação de adubação foliar à base de Mo, Co e Fe. Foram utilizados os produtos CoMo Ultra (como fonte de Co e Mo) e Kelamylth MP6 (como fonte de Fe), seguindo as recomendações descritas na bula do produto. O experimento da safra de 2022-2023 foi realizado aos moldes do anterior. No entanto, devido à disponibilidade de sementes, as quais foram recebidas por doação, foram utilizadas as variedades: ICS TORO, ICS RODEO, ICS 7019, AGROESTE 3730, PIONER 97Y91 IPRO e PIONER 96R10 IPRO. Dessa forma, o experimento foi instalado segundo delineamento de blocos casualizados com três repetições, em esquema fatorial duplo 6 x 3, considerando as variedades e o tratamento com fertilizante foliar. Os níveis do fator tratamento com fertilizante foliar e os produtos utilizados foram os mesmos da safra 2021-2022. Em ambos os experimentos, a unidade experimental foi constituída de cinco linhas de três metros das quais foram avaliadas as três linhas centrais de três metros. As variedades foram semeadas em sistema convencional de plantio, objetivando população final de 10 a 13 plantas por metro. Foi utilizada uma semeadora adubadora configurada para plantio direto, composta de 5 linhas de semeadura espaçadas 0,45m entre linhas.

Na unidade experimental, foram avaliadas as características altura de planta (H – em cm), altura da primeira vagem (Hpv – em cm), número de vagens (Nv), Número de grãos (Nv – quantidade média medida a partir de 5 plantas tomadas ao

acaso na área útil da parcela), número de hastes (Nh - quantidade média medida a partir de 5 plantas tomadas ao acaso na área útil da parcela), massa de 100 grãos (Mcg – em gramas), produtividade de grãos (Pg – quilos por hectare) a 13% a base umidade. As plantas foram colhidas manualmente, e submetidas à degreana mecanicamente com a trilhadora 150 PV da marca Vencedora MaqTron.

O manejo da irrigação foi realizado baseado na ETo obtidas a partir da Estação Meteorológica Campbell Scientific CR10X, estimada pelo método de Penman-Monteith (ALLEN et al., 1998) e multiplicado pelo (Kc) das fases fenológicas da cultura. Foi utilizado o sistema de irrigação por aspersão convencional, composto de 2 linhas com 6 aspersores da marca Fabrimar espaçados 12x12 m entre as linhas, lâmina de 7,0 mm/h, PS de 20 mca e turno de rega de 4 dias.

A análise de dados foi realizada por meio de rotinas desenvolvidas em linguagem R (R Core Team, 2024). Foi procedida análise de variância seguida de teste de comparação de médias.

3.2. Fenotipagem de alto rendimento e redes neurais artificiais

A fenotipagem de alto rendimento foi realizada por meio da aquisição de imagens aéreas com um drone Mavic 2 Pro com sua câmera nativa 4K 60 fps, por meio do aplicativo DJI GSP – Ground Station Pro para iPad. Foram realizados quatro voos após a emergência da cultura, a uma altura de 20 metros. Por fim, foi selecionado o voo que apresentou melhor associação com os dados de produtividade da cultura, em cada safra. Para construção do orthomosaico, foram utilizadas em média 320 fotografias para o experimento da safra 2021-2022, cujos vôos foram realizados em 01/02/2022, 20/02/2022, 03/03/2022 e 20/03/2022; e 238 fotografias na safra 2022-2023, cujos vôos foram realizados em 26/01/2023, 07/02/2023, 23/02/2023 e 20/03/2023.

A construção de orthomosaicos a partir das imagens foi realizada por meio do software Open Drone Map - WebODM Manager. Os ortomosaicos para análise foram então processados por meio do pacote FieldImager (MATIAS et al. 2020) no

software livre R, a partir do qual foram obtidas as estimativas, por parcela experimental, dos índices espectrais: BI, GLI, HI, NGRDI, SI, VARI e BGI.

Para associação dos dados extraídos das imagens, foi ajustada uma ANN do tipo perceptron multicamada, para cada experimento. A respeito da arquitetura da rede, foram utilizadas como covariáveis de entradas, os fatores do experimento, a citar aplicação de tratamento foliar, variedade e bloco; mais as estimativas de média, mediana e desvio padrão dos pixels das camadas Vermelho, Verde e Azul da imagem das parcela experimentais extraídas do orthomosaico; adicionado das mesmas estimativas associadas a cada um dos índices espectrais citados. Dessa forma, foram consideradas, à princípio, 33 informações com covariáveis na camada de entradas. Posteriormente, foram desconsideradas aquelas covariáveis que não apresentaram variação. Para cada covariável, os dados foram normalizados por meio da função $f(X_i) = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}$, sendo X_i o valor original da particular covariável de entrada, e $f(X_i)$, o valor normalizado de X_i . Foram utilizados 75% dos valores fenotípicos do experimento no processo de treinamento da ANN e os 25% restantes no processo de validação. A estimação dos pesos da ANN foi realizado em processo iterativo. Foram consideradas a construção de 100 redes, sendo salva aquela que proporcionou melhores métricas (RMSE – Root Mean Squared Error), tanto para o conjunto de treinamento, quanto para o conjunto de teste, nesta ordem. Foi utilizado o algoritmo de treinamento resilient backpropagation e a função de ativação logística do pacote neuralnet, nas camadas intermediárias. Foram consideradas ainda duas camadas ocultas, cada qual com 5 neurônios, tomados de forma arbitrária; e uma camada de saída, com um neurônio, sendo este associado à característica de produtividade. A modelagem das ANNs foi realizada por meio de rotinas de análise no software livre R (R CORE TEAM, 2024), utilizando o pacote neuralnet. A avaliação da eficácia da ANN foi realizada por meio de métricas de ajuste dos valores preditos e observados, a citar: Root Mean Squared Error – RMSE – raiz do erro quadrático médio $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$, e o coeficiente de determinação R^2 .

4. RESULTADOS E DISCUSSÃO

4.1. Experimentação – Ano Agrícola de 2021/2022

Na Tabela 4 estão apresentados os resultados da análise de variância para as características avaliadas no ano agrícola 2021/2022, os resultados indicaram existir diferenças entre médias no fator tratamento foliar para as características H e Mcg; e significância para o fator variedade para H, Nv, Ng e Pg. Os testes de média para essas características estão apresentados nas Tabelas 5 e 6. Não foram detectados efeitos de interação em nenhuma das variáveis consideradas. Com respeito ao efeito do tratamento aplicação foliar, verificou-se que a aplicação de Co + Mo (CoMo) assim como a aplicação do tratamento foliar CoMo + Fe conduziram a formação de plantas de maior altura comparadas ao controle – Tabela 5. De forma semelhante, os níveis de tratamento com micronutrientes aplicados via foliar proporcionaram grãos cujas Mcg foram em média 1,09g superior ao nível controle e significativo estatisticamente ($p > 0,05$). De acordo com SFREDO & OLIVEIRA (2010), as respostas com a adubação com molibdênio no Brasil, têm proporcionado resultados variáveis, relatados por diversos autores. Embora tenhamos detectado tal diferença na Mcg (um componente da produtividade) quando aplicado concomitante com Co e/ou Fe, de acordo com o autor, experimentos conduzidos com diversas variedades de soja, não apresentaram aumentos no rendimento de grãos, o que corrobora com resultados de Silva et al. (2011) e Galdino et. al (2020).

Com relação ao fator variedade de soja, foram detectadas diferenças significativas para as características H, Nv, Ng, Nh e Pg. As médias das respectivas variedades para tais características estão apresentadas na Tabela 6. A caracterização do comportamento das variedades é de particular interesse para recomendação de cultivares para regiões de cultivo da cultura da soja. A região Oeste do estado de SP é caracterizada por solos degradados, prioritariamente de textura arenosa, que nas últimas décadas foram utilizados para pastagem ou para cultivo da cultura da cana. O solo da área experimental onde foi realizado o experimento reflete bem essa realidade, tendo sido utilizado nos últimos 20 anos para cultivo de cana. Dessa forma, identificar variedades que se adaptem à tais condições é de extrema importância para produtores da região e para empresas do setor de melhoramento.

Tabela 4 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2021-2022.

FV	GL	QM						
		H	Hpv	Nv	Ng	Nh	Mcg	Pg
Tratamento Foliar	2	245.84***	26.66	2780.95	2169.05	7.75	7.14*	11760
Variedade	3	142.96***	15.28	5840.59**	4509.62**	22.57***	3.28	2814054*
Bloco	2	116.91*	1.13	194.87	93.50	5.54	4.01	482693
Interação	6	31.65	6.83	1109.56	842.66	5.13	1.30	738803
Resíduo	6	17.40	10.82	872.78	992.73	3.29	2.30	701938
Média		51,74	7.32	93.10	103.24	5.96	12.72	2531
CV(%)		8.06	44.94	31.73	30.52	30.46	11.94	33,1

* – $p < 0,05$; ** – $p < 0,01$; *** – $p < 0,001$. (H) Altura de plantas (Hpv) Altura de 1° vagem (Nv) Número de vagens (Ng) Número de grãos (Nh) Número de hastes (Mcg) Massa de cem grãos (Pg) Produtividade.

Tabela 5 - Teste de agrupamento de médias das características avaliadas para o fator tratamento foliar da safra 2021-2022, por meio do teste de Skott-Knott. Grupo de médias seguidas da mesma letra não diferem entre si.

Tratamentos	H	Mcg
Controle	47.24 b	11.99 b
CoMo	54.32 a	13.30 a
CoMo + Fe	53.68 a	12.86 a

Tabela 6 - Teste de agrupamento de médias das características avaliadas para o fator Variedade da safra 2021-2022, por meio do teste de Skott-Knott. Grupo de médias seguidas da mesma letra não diferem entre si.

Variedades	H	Nv	Ng	Nh	Pg
ICS 7019	56.24 a	79.10 b	89.25 b	6.63 a	2442 a
ICS Rodeo	52.66 b	89.20 b	118.51 a	5.45 b	2999 a
ICS 1332	49.17 c	125.38 a	121.28 a	7.45 a	2791 a
ICS Toro	48.91 c	78.71 b	83.93 b	4.31 b	1891 b

O nível de produtividade média obtido foi de 2531 kg.ha⁻¹, sendo considerado baixo, destacando-se negativamente a variedade ICS Toro (1891 kg.ha⁻¹). Tal nível de produtividade está abaixo da média obtida em outras safras, na mesma região, em torno de 4000 kg por hectare, mas se justifica por ser a primeira safra em uma área experimental. Destacou-se também a variedade ICS Rodeo (com produtividade acima da média) devido ao fato de ela não constar como recomendada para as condições edáficas da região. Visando melhor entendimento das relações entre os nutrientes considerados, faz-se necessária análise nutricional dos micronutrientes avaliados, principalmente nos grãos. Ainda, de posse de tal conhecimento em relação às variedades, e caso seja detectada alguma diferença estatística, tais resultados abrirão caminho para o estabelecimento de protocolos de biofortificação para tais nutrientes, na cultura da soja, e a identificação de fonte de variação genética para o melhor entendimento dos mecanismos de transporte de tais nutrientes.

4.2. Experimentação – Ano Agrícola de 2022-2023

O resultado da análise de variância apresentado na Tabela 7, indicou a existência de variabilidade devido a efeitos de Variedade e de Tratamento Foliar. Com respeito aos coeficientes de variação, estes foram baixos para H e Mcg; e médios para Hpv, Nh e Pg; e alto para Nv e Ng, de acordo com Pimentel-Gomes (1985). Estas estimativas foram menores, e conseqüentemente, melhores que as obtidas para as mesmas características da safra 2021/2022 e fornecem, segundo o autor, indícios a respeito da precisão experimental do experimento.

Salienta-se que assim como na safra de 2021/2022, não foi detectada para essas características efeito de interação entre os tratamentos e as variedades avaliadas. Os resultados dos testes de comparação de média para as características avaliadas, considerando os níveis dos fatores Tratamento Foliar e Variedade estão apresentados nas Tabelas 8 e 9, respectivamente. Para a característica Mcg, o tratamento controle e o tratamento com CoMo apresentaram estimativas estatisticamente iguais, e superiores ao tratamento com CoMo + Fe. Para a característica Nv, o tratamento com CoMo + Fe foi superior aos demais. Não foram encontrados indícios de que tais tratamentos foram capazes de aumentar a Pg da

cultura. As diferenças numéricas nas estimativas de produtividade não apresentaram significância estatística.

Com respeito às variedades, a ICS 7019, a PIONEER 96R10 e A ICS TORO apresentaram Mcg superiores às demais. Quanto à produtividade, as variedades ICS 7019, PIONEER 96R10, ICS Rodeo e AGROESTE 3730, apresentaram maiores níveis de produtividade, com média de 4357,25 kg.ha⁻¹. As outras duas variedades, com Pg significativamente menor apresentaram média de 3593 kg.ha⁻¹. Constatou-se, ainda, que o nível médio de produtividade da safra 2022/2023 foi 56% superior que o da anterior; sendo tal diferença devido principalmente a efeitos ambientais.

Ainda com relação à Pg, constata-se que tais resultados são importantes pois auxiliam o profissional Agrônomo / Engenheiro Agrônomo no processo de recomendação de variedades. Na região do Oeste Paulista, onde a experimentação foi executada, e baseando-se apenas nos níveis de produtividade, poderiam ser recomendadas as quatro variedades citadas. No entanto, a prática agrícola tem demonstrado que a variedade Agroeste 3730 tem se mostrado bastante susceptível ao acamamento, o que pode constituir um empecilho à colheita mecanizada. No teste de médias apresentado na Tabela 9, esta variedade é foi a que apresentou maior altura, comparativamente às demais.

Não é claro a dinâmica de distribuição destes nutrientes nos órgãos das plantas, e como eles interagem entre si, mas sabe-se que tanto o Co quanto o Mo são micronutrientes essenciais para o adequado funcionamento de enzimas, por exemplo, do metabolismo do nitrogênio (DROUIN et al., 2013) e do carbono (MENDEL & HÄNSCH; 2002). O Fe, por sua vez, é essencial para as plantas, desempenhando 25 funções diversas, inclusive no processo de síntese de clorofila e na transferência de elétrons na fotossíntese (MARSCHNER, 2012). Ainda de acordo com Marschner (2012), a absorção destes nutrientes ocorre principalmente pelas raízes, onde os íons de Co, Mo e Fe são transportados ativamente para o interior das células radiculares. Enquanto o Co e o Mo são considerados móveis, o Fe é menos móvel e sua redistribuição é limitada, o que explica a clorose foliar em caso de deficiência. Ainda, o autor relatou que o aumento da concentração de Fe, nas leguminosas, podem interferir na absorção e na assimilação adequada de cobalto e molibdênio, levando a deficiências desses micronutrientes. Deve-se ressaltar, no entanto, que efeitos específicos podem variar dependendo das condições de cultivo, interações complexas entre os nutrientes e a variedade específica de leguminosa

considerada. Gris et al. (2005) ressaltou que o Mo e/ou o Co são os responsáveis por respostas positivas sobre a produção de grãos e de proteína, uma vez que atuam como coadjuvantes no desenvolvimento do sistema radicular das plantas. Os resultados apresentados na Tabela 7 não corroboram, diretamente, a afirmação de Gris et al. (2005). Não foi verificado aumento na massa de grãos, uma vez que as médias observadas foram iguais estatisticamente, diferentemente do ano anterior em que os tratamentos com CoMo e CoMo + Fe aumentaram a Mcg. Ainda, na produtividade, não foi detectada diferença estatística entre os tratamentos. Com relação à aplicação concomitante de CoMo + Fe, comparado ao controle, verificou-se um efeito negativo na massa de grãos da soja, efeito tal qual relatado por Marschner (2012).

Assim como na safra de 2021/2022, não foi detectada para as características avaliadas, efeito de interação entre esses tratamentos e as variedades avaliadas. Tal fato constitui um bom indício de que a aplicação foliar de produtos e/ou tratamento à base de micronutriente atue de forma independente do material genético que é semeado. Faz-se necessário, no entanto, avaliar se tais tratamentos foram capazes de aumentar a concentração dos respectivos nutrientes nos grãos das variedades avaliadas. Caso tal hipótese seja confirmada, tal resultado permitirá direcionamento de cruzamentos visando o desenvolvimento de variedades específicas para fins de biofortificação, que poderá, por exemplo, ser utilizada na indústria de alimentos.

Tabela 7 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2022-2023.

FV	GL	QM						
		H	Hpv	Nv	Ng	Nh	Mcg	Pg
Tratamento Foliar	2	55.39	9.56	17688*	71332.12	1.05	10,88***	462655.5
Variedade	5	335.01***	52.44***	25337**	111732.38**	2.09	75,73***	1299568.5**
Bloco	3	8.34	3.24	1406.92	30017.95	0.85	3,04	202517
Interação	10	48.94	7.48	4832.49	41862.58	0.67	1,66	431710.8
Resíduo	51	25.31	3.01	5310.96	27394.64	1.29	1,35	283546.7
\bar{x}		66.63	14.74	62.6	137.68	2.19	23,20	3969
CV(%)		7.55	11.76	23.28	24.04	13.98	5,01	13,41

* – $p < 0,05$; ** – $p < 0,01$; *** – $p < 0,001$. (H) Altura de plantas (Hpv) Altura de 1° vagem (Nv) Número de vagens (Ng) Número de grãos (Nh) Número de hastes (Mcg) Massa de cem grãos (Pg) Produtividade.

Tabela 8 - Teste de agrupamento de médias das características avaliadas para o fator tratamento foliar da safra 2022-2023, por meio do teste de Skott-Knott. Grupo de médias seguidas da mesma letra não diferem entre si. As médias não apresentadas não diferiram na ANOVA.

Tratamentos	Nv	Mcg
Controle	60 b	23,80 a
CoMo	58,8 b	23,32 a
CoMo + Fe	68,8 a	22,47 b

Tabela 9 - Teste de agrupamento de médias das características avaliadas para o fator Variedade da safra 2022-2023, por meio do teste de Skott-Knott. Grupo de médias seguidas da mesma letra não diferem entre si. As médias não apresentadas não diferiram na ANOVA.

Variedades	H	Hpv	Nv	Ng	Mcg	Pg
ICS 7019	67.86 b	14.15 b	56 b	126.4 b	25,20 a	4086 a
PIONEER 96R10	60.25 c	12.87 c	54 b	125.98 b	25,04 a	4089 a
ICS Toro	62.33 c	12.86 c	70 a	158.97 a	24,49 a	3387 b
ICS Rodeo	70.18 b	14.81 b	53 b	122.69 b	23,32 b	4148 a
AGROESTE 3730	74.51 a	16.64 a	68 a	126.17 b	22,65 b	4306 a
PIONEER 97Y91	64.61 c	17.67 a	74 a	165.78 a	18,49 c	3799 b

(H) Altura de plantas (Hpv) Altura de 1º vagem (Nv) Número de vagens (Ng) Número de grãos (Nh) Número de hastes (Mcg) Massa de cem grãos (Pg) Produtividade.

4.3. Fenotipagem de alto Rendimento - Ano Agrícola de 2021-2022

Para a análise de fenotipagem de alto rendimento, foram consideradas 232 fotografias capturadas pelo drone. Na Figura 1 está apresentado o orthomosaico cujos resultados das análises apresentaram resultados mais promissores. Para análise dos orthomosaicos, foram considerados os índices espectrais: NGRDI, BGI, VARI, HI, SI e GLI; utilizando o pacote FIELDImageR para extração da informação.

Figura 1 - Orthomosaico construído a partir de 232 imagens de vôo realizado em 30/02/2022, representando parcelas experimentais do experimento da safra 2021/2022.



Fonte: Elaborado pelo autor.

Na Tabela 10 está apresentado o resultado na ANOVA para tratamento foliar, variedade e interação; considerando os índices de vegetação avaliados. Foram detectados efeitos significativos, para todos os índices avaliados, inclusive efeitos de interação para os índices VARI, HI e SI. Tais resultados são interessantes, mas ao mesmo tempo, de difícil entendimento para aplicabilidade direta, uma vez que os índices compõem uma equação entre as camadas de cores da imagem. O índice NGRDI, por exemplo (Tucker, 1979), é calculado a partir da refletância nas camadas verde e vermelha do espectro eletromagnético, captado pelas lentes, sendo dado pela equação $NGRDI = \frac{(G-R)}{G+R}$, em que G e R, correspondem às estimativas de reflectância nas bandas

espectrais referentes a faixa espectrais verde e vermelho, respectivamente. Esses índices, no entanto, podem se associar com nível de clorofila, biomassa e conteúdo de água das plantas, e daí a sua importância.

A análise pormenorizada dos resultados demonstrou grande variação de comportamento em relação aos níveis de Variedade e em relação aos níveis do Tratamento foliar realizados. Tal relação se mostrou variável, dependendo do tempo após aplicação do tratamento no qual as fotografias para análise foram obtidas. Constatou-se que após cinco dias de aplicação, não foi detectada diferença entre os índices. Cerca de 25 dias após aplicação do tratamento que diferenças passaram a ser detectadas. Ainda, o comportamento dos índices mostrou-se dependente da variedade avaliada. Isto pode demonstrar-se um empecilho uma vez que dificulta o uso da tecnologia de forma geral/generalizada.

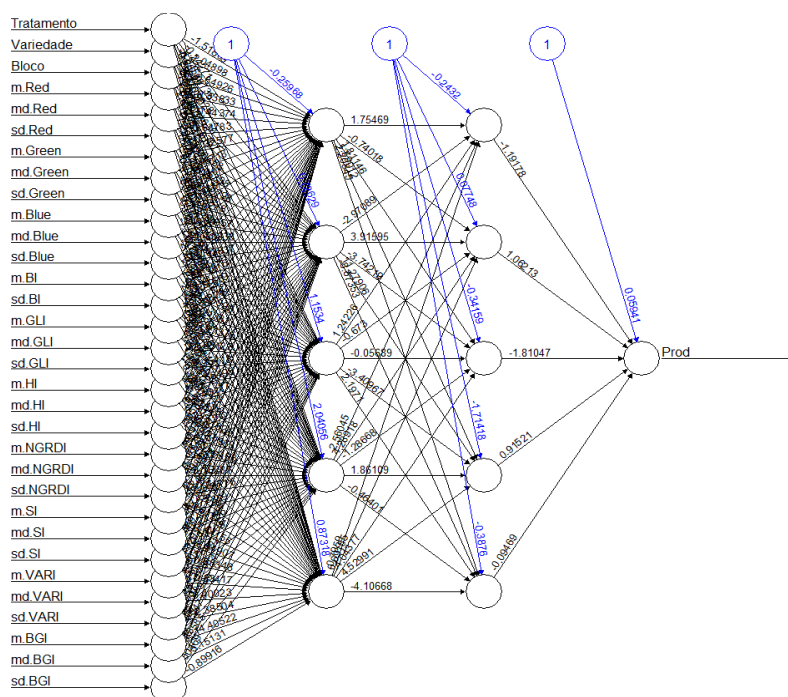
Tabela 10 - Resumo da ANOVA para as características de índices de vegetação considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2021-2022.

FV	GL	QM					
		NGRDI	BGI	VARI	HI	SI	GLI
Tratamento Foliar	2	0,0032*	0,0013*	0,0055**	0,0556**	0,0030**	0,0019*
Variedade	3	0,0147***	0,0102***	0,0213***	0,1959***	0,0082***	0,0125***
Bloco	2	0,0076***	0,0004	0,0128***	0,1484***	0,0068***	0,0031**
Interação	6	0,0013	0,0002	0,0025*	0,0317**	0,0024**	0,0004
Resíduo	6	0,0006	0,0004	0,0009	0,0091	0,0005	0,0004
\bar{x}		0,1722	0,3482	0,2141	0,164	0,346	0,3101
CV(%)		14,41	5,57	14,23	58,3	6,48	6,91

* – $p < 0,05$; ** – $p < 0,01$; *** – $p < 0,001$.

As informações os índices obtidos das parcelas experimentais foram utilizados para construção de uma rede neural (ANN) do tipo perceptron multicamada (MLP), em processo iterativo. A arquitetura utilizada para construção de ANN está apresentada na Figura 2.

Figura 2 - ANN do tipo PMC para predição da produtividade da parcela de soja utilizadas no experimento da safra 2021-2022.




Fonte: Elaborado pelo autor.


Em processo iterativo, foram construídas 100 ANNs, a partir das quais foi selecionada a melhor com base nas estimativas de RMSE, primeiramente no conjunto de treinamento e posteriormente no conjunto de teste. Na Figura 3 estão dispostas estimativas das duas métricas consideradas, e na Tabela 11 estão, os parâmetros da melhor ANN, selecionada para estimação da produtividade.

Figura 3 - Métricas RMSE (A) e R^2 (B) das ANN construídas para predição da produtividade. As linhas vermelhas constituem as métricas da população de treinamento e as linhas pretas, na população de teste.

(A)



(B)



Fonte: Elaborado pelo autor

O RMSE constitui uma medida de erro e, portanto, quanto menor sua estimativa, melhor tende a ser a predição. O R^2 , constitui um parâmetro capaz de exemplificar a capacidade de generalização da ANN. Na Tabela 11, está apresentado os parâmetros da rede selecionada.

Tabela 11 - Métricas das etapas de treinamento da melhor ANN construída para predição da produtividade da safra 2021-2022.

Etapa	Métricas	
Treinamento	RMSE	0.0614
	R ²	0.9003
Teste	RMSE	0.0526
	R ²	0.9121

De acordo com os resultados obtidos, a ANN selecionada foi capaz de prever os dados da produtividade os dados do conjunto de teste, o equivalente a 25% dos dados não utilizados no treinamento com coeficiente de determinação de 91,21%. Os resultados são considerados muito promissores. Normalmente estimativas de 80 a 85% são consideradas satisfatórias, e são obtidas com conjuntos de dados muito maiores. É sabido ainda que quanto maior o conjunto de dados, tais métricas tendem a diminuir, considerando que variação normalmente é inserida no conjunto.

4.4. Fenotipagem de alto Rendimento – Ano Agrícola de 2022-2023

Na Figura 4 está apresentado o orthomosaico cujos resultados das análises apresentaram resultados mais promissores. Para análise foram considerados os mesmos índices espectrais utilizados na safra anterior, e utilizando o pacote FIELDimageR para extração da informação.

A título de exemplificação, nas Figuras 5 e 6 estão apresentados os resultados significativos, avaliados para os índices BGI e SI. Por meio das análises, verificou-se que foram detectados efeitos tanto entre variedades, quanto com relação os tratamentos avaliados. Com relação a este último, verifica-se que isto mostra-se um resultado interessante, uma vez que a análise de imagens permitiu a distinção entre parcelas tratadas e não tratadas.

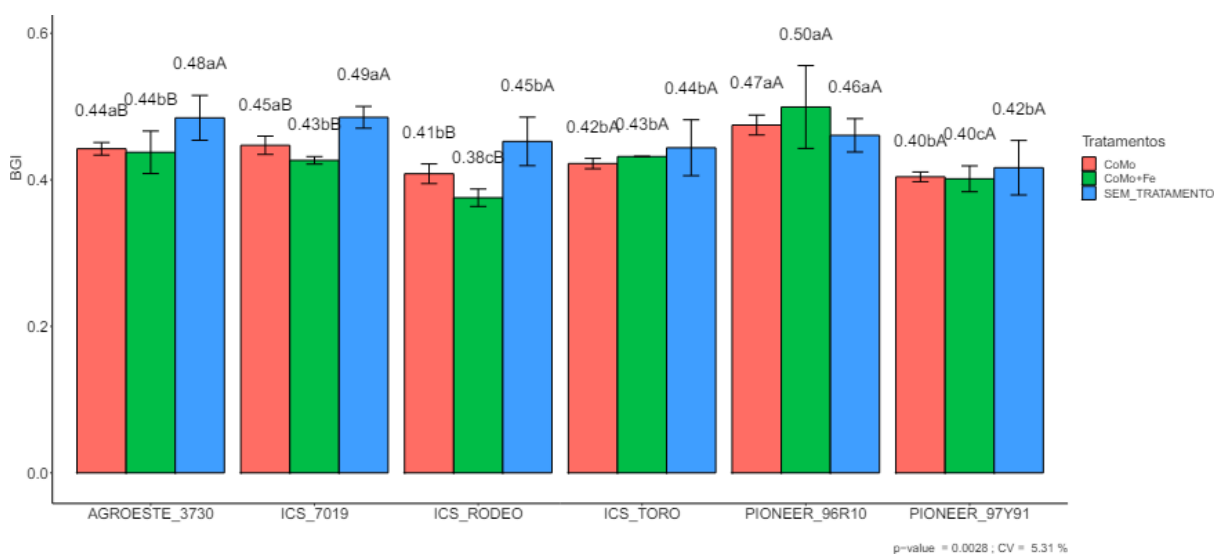
Figura 4 - Orthomosaico construído a partir de 238 imagens de voo realizado em 07/02/2023, representando parcelas experimentais do experimento da safra 2022/2023.



Fonte: Elaborado pelo autor

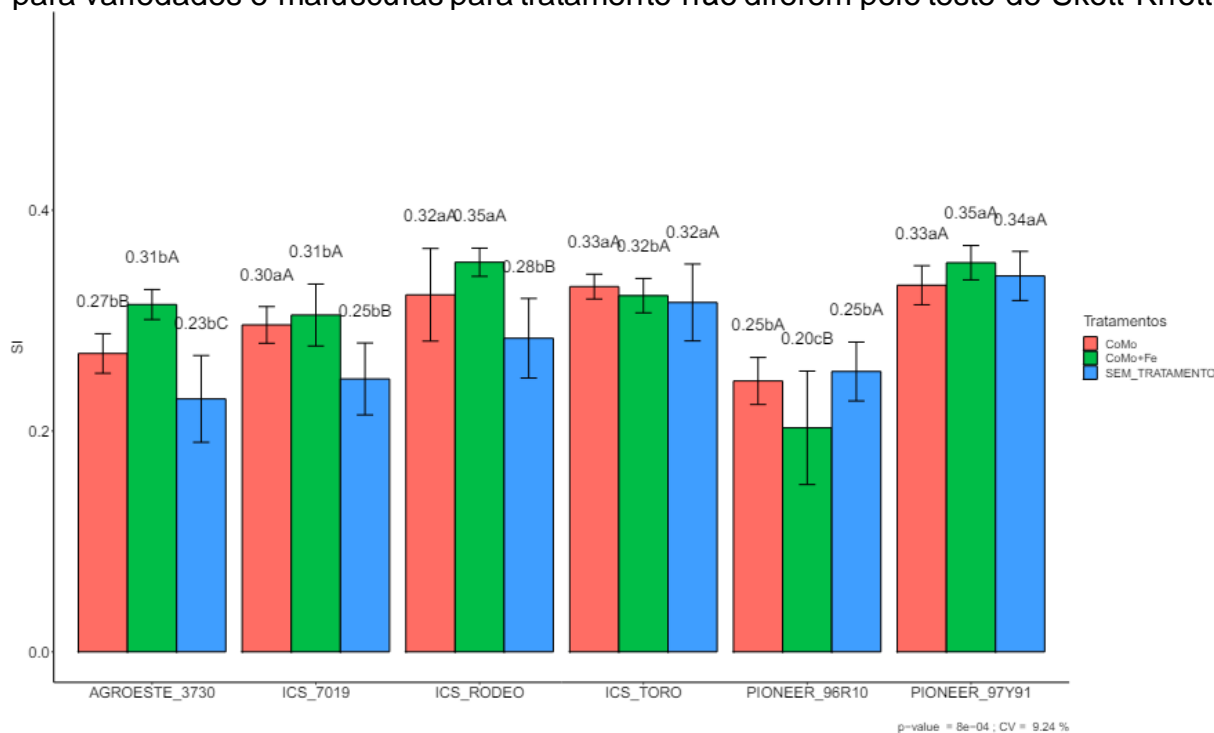
De acordo com Makanza et al. (2018), os métodos atuais para estimar o crescimento e produtividade da cultura são em sua maioria baseados em avaliação visual por estimativa, o que podem incorrer com subjetividade, além de serem demorados e caros. Dessa forma, o uso de imagens provenientes de câmeras RGB a bordo de um VANT de baixo custo, constituem estimativas interessantes para estimar a cobertura vegetal, monitorar senescência do dossel em ensaios de melhoramento, identificar falhas no experimento, dentre outras utilidades. De fato, os resultados obtidos demonstram utilidade de ambos os índices em discernir as variedades como demonstrado nas Figuras 5 e 6, o que eventualmente pode ter aplicabilidade no melhoramento vegetal, como por exemplo, ser utilizado como descritor complementar no processo de registro de cultivar.

Figura 5 - Estimativas do índice de vegetação BGI para variedades de soja e tratamento foliar. Agrupamento de médias seguidas pela mesma letra minúscula para variedades e maiúsculas para tratamento não diferem pelo teste de Skott-Knott.



Fonte: Elaborado pelo autor

Figura 6 - Estimativas do índice de vegetação SI para variedades de soja e tratamento foliar. Agrupamento de médias seguidas pela mesma letra minúscula para variedades e maiúsculas para tratamento não diferem pelo teste de Skott-Knott.



Fonte: Elaborado pelo autor

Tabela 12 - Resumo da ANOVA para as características avaliadas, considerando dos fatores Tratamento Foliar e o fator Variedade de soja da safra 2022-2023.

FV	GL	QM					
		NGRDI	BGI	VARI	HI	SI	GLI
Tratamento Foliar	5	0.0002	0.0056***	0.0002	0.0025	0.0057**	0.0012
Variedade	2	0.0037***	0.009***	0.0085***	0.2029***	0.0193***	0.0012*
Bloco	3	0.0012	0.0015*	0.0017	0.0268	0.0011	0.0011
Interação	10	0.0008	0.0017**	0.0015	0.0258	0.0027***	0.0006
Resíduo	51	0,0006	0.0005	0.0011	0.0163	0.0007	0.0004
\bar{x}		0.1215	0.4397	0.1593	0.2769	0.2955	0.2433
CV(%)		20.76	5.31	21.12	46.24	9.24	8.36

* - $p < 0,05$; ** - $p < 0,01$; *** - $p < 0,001$

As informações os índices obtidos das parcelas experimentais foram utilizados para construção de uma rede neural (ANN) do tipo perceptron multicamada (MLP), nos mesmos moldes do realizado com os dados da safra 2021/2022, sendo utilizada a mesma arquitetura apresentada na Figura 2. As métricas obtidas para ANN selecionada estão apresentados na Tabela 13.

Tabela 13 - Métricas das etapas de treinamento da melhor ANN construída para predição da produtividade da safra 2022-2023.

Etapa	Métricas	
Treinamento	RMSE	0.0917
	R ²	0.9285
Teste	RMSE	0.1227
	R ²	0.8974

A fenotipagem de alto rendimento tem se mostrado ser uma ferramenta importante para auxiliar na avaliação de experimentos agrícolas de soja, permitindo a medição rápida e precisa de várias características fenotípicas em um grande número de plantas, ajudando a identificar os melhores indivíduos para cruzamentos e selecionar características desejadas para futuros cultivares de soja.

Yin et al. (2019) apresentaram uma metodologia que utiliza imagens de VANTs para medir a altura do dossel na cultura do sorgo, permitindo uma avaliação de alto rendimento da altura da planta em diferentes estágios de crescimento. No entanto, talvez o próximo grande desafio seja associar a variabilidade mensurada por tais métodos, como o potencial genético dos cultivares. Os resultados por nós obtidos demonstraram os índices de vegetação são capazes de serem utilizados para discernir variedades (Tabela 12 e Figuras 5 e 6). Ainda é um desafio a predição da produtividade em larga escala, e os resultados obtidos apresentam um passo em direção a esse fim.

5. CONCLUSÕES

No experimento da safra 2021/2022, verificou-se que o processo de fertilização foliar com os micronutrientes conduziram à melhoria em apenas dois caracteres de produtividade da cultura da soja, altura e massa de cem grãos. Não foi detectado efeito na aplicação dos fertilizantes foliares na produtividade da cultura. Com relação às variedades, elas puderam ser selecionadas, e recomendadas para cultivo na região.

No experimento da safra 2022/2023, verificou-se que o processo de fertilização foliar com os micronutrientes apresentou resultados negativos na Mcg e positivos para Nv. Esses resultados são discrepantes do obtido na safra anterior e, portanto, maiores esforços são necessários para entender a relação entre esses micronutrientes e a soja. Com relação às variedades, de forma semelhante, elas puderam ser selecionadas, e recomendadas para cultivo na região.

A análise de fenotipagem com os índices de vegetação foi capaz de discernir com sucesso tanto variedades, quanto tratamentos foliares aplicados. As ANNs construídas foram capazes de prever de forma satisfatória a produtividade das variedades na cultura da soja.

Os resultados são promissores para o desenvolvimento de aplicações as quais podem ser utilizados no monitoramento e na predição da produtividade da cultura da soja.

REFERÊNCIAS

- ACHOURI, A.; BOYE, J. I.; BELANGER D. Soybean Isoflavones: efficacy of extraction condition and an effect of food type on extractability. **Food Research International**, v.38, p.1199-1204, 2005.
- ALLEN, R. G., PEREIRA, L. S., RAES, D., & SMITH, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56. **Fao**, Rome, 300(9), D05109.
- ARAUS, J.L., CAIRNS, J.E. Field high-throughput phenotyping: the new crop breeding frontier. *Trends Plant Sci.* 19 (1), 52–61, 2014. <https://doi.org/10.1016/j.tplants.2013.09.008>. ISSN 13601385.
- BORKERT, C. M.; YORINORI, J. T.; ALMEIDA, A. M. R.; FERREIRA, B. S. C.; FERREIRA, L. P.; SFREDO, G. J. Seja doutor da sua soja. *Arquivo agrônômico*, v. 66, n. 5, p. 4. 1994.
- BORNHOFEN, E.; BENIN, G.; GALVAN, D.; FABER FLORES, M. Épocas de semeadura e desempenho qualitativo de sementes de soja. **Pesquisa Agropecuária Tropical**, v. 45, n. 1, p. 46-55, 2015.
- BRAGA, A. D. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- CAKMAK, I. Enrichment of cereal grains with zinc: Agronomic or genetic biofortification? *Plant Soil*, v. 302, p 1-17. 2008
- CARNEIRO, V.Q. ; SILVA, G.N. ; CRUZ, C.D. ; CARNEIRO, P.C.S ; NASCIMENTO, M. ; CARNEIRO, J.E.S. . Artificial neural networks as auxiliary tools for the improvement of bean plant architecture. **GENETICS AND MOLECULAR RESEARCH**,v. 16, p. 16, 2017.
- CARNEIRO, Vinícius Quintão et al. Fuzzy control systems for decision-making in cultivars recommendation. **Acta Scientiarum**. Agronomy, v. 40, 2018.
- CECCHERINI, Guilherme José. Biofortificação agrônômica de rúcula (*Eruca sativa* Miller.) com ferro em cultivo hidropônico. 2022.
- COMBS, G. F. Selenium in global food systems. *British Journal of Nutrition*, Cambridge, v. 85, n. 5, p. 517-547, May 2001.
- CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da Safra Brasileira de Grãos, Brasília, DF, v. 8, safra 2022/23, n. 5, quinto levantamento, fev. 2023.
- DHONDT, S., Wuyts, N., Inzé, D., 2013. Cell to whole-plant phenotyping: the best is yet to come. *Trends in Plant Science* 18, 428-439.
- DROUIN P., ET AL. . Impact of cobalt supply on competition for nodulation in a legume–rhizobium mutualism. *PLoS ONE*, 8(1), e54506, 2013

EBERHART, S. A., & RUSSELL, W. A. (1966). Stability parameters for comparing varieties. *Crop Science*, 6(1), 36-40. doi: 10.2135/cropsci1966.0011183X000600010011x

FERREIRA, N. H.; ZIBIANI, R. M.; BASSI, W. A. L.; NEVES, C. C. dos S. das; CARVALHO, J. B. de; NAKAO, A. H. FORMAS DE APLICAÇÃO DE MICRONUTRIENTES NA CULTURA DA SOJA INOCULADA COM DOSES DE *Bradyrhizobium*. UNIFUNEC CIENTÍFICA MULTIDISCIPLINAR, Santa Fé do Sul, São Paulo, v. 11, n. 13, p. 1–14, 2022. DOI: 10.24980/ucm.v11i13.5545. Disponível em: <https://seer.unifunec.edu.br/index.php/rfc/article/view/5545>. Acesso em: 22 fev. 2024.

FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. Estimativa de covariância inversa esparsa com o laço gráfico. *Bioestatística*, v. 9, n. 3, pág. 432-441, 2008.

FRITSCHÉ-NETO, R.; BORÉM, A. Fenômica: como a fenotipagem de próxima geração está revolucionando o melhoramento de plantas. 1 ed. Viçosa, MG:UFV, 2016

GALDINO, P. L. F. et al. Cobalto e molibdênio aplicados via foliar no crescimento vegetativo e na produtividade da soja Cobalt and molybdenum applicated via leaf in the growth vegetative and yield of soybean. 2020.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**: adaptive computation and machine learning. MIT press, 2016.

GRIS, E.P. CONTE, A.M. OLIVEIRA, F.F. Produtividade da soja em resposta à aplicação de molibdênio e inoculação com *Bradyrhizobium japonicum*. **Revista Brasileira Ciência Solo**, Viçosa, v.29, p.151-155, 2005.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New York: Prentice Hall, 2008.

HERRERO-HUERTA, M., Rodriguez-Gonzalvez, P., Rainey, K.M. Yield prediction by machine learning from UAS-based mulit-sensor data fusion in soybean. *Plant Methods* 16, 78. 2020. <https://doi.org/10.1186/s13007-020-00620-6>. ISSN 17464811.

KABATA-PENDIAS, A. Trace elements in soils and plants. 4 ed. New York: CRC Press, 2011. 548p.

KIM, E. H.; RO, H. M.; KIM, S. L.; KIM, H. S.; I. M. CHUNG. Analysis of isoflavone, phenolic, soyasapogenol, and tocopherol compounds in soybean [*Glycine max* (L.) Merrill] germplasms of different seed weights and origins. **Journal of agricultural and food chemistry**, v. 60, n. 23, p. 6045-6055, 2012.

MARSCHNER H. Mineral Nutrition of Higher Plants. Academic Press. 2012

MARTINS, E. R.; BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H.; DUTRA, G. C. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, vol. 11, n. 1, pp. 33-38, 2016.

Matias FI, Caraza-Harter MV, Endelman JB. FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. *The Plant Phenome J.* 2020; e 20005. <https://doi.org/10.1002/ppj2.20005>

MENDEL R.R., HÄNSCH R. (2002). Molybdoenzymes and molybdenum cofactor in plants. *Journal of Experimental Botany*, 53(375), 1689-1698. 2002

MORAES, L. M. F. Translocação de Co e Mo aplicados em diferentes épocas na cultura da soja. 2006. 43 p. Dissertação de Mestrado. **Universidade Federal de Uberlândia**. Uberlândia, MG, 2006.

OLIVEIRA, Flavio Sarmiento de. Biofortificação agronômica do milho verde com ferro e zinco. 2019.

Olivoto T, Lúcio AD (2020). “metan: An R package for multi-environment trial analysis.” *Methods in Ecology and Evolution*, 11(6), 783-789. doi:10.1111/2041-210X.13384.

ÖZÇELİK R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT JR., H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**. Elsevier, v. 91, n. 3, p. 742-753, 2010.

PIMENTEL, D.; PATZEK, T. W. Ethanol production using corn, switchgrass, and wood; biodiesel production using soybean and sunflower. **Natural Resources Research**, v. 14, n. 1, p. 65-76, 2005.

PIMENTEL-GOMES, F. Curso de Estatística Experimental. São Paulo: USP/ESALQ, 1985, 467 p.

PRADO, E.V. Uso de características espectrais para detecção precoce da antracnose e murcha-de-fusário em feijoeiro-comum. 2015. Tese. Universidade Federal de Viçosa.

QUAGGIO, J. A.; RAIJ, B. V.; MALAVOLTA, E. Alternative use of the SPM – buffer solution to determine lime requirement of soil. **Communications in Soil Science and Plant Analysis**, v.16, p.245-260, 1985.

R Core Team (2024). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RAIJ, B. V.; ANDRADE, J. C.; CANTARELA, H.; QUAGGIO, J. A. **Análise Química para fertilidade de solos tropicais**. (Ed.), Campinas, Instituto Agronômico & Fundação IAC, 2001. 285 pp.

RAIJ, B. V.; ANDRADE, J. C.; CANTARELA, H.; QUAGGIO, J. A. **Análise Química para fertilidade de solos tropicais**. (Ed.), Campinas, Instituto Agronômico & Fundação IAC, 2001. 285 pp.

RAIJ, B. van; CANTARELLA, H. QUAGGIO, J. A.; FURLANI, A. M. C. Recomendação de adubação e calagem para o Estado de São Paulo. 2ª ed. Instituto Agrônomo de Campinas -IAC.Campinas. 1997. 285p. (Boletim Técnico, 100).

Rosado, R. D. S., Cruz, C. D., Barili, L. D., de Souza Carneiro, J. E., Carneiro, P. C. S., Carneiro, V. Q., Silva, J. T., Nascimento, M. (2020). Artificial Neural Networks in the Prediction of Genetic Merit to Flowering Traits in Bean Cultivars. *Agriculture*, 10(12), 638.

ROTH, L., HUND, A., AASEN, H. PhenoFly Planning Tool: flight planning for high-resolution optical remote sensing with unmanned aerial systems. *Plant Methods* 14, 116. 2018. <https://doi.org/10.1186/s13007-018-0376-6>.
<https://shiny.usys.ethz.ch/PhenoFlyPlanningTool/>.

RUSSELL, S., BINDER, J., KOLLER, D., & KANAZAWA, K. (1995, August). Local learning in probabilistic networks with hidden variables. In *IJCAI* (Vol. 95, pp. 1146-1152).

SADRAS, V.O., REBETZKE, G.J., EDMEADE, G.O., 2013. The phenotype and the components of phenotypic variance of crop traits. *Field Crops Research* 154, 255-259.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; CUNHA, T. J. F.; OLIVEIRA, J. B. **Sistema brasileiro de classificação de solos**. 3.ed. Brasília: Embrapa, 2013. 353p.

SCHAUB, J.; MCARTHUR, W. C.; HACKLANDER, D.; GLAUBER, J.; LEATH, M.; DOTY, H.; The U.S. soybean industry. commodity economics division. economic research service. U.S. **Department of Agriculture. Agricultural Economic Report**, v. 588, 1988.

SFREDO, G., J.; BORKERT, C., M. Deficiência e toxidades de nutrientes em plantas de soja. Londrina: EMBRAPA Soja, 2004. 44p. (Documentos, 231)

SFREDO, G.J.; OLIVEIRA, M.C.N. Soja: molibdênio e cobalto. **Embrapa Soja- Documentos (INFOTECA-E)**, 2010.

Silva, A. F. da, Schoninger, E. L., Monteiro, S., Caione, G., Carvalho, M. A. C. de, Dalchiavon, F. C., & Noetzold, R. (2011). Inoculação com bradyrhizobium e formas de aplicação de Cobalto e Molibdênio na cultura da soja. *Agrarian*, 4(12), 98–104. Recuperado de <https://ojs.ufgd.edu.br/index.php/agrarian/article/view/829>

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. 1. ed. São Paulo: ArtLiber Editora, 2010.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

VIANNA, V. F.; UNÊDA-TREVISOLI, S. H.; BIZARI, E. H.; FERRAUDO, A. S.; DI MAURO, A. O. Divergência genética e fenotípica de genótipos precoces de soja a partir de dados moleculares e agronômicos. **Ciência & Tecnologia Fatec-JB**, v. 4, n. Supl., 2013.

VIEIRA, C. R.; CABRAL, L. C.; PAULA, A. C. O. Composição centesimal e conteúdo de aminoácidos, ácidos graxos e minerais de seis cultivares de soja destinadas à alimentação humana. **Pesquisa Agropecuária Brasileira**, v. 34, n. 7, p.1277-1283, 1999.

WALTER, A., Liebisch, F., Hund, A., 2015. Plant phenotyping: from bean weighing to image analysis. **Plant Methods** 11, 14.

XAVIER, A.; HALL, B.; HEARST, A. A.; CHERKAUER, K. A. A.; RAINEY, K. M. Genetic architecture of phenomic-enabled canopy coverage in *Glycine max*. *Genetics*, v. 206, n. 2, p. 1081-1089, 2017.

Yu, N., Li, L., Schmitz, N., Tian, L.F., Greenberg, J.A., Diers, B.W. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sens. Environ.* 187, 91–101., 2016. <https://doi.org/10.1016/j.rse.2016.10.005>. ISSN 00344257.

ZHOU, Z.; JIANG, Y.; WANG, Z.; GOU, Z.; LYU, J.; LI, W.; FANG, C. Resequencing 302 wild and cultivated accessions identifies genes related to domestication and improvement in soybean. *Nature biotechnology*, v. 33, n. 4, p. 408, 2015.

ZIBIANI, R. M.; BASSI, W. A. L.; FERREIRA, N. H.; NEVES, C. C. dos S. das; CARVALHO, J. B. de; NAKAO, A. H. Inoculação com *Bradyrhizobium* via Sulco de Plantio e Formas de Aplicação de Cobalto e Molibdênio na Cultura da Soja de Segundo Ano. *Ensaio e Ciência C Biológicas Agrárias e da Saúde*, [S. l.], v. 27, n. 2, p. 197–203, 2023. DOI: 10.17921/1415-6938.2023v27n2p197-203. Disponível em: <https://ensaioseciencia.pgsscogna.com.br/ensaioeciencia/article/view/10506>. Acesso em: 22 fev. 2024.

ZUFFO, A. M.; REZENDE, P. M.; BRUZI, A. T.; OLIVEIRA, N. T.; SOARES, I. O.; NETO, G. F. G.; CARDILLO, B. E. S.; SILVA, L. O. Coinoculação de *Bradyrhizobium japonicum* e *Azospirillum brasilense* na cultura da soja. **Revista de Ciências Agrárias**, v. 38, n. 1, p. 87-93, 2015.