

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

EDUARDO TAGLIATI DE OLIVEIRA

DETECÇÃO DE FÓSFORO FOLIAR NA CULTURA DA BATATA ATRAVÉS DE
IMAGENS MULTIESPECTRAIS

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia, Campus Monte Carmelo, como parte das exigências para obtenção do título de “Mestre”.

Orientadora:

Prof^a. Dr^a. Renata Castoldi

Coorientador:

Prof. Dr. George Deroco Martins

MONTE CARMELO
MINAS GERAIS - BRASIL
2025

EDUARDO TAGLIATI DE OLIVEIRA

DETECÇÃO DE FÓSFORO FOLIAR NA CULTURA DA BATATA ATRAVÉS DE
IMAGENS MULTIESPECTRAIS

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia, Campus Monte Carmelo, como parte das exigências para obtenção do título de “Mestre”.

Banca examinadora

Prof^a. Dr^a. Renata Castoldi - Universidade Federal de Uberlândia - UFU

Prof^a. Dr^a. Cinara Xavier de Almeida - UFU

Prof. Dr. Hamilton César de Oliveira Charlo – IFTM, Campus Uberaba

Prof^a. Dr^a. Renata Castoldi
ICIAG-UFU

MONTE CARMELO
MINAS GERAIS - BRASIL
2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

O48 Oliveira, Eduardo Tagliati de, 1990-
2025 Detecção de Fósforo Foliar na Cultura da Batata Através de
Imagens Multiespectrais [recurso eletrônico] / Eduardo Tagliati de
Oliveira. - 2025.

Orientadora: Renata Castoldi.
Coorientador: George Deroco Martins.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Agricultura e Informações Geoespaciais.
Modo de acesso: Internet.
DOI <http://doi.org/10.14393/ufu.di.2025.674>
Inclui bibliografia.
Inclui ilustrações.

1. Agronomia. I. Castoldi, Renata ,1982-, (Orient.). II. Martins,
George Deroco,1987-, (Coorient.). III. Universidade Federal de
Uberlândia. Pós-graduação em Agricultura e Informações
Goespaciais. IV. Título.

CDU: 631

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074


UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Agricultura e Informações
Geoespaciais

Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-MG, CEP 38.500-000
Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br


ATA DE DEFESA - PÓS-GRADUAÇÃO

| | | | | | |
|------------------------------------|--|-----------------|----------|-----------------------|----------|
| Programa de Pós-Graduação em: | Agricultura e Informações Geoespaciais | | | | |
| Defesa de: | Dissertação de Mestrado Acadêmico | | | | |
| Data: | 18/11/2025 | Hora de início: | 13h00min | Hora de encerramento: | 15h10min |
| Matrícula do Discente: | 32222AIG011 | | | | |
| Nome do Discente: | Eduardo Tagliati de Oliveira | | | | |
| Título do Trabalho: | Detecção de Fósforo Foliar na Cultura da Batata Através de Imagens Multiespectrais | | | | |
| Área de concentração: | Informações geoespaciais e tecnologias aplicadas à produção agrícola | | | | |
| Linha de pesquisa: | Sistemas Integrados de Produção Vegetal | | | | |
| Projeto de Pesquisa de vinculação: | Caracterização de genótipos, manejo de hortaliças e detecção de resistência através de imagens multiespectrais | | | | |

Reuniu-se em sala virtual a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, composta pela Profª. Drª. Renata Castoldi (Universidade Federal de Uberlândia-UFU), orientadora do candidato, Profª. Drª. Cinara Xavier de Almeida (Universidade Federal de Uberlândia-UFU), e Prof. Dr. Hamilton César de Oliveira Charlo (Instituto Federal do Triângulo Mineiro - IFTM).

Iniciando os trabalhos o presidente da mesa, Dra. Renata Castoldi, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu ao discente a palavra para a exposição do seu trabalho. A duração da apresentação do discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir a senhora presidente concedeu a palavra, pela ordem sucessivamente, aos(as) examinadores(as), que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Renata Castoldi, Professor(a) do Magistério Superior**, em 18/11/2025, às 15:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cinara Xavier de Almeida, Professor(a) do Magistério Superior**, em 18/11/2025, às 15:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Hamilton César de Oliveira Charlo, Usuário Externo**, em 21/11/2025, às 10:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6855790** e o código CRC **599825DB**.

AGRADECIMENTOS

A Deus Pai, ao Nosso Senhor Jesus Cristo, ao Espírito Santo, à Virgem Santíssima e ao meu Anjo da Guarda.

Aos meus avós, Marlene Ricardo de Oliveira e Sebastião Antônio de Oliveira, cuja dedicação e apoio incondicional foram fundamentais ao longo da minha trajetória.

À minha noiva, Larissa Aparecida Santos de Moraes, por todo o apoio.

À Professora Dr^a. Renata Castoldi pela orientação, dedicação e paciência, pois não mediou esforços para a realização deste trabalho.

Ao Professor Dr. George Deroco Martins pela orientação, disponibilidade e ensinamentos para o desenvolvimento da pesquisa.

À doutoranda Jordhanna Marilia Silva, membro do NUPOL (Núcleo de Pesquisa em Olericultura) pela disponibilidade e suporte.

À Universidade Federal de Uberlândia, em especial ao NUPOL pela estrutura física disponibilizada e profissionais competentes, que foram fundamentais para o desenvolvimento da pesquisa.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro – Campus Uberaba, em nome do Professor Dr. Hamilton César de Oliveira Charlo pela disponibilidade da estrutura para realização do experimento e auxílio na condução da cultura.

A todos os amigos e funcionários do campus, que tiveram participação direta ou indireta, no decorrer do desenvolvimento de toda a pesquisa.

BIOGRAFIA

Eduardo Tagliati de Oliveira nasceu em 26 de maio de 1990, na cidade de Araguari, Minas Gerais, Brasil. É filho de Silvia Helena Tagliati e Eduardo Antônio de Oliveira. Graduou-se em Agronomia pela Universidade Presidente Antônio Carlos, em Uberlândia, Minas Gerais, em dezembro de 2020. Em dezembro de 2021, concluiu a especialização em Nutrição de Plantas e Fertilidade de Solos pela Faculdade Venda Nova do Imigrante, Espírito Santo. Em agosto de 2022, ingressou no Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia (UFU) – *Campus Monte Carmelo*, sob orientação da Prof^a Dr^a Renata Castoldi, doutora em Fitotecnia (Olericultura). No âmbito do mestrado, desenvolveu a dissertação intitulada “Detecção de Fósforo Foliar na Cultura da Batata Através de Imagens Multiespectrais”.

SUMÁRIO

| | |
|------------------------------------|----|
| RESUMO | i |
| ABSTRACT | ii |
| 1 INTRODUÇÃO..... | 1 |
| 2 REFERENCIAL TEÓRICO..... | 3 |
| 3 MATERIAL E MÉTODOS..... | 23 |
| 4 RESULTADOS E DISCUSSÃO | 31 |
| 5 CONCLUSÕES | 40 |
| 6 REFERÊNCIAS BIBLIOGRÁFICAS | 41 |

RESUMO

OLIVEIRA, EDUARDO TAGLIATI DE. **Detecção de fósforo foliar na cultura da batata através de imagens multiespectrais.** 2025. 52p. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) – Universidade Federal de Uberlândia, Campus Monte Carmelo, Minas Gerais, Brasil¹.

O fósforo é um nutriente essencial ao desenvolvimento da cultura da batata (*Solanum tuberosum* L.), porém nos solos agrícolas há baixa disponibilidade natural, exigindo aplicações recorrentes. Frente ao cenário de esgotamento de reservas minerais e à necessidade de uma agricultura de precisão, o diagnóstico rápido e não destrutivo do teor foliar desse nutriente torna-se necessário, a fim de reduzir desperdícios, evitar impactos ambientais e maximizar a eficiência produtiva. Dessa forma, o presente trabalho objetivou avaliar a viabilidade do uso de imagens multiespectrais a partir da câmara Survey 3 da MAPIR, obtidas por sensoriamento remoto, para a estimativa do teor foliar de fósforo em plantas de batata. Visando promover variabilidade de dados, um experimento foi conduzido em casa de vegetação, em vasos de 13 litros, no Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro – Campus de Uberaba (IFTM), em delineamento de blocos casualizados, composto por oito tratamentos e 40 repetições. Os tratamentos consistiram em doses crescentes de P_2O_5 (0; 50; 100; 200; 400; 800; 1.600 e 3.200 kg ha^{-1}), totalizando 320 vasos, sendo cada vaso considerado como uma unidade experimental. No início da tuberização, foram capturadas imagens multiespectrais de todas as plantas, utilizando-se para isto a câmara Survey 3 da MAPIR. Logo após a obtenção das imagens, foram coletadas amostras foliares para determinação do teor de fósforo. De posse de todos os dados, calcularam-se os seguintes índices de vegetação: índice da diferença normalizada (NDVI), índice de vegetação por diferença normalizada do verde (GNDVI), índice de vegetação verde vermelho (GRVI). Modelos de regressão linear e métodos de aprendizado de máquina (Random Forest, Multilayer Perceptron e SMOREG) foram empregados para testar a capacidade preditiva dos índices e bandas combinados. Observou-se correlação inversa significativa entre o NDVI e o teor foliar de fósforo ($r = -0,71$), explicada fisiologicamente pelo efeito de diluição nutricional. O algoritmo Random Forest apresentou o melhor desempenho (RMSE relativo de 19,01%), destacando-se entre os métodos avaliados por integrar múltiplos atributos espetrais. A combinação de variáveis multiespectrais permitiu ganhos significativos de precisão na predição do fósforo em relação a abordagens univariadas, ampliando a robustez dos resultados para cenários reais. Os achados reforçam o NDVI como o principal indicador, mas evidenciam o valor agregado da integração multiespectral aliada ao aprendizado de máquina para o diagnóstico nutricional da batata em sistemas de agricultura de precisão.

Palavras-chave: *Solanum tuberosum* L., Sensoriamento remoto, Aprendizado de máquina, Índices de vegetação

¹ Orientadora: Renata Castoldi – UFU

ABSTRACT

OLIVEIRA, EDUARDO TAGLIATI DE. **Foliar phosphorus detection in potato crop through multispectral imagery.** 2025. 52p. Dissertation (Master in Agriculture and Geospatial Information) – Universidade Federal de Uberlândia, Monte Carmelo Campus, Minas Gerais, Brazil¹.

Phosphorus is an essential nutrient for the development of potato crops (*Solanum tuberosum* L.); however, its natural availability in agricultural soils is low, requiring frequent applications. Given the scenario of depleting mineral reserves and the need for precision agriculture, a rapid and non-destructive diagnosis of leaf phosphorus content becomes necessary to reduce waste, avoid environmental impacts, and maximize production efficiency. Therefore, this study aimed to evaluate the feasibility of using multispectral images obtained through remote sensing with the MAPIR Survey 3 camera to estimate leaf phosphorus content in potato plants. To generate data variability, an experiment was conducted in a greenhouse using 13-liter pots at the Federal Institute of Education, Science and Technology of the Triângulo Mineiro – Uberaba Campus (IFTM), in a randomized block design with eight treatments and 40 replications. The treatments consisted of increasing doses of P₂O₅ (0, 50, 100, 200, 400, 800, 1,600, and 3,200 kg ha⁻¹), totaling 320 pots, each considered an experimental unit. At the onset of tuberization, multispectral images of all plants were captured using the MAPIR Survey 3 camera. Immediately after imaging, leaf samples were collected to determine phosphorus content. Using the complete dataset, the following vegetation indices were calculated: normalized difference vegetation index (NDVI), green normalized difference vegetation index (GNDVI), and green–red vegetation index (GRVI). Linear regression models and machine learning methods (Random Forest, Multilayer Perceptron, and SMOreg) were employed to test the predictive ability of the indices and combined spectral bands. A significant inverse correlation was observed between NDVI and leaf phosphorus content ($r = -0.71$), physiologically explained by the nutritional dilution effect. The Random Forest algorithm showed the best performance (relative RMSE of 19.01%), standing out among the evaluated methods for its ability to integrate multiple spectral attributes. The combination of multispectral variables yielded significant gains in accuracy for phosphorus prediction when compared to univariate approaches, enhancing the robustness of the results for real-world scenarios. The findings reinforce NDVI as the primary indicator but also highlight the added value of multispectral integration coupled with machine learning for nutritional diagnosis of potato crops in precision agriculture systems.

Key-words: *Solanum tuberosum* L., remote sensing, machine learning, vegetation indices

² Orientadora: Renata Castoldi – UFU

1 INTRODUÇÃO

A batata (*Solanum tuberosum* L.) é a hortaliça mais consumida no mundo, desempenhando papel crucial na alimentação e na economia agrícola do Brasil. Em 2024, o país produziu cerca de 4,5 milhões de toneladas. Esse volume representa crescimento de aproximadamente 7,5% em relação à produção registrada em 2023 (IBGE, 2024a).

O cultivo de batata depende de práticas agronômicas eficazes e, entre elas, o manejo adequado dos nutrientes se destaca como um fator importante para a qualidade e produtividade dos tubérculos. O fósforo, nesse contexto, é um dos macronutrientes mais relevantes para o correto desenvolvimento da planta, uma vez que participa de processos fisiológicos vitais como: fotossíntese, respiração, síntese de ácidos nucleicos e formação de adenosina trifosfato (TAIZ et al., 2017). A deficiência de fósforo pode comprometer o desenvolvimento radicular, diminuir o número e o peso dos tubérculos, além de retardar a maturação, o que leva a quedas significativas na produtividade (FERNANDES et al., 2017).

A batateira é considerada uma das culturas mais exigentes em disponibilidade e quantidade de nutrientes para sua produção, sendo o nitrogênio, fósforo e potássio os nutrientes exigidos em maior quantidade pela cultura (FERNANDES, 2021). Diante disso, produtores de batata empregam altas doses de fertilizantes, muitas vezes sem o devido monitoramento da necessidade, visto que a correta nutrição da planta é fundamental para obtenção de elevadas produtividades e qualidade do produto colhido.

Embora o fósforo seja abundante no solo, sua disponibilidade para as plantas é limitada, especialmente devido à sua rápida fixação em formas insolúveis, principalmente em solos tropicais ácidos e naturalmente férteis (NOVAIS; SMYTH, 1999). Essa característica aumenta a dependência dos fertilizantes fosfatados, tornando o manejo desse nutriente um desafio tanto agronômico, quanto ambiental.

Além dos desafios técnicos e ambientais, o manejo do fósforo na agricultura enfrenta uma limitação estratégica global. O fósforo é um recurso mineral finito, cuja principal fonte para fertilizantes – as rochas fosfáticas – está concentrada em poucos países, tornando-o um insumo estratégico e sujeito a oscilações de preço e disponibilidade (ILLAKWAHHI; VEGI; SRIVASTAVA, 2024). A expectativa de escassez e os impactos ambientais associados ao uso excessivo de fertilizantes têm impulsionado a busca por alternativas, como a reciclagem de resíduos orgânicos, o uso de microrganismos solubilizadores de fósforo e a adoção de práticas de manejo de precisão, que visam otimizar a eficiência de uso desse nutriente (GILBERT, 2009).

Nesse contexto, tecnologias que permitam o monitoramento preciso da disponibilidade de fósforo no campo são essenciais para o desenvolvimento de sistemas agrícolas mais resilientes e sustentáveis. Métodos tradicionais, como a análise foliar, embora eficazes, apresentam limitações em termos de tempo, custo e destrutividade, dificultando sua aplicação em larga escala e em tempo real (FERNANDES et al., 2017). Assim sendo, o avanço das tecnologias de sensoriamento remoto tem se mostrado promissor para a agricultura de precisão (SISHODIA; RAY; SINGH, 2020).

Utilizando imagens multiespectrais obtidas por sensores a bordo de satélites, aviões ou drones, o sensoriamento remoto pode ser uma forma rápida, não destrutiva e abrangente de monitorar o estado fisiológico e nutricional das plantas. As variações nas respostas espectrais das folhas, analisadas em diferentes bandas do espectro eletromagnético, podem ser associadas a alterações metabólicas causadas pela deficiência de fósforo. Índices espectrais como o NDVI (Normalized Difference Vegetation Index) têm sido amplamente utilizados para estimar características biofísicas e bioquímicas das culturas, permitindo monitoramento contínuo e dinâmico do status nutricional (XUE; SU, 2017).

Em estudo conduzido com rúcula (*Eruca sativa*), Silva (2021) demonstrou que o processamento digital de imagens multiespectrais foi eficaz na estimativa do teor de nitrogênio foliar, com destaque para o uso de índices espectrais como NDVI e GNDVI, que apresentaram correlações significativas com os dados laboratoriais. Essa abordagem possibilitou a distinção entre diferentes níveis de adubação nitrogenada, reforçando o potencial do sensoriamento remoto para o manejo nutricional em hortaliças de ciclo curto.

A aplicação dessas tecnologias na gestão da cultura da batata pode otimizar o uso de fertilizantes, reduzindo custos, aumentando a produtividade e minimizando os impactos ambientais. Pesquisas recentes indicam que a análise multiespectral é capaz de identificar deficiências de fósforo antes que sinais visuais apareçam, permitindo intervenções mais rápidas e eficazes na fertilização (BARBEDO, 2019). Portanto, a integração do sensoriamento remoto no manejo nutricional representa um avanço significativo na sustentabilidade da produção de batata, equilibrando benefícios econômicos com a preservação ambiental.

Ma et al. (2023) integraram índices de vegetação (VIs), cobertura vegetal fracional (FVC) e métricas de textura baseadas em matriz de co-ocorrência de níveis de cinza (GLCM) extraídas de imagens multiespectrais para estimar o conteúdo de potássio nas plantas de batata. Os autores conseguiram alcançar coeficientes de determinação (R^2) de até 0,84 em certas

fases de crescimento, mostrando que a fusão de diferentes tipos de informação (espectral + estrutural) pode aumentar significativamente a acurácia da predição nutricional.

Apesar dos avanços na utilização de imagens multiespectrais na agricultura de precisão, a literatura ainda apresenta escassez de estudos voltados à detecção do teor de fósforo foliar em plantas de batata por meio dessa tecnologia. Nesse contexto, o presente trabalho teve como objetivo investigar o potencial das imagens multiespectrais para a detecção do fósforo foliar na cultura da batata com o auxílio de índices espectrais e aprendizado de máquina.

2 REFERENCIAL TEÓRICO

2.1 A cultura da batata

A cultura da batata (*Solanum tuberosum* L.) tem origem nos Andes centrais da América do Sul, principalmente nas regiões atuais do Peru e da Bolívia, onde seu cultivo remonta a aproximadamente 8.000 anos. Povos indígenas desenvolveram técnicas agrícolas complexas para a cultura do tubérculo, tornando-o base alimentar ao lado de outros produtos nativos, como o milho (CARTAY; DÁVILA, 2020).

A batata é uma planta herbácea, anual, pertencente à família Solanaceae, a qual possui caules aéreos e caules subterrâneos modificados denominados tubérculos. O sistema radicular é predominantemente superficial e delicado, com a maioria das raízes concentradas nos primeiros 30 cm do solo, embora possam se estender mais profundamente em condições favoráveis (DEGUCHI et al., 2015). O tubérculo é essencialmente um caule subterrâneo bem desenvolvido que serve como órgão de armazenamento, acumulando carboidratos e outros nutrientes (HILL et al., 2021).

A batata ocupa posição estratégica no sistema alimentar global e desempenha papel fundamental no fortalecimento da segurança alimentar e na redução da pobreza, contribuindo para os quatro pilares da segurança alimentar: disponibilidade, acesso, utilização e estabilidade (FAO, 2025). Por possuir elevada produtividade por hectare, adaptação a diversos tipos de solo e clima, além de ciclo de cultivo curto, a batata representa solução estratégica para regiões com escassez de terra agrícola e recursos naturais limitados (FAO, 2025).

Os tubérculos possuem diversos benefícios à saúde humana devido a serem ricos em fibras, polifenóis, vitaminas e amido. Estudos clínicos com humanos e animais indicam que a batata possui propriedades antioxidantes, antibacterianas, antinflamatórias, antiobesidade, anticancerígenas e antidiabéticas (CAMIRE; KUBOW; MAZZA, 2009). Esses efeitos fisiológicos são especialmente evidentes quando a batata é consumida com preparo adequado e dentro de contextos dietéticos equilibrados.

A área cultivada de batata no Brasil atingiu em abril de 2024, 131,2 mil hectares, com aumento de 2,1 % na área cultivada em relação ao ano anterior (IBGE, 2024a). A produção nacional do tubérculo, considerando as três safras anuais (verão, outono e inverno), foi estimada em aproximadamente 4,5 milhões de toneladas, o que representa aumento de 1,1% em relação ao ano anterior (IBGE, 2024b). O estado de Minas Gerais lidera a produção nacional, respondendo por aproximadamente 31% do total, com destaque para a região do Triângulo Mineiro e Alto Paranaíba, consideradas as principais áreas produtoras da América do Sul, devido ao clima favorável, mecanização, apoio tecnológico e proximidade com indústrias e mercados consumidores (ABBA, 2023).

2.2.1 Fósforo

O fósforo é um macronutriente essencial ao desenvolvimento das plantas, participando ativamente de processos bioquímicos como a transferência de energia, formação de biomoléculas e síntese de ácidos nucleicos. De acordo com Heinrich (1966), nos solos tropicais brasileiros, como Latossolos e Neossolos, a disponibilidade de fósforo é severamente limitada, principalmente em razão da elevada capacidade de adsorção por óxidos de ferro e alumínio, o que o torna quimicamente indisponível para absorção pelas raízes. Essa característica exige aplicações constantes de fertilizantes fosfatados para suprir as necessidades das culturas, o que eleva os custos de produção (SANTOS et al., 2021).

A principal fonte mineral de fósforo explorada no Brasil é a apatita, extraída de rochas ígneas. No entanto, o seu beneficiamento apresenta alto custo e complexidade técnica, o que compromete a competitividade nacional. Em função disso, o país é amplamente dependente de importações de fertilizantes fosfatados, oriundos majoritariamente de países como Marrocos, China e Rússia. Atualmente, apenas cerca de 20% da demanda interna é atendida

por produção nacional, evidenciando situação de vulnerabilidade econômica e estratégica do setor agrícola (WITHERS et al., 2018).

Conforme Dechen e Nachtigall (2007), o fósforo nas plantas atua em processos metabólicos fundamentais, como a fotossíntese, a respiração celular, a divisão celular e o crescimento radicular. Além disso, compõe estruturas essenciais como o DNA, RNA, ATP e fosfolipídios. A deficiência desse nutriente resulta em sintomas visuais, como folhas com coloração roxa, atrofiamento do crescimento e redução do sistema radicular, impactando negativamente a produtividade das lavouras.

Segundo Soares et al. (2017), a baixa mobilidade e disponibilidade do fósforo nos solos tropicais brasileiros decorre da sua forte fixação por minerais presentes em ambientes ácidos. Essa condição compromete o aproveitamento agronômico do fósforo aplicado e eleva os custos com fertilizantes, constituindo um desafio significativo para o manejo sustentável do nutriente nas regiões agrícolas do país.

De acordo com Pavinato et al. (2020), uma grande parte do fósforo aplicado em décadas anteriores permanece acumulada no solo na forma de “fósforo legado” (legacy P), que pode ser reaproveitado por meio de estratégias de manejo adequadas. Estima-se que os solos agrícolas brasileiros contenham entre 33 e 106 teragramas de fósforo residual. Para mobilizar esse estoque, têm-se recomendado práticas como o uso de cultivares com maior eficiência na absorção de fósforo, rotação de culturas, calagem e aplicação de microrganismos solubilizadores.

O uso excessivo e desordenado de fertilizantes fosfatados pode ocasionar impactos ambientais significativos, como a eutrofização de ambientes aquáticos. O excesso de fósforo pode ser transportado por meio de processos erosivos ou lixiviação, contribuindo para a proliferação de algas e consequente redução dos níveis de oxigênio nos corpos hídricos. Além disso, certos fertilizantes fosfatados podem conter elementos potencialmente tóxicos, como cádmio e urânio, que representam riscos à saúde ambiental e humana (AHMAD et al., 2023).

Dessa forma, a gestão eficiente do fósforo deve ser tratada como uma prioridade estratégica (WITHERS et al., 2018). Isso envolve o uso racional de fertilizantes, o desenvolvimento de tecnologias que promovam a reciclagem do nutriente e a valorização de fontes alternativas. A integração entre inovação tecnológica e boas práticas agronômicas é essencial para garantir uma agricultura produtiva, ambientalmente sustentável e economicamente resiliente no Brasil.

2.2.2 Importância do fósforo no cultivo da batata

O fósforo desempenha funções vitais no metabolismo da batateira, participando de processos fundamentais que determinam o crescimento, desenvolvimento e produtividade da cultura. Esse elemento interfere diretamente na síntese de amido nos tubérculos, processo essencial para a formação e qualidade dos órgãos de reserva. Além disso, o fósforo é o nutriente que mais frequentemente limita a produtividade da cultura, sendo indispensável para obtenção de rendimentos comerciais competitivos (FERNANDES; SORATTO, 2012).

Aliado a isso, o nutriente pode influenciar outras características ligadas à qualidade e produtividade, tais como: tamanho, peso específico, porcentagem de matéria seca, teor de amido, ácido ascórbico e proteína. Estudos conduzidos por Tarouco et al. (2021) demonstraram elevação da taxa de assimilação líquida de CO₂ e da condutância estomática em clones de batata adubados com 70 a 280 kg ha⁻¹ de P₂O₅, confirmando o papel do nutriente na eficiência fotossintética.

De acordo com Fernandes et al. (2016), mesmo em áreas com teores mais elevados de fósforo disponível no solo, é comum observar a aplicação desse nutriente, com o objetivo de aumentar a produtividade e o tamanho dos tubérculos de batata. Da mesma forma, o manejo correto desse nutriente potencializa não só o desenvolvimento inicial das plantas e a tuberização, mas também influencia positivamente nos atributos qualitativos dos tubérculos, como massa média, firmeza e teor de amido.

Em solos com baixa disponibilidade de fósforo (cerca de 14 mg dm⁻³), a aplicação de doses elevadas de P₂O₅ pode resultar em aumentos expressivos na produtividade de tubérculos comerciais, chegando a valores superiores a 370% (FERNANDES et al., 2016).

A aplicação de adubação fosfatada demonstra efeitos decisivos na qualidade e rendimento dos tubérculos de batata. Segundo Fernandes et al. (2016), a fertilização com fósforo eleva a massa média dos tubérculos, aumenta sua firmeza e o teor de amido, além de reduzir a concentração de açúcares redutores — aspecto crítico para a indústria de fritura, ao minimizar escurecimento e melhorar a textura final. Em solos de baixa fertilidade, especialmente, esses benefícios são ainda mais evidentes devido ao estímulo de crescimento radicular e produção de biomassa.

Fernandes et al. (2017) confirmam que o fornecimento de fósforo em solos com baixo, médio ou alto nível de disponibilidade promove maior absorção de nutrientes como nitrogênio, potássio, cálcio e magnésio. Essa resposta está associada ao incremento na

biomassa e no acúmulo de matéria seca, e particularmente é notável em solos deficientes em fósforo, onde a absorção de nutrientes pode ser de 3 a 4 vezes maior, quando aplicado doses de até 500 kg ha⁻¹ de P₂O₅ (FERNANDES et al., 2017).

Por outro lado, Fernandes e Soratto (2012) enfatizam que, em solos com alta disponibilidade de fósforo, doses elevadas podem provocar absorção em excesso do nutriente, diminuindo a eficiência de utilização e, até mesmo, prejudicando a absorção de micronutrientes como manganês e zinco.

2.3 Sensoriamento Remoto

O sensoriamento remoto teve suas primeiras manifestações conceituais em 1858, sendo inicialmente associado à utilização de câmeras fotográficas acopladas a balões para a captura de imagens aéreas. A evolução conceitual do sensoriamento remoto ganhou impulso significativo com o desenvolvimento da tecnologia espacial nas décadas de 1950 e 1960. O lançamento do Sputnik em 1957 pela União Soviética marcou o início da era espacial e abriu novas possibilidades para a observação da Terra a partir de plataformas orbitais (NOVO, 2010).

A American Society for Photogrammetry and Remote Sensing (ASPRS) define sensoriamento remoto como a arte, ciência e tecnologia de obter informações confiáveis sobre objetos físicos e o ambiente, por meio do processo de registro, medição e interpretação de imagens e representações digitais de padrões de energia derivados de sistemas sensores sem contato (ASPRS, 1989).

Já Novo (2010) define sensoriamento remoto como a utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados colocados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que o compõem.

O sensoriamento remoto transcende suas aplicações técnicas imediatas, estabelecendo-se como ferramenta fundamental para o entendimento e monitoramento dos processos terrestres em múltiplas escalas temporais e espaciais. Essa tecnologia permite a observação sistemática e contínua da superfície terrestre, fornecendo dados essenciais para diversas áreas do conhecimento científico e aplicado (JENSEN, 2009).

A perspectiva multitemporal constitui outro aspecto fundamental da importância do sensoriamento remoto. A capacidade de obter dados sobre uma mesma área em diferentes

momentos, permite a análise de mudanças e tendências ao longo do tempo, possibilitando estudos de dinâmica temporal de fenômenos naturais e antrópicos. Essa característica é particularmente relevante para o monitoramento de mudanças climáticas, desmatamento, expansão urbana e outros processos de transformação territorial (WEISS; JACOB; DUVEILLER, 2020).

A aplicação do sensoriamento remoto na agricultura representa uma das mais significativas e bem-sucedidas utilizações dessa tecnologia, transformando fundamentalmente as práticas de manejo agrícola e contribuindo para o desenvolvimento da agricultura de precisão. Essa aplicação baseia-se na capacidade dos sensores remotos de detectar e quantificar características biofísicas das culturas agrícolas através da análise da radiação eletromagnética refletida ou emitida pela vegetação (SISHODIA; RAY; SINGH, 2020).

O monitoramento do desenvolvimento das culturas constitui uma das principais aplicações do sensoriamento remoto na agricultura. Por meio da análise de índices de vegetação, é possível acompanhar o crescimento das plantas, avaliar sua condição fitossanitária e identificar áreas com problemas de desenvolvimento. Esses índices exploram as diferenças características na reflectância da vegetação saudável entre as regiões do vermelho e infravermelho próximo do espectro eletromagnético (LIMA et al., 2012).

A detecção precoce de estresses bióticos e abióticos representa outra aplicação importante do sensoriamento remoto na agricultura. A capacidade de identificar problemas como deficiências nutricionais, estresse hídrico, ataques de pragas e doenças, antes que se tornem visualmente evidentes, permite intervenções mais rápidas e eficazes, reduzindo perdas de produtividade. Estudos demonstram que alterações na reflectância espectral podem ser detectadas dias ou semanas antes do aparecimento de sintomas visíveis (BARBEDO, 2019).

O sensoriamento remoto também contribui para a sustentabilidade agrícola por meio do monitoramento de práticas conservacionistas, avaliação da qualidade ambiental das propriedades rurais e verificação do cumprimento de regulamentações ambientais. Sistemas de monitoramento baseados em sensoriamento remoto são utilizados para verificação de áreas de preservação permanente, reserva legal e práticas de manejo sustentável (RUDORFF et al., 2011).

As ondas eletromagnéticas constituem um dos fenômenos físicos mais fundamentais da natureza e representam oscilações formadas por campos elétricos e magnéticos variáveis que se propagam tanto no vácuo quanto em meios materiais, transportando energia sem transportar matéria. A radiação eletromagnética (REM) é definida como uma forma de

energia que se propaga através de ondas eletromagnéticas, consistindo em campos elétricos e magnéticos que oscilam perpendicularmente entre si e se movem em linha reta a uma velocidade constante (INPE, 2005).

O espectro eletromagnético representa o intervalo completo de todas as possíveis frequências da radiação eletromagnética, estendendo-se desde as ondas de baixa frequência até as de alta frequência. Esse espectro é tradicionalmente dividido em sete categorias principais: ondas de rádio, micro-ondas, infravermelho, luz visível, ultravioleta, raios X e raios gama, cada uma com características específicas de comprimento de onda, frequência e energia associada (UTFPR, 2019). As ondas de rádio apresentam os maiores comprimentos de onda e as menores frequências, sendo utilizadas para comunicações, TV e rádio, enquanto os raios gama possuem os menores comprimentos de onda e as maiores frequências, encontrando aplicações em medicina nuclear e astronomia (UTFPR, 2016). A luz visível, que representa apenas uma pequena fração do espectro eletromagnético, compreende comprimentos de onda entre 400nm e 700 nm, correspondendo às frequências necessárias para a fotossíntese das plantas.

As ondas eletromagnéticas no estudo de vegetação fundamentam-se nos princípios do sensoriamento remoto, técnica que permite obter informações sobre plantas sem contato físico direto, utilizando a radiação eletromagnética como elo de comunicação entre os objetos vegetais e os sensores remotos (INPE, 2018). Essa técnica explora a assinatura espectral única de cada tipo de vegetação, a qual é definida pelo padrão específico de absorção, reflexão e transmissão da radiação eletromagnética. Essa característica permite distinguir diferentes espécies vegetais e avaliar sua condição fisiológica por meio da espectroscopia de imagem, que capta variações sutis na resposta espectral das plantas (GAMON et al., 2019). A interação entre a radiação eletromagnética e a vegetação ocorre por meio de três processos fundamentais: absorbância, onde a planta absorve radiação eletromagnética especialmente nas bandas azul (400-500 nm) e vermelha (630-690 nm) para fotossíntese; reflectância, caracterizada pela reflexão da radiação não absorvida, particularmente intensa no infravermelho próximo (700-1300 nm); e transmitância, que representa a transmissão da radiação através das folhas superiores para os terços médios e inferiores da planta (Figura 1) (INPE, 2005).

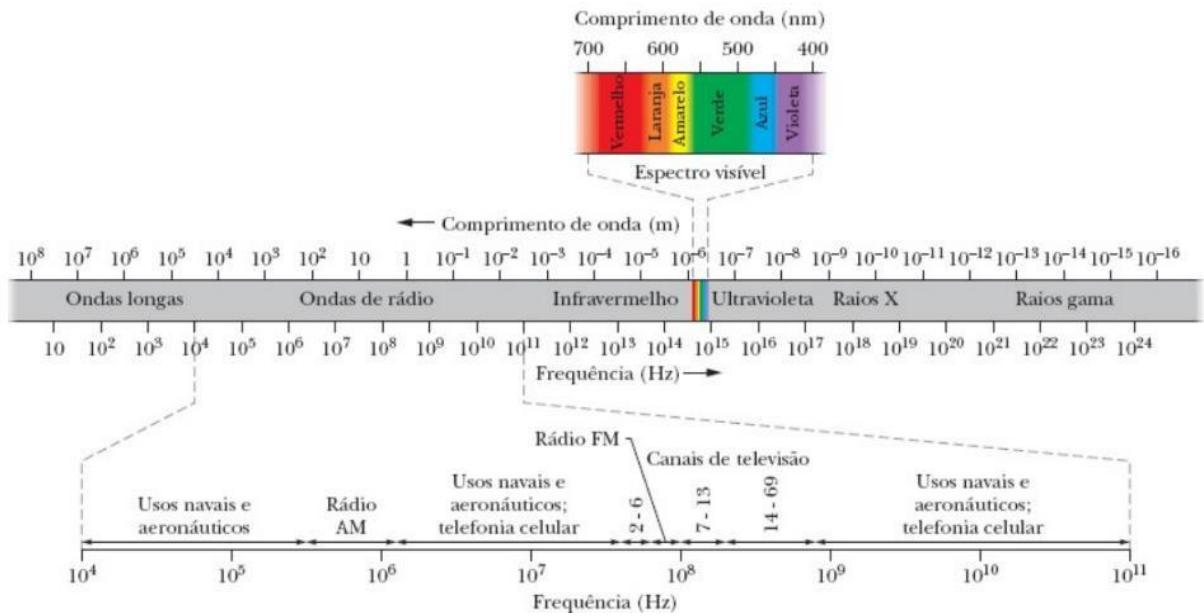


FIGURA 1. Representação do espectro eletromagnético. Fonte: Halliday; Resnick e Walker (2016).

O uso de Veículos Aéreos Não Tripulados (VANTS) na agricultura tem expandido significativamente as possibilidades de aplicação do sensoriamento remoto. Essas plataformas oferecem maior flexibilidade operacional, resolução espacial ultra alta e custos relativamente baixos para propriedades de pequeno e médio porte. VANTS equipados com sensores multiespectrais, hiperespectrais e termais permitem monitoramento detalhado de culturas, detecção de plantas daninhas, avaliação da eficiência de irrigação e mapeamento de variabilidade em talhões (KHANAL et al., 2017).

Durante duas safras consecutivas (2021-2022), Camenzind e Yu (2024) exploraram a fenotipagem de trigo de inverno europeu por meio de imagens multiespectrais capturadas por VANTS. As imagens foram adquiridas em até 22 pontos temporais ao longo do ciclo fenológico, desde o perfilhamento até a colheita, e analisadas com base em reflectâncias de banda única, índices de vegetação e métricas de textura derivadas da matriz de coocorrência de níveis de cinza. Segundo os autores, o índice NDRE apresentou as melhores previsões de rendimento com RMSE de 49,1 g m⁻² e 60,6 g m⁻², reforçando a eficácia da abordagem para avaliação antecipada da produtividade.

Utilizando imagens RGB e multiespectrais obtidas por VANTS ao longo do ciclo do trigo, diversos estudos avaliaram parcelas experimentais para estimar características fenotípicas e agronômicas. A abordagem incluiu extração de índices de vegetação, medidas de cobertura do dossel, altura das plantas via modelos de superfície digital, além de parâmetros

texturais. Como destacaram Khaki e Wang (2019), a predição do peso de grãos por meio de redes neurais artificiais demonstrou desempenho promissor, especialmente quando alimentada com múltiplos tipos de características derivadas das imagens aéreas.

Peng et al. (2022) ao desenvolverem um dispositivo portátil de imageamento multiespectral ativo (A-MSI) combinado com aprendizado de máquina, para detecção precoce da doença estria marrom da mandioca (CBSD) em tempo real, verificaram vantagens do dispositivo A-MSI sobre MSI passivo e sistemas convencionais de câmeras, devido à melhoria da relação sinal-ruído espectral e repetibilidade temporal. As técnicas de fusão de informações combinaram informações espectrais e espaciais para identificar características que distinguem plantas saudáveis de plantas doentes aos 28 dias pós-inoculação, demonstrando que a aplicação do dispositivo tem potencial para aumentar o acesso dos produtores a materiais de plantio saudáveis e reduzir perdas devido à CBSD na África.

2.4 Índices de Vegetação

Os índices de vegetação são expressões matemáticas adimensionais criadas a partir da relação entre bandas espectrais do visível e do infravermelho próximo, tipicamente o vermelho (Red) e o infravermelho (NIR). Esses índices exploram a diferença entre o forte contraste de reflectância da vegetação nessas bandas, a fim de realçar propriedades biofísicas como densidade, biomassa e vigor vegetal (BANNARI; MORIN; HUETE, 1995).

Na agricultura moderna, os índices de vegetação tornaram-se ferramentas essenciais para o monitoramento contínuo das culturas, contribuindo diretamente para a gestão da produtividade e a tomada de decisões nos sistemas de agricultura de precisão (XUE; SU, 2017). Esses índices espectrais, derivados de combinações matemáticas entre bandas do espectro eletromagnético, permitem aos profissionais do campo realizar diagnósticos quantitativos sobre o vigor das plantas, bem como identificar precocemente áreas afetadas por estresse hídrico, deficiência nutricional ou pragas, muitas vezes antes da manifestação visual dos sintomas (VIDICAN et al., 2023).

A utilização de índices tem diversas funções, tais como: possibilitar a análise contínua da saúde das plantas, aplicar localizadamente insumos com taxas variáveis, dentre outras; otimizando o uso de fertilizantes, pesticidas e água, e contribuindo para a redução de impactos ambientais (PETTORELLI, 2013).

2.4.1 Índice da diferença normalizada

O índice da diferença normalizada, do inglês Normalized Difference Vegetation Index (NDVI), foi proposto originalmente por Rouse et al. (1974) e posteriormente aprimorado por Tucker (1979), a fim de mostrar a correlação com biomassa verde acima do solo. O NDVI é calculado por meio da razão entre as diferenças e somas das reflectâncias no infravermelho próximo (NIR) e vermelho (RED), conforme a Equação 1 (ROUSE et al., 1974).

$$\text{NDVI} = \frac{(B_{850} - B_{660})}{(B_{850} + B_{660})} \quad (1)$$

onde: B_{850} = canal do sensor RGN do infravermelho próximo e B_{660} = canal do sensor RGN do vermelho.

Brandão et al. (2024) realizaram um estudo visando correlacionar índices de vegetação provenientes de imagens de satélite com o teor de fósforo em folhas de algodão. Os autores utilizaram, entre outros índices, o NDVI e, demonstraram correlação significativa entre os valores desse índice e os teores foliares de fósforo, inclusive em condições de baixa disponibilidade do nutriente. Dessa forma, verificou-se que o NDVI pode ser utilizado como ferramenta de diagnóstico espacial dos níveis nutricionais de fósforo nas principais fases fenológicas do algodão, potencializando o manejo de adubação em áreas agrícolas de grande escala.

Em estudo conduzido por Pailliè Jiménez et al. (2023), foram avaliadas diferentes estratégias de adubação fosfatada em sistemas integrados de cultivo e pecuária sobre a dinâmica da biomassa e absorção de fósforo pela soja. O NDVI, medido ao longo das fases de desenvolvimento da cultura, apresentou forte correlação com a biomassa da parte aérea e absorção de fósforo pelas plantas.

Fan et al. (2024) analisaram diversos índices espectrais para prever a concentração de fósforo em folhas de arroz, e destacaram o NDVI como o índice de maior correlação com o teor foliar de fósforo ($R^2 = 0,62$). Os resultados apontam para a superioridade do NDVI em relação a outros índices, tornando-o uma das principais ferramentas para monitorar a nutrição fosfatada em culturas de arroz por sensoriamento remoto.

Sun et al. (2019) desenvolveram modelos de predição não destrutivos para determinar teor de nitrogênio, fósforo e potássio em plantas de tomate cultivadas em estufa, com base em imagens multiespectrais e índices de vegetação, incluindo o NDVI. O estudo constatou forte relação entre o NDVI e o conteúdo foliar de fósforo, sendo que o índice apresentou desempenho consistente como preditor do estado nutricional das plantas. O NDVI revelou-se eficaz para o monitoramento rápido e acurado do teor de fósforo em folhas de tomate ao longo do desenvolvimento, permitindo fortalecer o manejo de fertirrigação e a sustentabilidade produtiva em sistemas protegidos.

2.4.2 Índice de vegetação por diferença normalizada do verde

O índice de vegetação por diferença normalizada do verde, do inglês Green Normalized Difference Vegetation Index (GNDVI), é um índice espectral que utiliza as bandas do infravermelho próximo (NIR) e verde (GREEN) (Equação 2) para avaliar o vigor da vegetação, apresentando maior sensibilidade ao conteúdo de clorofila e ao estado nutricional das plantas em comparação ao NDVI, especialmente em situações de estresse hídrico ou nutricional (GTELSON et al., 1996).

$$\text{GNDVI} = \frac{(B_{850} - B_{550})}{(B_{850} + B_{550})} \quad (2)$$

onde: B_{850} = canal do sensor RGN do infravermelho próximo e B_{550} = canal do sensor RGN do verde.

Gracia-Romero et al. (2017), utilizaram o GNDVI para estimar teores de fósforo disponíveis no solo em talhões de cana-de-açúcar e, demonstraram que tal índice apresentou correlação estatisticamente significativa com a variabilidade espacial do fósforo, especialmente em solos com alto teor de matéria orgânica, possibilitando o mapeamento de áreas de deficiência e o direcionamento de adubação localizada.

Em culturas irrigadas, como o arroz, Le e Pham (2025) avaliaram diversos índices espetrais para estimar o teor foliar de fósforo ao longo das fases fenológicas. Dentre os índices avaliados, o GNDVI apresentou forte correlação linear com a concentração de fósforo, demonstrando capacidade robusta de predição e desempenho superior a outros índices

baseados nas bandas do vermelho e infravermelho próximo. Esses resultados indicam que o GNDVI é um indicador prático e eficaz para o monitoramento nutricional em sistemas agrícolas, o que reforça seu potencial uso também na cultura da batata (Mukiibi et al., 2024).

2.4.3 Índice de vegetação por razão entre infravermelho próximo e verde

O índice de vegetação verde vermelho, do inglês Green-Red Vegetation Index (GRVI) é um índice espectral que utiliza a reflectância das bandas verde e vermelho (Equação 3), para estimar o conteúdo de clorofila e o vigor da vegetação, sendo sensível às mudanças na pigmentação foliar e adequado para detectar variações fisiológicas em plantas (GTELSON et al., 2003).

$$\text{GRVI} = \frac{B_{550} - B_{660}}{B_{550} + B_{660}} \quad (3)$$

onde: B_{550} = canal do sensor RGN do verde e B_{660} = canal do sensor RGN do vermelho.

Yin et al. (2022) avaliaram a aplicabilidade do GRVI para monitorar a fenologia e o estado nutricional em diferentes espécies de plantas, incluindo hortaliças. Os autores observaram que o índice foi responsável por alterações de coloração das folhas provocadas por deficiência de fósforo, permitindo a identificação de fases de crescimento mais suscetíveis ao estresse nutricional, o que pode subsidiar práticas de manejo mais precisas.

Em experimento conduzido por Gracia-Romero et al. (2017), o GRVI foi avaliado quanto à sua capacidade de detectar deficiências nutricionais em milho nas fases iniciais de desenvolvimento. Os resultados destacaram que o GRVI apresentou correlação significativa com o teor de fósforo nas folhas, especialmente em condições em que a deficiência do nutriente limitava o crescimento vegetativo, evidenciando seu potencial para o diagnóstico rápido e de baixo custo via câmeras digitais.

2.5 Aprendizado de Máquina

O aprendizado de máquina (AM) constitui uma área da ciência da computação que capacita sistemas a extrair padrões e conhecimentos de dados de forma autônoma, sendo amplamente aplicado na agricultura de precisão. Essa tecnologia tem se mostrado

fundamental na análise de dados derivados de sensoriamento remoto (SR), permitindo o processamento de informações espaciais e temporais para otimizar práticas agrícolas sustentáveis e eficientes (PATEL; POKHARIYAL; SINGH, 2023).

As tarefas associadas ao AM são geralmente organizadas conforme o tipo de aprendizado (supervisionado ou não supervisionado) e, conforme as técnicas empregadas (classificação, regressão, agrupamento e redução de dimensionalidade). Diversos modelos de aprendizado de máquina, como redes neurais convolucionais, florestas aleatórias, máquinas de vetores de suporte e algoritmos de aprendizado profundo, são implementados com algoritmos específicos, como o YOLO (para detecção de objetos), o LSTM (para análise de séries temporais) e o XGBoost (para regressão), visando resolver desafios complexos no monitoramento agrícola. Segundo El-Kenawy et al. (2025), tais abordagens têm se mostrado eficazes na previsão de produtividade agrícola e no suporte a práticas sustentáveis.

Quanto às contribuições do AM no tratamento de dados de SR, o aprendizado supervisionado se sobressai como a abordagem mais adotada. Nessa modalidade, algoritmos constroem modelos que relacionam variáveis de entrada a saídas esperadas, a partir de conjuntos de dados rotulados. Quando as saídas são variáveis discretas, os rótulos definem classes pré-determinadas, configurando métodos de classificação que contribuem para tarefas como o mapeamento de cultivos e a previsão de produtividade agrícola (BELGIU; DRĂGUȚ, 2016).

Mujawar et al. (2024), ao empregar algoritmos de aprendizado de máquina em sistemas inteligentes de irrigação voltados para o cultivo de arroz, verificaram ganhos significativos na eficiência hídrica. Isso evidencia o potencial do AM em promover a resiliência agrícola frente à escassez de recursos, alinhando-se a objetivos de sustentabilidade global.

Já em análises realizada por Van Klompenburg, Kassahun e Zhou (2020) sobre previsões de rendimento de cultivos usando AM, focando em modelos como XGBoost e redes neurais, os autores indicaram que tais algoritmos superam métodos estatísticos em cenários de variabilidade climática, com aplicações práticas em planejamento agrícola, embora apontem desafios como a necessidade de dados de alta qualidade para treinamento eficaz.

Em estudo de Ferentinos (2018), redes neurais convolucionais foram aplicadas à detecção de doenças em plantas com acurácia frequentemente elevadas, evidenciando o potencial do aprendizado profundo para diagnóstico precoce e suporte à redução do uso de pesticidas. Embora o trabalho use imagens convencionais, os princípios se estendem a fluxos

com drones, reforçados por revisões recentes que documentam resultados semelhantes com imagens aéreas.

2.5.1 Multilayer Perceptron

O Multilayer Perceptron (MLP) é uma arquitetura clássica de rede neural artificial do tipo feedforward, composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, todas densamente conectadas (Figura 2).

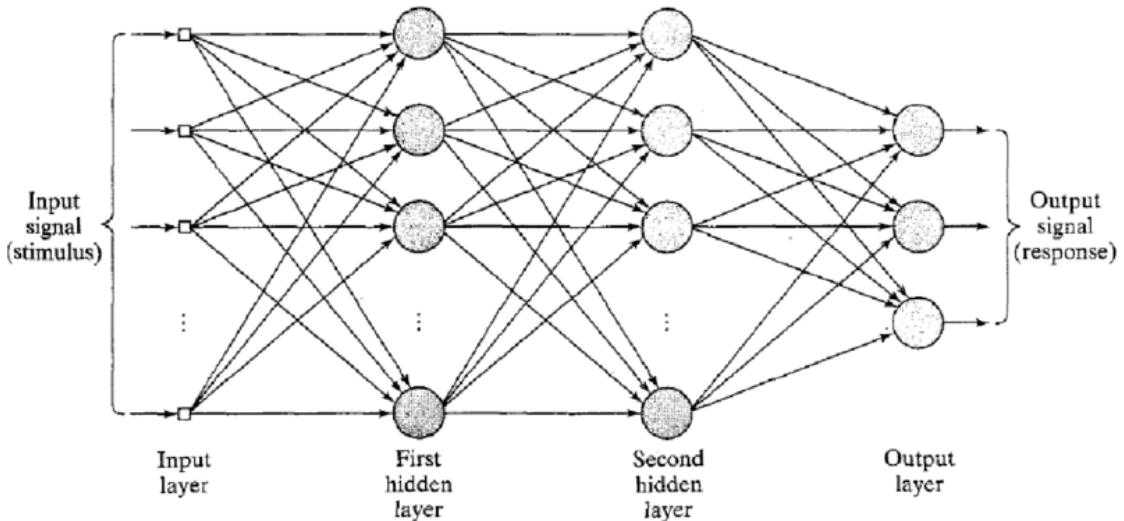


FIGURA 2. Esquema de uma rede Multilayer Perceptron (MLP) com duas camadas ocultas.
Fonte: adaptado de Haykin (2009).

Cada neurônio processa informações por meio de combinações lineares dos dados de entrada seguidas da aplicação de funções de ativação não lineares, como ReLU (Rectified Linear Unit) ou sigmoide, o que permite ao modelo aprender e representar relações complexas entre variáveis (HAYKIN, 2009; CHAN et al., 2023). Essa estrutura torna o MLP particularmente adequado para tarefas que envolvem dados não lineares e problemas de classificação, regressão e reconhecimento de padrões.

O trabalho de LeCun et al. (2015) explora o funcionamento do MLP em contextos de aprendizado profundo, destacando como ele se baseia em camadas ocultas que transformam representações de dados, com propagação forward e retropropagação de erros para otimização. Na classificação, o MLP é trabalhado definindo camadas de saída com ativações softmax para

probabilidades de classes, permitindo treinamento com gradiente descendente estocástico e avaliação por métricas como acurácia, adaptando-se a problemas de alta dimensionalidade (LECUN et al., 2015).

No estudo de Bishop (2006), o MLP é apresentado como uma extensão de perceptos lineares, funcionando por meio de combinações lineares seguidas de não linearidades, baseado na teoria estatística de inferência bayesiana para modelagem probabilística. Para classificação, envolve pré-processamento de dados, escolha de hiperparâmetros como número de camadas e neurônios, e treinamento com regularização para evitar sobreajuste, facilitando a separação de classes em espaços de características não lineares (BISHOP, 2006).

Schmidhuber (2015) discute a evolução histórica do MLP, enfatizando seu funcionamento recursivo em camadas que aprendem hierarquias de características representativas, ancorado na base teórica de redes recorrentes e de alimentação direta para processamento sequencial. Em classificação, o modelo é aplicado configurando saídas para vetores binários exclusivos, otimizando por meio de algoritmos como Adam e validando com conjuntos de teste, o que permite lidar com desbalanceamentos de classes por meio de técnicas de amostragem (SCHMIDHUBER, 2015).

Já em pesquisa de Rumelhart et al. (1986), o MLP é conceituado como um sistema que propaga erros reversamente para aprendizado, baseado na regra delta generalizada para ajustes de pesos, revolucionando o treinamento de redes multicamadas. O trabalho com classificação envolve inicialização aleatória de pesos, iterações de épocas com lotes de dados, e monitoramento de convergência, o que permite classificar padrões complexos em domínios variados com alta capacidade de generalização (RUMELHART et al., 1986).

2.5.2 Support Vector Machine

O Support Vector Machine (SVM) constitui um algoritmo de aprendizado supervisionado amplamente empregado em tarefas de classificação e regressão, com ênfase na identificação de um hiperplano ótimo que maximize a margem de separação entre classes em um espaço de características (Figura 3) (CORTES; VAPNIK, 1995).

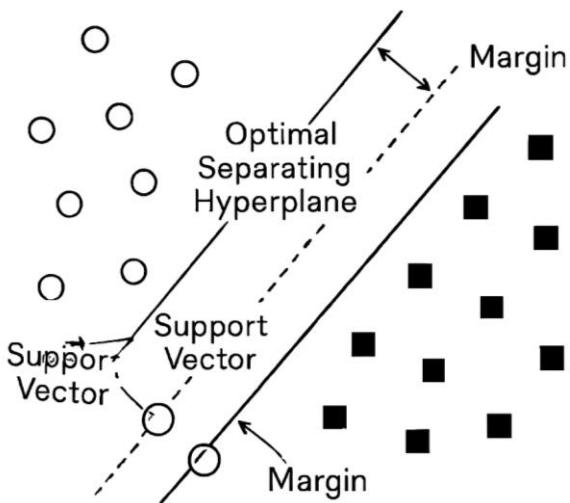


FIGURA 3. Representação gráfica do Support Vector Machine (SVM) com margem e vetores de suporte, mostrando o hiperplano ótimo separando duas classes de dados. Fonte: Cortes e Vapnik (1995).

Esse hiperplano é determinado pelos vetores de suporte, que são os pontos de dados mais próximos à fronteira de decisão, permitindo uma separação robusta, mesmo em conjuntos de dados não lineares, por meio de funções kernel, como a Radial Basis Function (RBF) (LIU; GU; QIN, 2023).

Para problemas de regressão, o SVM é adaptado na forma de Support Vector Regression (SVR), onde o objetivo é minimizar o erro dentro de uma banda de tolerância em torno da função de regressão, ajustando-se a valores contínuos em vez de classes discretas (ABDEL-SALAM; KUMAR; MAHAJAN, 2024).

Entre as vantagens, destaca-se a minimização do risco estrutural por meio da maximização da margem, promovendo modelos com baixa variância e alta interpretabilidade. No entanto, limitações incluem a sensibilidade à escolha da função de núcleo e o alto custo computacional em grandes conjuntos de dados (SHEVADE et al., 2000). Um exemplo prático é sua aplicação em classificação de compostos químicos, onde o SVM com função de base radial (RBF) supera métodos tradicionais em precisão, como observado em análises de robustez contra-ataques adversariais (PLATT, 1998).

Em diversos contextos, os dados observados não apresentam separação linear clara entre as classes, o que torna ineficazes os métodos baseados em fronteiras lineares no espaço original de características. Para lidar com essa limitação, as máquinas de vetores de suporte (SVM) utilizam uma técnica conhecida como truque do kernel, que permite ao algoritmo lidar

com dados complexos ao transformá-los matematicamente, tornando-os mais fáceis de serem separados. Essa transformação é realizada de maneira implícita, por meio de funções de núcleo como a polinomial ou a função de base radial, sem a necessidade de calcular diretamente as novas coordenadas dos dados. Ao operar nesse novo espaço, o algoritmo consegue encontrar um hiperplano de separação ótimo, mesmo em situações em que as classes apresentem sobreposição complexa no espaço original. Essa abordagem amplia consideravelmente a capacidade preditiva do modelo, mantendo, ao mesmo tempo, bom desempenho computacional, e tem se consolidado como uma das estratégias mais eficazes em problemas de classificação com dados não linearmente distribuídos (SCHÖLKOPF; SMOLA, 2002).

2.5.2 Sequential Minimal Optimization

O Sequential Minimal Optimization (SMO) é um algoritmo eficiente utilizado para treinar SVM em tarefas de classificação, decompondo o problema de otimização quadrática em subproblemas menores envolvendo pares de multiplicadores de Lagrange, o que acelera a convergência sem a necessidade de resolvedores numéricos complexos (PLATT, 1998).

Essa abordagem permite resolver o dual do problema SVM de forma iterativa, selecionando pares de exemplos para otimização analítica. Durante esse processo, é garantido que as condições de Karush-Kuhn-Tucker (KKT) — um conjunto de regras matemáticas que asseguram que a solução encontrada respeita todas as limitações e é realmente ótima para o problema — sejam satisfeitas progressivamente. Em outras palavras, ao otimizar, o algoritmo verifica se está obedecendo todas as restrições necessárias para alcançar o melhor resultado possível. Isso torna o método particularmente adequado para conjuntos de dados de grande escala, pois possibilita uma avaliação precisa e eficiente, mesmo diante de restrições complexas (KEERTHI et al., 2001).

Em aplicações práticas, o SMO demonstra superioridade em termos de velocidade e escalabilidade, como na classificação de textos, onde otimiza o hiperplano de separação com alta precisão, reduzindo o tempo de treinamento em comparação a métodos tradicionais (FAN; CHEN; LIN, 2005).

Variações do SMO, como o uso de heurísticas para seleção de pares, aprimoraram sua eficiência em cenários de alta dimensionalidade, facilitando a classificação em domínios

como reconhecimento de padrões, com convergência rápida e baixa demanda computacional (SHEVADE et al., 2000).

2.5.3 Sequential Minimal Optimization for regression

O algoritmo de otimização sequencial mínima para regressão (SMOreg) é uma extensão do algoritmo SMO adaptada para Support Vector Regression (SVR), permitindo o treinamento eficiente de modelos de regressão ao decompor o problema de otimização em subproblemas menores, focando na minimização de uma função de perda ϵ -insensível para prever valores contínuos (SHEVADE et al., 2000).

Diferentemente do SMO para classificação, o SMOreg incorpora uma margem de tolerância para erros regressivos, atualizando multiplicadores de Lagrange de forma sequencial para construir uma função de regressão robusta a outliers, com aplicações em previsão de séries temporais (SMOLA; SCHÖLKOPF, 2004).

Em contextos agrícolas, o SMOreg é empregado para estimar variáveis como rendimento de cultivos com base em dados climáticos, oferecendo precisão elevada e eficiência computacional em grandes conjuntos de dados (LI et al., 2025).

Os benefícios incluem a capacidade de lidar com não linearidades via kernels, embora desafios como a sensibilidade a hiperparâmetros exijam calibração cuidadosa para evitar subajuste em cenários ambientais voláteis (CHANG; LIN, 2011).

2.5.4 Random Forest

O Random Forest é um algoritmo de aprendizado de máquina baseado em ensemble, que combina múltiplas árvores de decisão para melhorar a precisão e a robustez das previsões. O algoritmo opera no paradigma do aprendizado supervisionado, onde um modelo é treinado com dados rotulados para prever resultados em novos conjuntos de dados, sendo particularmente eficaz em tarefas de classificação e regressão, devido à sua capacidade de reduzir o sobreajuste e lidar com dados complexos (BREIMAN, 2001).

O funcionamento do Random Forest inicia-se com a criação de um conjunto de árvores de decisão, cada uma construída a partir de um subconjunto aleatório dos dados de

treinamento, obtido por meio de amostragem com reposição (bootstrap aggregating ou bagging) (Figura 4). Esse processo garante diversidade entre as árvores, minimizando a correlação entre elas e melhorando a capacidade de generalização do modelo (SUN et al., 2024).

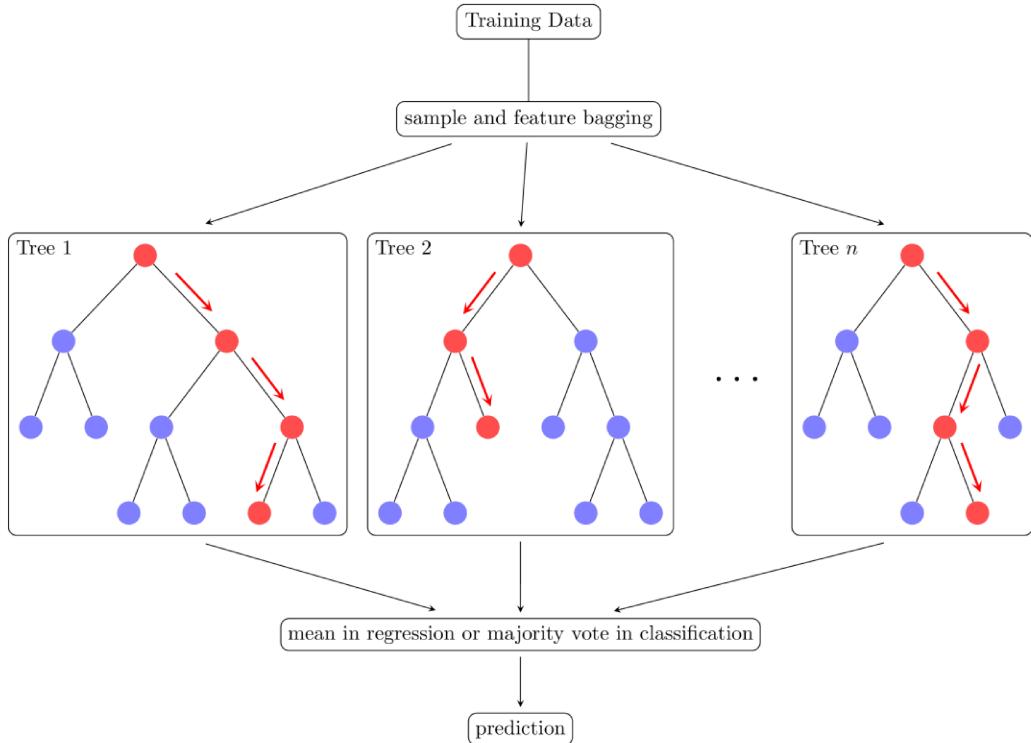


FIGURA 4. Esquema do algoritmo Random Forest, ilustrando o fluxo dos dados de treinamento, amostragem bootstrap, seleção aleatória de atributos e agregação das previsões por votação majoritária ou média. Fonte: Adaptado de TikZ.net (2023).

Em seguida, para cada árvore, ocorre a seleção aleatória de subconjuntos de variáveis em cada nó de divisão, o que introduz variação adicional e evita que features dominantes influenciem excessivamente o resultado. No caso de tarefas de classificação, as previsões finais são determinadas por votação majoritária das árvores, enquanto em regressão, utiliza-se a média das previsões individuais, resultando em uma saída agregada mais estável e precisa (SCHONLAU; ZOU, 2020).

Qomariyah et al. (2024) investigaram a aplicação de Random Forest na seleção de culturas em agricultura de precisão, integrando dados obtidos via IoT (Internet of Things – Internet das Coisas). O modelo se destacou pela acurácia na previsão da produtividade de arroz com base em clima, solo e irrigação. Contudo, os autores também apontam limitações, como a sensibilidade a ruídos e desequilíbrios nos dados, e sugerem a combinação com outras

técnicas para ampliar a generalização dos resultados, principalmente em contextos agrícolas diversos.

Ao abordar a detecção de pragas, uma revisão conduzida por Kamaris e Prenafeta-Boldú (2018), evidenciou a eficiência do Random Forest na análise de dados espectrais e imagens digitais. A técnica foi eficaz na identificação de doenças, como a giberela, causada pelo fungo *Gibberella zae* do trigo, e demonstrou maior robustez ao sobreajuste em comparação ao SVM, contribuindo para o manejo integrado de pragas e aumentando a precisão em cenários agrícolas complexos.

Um algoritmo baseado em Random Forest foi desenvolvido para previsões espaciais intensivas de produtividade agrícola, dispensando métodos geoestatísticos tradicionais. A abordagem mostrou alto desempenho, especialmente ao lidar com grandes volumes de dados heterogêneos. Essa iniciativa reforça o uso da técnica em decisões agronômicas orientadas por dados, como destacado por Talebi et al. (2022).

Em outro contexto, Jeune et al. (2018) aplicaram o Random Forest e a Regressão Logística Multinomial para mapear solos no Haiti e compararam os desempenhos. O Random Forest apresentou maior acurácia na classificação das classes de solo, utilizando a técnica de empacotamento e amostras fora do conjunto de treinamento para avaliar a importância das variáveis preditoras, gerando mapas digitais relevantes para o manejo agrícola local.

A previsão de rendimento de safra também foi investigada, com uso de Random Forest aliado ao ajuste de hiperparâmetros por Random Search. O modelo obteve coeficiente de determinação de 0,99, apresentando ganhos substanciais frente a outras técnicas como Decision Tree e Regressão Linear. Essa pesquisa, de acordo com Padma e Sinha (2023), oferece suporte valioso ao planejamento agrícola baseado em dados.

Na previsão da produtividade de milho, o Random Forest foi aplicado para analisar parâmetros agronômicos e ambientais, demonstrando robustez na identificação de fatores preditores e na gestão da variabilidade espacial. Esse modelo promove melhorias no planejamento agronômico e na eficiência produtiva, como descrito por Santos et al. (2023).

O uso combinado de modelagem de cultivos e Random Forest foi implementado para prever o rendimento de trigo e canola. A abordagem integrada superou os métodos tradicionais isolados, captando melhor a variabilidade espacial e temporal do rendimento. Tal estratégia mostrou-se útil para elaboração de políticas públicas, planejamento de seguro rural e manejo agrícola regionalizado, como relataram (DHILLON et al., 2023).

Por fim, a aplicação do Random Forest na classificação da textura do solo em uma bacia agrícola brasileira mostrou-se eficaz no planejamento do uso e conservação dos solos. O método proporcionou melhor entendimento da distribuição das propriedades físicas do solo, elemento essencial para práticas agrícolas sustentáveis e para a prevenção da erosão, conforme obtido no estudo conduzido por Santos et al. (2025).

3 MATERIAL E MÉTODOS

3.1 Experimento de campo

O experimento foi conduzido no município de Uberaba, nas dependências do Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro – Campus Uberaba (Figura 5).

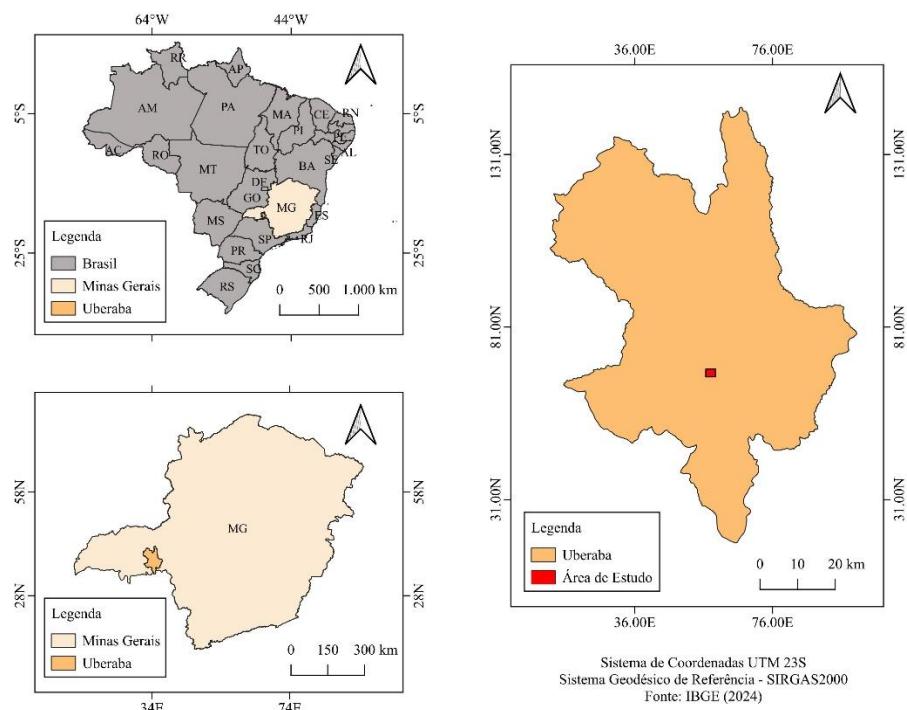


FIGURA 5. Mapa de localização do experimento, Uberaba, MG.

O clima da região é caracterizado como Aw (tropical quente e úmido), apresentando inverno frio e seco, bem como verão quente e úmido, segundo a classificação de Köppen (BECK et al., 2018).

O experimento foi realizado em vasos de 13 L, dentro de casa de vegetação do tipo arco, coberta por filme plástico difusor de luz com 150 micra e laterais fechadas com tela de sombreamento de 50% (Figura 6).



FIGURA 6. Demonstração dos vasos de 13 L utilizados no experimento.

O delineamento experimental adotado foi de blocos casualizados, com oito tratamentos e 40 repetições. Cada vaso foi considerado uma unidade experimental, totalizando 320 vasos. Os tratamentos foram constituídos de oito doses de P_2O_5 (0; 50; 100; 200; 400; 800; 1.600 e 3.200 $Kg\ ha^{-1}$ de P_2O_5).

Os vasos foram preenchidos com solo de barranco, ou seja, um solo não cultivado. O solo foi classificado como Latossolo Vermelho Distrófico, de acordo com o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2018), apresentando textura média nas profundidades de 0–20 cm e 20–40 cm, além de baixo teor inicial de fósforo. Previamente ao plantio, e antes da realização de qualquer correção ou adubação, procedeu-se à amostragem do solo e à sua análise química, cujos resultados são apresentados na Tabela 1.

TABELA 1. Caracterização química do solo, coletado na profundidade de 0 a 20 cm.

| pH CaCl ₂ | P _{res} mg dm ⁻³ | K ⁺ | H+Al | Al ³⁺ | Ca ⁺² | Mg ⁺² | SB | T | t | V % |
|------------------------------------|---|----------------|-------|------------------|------------------|------------------|------|-------|------|--------|
| ----- mmolc dm ⁻³ ----- | | | | | | | | | | |
| 4,9 | 1,3 | <0,50 | 33,00 | 0,56 | 1,4 | <0,1 | 2,02 | 35,56 | 2,02 | 5,77 |

Anteriormente ao plantio, realizou-se a correção do solo com aplicação de calcário, para elevar a saturação por bases a 60% (RIBEIRO et al., 1999) e procedeu-se ao processo de incubação do solo, o qual durou aproximadamente 37 dias. Em seguida, procedeu-se à adubação de plantio. A adubação fosfatada foi realizada conforme a dose prevista para cada tratamento (Tabela 2).

TABELA 2. Doses de P₂O₅ (kg ha⁻¹) e as respectivas quantidades de superfosfato simples aplicadas por vaso (g por vaso).

| Tratamentos | Dose de P ₂ O ₅ (kg ha ⁻¹) | Quantidade de Superfosfato Simples (g por vaso) |
|-------------|---|--|
| 1 | 0 | 0 |
| 2 | 50 | 1,8 |
| 3 | 100 | 3,6 |
| 4 | 200 | 7,2 |
| 5 | 400 | 14,4 |
| 6 | 800 | 28,8 |
| 7 | 1600 | 57,6 |
| 8 | 3200 | 115,2 |

Para a adubação potássica, adotou-se a dose recomendada de 350 kg ha⁻¹ de K₂O (RIBEIRO et al., 1999), a qual foi aplicada integralmente no plantio, correspondendo a 4,20 g de cloreto de potássio (KCl) por vaso. De forma análoga, a adubação nitrogenada também foi realizada integralmente no plantio, utilizando-se 2,8 g de ureia por vaso, equivalendo à dose recomendada de 190 kg ha⁻¹ de nitrogênio (N).

O cálculo das doses por vaso foi realizado com base em um volume de solo de 2.000.000 dm³, correspondente a uma área de 1.000.000 dm² (1 hectare) com 0,20 m de profundidade (1.000 dm × 1.000 dm × 2 dm). A partir dessa estimativa, as doses recomendadas por hectare foram ajustadas proporcionalmente ao volume de solo presente em 13 L (13 dm³) por vaso.

O plantio foi realizado em 31 de maio de 2021. Para tanto, três tubérculos-semente da cultivar Ágata, do tipo III (35 a 55 mm), com dormência superada, foram plantados em cada vaso.

A cultivar Ágata foi escolhida por sua ampla adaptação às condições brasileiras, elevada produtividade, boa qualidade comercial e desempenho consistente em diversos tipos de solo, apresentando ainda resistência moderada a distúrbios fisiológicos, como rachaduras e murcha bacteriana, o que a torna ideal para experimentos que exigem confiabilidade agronômica (ABBA, 2010). A escolha desse tipo de tubérculo baseou-se em seu maior acúmulo de reservas energéticas, o que favorece o vigor inicial das plantas e contribui para uniformidade nas parcelas.

Exceto a adubação fosfatada de plantio, todos os demais tratos culturais foram realizados conforme o manejo recomendado para a cultura.

A irrigação foi por gotejamento, uma a duas vezes ao dia, ao longo de todo o experimento, conforme a necessidade observada. Esse manejo seguiu protocolos comumente adotados em estudos com batata cultivada em vasos, que buscam manter a umidade do solo próxima à capacidade de campo.

Logo após a obtenção das imagens, as plantas que estavam no início da tuberização, foram colhidas (Figura 7), lavadas e encaminhadas ao laboratório para determinação do teor de fósforo (P) (g kg^{-1}), conforme metodologia da Embrapa (2009).



FIGURA 7. Plantas em laboratório preparadas para análise.

3.2 Aquisição das imagens

A coleta das imagens foi realizada quando as plantas se apresentavam no início da tuberização. Para tanto, utilizou-se a câmara Survey 3 da MAPIR, a qual possui resolução de 12 bits, focal de 19 mm, GSD (Ground Sample Distance) de 2,3 cm e as bandas: verde (550 nm), vermelho (660 nm) e infravermelho próximo (850 nm). As imagens foram capturadas em todas as plantas, totalizando 320 imagens.

A câmara foi instalada em um suporte nivelado horizontalmente e verticalmente a 1,20 m do solo na posição nadir. As plantas foram colocadas sob um tecido de polipropileno preto, a fim de mitigar efeito da refletância de alvos vizinhos (Figura 8) (MARTINS; GALO; VIEIRA, 2017).



FIGURA 8. Coleta das imagens multiespectrais em plantas de batata.

Para garantir condições de máxima absorção e reflexão da radiação eletromagnética solar (JENSEN, 2009), as imagens foram capturadas no período das 11h 30min às 12h 30 min, com ausência de qualquer tipo de sombreamento, que pode ser causado por nuvens ou feições antrópicas próximas ao frame da área de captura.

3.3 Pré-processamento das imagens

3.3.1 Extração dos dados radiométricos

Os dados radiométricos (valores médios das reflectâncias nas bandas RGN) das 320 plantas foram extraídos de cada mosaico, utilizando a função Region of Interest (ROI) do software ENVI 5.1, a fim de que fizessem parte dos dados de entrada de classificação.

3.3.2 Cálculo dos índices de vegetação

Após a extração dos valores das bandas espectrais referentes a cada ROI, os dados foram organizados em planilhas e utilizados para o cálculo dos índices de vegetação (GRVI, NDVI e GNDVI), conforme as equações previamente descritas na Tabela 3. Esse fluxo de trabalho garantiu acurácia na obtenção dos dados espectrais e permitiu correlacionar de forma eficaz as respostas óticas com os tratamentos aplicados.

TABELA 3. Equações e referências para cálculos dos índices de vegetação derivados das bandas originais da câmera Survey 3.

| Índices de vegetação | Equação | Referência |
|--|--|-------------------------|
| Green-Red Vegetation Index | $\text{GRVI} = \frac{B_{550} - B_{660}}{B_{550} + B_{660}}$ | (SIMS; GAMON, 2002) |
| Normalized Difference Vegetation Index | $\text{NDVI} = \frac{(B_{850} - B_{660})}{(B_{850} + B_{660})}$ | (ROUSE et al., 1974) |
| Green Normalized Difference Vegetation Index | $\text{GNDVI} = \frac{(B_{850} - B_{550})}{(B_{850} + B_{550})}$ | (GITELSON et al., 1996) |

Canais do sensor RGN: vermelho (B_{660}), verde (B_{550}) e infravermelho próximo (B_{850}). B: Banda

3.4 Análises estatísticas

3.4.1 Correlação entre Índices Espectrais e Fósforo Foliar

Para as análises estatísticas de correlação entre variáveis espectrais e o teor de fósforo, os dados oriundos de todos os tratamentos foram agrupados, desconsiderando-se a separação original entre doses. Essa abordagem visou explorar relações contínuas e globais entre os atributos espectrais e a concentração de fósforo, sem o intuito de comparar os efeitos específicos de cada dose.

Para a análise estatística dos dados deste experimento, os valores dos índices de vegetação NDVI, GNDVI e GRVI, calculados a partir das bandas espectrais extraídas das imagens, foram correlacionados com o teor foliar de fósforo, utilizando o software Minitab. Para cada um dos índices, foi realizado o cálculo da correlação de Pearson, com o objetivo de avaliar o grau de associação entre os índices espectrais e os teores de fósforo nas folhas das plantas. A correlação de Pearson foi escolhida por se tratar de um método adequado para avaliar relações lineares entre variáveis contínuas, assumindo distribuição aproximadamente normal dos dados (FERREIRA, 2018).

O procedimento no Minitab consistiu na seleção das variáveis correspondentes aos índices (NDVI, GNDVI e GRVI) e à variável fósforo, seguido do cálculo das matrizes de correlação e geração de tabelas e gráficos descritivos.

3.4.2 Classificação supervisionada

Para modelar a relação entre índices espectrais (NDVI, GNDVI e GRVI) e o teor foliar de fósforo, com base em dados espectrais obtidos por sensoriamento remoto, foram realizadas classificações supervisionadas com base em três algoritmos de regressão: Random Forest, Multilayer Perceptron e SMOREg. O processamento e a análise dos dados foram realizados no software Weka Explorer, que oferece uma plataforma integrada para aplicação de algoritmos de aprendizado de máquina e análise dos resultados (HALL et al., 2009).

O algoritmo Random Forest foi selecionado por sua robustez à presença de outliers e capacidade de lidar com variáveis altamente correlacionadas (BREIMAN, 2001). O Multilayer Perceptron foi incluído por sua habilidade de capturar relações não lineares,

enquanto o SMOrég foi considerado por seu bom desempenho em conjuntos de dados multidimensionais (SCHÖLKOPF; SMOLA, 2002).

A performance dos modelos foi avaliada com base no Erro Quadrático Médio da Raiz (RMSE) e Coeficiente de Correlação de Pearson (r), todas obtidas via validação cruzada com 10 subconjuntos. O RMSE (Equação 5) penaliza mais fortemente os erros maiores, sendo sensível a *outliers* (CHAI; DRAXLER, 2014). Já o coeficiente de correlação indica o grau de associação linear entre as variáveis observadas e preditas, sendo considerado satisfatório quando superior a 0,8 (MUKAKA, 2012).

$$\text{RMSE} = \sqrt{\left[\left(\frac{1}{n} \right) \times \sum_{i=1}^n (y_i - \hat{y}_i)^2 \right]}$$

onde: n = número total de observações, y_i = valor observado na i -ésima instância e \hat{y}_i = valor predito na i -ésima instância

O erro quadrático médio da raiz (RMSE) é amplamente reconhecido como uma métrica robusta e confiável para avaliar o desempenho preditivo de modelos em diversas áreas da ciência, incluindo aplicações em sensoriamento remoto e predição agronômica. Conforme discutido por Chai e Draxler (2014), o RMSE é particularmente útil por penalizar de forma mais severa os erros maiores, o que o torna mais sensível a discrepâncias entre os valores observados e preditos. Essa característica é desejável em situações em que grandes erros são mais críticos do que pequenos desvios, como ocorre frequentemente em modelos aplicados à agricultura de precisão.

A validação dos modelos foi realizada por meio de validação cruzada (Equação 6) do tipo k -fold ($k = 10$), técnica que consiste em dividir o conjunto de dados em dez subconjuntos de tamanho aproximadamente igual. Em cada iteração, um subconjunto foi utilizado para teste enquanto os demais serviram para treinamento, permitindo que todas as instâncias fossem avaliadas ao longo das iterações. Esse procedimento busca obter uma estimativa mais confiável da performance preditiva dos modelos e reduzir o risco de *overfitting* (KOHAVI, 1995).

$$E_{cv} = \frac{1}{k} \sum_{i=1}^k E_i \quad (6)$$

onde: E_{cv} = erro médio de validação cruzada, k = número de folds (neste estudo, $k = 10$), e_i = erro obtido no i -ésimo subconjunto (fold).

4 RESULTADOS E DISCUSSÃO

Foram ajustadas equações lineares entre os valores observados de fósforo foliar e três índices espectrais derivados de imagens multiespectrais: índice da diferença normalizada (NDVI), índice de vegetação por diferença normalizada do verde (GNDVI) e índice de vegetação verde vermelho (GRVI). Os coeficientes de determinação (R^2) e os resíduos padronizados (S) foram utilizados como métricas para avaliar o ajuste dos modelos.

O coeficiente de determinação é uma medida estatística utilizada a fim de avaliar a qualidade do ajuste do modelo de regressão. Já o resíduo padronizado representa a diferença entre o valor observado e o valor previsto pelo modelo, ajustado pela variabilidade dos dados, sendo uma ferramenta estatística crucial utilizada na análise de dados, especialmente em modelos de regressão.

O NDVI apresentou o melhor desempenho na estimativa do teor de fósforo, com coeficiente de determinação de 50,2% e valor de resíduo padronizado de 0,5543, indicando que aproximadamente metade da variação nos dados de fósforo foliar pode ser explicada por esse índice (Figura 9).

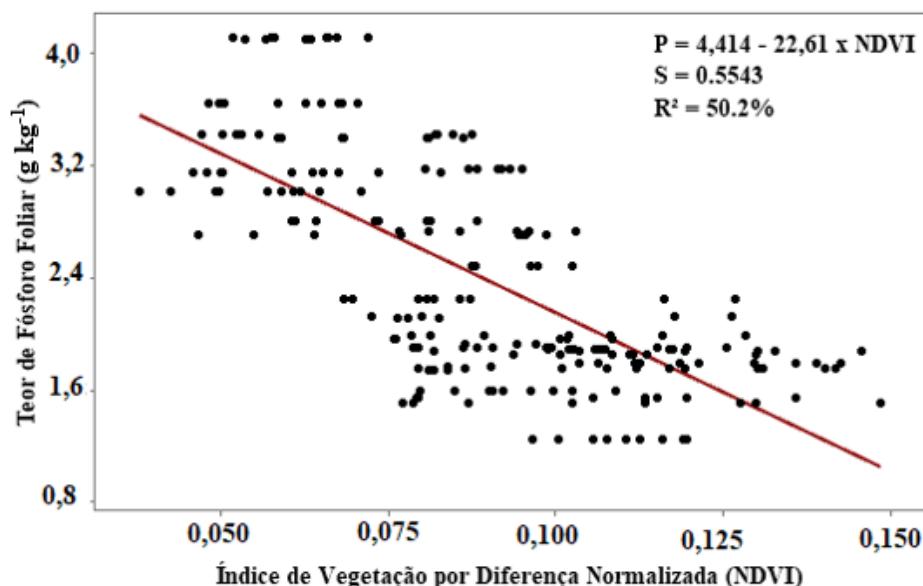


FIGURA 9. Relação entre o índice da diferença normalizada (NDVI) e o teor foliar de fósforo em plantas de batata.

Esse resultado revela a existência de relação inversa entre NDVI e o teor de fósforo, ou seja, quanto maior o NDVI, menor o valor de fósforo foliar. Isso pode estar relacionado ao efeito de diluição de nutrientes, fenômeno amplamente discutido na literatura, onde altas taxas de crescimento vegetativo, refletidas por valores elevados de NDVI, tendem a levar à diluição de nutrientes nos tecidos foliares quando a reposição de nutrientes não acompanha a expansão da biomassa (MARSCHNER, 2012).

Para o GNDVI, o coeficiente de determinação foi de 22,3%, com resíduo padronizado de 0,692, apresentando tendência negativa com o teor de fósforo (Figura 10).

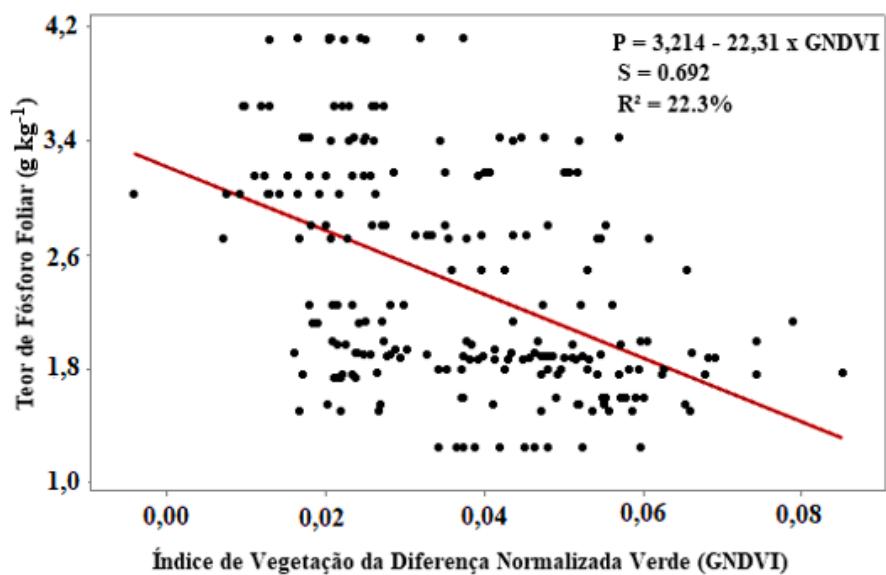


FIGURA 10. Relação entre o índice de vegetação por diferença normalizada do verde (GNDVI) e o teor foliar de fósforo em plantas de batata.

Apesar do GNDVI ser particularmente sensível à reflectância da banda verde, podendo ser influenciado por variáveis fisiológicas tais como o teor de clorofila e o índice de área foliar, tais parâmetros podem não estar diretamente associados ao teor de fósforo (GITELSON et al., 2003) já que a aplicação de adubação fosfatada demonstra efeitos decisivos na qualidade e rendimento dos tubérculos, não sendo evidenciados muitas vezes isso nas folhas.

De acordo com Fernandes et al. (2016), a fertilização com fósforo eleva a massa média dos tubérculos, aumenta sua firmeza e o teor de amido, além de reduzir a concentração de açúcares redutores.

O GRVI apresentou desempenho semelhante ao GNDVI, com coeficiente de determinação de 22,1% e resíduo padronizado de 0,693 (Figura 11).

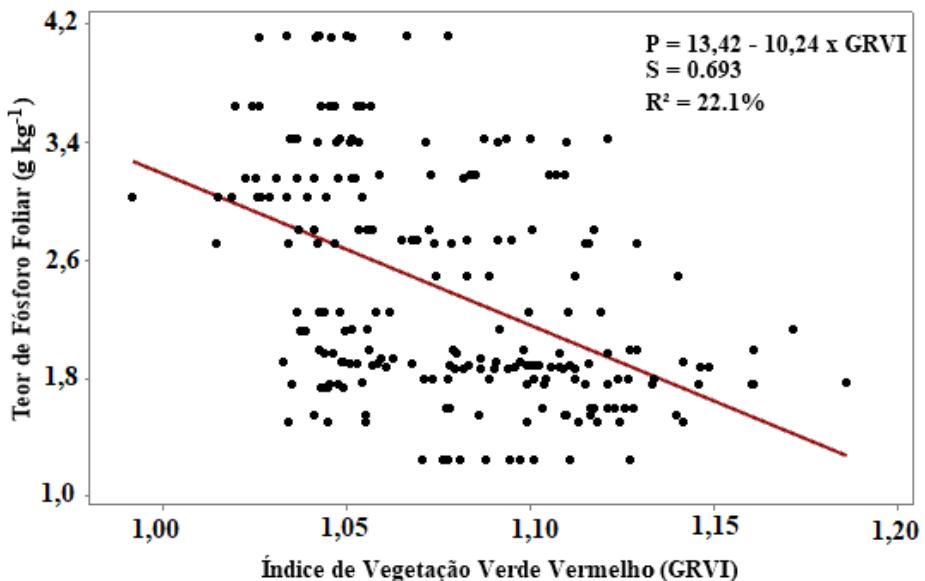


FIGURA 11. Relação entre índice de vegetação verde vermelho (GRVI) e o teor foliar de fósforo em plantas de batata.

Apesar do GRVI utilizar combinações das bandas do verde e vermelho, seu desempenho inferior ao NDVI pode estar relacionado à sua menor sensibilidade a mudanças na estrutura foliar e na densidade de vegetação, fatores intimamente associados ao estado nutricional das plantas (XUE; SU, 2017).

Esses instrumentos estatísticos subsidiaram a interpretação e comparação dos resultados, possibilitando identificar quais índices apresentaram maior sensibilidade e relação com o nutriente em questão.

Entre os três índices avaliados, o NDVI apresentou os maiores valores de ajuste estatístico para estimativa do fósforo foliar. Especificamente, os valores obtidos para o NDVI foram 125% e 127% superiores aos alcançados com o GNDVI e o GRVI, respectivamente, no que diz respeito ao coeficiente de determinação (R^2). Esses resultados corroboram com estudos prévios que apontam o NDVI como um dos principais índices espectrais para avaliação do estado nutricional em culturas agrícolas, dada sua reconhecida sensibilidade à biomassa verde e ao vigor vegetativo, os quais muitas vezes refletem de forma indireta a disponibilidade de nutrientes essenciais, como o fósforo (XUE; SU, 2017).

De acordo com Shammi et al. (2024), o NDVI destaca-se por sua resposta robusta à variação da cobertura vegetal, podendo superar outros índices, especialmente em condições de campo, onde múltiplos fatores ambientais influenciam o espectro de reflectância das culturas.

A matriz de correlação evidencia as relações lineares entre os índices espectrais NDVI, GNDVI, GRVI e o teor foliar de fósforo (P) a partir dos coeficientes de correlação de Pearson, estimados com intervalos de confiança de 95% (Figura 12).

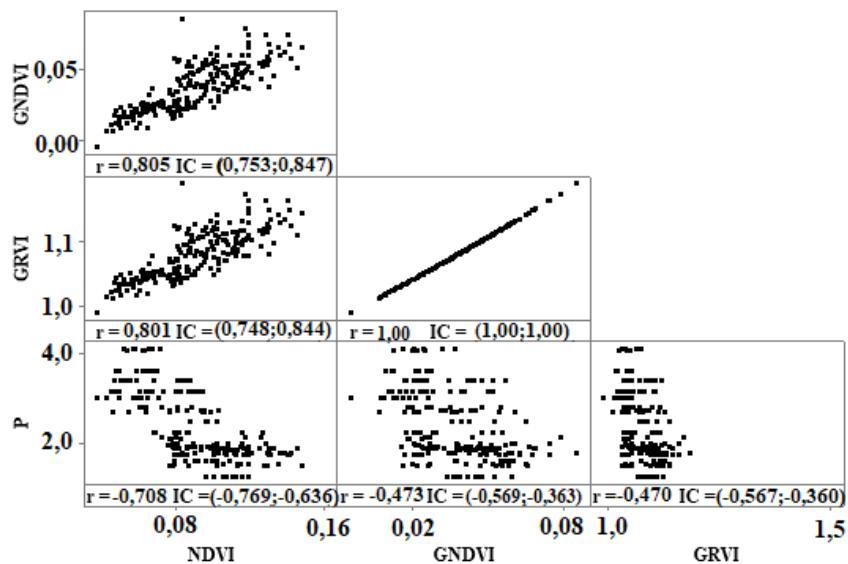


FIGURA 12. Matriz de dispersão entre os índices espectrais (NDVI, GNDVI e GRVI) e o teor foliar de fósforo em plantas de batata.

r = coeficiente de correlação de Pearson; IC = Intervalo de Confiança; NDVI: Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index); GNDVI: Índice de Vegetação por Diferença Normalizada do Verde (Green Normalized Difference Vegetation Index); GRVI: Índice de Vegetação Verde-Vermelho (Green-Red Vegetation Index).

Esse tipo de análise proporciona visão abrangente das interações entre os atributos espectrais e a variável nutricional de interesse, facilitando a identificação dos índices mais associados à dinâmica do fósforo nas plantas, prática consolidada em estudos agronômicos com sensoriamento remoto (XUE; SU, 2017; ARAÚJO et al., 2017).

Observa-se que o NDVI apresentou correlação negativa com o teor foliar de fósforo ($r = -0,708$; IC 95%: $-0,769$ a $-0,636$), superando os demais índices. Esse resultado corrobora com os modelos de regressão lineares apresentados, reforçando que valores elevados de NDVI estão associados a menores teores de fósforo nas folhas. Essa relação inversa é frequentemente atribuída ao efeito de diluição de nutrientes em plantas de elevado vigor

vegetativo, como detalhado por Marschner (2012), os quais destacam o NDVI como referência para avaliações nutricionais não destrutivas.

O GNDVI e o GRVI também exibiram correlações negativas com o teor de fósforo, indicando que a associação entre esses índices e o teor foliar de fósforo é fraca e pouco significativa sob o ponto de vista estatístico, e com intervalos de confiança mais dispersos. Esses índices, ainda que úteis para captar variações fisiológicas e estruturais da vegetação, são mais influenciados por fatores como teor de clorofila, área foliar e propriedades ópticas das folhas, que nem sempre refletem diretamente as oscilações nos níveis de fósforo, conforme argumentado por Gitelson et al. (2003).

A correlação positiva observada entre NDVI e GNDVI ($r = 0,805$) e entre NDVI e GRVI ($r = 0,801$) evidencia a redundância parcial dessas métricas derivadas do comportamento espectral da vegetação, mas reforça a especificidade do NDVI para captar variações associadas à biomassa verde e aos nutrientes de mobilidade moderada, como o fósforo (XUE; SU, 2017). Essa sobreposição é comum e salienta a importância da seleção criteriosa do índice mais sensível para cada contexto de diagnóstico nutricional. Adicionalmente, a ausência de correlações significativas próximas de zero entre alguns pares de índices reforça que nem todo índice espectral responde uniformemente às alterações em nutrientes foliares (FARIAS et al., 2022).

Os resultados da matriz de correlação estão em consonância com pesquisas recentes acerca da aplicação de sensoriamento remoto na agricultura, consolidando o uso combinado de análise de correlação e modelos preditivos na identificação de indicadores espectrais efetivos para programas de monitoramento nutricional (XUE; SU, 2017).

A análise visual das relações entre os atributos espectrais e o teor foliar de fósforo, por meio da matriz de dispersão, oferece uma perspectiva complementar às análises estatísticas já detalhadas. Tal abordagem permite identificar não apenas a direção e força das associações, mas também a linearidade dos dados e possíveis desvios ou padrões atípicos que podem influenciar a interpretação agronômica dos resultados (FARIAS et al., 2022).

O NDVI, por refletir majoritariamente o vigor vegetativo (biomassa verde ativa), responde à proporção entre radiação absorvida pelo pigmento clorofila e radiação refletida pelo dossel vegetal. Em diversas culturas, foi observado que plantas mais vigorosas, com maior índice de área foliar e biomassa, frequentemente apresentam valores relativamente reduzidos de fósforo por unidade de massa seca, fenômeno conhecido como “efeito de diluição” dos nutrientes (MARSCHNER, 2012). Isso ocorre porque, à medida que a planta

cresce rapidamente e aumenta a biomassa, o fornecimento de fósforo pode não acompanhar a mesma taxa, resultando em diminuição relativa do teor no tecido vegetal, mesmo que o suprimento absoluto do nutriente seja alto.

Farias et al. (2022) destacam que altos valores de NDVI estão tipicamente relacionados a teores foliares mais baixos de nutrientes como o fósforo, sendo este índice um dos mais robustos para monitorar, de maneira não destrutiva, o status nutricional em campo. De acordo com Xue e Su (2017), em revisões abrangentes sobre o uso de índices espectrais, o NDVI aparece sistematicamente entre os preditores de maior poder explicativo para nutrientes em diferentes espécies agrícolas, sendo particularmente sensível a variações de fósforo, nitrogênio e clorofila.

A relação inversa observada entre o teor foliar de fósforo e o NDVI destaca-se como um dos achados centrais deste trabalho. O coeficiente de correlação de Pearson, aliado ao intervalo de confiança estreito, evidencia não apenas a força, mas também a estabilidade estatística dessa associação negativa. Ou seja, quanto maior o teor de fósforo nas folhas, menor tende a ser o valor de NDVI observado.

Esse comportamento reflete um fenômeno fisiológico bem documentado: o chamado “efeito de diluição” dos nutrientes. Em situações em que o crescimento vegetativo é vigoroso, detectado por maiores valores de NDVI, há aumento acentuado da biomassa foliar, frequentemente superando o suprimento proporcional de nutrientes como o fósforo. Isso resulta na redução dos teores foliares relativos por unidade de massa seca, mesmo que a absorção absoluta do nutriente seja alta (MARSCHNER, 2012). Esse padrão é recorrente em culturas de alto rendimento, conforme revisões realizadas por Xue e Su (2017).

Diversos trabalhos recentes validam esse entendimento fisiológico com resultados empíricos. Farias et al. (2022), ao estudarem a soja, mostraram que, após um determinado acúmulo de biomassa, os valores de NDVI se estabilizam ou podem até diminuir, mesmo enquanto ocorre elevação do teor foliar de fósforo. Os autores associam esse comportamento diretamente ao efeito de diluição, em que plantas de crescimento intenso apresentam menor concentração relativa de fósforo. Já Gracia-Romero et al. (2017), pesquisando o milho, observaram que, embora aplicações de fósforo inicialmente elevem o NDVI, por promoverem o crescimento, as plantas mais vigorosas apresentaram teores foliares de fósforo mais baixos quando considerados em termos relativos, reforçando a tendência negativa detectada neste trabalho.

Bazhenov et al. (2023), estudando trigo, chegaram a conclusões semelhantes: genótipos de crescimento eficiente apresentaram valores mais altos de NDVI com teores foliares de fósforo relativamente menores, confirmando que o acúmulo de biomassa dilui a concentração do nutriente, refletida no padrão inverso entre NDVI e fósforo. Essa dinâmica é resultado direto das estratégias adaptativas das plantas em resposta à disponibilidade de nutrientes e ao ambiente, sendo documentada para diferentes culturas e condições experimentais (MARSCHNER, 2012; XUE; SU, 2017).

Esse entendimento é importante, pois embasa cientificamente a aplicação do NDVI em diagnósticos nutricionais na agricultura de precisão, permitindo a identificação de áreas com potencial diluição de nutrientes e orientando tomadas de decisão quanto ao manejo e à recomendação de fertilizantes (FARIAS et al., 2022; GRACIA-ROMERO et al., 2017). Portanto, os resultados deste estudo corroboram e ampliam as evidências presentes na literatura, consolidando o NDVI como ferramenta fundamental na inferência e no monitoramento não destrutivo do status de fósforo em plantas cultivadas.

Outro aspecto crucial, evidenciado pela amplitude do coeficiente de correlação e pelo agrupamento dos pontos na dispersão, é a aplicabilidade direta desse resultado em programas de agricultura de precisão. Como o NDVI pode ser obtido rápida e economicamente por sensores remotos embarcados em drones ou satélites, abre-se a possibilidade de se detectar e mapear deficiências locais de fósforo, tornando as recomendações de manejo mais assertivas e menos dependentes de amostragem destrutiva tradicional.

No entanto, vale ressaltar que a associação robusta entre NDVI e fósforo, embora significativa, não é absoluta. Outros fatores ambientais ou fisiológicos – tais como disponibilidade hídrica, densidade de plantas, estádio de desenvolvimento e presença de fatores limitantes no solo – também afetam o NDVI e, por consequência, a sua capacidade de isolar exclusivamente o efeito do fósforo sobre a vegetação (GITELSON et al., 2003). Isso justifica estratégias analíticas complementares, integrando NDVI a outros índices espectrais e covariáveis para aumentar a exatidão preditiva em condições reais de campo.

A adoção de uma abordagem multivariada, não apenas segue recomendações metodológicas reconhecidas (XUE; SU, 2017), como também oferece vantagens fundamentais. Essa estratégia permite ao modelo explorar possíveis interações, complementariedades e efeitos contextuais que apenas a análise univariada poderia deixar de captar, além de otimizar a capacidade preditiva em diferentes cenários de campo ou anos sazonais (PULLANAGARI; CAVALLI, 2023).

Quanto à estratégia de combinar diferentes índices como NDVI, GNDVI e GRVI com bandas espectrais (infravermelho próximo, vermelho e verde), revisões e artigos experimentais detalham que esse procedimento amplia significativamente a acurácia dos modelos preditivos. Gracia-Romero et al. (2017) demonstraram que, em milho, a utilização conjunta de vários índices e bandas permitiu maior robustez na estimação do estado nutricional (incluindo fósforo foliar), sobretudo em cenários com alta variabilidade ambiental e fisiológica. Passos similares são reiterados em sínteses recentes de machine learning para agricultura e sensoriamento remoto, que apontam a abordagem multivariada como essencial para aumentar a confiabilidade da inferência nutricional e reduzir as incertezas inerentes ao uso isolado de apenas um índice ou atributo espectral.

O modelo Random Forest obteve a melhor performance geral, alcançando RMSE relativo de 19,01%, além de coeficiente de correlação de 0,81 e menor erro absoluto médio entre as abordagens testadas (Tabela 4).

TABELA 4. Valores de erro médio quadrático (RMSE), erro percentual (RMSE%) e coeficiente de correlação de Pearson (*r*) obtidos para a variável fósforo utilizando os algoritmos Random Forest, Multilayer Perceptron e SMOreg.

| Teor | Classificadores | | | | | | | | |
|-------------------------------|-----------------|-------|----------|-----------------------|-------|----------|--------|-------|----------|
| | Random Forest | | | Multilayer Perceptron | | | SMOreg | | |
| foliar de | RMSE | RMSE% | <i>r</i> | RMSE | RMSE% | <i>r</i> | RMSE | RMSE% | <i>r</i> |
| fósforo (g kg ⁻¹) | 0.45 | 19.05 | 0.81 | 0.56 | 23.41 | 0.74 | 0.55 | 22.98 | 0.71 |

RMSE = raiz do erro quadrado médio; RMSE% = raiz do erro quadrático médio em percentual em relação à média observada; *r* = Coeficiente de correlação de Pearson entre os valores observados e preditos.

A avaliação comparativa dos algoritmos Random Forest, Multilayer Perceptron e SMOreg, utilizando fósforo como variável predita e os índices espectrais (NDVI, GNDVI, GRVI) juntamente com bandas RGN (infravermelho próximo, vermelho e verde) como atributos de entrada através do software WEKA, traz insights valiosos para o avanço das estratégias de estimação não destrutiva de fósforo foliar na cultura da batata.

Essa superioridade do modelo Random Forest pode ser atribuída à capacidade do algoritmo combinar múltiplas árvores de decisão, explorando relações não lineares e interações entre diferentes atributos espectrais. Isso é especialmente relevante quando se

trabalha com variáveis de natureza distinta (índices e bandas), pois o algoritmo consegue adaptar-se à complexidade fisiológica da cultura da batata e responder com precisão às nuances apresentadas no padrão espectro-nutricional, reforçando achados prévios na literatura para culturas de grande relevância econômica

No aspecto metodológico, o desempenho preditivo do Random Forest, alinhado ao que foi apresentado com métodos lineares, evidencia que a relação entre os atributos espectrais e o fósforo foliar é preditivamente estável e majoritariamente linear, com ganhos episódicos ao se incluir múltiplos atributos, devido à possível presença de interações específicas ou outliers. A validação cruzada, utilizada para avaliar o modelo, confere robustez e maior fidedignidade ao desempenho reportado (HALL et al., 2009).

Além disso, a análise de importância dos atributos promovida pelo Random Forest reforça a transparência metodológica, pois torna explícitas as contribuições individuais de cada variável ao modelo final, permitindo justificar cientificamente a priorização do NDVI e, ao mesmo tempo, demonstrar a coerência da inclusão de outras variáveis – estratégia alinhada ao que há de mais recente em sensoriamento remoto agrícola (XUE; SU, 2017).

A aplicação desse método multiespectral e da modelagem por Random Forest é particularmente relevante para culturas como a batata, caracterizadas por rápida dinâmica de crescimento e sensibilidade à disponibilidade de fósforo. Como discutido por Xue e Su (2017), a integração de informações fisiológicas provenientes de múltiplos índices permite captar nuances do estado nutricional da planta, ampliando o valor agronômico das previsões e alinhando o processo às demandas da agricultura de precisão.

O Multilayer Perceptron apresentou RMSE relativo de 23,41% e coeficiente de correlação de 0,74 (Tabela 4). Seu desempenho, embora inferior ao Random Forest, destaca-se pela habilidade de modelar relações não lineares complexas e capturar padrões que podem escapar a métodos tradicionalmente lineares. A ligeira queda na performance, quando comparado ao Random Forest, pode ser atribuída ao tamanho amostral limitado ou à própria natureza dos dados, sugerindo que, no contexto estudado, a relação entre atributos espectrais e fósforo é robusta, porém relativamente linear ou modulada por poucas interações mais simples (XUE; SU, 2017). Mesmo assim, a adoção desse algoritmo é relevante pois valida, de forma independente, os ganhos decorrentes da multiespectralidade, além de permitir adaptações futuras para bancos de dados maiores e cenários mais complexos (GRACIA-ROMERO et al., 2017).

O modelo SMOreg, correspondente ao Support Vector Regression (SVR), apresentou resultados sólidos para a predição do teor foliar de fósforo a partir de atributos espectrais multivariados, com RMSE relativo de 22,98% e coeficiente de correlação de 0,71 (Tabela 4). Esse desempenho evidencia a robustez do SMOreg em cenários agronômicos, atuando, eficazmente, mesmo na presença de variáveis não linearmente correlacionadas ou de outliers nos dados espectrais (GUEVARA et al., 2023). Embora o SMOreg não tenha exibido a menor margem de erro quando comparado ao Random Forest ou ao Multilayer Perceptron, sua estabilidade e capacidade de generalização reforçam sua utilidade prática, especialmente para bancos de dados de tamanho moderado ou variabilidade significativa de campo (XUE; SU, 2017).

Os resultados obtidos neste estudo oferecem contribuições iniciais para o desenvolvimento de métodos voltados à detecção instantânea de fósforo na cultura da batata, indicando potencial para aplicações que otimizem o manejo nutricional do cultivo. Embora representem apenas um passo dentro de um campo em expansão, os achados reforçam a importância de aprofundar pesquisas futuras, tanto em ambiente controlado quanto em condições de campo, para validar e aprimorar a viabilidade dessa abordagem. Dessa forma, este trabalho se apresenta como uma base para investigações subsequentes que visem consolidar estratégias de monitoramento rápido e eficiente do fósforo, contribuindo para práticas agrícolas mais sustentáveis e produtivas.

5 CONCLUSÕES

Há possibilidade da detecção de fósforo foliar na cultura da batata (*Solanum tuberosum* L.), especialmente quando se faz uso de imagens multiespectrais derivadas da câmera MAPIR Survey3 (sensor RGN), empregando o índice espectral NDVI e algoritmos de aprendizado de máquina como o Random Forest.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ABDEL-SALAM, M.; KUMAR, N.; MAHAJAN, S. A proposed framework for crop yield prediction using hybrid feature selection approach and optimized machine learning. **Neural Computing and Applications**, v. 36, p. 20723–20750, 2024. DOI: <https://doi.org/10.1007/s00521-024-10226-x>. Disponível em: <https://link.springer.com/article/10.1007/s00521-024-10226-x>. Acesso em: 15 set. 2025.
- AHMAD, N. *et al.* Environmental implications of phosphate-based fertilizer industrial waste and its management practices. **Environmental Monitoring and Assessment**, v. 195, art. 1326, 2023. DOI: <https://doi.org/10.1007/s10661-023-11958-4>. Disponível em: <https://link.springer.com/article/10.1007/s10661-023-11958-4>. Acesso em: 13 mai. 2025.
- ASSOCIAÇÃO BRASILEIRA DA BATATA. **Agata** – características agronômicas. ABBA. Itapetininga, SP, 2010. Disponível em: <https://www.abbabatatabrasileira.com.br/variedades/agata>. Acesso em: 22 jul. 2025.
- ASSOCIAÇÃO BRASILEIRA DA BATATA. **Batata no Triângulo Mineiro**: o crescimento da bataticultura no Alto Paranaíba e Triângulo Mineiro e a importância do ICIAG/UFU – Uberlândia/MG na formação de profissionais para o setor. Revista da Batata Show, Itapetininga SP, 2023. Disponível em <https://www.abbabatatabrasileira.com.br/materias-das-revistas/batata-no-triangulo-mineiro-o-crescimento-da-bataticultura-no-alto-paranaiba-e-triangulo-mineiro-e-a-importancia-do-iciag-ufu-%C2%96-uberlandiamg-na-formacao-de-profissionais-para-o-setor/>. Acesso em: 01 jun. 2025.
- ARAÚJO, S. M. S. *et al.* Aplicação de índices de vegetação derivados de dados multiespectrais no monitoramento de culturas agrícolas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 8, p. 562-568, 2017.
- AMERICAN SOCIETY FOR PHOTOGRAVIMETRY AND REMOTE SENSING. The American Society for Photogrammetry and Remote Sensing. **Photogrammetric Engineering & Remote Sensing**, v. 55, n. 7, p. 979-984, 1989. Acesso em: 30 mai. 2025.
- BANNARI, A.; MORIN, D.; HUETE, A. R. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, n. 1-2, p. 95-120, 1995.
- BARBEDO, J. G. A. A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. **Drones**, v. 3, n. 2, p. 40, 2019. DOI: <https://doi.org/10.3390/drones3020040>. Disponível em: <https://www.mdpi.com/2504-446X/3/2/40>. Acesso em: 15 jun. 2025.
- BAZHENOV, M. *et al.* Evaluation of phosphate rock as the only source of phosphorus for the growth of tall and semi-dwarf durum wheat and rye plants using digital phenotyping. **PeerJ**, v. 11, e15972, 2023. DOI: <https://doi.org/10.7717/peerj.15972>. Disponível em: <https://peerj.com/articles/15972/>. Acesso em: 30 ago. 2025.
- BECK, H. E. *et al.* Present and future Köppen–Geiger climate classification maps at 1-km resolution. **Scientific Data**, v. 1, p.1-12, 2018.

BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: a review of applications and future directions. **Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271616300039>. Acesso em: 6 jun. 2025.

BISHOP, C. M. Pattern Recognition and Machine Learning. New York: **Springer**, 2006. 738 p. ISBN 978 0 387 31073 2.

BRANDÃO, Z. N. *et al.* Estimation of nitrogen and phosphorus content in cotton leaves from medium-resolution satellite images. **Revista Caderno Pedagógico**, v. 21, n. 6, p. 01–21, 2024. DOI: <https://doi.org/10.54033/cadpedv21n6-293>. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/5292>. Acesso em: 09 set. 2025.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, 2001. Disponível em: <https://link.springer.com/article/10.1023/A:1010933404324>. Acesso em: 19 ago. 2025.

CAMENZIND, M. P.; YU, K. Multi-temporal multispectral UAV remote sensing allows for yield assessment across European wheat varieties already before flowering. **Frontiers in Plant Science**, v. 14, 2024. DOI: <https://doi.org/10.3389/fpls.2023.1214931>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2023.1214931/full>. Acesso em: 11 jul. 2025.

CAMIRE, M. E.; KUBOW, S.; MAZZA, G. Health benefits of potatoes. **Critical Reviews in Food Science and Nutrition**, v. 49, n. 10, p. 823–840, 2009. DOI: <https://doi.org/10.1080/10408390903041996>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10408390903041996>. Acesso em: 25 mai. 2025.

CARTAY, R.; DÁVILA, L. R. Nuevo Mundo e historia de la alimentación: el “dulce tubérculo” (*Ipomoea batatas*) de los Cronistas de Indias. **Revista Complutense de Historia de América**, v. 46, p. 85–104, 2020. DOI: <https://doi.org/10.5209/rcha.69414>. Disponível em: <https://revistas.ucm.es/index.php/RCHA/article/view/69414>. Acesso em: 6 mar. 2025.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247–1250, 2014. DOI: <https://doi.org/10.5194/gmd-7-1247-2014>. Disponível em: <https://gmd.copernicus.org/articles/7/1247/2014/>. Acesso em: 11 jul. 2025.

CHAN, K. Y. *et al.* Deep neural networks in the cloud: review, applications, challenges and research directions. **Neurocomputing**, v. 545, p. 126316, 2023. DOI: <https://doi.org/10.1016/j.neucom.2023.126316>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0925231223004393?via%3Dihub>. Acesso em: 7 dez. 2025.

CHANG, C. C.; LIN, C.J. LIBSVM: a library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, p. 1-27, 2011. DOI:

<https://doi.org/10.1145/1961189.1961199>. Disponível em:
<https://dl.acm.org/doi/10.1145/1961189.1961199>. Acesso em: 21 abr. 2025.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273- 297, 1995. DOI: <https://doi.org/10.1007/BF00994018>. Disponível em:
<https://link.springer.com/article/10.1007/BF00994018>. Acesso em: 8 jul. 2025.

DECHEN, A. R.; NACHTIGALL, G. R. Nutrição mineral de plantas. In: FERNANDES, M. S. (org.). Nutrientes para as plantas cultivadas. Viçosa: **Sociedade Brasileira de Ciência do Solo**, 2007. p. 377–440. Disponível em:
<https://ainfo.cnptia.embrapa.br/infoteca/handle/doc/866512>. Acesso em: 21 ago. 2025.

DEGUCHI, T. *et al.* Effect of varietal difference in root system on hydraulic conductance in potatoes under different soil water conditions and planting dates. **Potato Research**, v. 58, p. 103-119, 2015. DOI: <https://doi.org/10.1007/s11540-015-9289-1>. Disponível em:
<https://link.springer.com/article/10.1007/s11540-015-9289-1>. Acesso em: 16 jul. 2025.

DHILLON, M. S. *et al.* Integrating random forest and crop modeling improves the crop yield prediction of winter wheat and oilseed rape. **Frontiers in Remote Sensing**, v. 3, 2023. DOI: <https://doi.org/10.3389/frsen.2022.1010978>. Disponível em:
<https://www.frontiersin.org/articles/10.3389/frsen.2022.1010978/full>. Acesso em: 21 ago. 2025.

EL-KENAWY, E. M. *et al.* Predicting potato crop yield with machine learning and deep learning for sustainable agriculture. **Potato Research**, v. 68, p. 759–792, 2025. DOI: <https://doi.org/10.1007/s11540-024-09753-w>. Disponível em:
<https://link.springer.com/article/10.1007/s11540-024-09753-w>. Acesso em: 15 set. 2025.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Manual de métodos de análises químicas de solos, plantas e fertilizantes**. 2. ed. Embrapa Solos. Embrapa, Brasília, DF, 2009. 627 p

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Embrapa, Brasília, DF, 2018. 356 p.

FAN, F. *et al.* Estimating leaf phosphorus concentration in rice by combining spectral and texture features. **Agronomy for Sustainable Development**, 2024. DOI: <https://doi.org/10.1002/agg2.70160>. Disponível em:
<https://onlinelibrary.wiley.com/doi/10.1002/agg2.70160>. Acesso em: 18 ago. 2025.

FAN, R. E.; CHEN, P. H.; LIN, C. J. Working set selection using second order information for training support vector machines. **Journal of Machine Learning Research**, v. 6, p. 1889- 1918, 2005. Disponível em: <https://www.jmlr.org/papers/volume6/fan05a/fan05a.pdf>. Acesso em: 21 jun. 2025.

FARIAS, J. R. B. *et al.* Normalized Difference Vegetation Index (NDVI) for soybean shoot biomass and phosphorus and potassium uptake prediction. **Frontiers in Sustainable Food Systems**, 2022. DOI: <https://doi.org/10.3389/fsufs.2022.959681>. Disponível em:
<https://www.frontiersin.org/articles/10.3389/fsufs.2022.959681/full>. Acesso em: 17 ago.

2025.

FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311–318, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.01.009>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169917311742>. Acesso em: 19 mai. 2025.

FERNANDES, A. M. *et al.* Influência do fósforo na qualidade e produtividade de tubérculos de cultivares de batata de duplo propósito. **Horticultura Brasileira**, Brasília, v. 34, n. 3, p. 346–355, 2016. DOI: <https://doi.org/10.1590/S0102-05362016003007>. Disponível em: <https://www.scielo.br/j/hb/a/7tZb7cYJ9V9JkQ7N9g7g7g7/?lang=pt>. Acesso em: 8 ago. 2025.

FERNANDES, A. M. *et al.* Nutrient uptake and removal by potato cultivars as affected by phosphate fertilization of soils with different levels of phosphorus availability. **Revista Brasileira de Ciência do Solo**, v. 41, 2017. DOI: 10.1590/18069657rbcs20160288. DOI: <http://dx.doi.org/10.1590/18069657rbcs20160288>. Disponível em: <https://www.rbcjournal.org/article/nutrient-uptake-and-removal-by-potato-cultivars-as-affected-by-phosphate-fertilization-of-soils-with-different-levels-of-phosphorus-availability/>. Acesso em: 15 mai. 2025.

FERNANDES, A. M. *et al.* Manejo da adubação fosfatada na cultura da batata. **Informações Agronômicas**, n. 158, p. 1-10, 2017. Disponível em: <http://ipni.net/publication/ia-brasil.nsf/issue/IA-BRASIL-2017-158?OpenDocument&toc=1>. Acesso em: 28 ago. 2025.

FERNANDES, A. M.; SORATTO, R. P. Nutrição, acúmulo e partição da matéria seca e eficiência de utilização do fósforo pela batateira sob doses de fósforo em solução nutritiva. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 36, n. 5, p. 1528–1537, set./out. 2012. DOI: <https://doi.org/10.1590/S0100-06832012000500017>. Disponível em: <https://www.scielo.br/j/rbcs/a/DCNcGNbwmpz6t4PMvksGt6j/?lang=en>. Acesso em: 2 set. 2025.

FERNANDES, F. M. **Produtividade de tubérculos e extração de nutrientes em batata sob manejo de nitrogênio**. 2021. Tese (Doutorado em Agronomia) – Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Botucatu, SP, 2021. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/202878/fernandes_fm_dr_botfca.pdf?sequence=10&isAllowed=y. Acesso em: 11 jun. 2025.

FERREIRA, D. F. **Estatística multivariada**. 2. ed. Lavras: UFLA, 2018.

GAMON, J. A. *et al.* Assessing vegetation function with imaging spectroscopy. **Surveys in Geophysics**, v. 40, p. 489-513, 2019. DOI: <https://doi.org/10.1007/s10712-019-09511-5>. Disponível em: <https://link.springer.com/article/10.1007/s10712-019-09511-5>. Acesso em: 8 ago. 2025.

GILBERT, N. Environment: The disappearing nutrient. **Nature**, v. 461, p. 716-718, 2009. DOI: <https://doi.org/10.1038/461716a>. Disponível em: <https://www.nature.com/news/2009/091007/pdf/461716a.pdf>;

<https://www.nature.com/articles/461716a>. Acesso em: 19 ago. 2025.

GITELSON, A. A; KAUFMAN, Y.; MERZLYAK, M. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7). Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425796000727>. Acesso em: 15 mai. 2025.

GITELSON, A. A. *et al.* Remote estimation of canopy chlorophyll content in crops. **Geophysical Research Letters**, v. 30, n. 17, p.1893, 2003. DOI: <https://doi.org/10.1029/2005GL022688>. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2005GL022688>. Acesso em: 27 jun. 2025.

GRACIA-ROMERO, A. *et al.* Comparative performance of ground vs. aerially assessed vegetation indices to detect deficiencies of iron, sulfur, and phosphorus in maize. **Frontiers in Plant Science**, 2017. DOI: <https://doi.org/10.3389/fpls.2017.02004>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2017.02004/full>. Acesso em: 22 ago. 2025.

GUEVARA, de L. *et al.* Application of Machine Learning Algorithms to Describe Agricultural Outcomes. **Animals**, v. 13, n. 17, 2023. DOI: <https://doi.org/10.3390/ani13172772>. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10487024/>. Acesso em: 09 dez. 2025. Acesso em: 18 jul. 2025.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Upper Saddle River: Prentice Hall, 2009. Disponível em: <https://www.pearson.com/en-us/subject-catalog/p/neural-networks-and-learning-machines/P200000000281/9780131471399>. Acesso em: 20 ago. 2025.

HALL, F. G. *et al.* Radiometric rectification: toward a common radiometric response among multiday, multisensor images. **Remote Sensing of Environment**, v. 35, n. 1, p. 11-27, 1991. DOI: [https://doi.org/10.1016/0034-4257\(91\)90062-B](https://doi.org/10.1016/0034-4257(91)90062-B). Disponível em: <https://www.sciencedirect.com/science/article/pii/003442579190062B>. Acesso em: 8 dez. 2025.

HALL, M. *et al.* The WEKA data mining software: an update. **ACM SIGKDD explorations newsletter**, v. 11, n. 1, p. 10–18, 2009.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de física**: vol. 3 – Eletromagnetismo. 10. ed. São Paulo: LTC, 2016.

HEINRICH, P. O fósforo nos solos brasileiros. **Boletim da Faculdade de Agronomia da UFRGS**, Porto Alegre, n. 23, p. 15–28, 1966.

HILL, D. *et. al.* Morphophysiology of potato (*Solanum tuberosum*) in response to drought stress: paving the way forward. **Frontiers in Plant Science**, v. 11:597554, jan. 2021. DOI: <https://doi.org/10.3389/fpls.2020.597554>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2020.597554/full>. Acesso em: 12 mar. 2025.

ILLAKWAHHI, D. T.; VEGI, M. R.; SRIVASTAVA, B. B. L. Phosphorus' future insecurity, the horror of depletion, and sustainability measures. **International Journal of Environmental Science and Technology**, v. 21, p. 9265–9280, 2024. DOI: <https://doi.org/10.1007/s13762-024-05664-y>. Disponível em: <https://link.springer.com/article/10.1007/s13762-024-05664-y>. Acesso em: 21 ago. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Levantamento Sistemático da Produção Agrícola** – outubro/2024. Rio de Janeiro: IBGE, 2024a. Disponível em: https://ftp.ibge.gov.br/Producao_Agricola/Levantamento_Sistematico_da_Producao_Agricola_%5Bmensal%5D/Fasciculo_Indicadores_IBGE/2024/estProdAgri_202410.pdf. Acesso em: 10 mai. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Produção de batata apresenta variação no Brasil. **Boletim de Conjuntura Agropecuária** – Levantamento Sistemático da Produção Agrícola (LSPA), 6 jun. 2024b. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/40079-release-lspa-abril>. Acesso em: 10 mai. 2025.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Radiação eletromagnética e princípios de sensoriamento remoto**. São José dos Campos: INPE, 2005. Disponível em: http://www.dpi.inpe.br/sensoriamento_remoto/. Acesso em: 21 mai. 2025.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Sensoriamento remoto: estudo da vegetação**. São José dos Campos: INPE, 2018. Disponível em: http://www.obt.inpe.br/DSR/educacao/uso-escolar-sensoriamento-remoto/material-didatico-anos-anteriores/arquivos/capitulo_8.pdf. Acesso em: 25 mai. 2025.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. Tradução da 2^a ed. por (pesquisadores do INPE): José Carlos N. Epiphanio (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 672 p, 2009.

JEUNE, de W. *et al.* Multinomial logistic regression and random forest classifiers in digital mapping of soil classes in western Haiti. **Revista Brasileira de Ciência do Solo**, v. 42, e0170133, 2018. DOI: <https://doi.org/10.1590/18069657rbcs20170133>. Disponível em: <https://www.scielo.br/j/rbcs/a/9tYF9f7hL9W7kYhX9Jm7V7m/?lang=en>. Acesso em: 1 mai. 2025.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.02.016>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917308803?via%3Dihub>. Acesso em: 5 set. 2025.

KEERTHI, S. S. *et al.* Improvements to Platt's SMO algorithm for SVM classifier design. **Neural Computation**, v. 13, n. 3, p. 637-649, 2001. DOI: <https://doi.org/10.1162/089976601300014493>. Disponível em:

<https://direct.mit.edu/neco/article-abstract/13/3/637/6885>. Acesso em: 30 mai. 2025.

KHAKI, S.; WANG, L. Crop yield prediction using deep neural networks. **Frontiers in Plant Science**, v. 10, p. 621, 2019. DOI: <https://doi.org/10.3389/fpls.2019.00621>. Disponível em: <https://doi.org/10.3389/fpls.2019.00621>. Acesso em: 5 set. 2025.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22-32, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.05.001>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169917302287>. Acesso em: 10 jun. 2025.

KOHAVI, Ron. A study of cross-validation and bootstrap for accuracy estimation and model selection. **Proceedings of the 14th international joint conference on artificial intelligence** - Volume 2, Montreal, QC, Canada, p. 1137–1143, 1995.

LE, C. V.; PHAM, L. T. Estimating leaf phosphorus concentration in rice by combining vegetation indices, texture features, and water indices from UAV multispectral imagery. **Agrosystems, Geosciences & Environment**, v. 8, n. 1, e70160, 2025. DOI: <https://doi.org/10.1002/agg2.70160>. Disponível em: <https://acsess.onlinelibrary.wiley.com/doi/pdf/10.1002/agg2.70160>. Acesso em: 15 set. 2025.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436 444, 2015. DOI: <https://doi.org/10.1038/nature14539>. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 10 ago. 2025.

LI, C. *et al.* Predicting changes in agricultural yields under climate change scenarios and their implications for global food security. **Scientific Reports**, v. 15, art. 87047, 2025. DOI: <https://doi.org/10.1038/s41598-025-87047-y>. Disponível em: <https://www.nature.com/articles/s41598-025-87047-y>. Acesso em: 13 mai. 2025.

LIU, X.; GU, W.; QIN, S. Adaptive kernel scaling support vector machine with application to a prostate cancer image study. **Computational and Mathematical Methods in Medicine**, v. 2023, p. 1-17, 2023. DOI: <https://doi.org/10.1080/02664763.2020.1870669> Disponível em: https://pmc.ncbi.nlm.nih.gov/articles/PMC9041565/?utm_source=chatgpt.com. Acesso em: 15 mai. 2025.

LIMA, G. C. *et al.* Os índices de vegetação NDVI e EVI no monitoramento do cultivo da soja no município de Querência – MT, safra 2020/2021. **Contexto Geográfico**, v. 8, n. 16, p. 121– 134, 2012. DOI: <https://doi.org/10.28998/contegeo.8i16.15694>. Disponível em: <https://ufal.emnuvens.com.br/contextogeografico/article/view/15694>. Acesso em: 16 jul. 2025.

MA, Y. P. *et al.* Estimating potassium in potato plants based on multispectral images acquired from unmanned aerial vehicles. **Frontiers in Plant Science**, v. 14, 2023. DOI: <https://doi.org/10.3389/fpls.2023.1265132>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2023.1265132/full>. Acesso em: 8 dez. 2025.

MARSCHNER, P. **Marschner's Mineral Nutrition of Higher Plants**. 3. ed. Academic Press, 2012.

MARTINS, G. D.; GALO, M. L. B. T.; VIEIRA, B. S. Detecting and Mapping Root-Knot Nematode Infection in Coffee Crop Using Remote Sensing Measurements. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, p. 1-9, 2017. DOI: <https://doi.org/10.1109/JSTARS.2017.2737618>. Disponível em: <https://ieeexplore.ieee.org/document/8012578>. Acesso em: 10 jul. 2025.

MUJAWAR, R. Y. *et al.* IoT-enabled intelligent irrigation system with machine learning-based monitoring for effective rice cultivation. **International Journal of Intelligent Systems and Applications in Engineering**, v. 12, n. 11s, 2024. Disponível em: <https://ijisae.org/index.php/IJISAE/article/view/4476>. Acesso em: 12 jul. 2025.

MUKAKA, M. M. Statistics corner: A guide to appropriate use of correlation coefficient in medical research. **Malawi Medical Journal**, v. 24, n. 3, p. 69–71, 2012. DOI: <https://pubmed.ncbi.nlm.nih.gov/23638278/>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3576830/>. Acesso em: 12 mar. 2025.

MUKIIBI, A. *et. al.* A systematic review of vegetation indices for potato growth monitoring and tuber yield prediction from remote sensing. **Potato Research**, v. 68, p. 409–448, 2024. DOI: <https://doi.org/10.1007/s11540-024-09748-7>. Disponível em: <https://link.springer.com/article/10.1007/s11540-024-09748-7>. Acesso em: 19 jul. 2025.

NOVAIS, R. F.; SMYTH, T. J. **Fósforo em solo e planta em condições tropicais**. Viçosa: Universidade Federal de Viçosa, 1999. 399 p.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010. 387 p.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA ALIMENTAÇÃO E AGRICULTURA. **Potatoes: so familiar, so much more to learn**. Roma: FAO, 2025. Disponível em: <https://www.fao.org/publications/news-archive/detail/potatoes-so-familiar-so-much-more-to-learn/en>. Acesso em: 8 jun. 2025.

PADMA, T.; SINHA, D. Crop Yield Prediction Using Improved Random Forest. **ITM Web of Conferences**, v. 56, 2023. DOI: <https://doi.org/10.1051/itmconf/20235602007>. Disponível em: https://www.itm-conferences.org/articles/itmconf/abs/2023/01/itmconf_icacc2023_02007/itmconf_icacc2023_02007.html. Acesso em: 24 ago. 2025.

PAILLIÈ JIMÉNEZ, M. E. *et al.* Normalized difference vegetation index (NDVI) for soybean biomass and nutrient uptake estimation in response to production systems and fertilization. **Lume Repositório Digital**, 2023. Disponível em: <http://hdl.handle.net/10183/262519>. Acesso em: 20 jun. 2025.

PATEL, N. R.; POKHARIYAL, S.; SINGH, R. P. Advancements in remote sensing based

crop yield modelling in India. **Journal of Agrometeorology**, v. 25, n. 3, p. 345–355, 2023. DOI: <https://doi.org/10.54386/jam.v25i3.2316>. Disponível em: <https://journal.agrimetassociation.org/index.php/jam/article/view/2316>. Acesso em: 10 jul. 2025.

PAVINATO, P. S. *et al.* Revealing soil legacy phosphorus to promote sustainable agriculture in Brazil. **Scientific Reports**, v. 10, art. 15615, 2020. DOI: <https://doi.org/10.1038/s41598-020-72302-1>. Disponível em: <https://www.nature.com/articles/s41598-020-72302-1>. Acesso em: 29 jun. 2025.

PENG, Y. *et al.* Early detection of plant virus infection using multispectral imaging and spatial-spectral machine learning. **Scientific Reports**, v. 12, n. 1, p. 2345, 2022. DOI: <https://doi.org/10.1038/s41598-022-06372-8>. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8873445>. Acesso em: 29 ago. 2025.

PETTORELLI, N. The normalized difference vegetation index. **Oxford**: Oxford University Press, 2013. 194 p.

PLATT, J. Sequential minimal optimization: a fast algorithm for training support vector machines. **Advances in Kernel Methods: Support Vector Learning**, p. 185-208, 1998.

PULLANAGARI, R. R.; CAVALLI, D. Advances and applications of multivariate statistics and soil-crop sensing to improve nutrient use efficiency and monitor carbon cycling. **Nutrient Cycling in Agroecosystems**, v. 127, p. 97–99, 2023. DOI: <https://doi.org/10.1007/s10705-023-10310-z>. Disponível em: <https://link.springer.com/article/10.1007/s10705-023-10310-z>. Acesso em: 8 ago. 2025.

QOMARIYAH, N. *et al.* Applying Random Forest for optimal crop selection to precision agriculture. **Atlantis Highlights in Computer Sciences**, v. 7, 2024. DOI: https://doi.org/10.2991/978-94-6463-620-8_6. Disponível em: https://www.atlantis-press.com/proceedings/icacs-24/978-94-6463-620-8_6. Acesso em: 12 jul. 2025.

RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ V., V. H. (ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5^a aproximação**. Viçosa: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999. 359 p.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. In: Third Earth Resources Technology Satellite-1. **Symposium**, 1974, Washington. Proceedings. Washington: NASA, 1974. p. 309–317.

RUDORFF, B. F. T. *et al.* The soy moratorium in the Amazon biome monitored by remote sensing images. **Remote Sensing**, v. 3, n. 1, p. 185-202, 2011. DOI: <https://doi.org/10.3390/rs3010185>. Disponível em: <https://doi.org/10.3390/rs3010185>. Acesso em: 19 mai. 2025.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back propagating errors. **Nature**, v. 323, n. 6088, p. 533 536, 1986. DOI: <https://doi.org/10.1038/323533a0>. Disponível em: <https://doi.org/10.1038/323533a0>. Acesso em: 3 ago. 2025.

SANTOS, A. P. *et al.* Random forest algorithm applied to model soil textural classification in rural basins. **Environmental Monitoring and Assessment**, v. 197, n. 5, 2025. DOI: <https://doi.org/10.1007/s10661-025-13786-0>. Disponível em: <https://doi.org/10.1007/s10661-025-13786-0>. Acesso em: 21 ago. 2025.

SANTOS, J. J. S. *et al.* Capacidade de adsorção de fósforo em solos de textura arenosa com fertilidade construída. **Revista Agrogeoambiental**, Pouso Alegre, v. 13, n. 3, p. 606-614, set. 2021. DOI: <http://dx.doi.org/10.18406/2316-1817v13n320211639>. Disponível em: <http://dx.doi.org/10.18406/2316-1817v13n320211639>. Acesso em: 2 ago. 2025.

SCHMIDHUBER, J. Deep learning in neural networks: an overview. **Neural Networks**, v. 61, p. 85 117, 2015. DOI: <https://doi.org/10.1016/j.neunet.2014.09.003>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/25462637/>. Acesso em: 19 jun. 2025.

SCHONLAU, M.; ZOU, R. Y. The random forest algorithm for statistical learning. **The Stata Journal**, v. 20, n. 1, p. 3-29, 2020. DOI: <https://doi.org/10.1177/1536867X20909688>. Disponível em: <https://www.stata-journal.com/article.html?article=st0586>. Acesso em: 30 mai. 2025.

SCHÖLKOPF, B.; SMOLA, A. J. **Learning with kernels**: support vector machines, regularization, optimization, and beyond. Cambridge: MIT Press, 2002.

SHAMMI, A. *et al.* Application of UAV multispectral imaging to monitor soybean growth with yield prediction through machine learning. **Agronomy**, v. 14, n. 4, 672, 2024. DOI: <https://doi.org/10.3390/agronomy14040672>. Disponível em: <https://www.mdpi.com/2073-4395/14/4/672>. Acesso em: 8 dez. 2025.

SHEVADE, S. K. *et al.* Improvements to the SMO algorithm for SVM regression. **IEEE Transactions on Neural Networks**, v. 11, n. 5, p. 1188-1193, 2000. DOI: <https://doi.org/10.1109/72.870050>. Disponível em: http://www.keerthis.com/smoreg_ieee_shevade_00.pdf. Acesso em: 30 ago. 2025.

SILVA, P H S. **Diagnóstico nutricional da rúcula para nitrogênio com processamento digital de imagens. Jaboticabal**. Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2021. Tese (Doutorado em Agronomia – Produção Vegetal). Disponível em: <https://repositorio.unesp.br/entities/publication/03a6f85d-2ebe-4036-baae-00edc9b687e6>. Acesso em: 18 nov. 2025.

SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 337-354, 2002.

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. Applications of remote sensing in precision agriculture: a review. **Remote Sensing**, v. 12, n. 19, p. 3136, 2020. DOI: <https://doi.org/10.3390/rs12193136>. Disponível em: <https://www.mdpi.com/2072-4292/12/19/3136>. Acesso em: 15 set. 2025.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, v. 14, n. 3, p. 199-222, 2004. DOI:

<https://doi.org/10.1023/B:STCO.0000035301.49549.88>. Disponível em:
<http://i2pc.es/coss/Docencia/SignalProcessingReviews/Smola2004.pdf>. Acesso em: 30 ago. 2025.

SOARES, N. B. *et al.* Soil factors affecting phosphorus adsorption in soils of the Cerrado, Brazil. **Semina: Ciências Agrárias**, Londrina, v. 38, n. 5, p. 2909–2920, 2017. DOI: <https://doi.org/10.1016/j.geodrs.2020.e00298>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352009420300980>. Acesso em: 24 jul. 2025.

SUN, G. *et al.* Nondestructive determination of nitrogen, phosphorus and potassium contents in greenhouse tomato plants based on multispectral three-dimensional imaging. **Sensors**, v. 19, n. 23, p. 5295, 2019. DOI: <https://doi.org/10.3390/s19235295>. Disponível em: <https://www.mdpi.com/1424-8220/19/23/5295>. Acesso em: 4 ago. 2025.

SUN, Z. *et al.* An improved random forest based on the classification accuracy and correlation measurement of decision trees. **Expert Systems with Applications**, v. 237, 2024. DOI: <https://doi.org/10.1016/j.eswa.2023.121549>. Disponível em: https://search.library.newschool.edu/discovery/fulldisplay/cdi_crossref_primary_10_1016_j_eswa_2023_121549/01NYU_TNS:TNS. Acesso em: 4 ago. 2025.

TAIZ, L. *et al.* **Fisiologia e desenvolvimento vegetal**. 6. ed. Porto Alegre: Artmed, 2017.

TALEBI, H. *et al.* A truly spatial random forests algorithm for geoscience data analysis and modelling. **Mathematical Geosciences**, v. 54, p. 1–22, 2022. DOI: <https://doi.org/10.1007/s11004-021-09946-w>. Disponível em: <https://link.springer.com/article/10.1007/s11004-021-09946-w>. Acesso em: 21 jun. 2025.

TAROUCO, C. P. *et al.* Atividade fotossintética e produção de biomassa de clones de batata em função da disponibilidade de fósforo no solo. **Research, Society and Development**, Lavras, v. 10, n. 8, e24310817326, 2021. DOI: <https://doi.org/10.33448/rsd-v10i8.17326>. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/17326>. Acesso em: 12 set. 2025.

TIKZ.NET. Random Forest [imagem]. 2023. Disponível em: <http://diagrams.janosh.dev/random-forest>. Acesso em: 19 jun. 2025.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0). Disponível em: <https://www.sciencedirect.com/science/article/pii/0034425779900130>. Acesso em: 2 jun. 2025.

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ. **Ondas eletromagnéticas**: material didático de apoio. Curitiba: UTFPR, 2019. Disponível em: <https://repositorio.utfpr.edu.br/jspui/bitstream/1/5137/1/ondaseletromagneticasdidatica.pdf>. Acesso em: 5 jun. 2025.

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ. **Estudo do espectro eletromagnético e sua representação em materiais de ensino de Física**. 2016. Dissertação

(Mestrado em Ensino de Ciências e Tecnologia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2016. Disponível em:
https://repositorio.utfpr.edu.br/jspui/bitstream/1/1917/2/CT_PPGFCET_M_Rodrigues,%20Jean%20Marcos_2016.pdf. Acesso em: 8 jun. 2025.

VAN KLOMPENBURG, T.; KASSAHUN, A.; ZHOU, J. Crop yield prediction using machine learning: a systematic literature review. **Computers and Electronics in Agriculture**, v. 177, p. 105709, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105709>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169919310194>. Acesso em: 13 ago. 2025.

VIDICAN, R. *et al.* Using remote sensing vegetation indices for the discrimination and monitoring of agricultural crops: a critical review. **Agronomy**, v. 13, n. 12, p. 3040, 2023. DOI: <https://doi.org/10.3390/agronomy13123040>. Disponível em: <https://www.mdpi.com/2073-4395/13/12/3040>. Acesso em: 24 ago. 2025.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, v. 236, p. 111402, 2020. DOI: <https://doi.org/10.1016/j.rse.2019.111402>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425719305169>. Acesso em: 10 ago. 2025.

WITHERS, P. J. A. *et al.* Transitions to sustainable management of phosphorus in Brazilian agriculture. **Scientific Reports**, v. 8, art. 2537, 2018. DOI: <https://doi.org/10.1038/s41598-018-20887-z>. Disponível em: <https://www.nature.com/articles/s41598-018-20887-z>. Acesso em: 25 set. 2025.

XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of Sensors**, v. 2017, p. 1–17, 2017. DOI: <https://doi.org/10.1155/2017/1353691>. Disponível em: <https://www.hindawi.com/journals/js/2017/1353691/>. Acesso em: 10 set. 2025.

YIN, G. *et al.* A Broadband Green-Red Vegetation Index for Monitoring Gross Primary Production Phenology. **Journal of Remote Sensing**, v. 2022, art. 9764982, 2022. DOI: <https://doi.org/10.34133/2022/9764982>. Disponível em: <https://doi.org/10.34133/2022/9764982>. Acesso em: 30 ago. 2025.

ZHANG, Y. *et al.* Based on machine learning algorithms for estimating leaf phosphorus concentration in wheat using multispectral images. **Frontiers in Plant Science**, v. 14, p. 1208135, 2023. DOI: <https://doi.org/10.3389/fpls.2023.1185915>. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2023.1185915/full>. Acesso em: 15 jul. 2025.