

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

MONARA NOGUEIRA SILVA

IMAGENS MULTIESPECTRAIS PARA DIFERENCIAÇÃO DE PLANTAS DE ALFACE
INOCULADAS COM FUNGO SOLUBILIZADOR DE FOSFATO SOB DIFERENTES
DOSES DE FÓSFORO

MONTE CARMELO

2025

MONARA NOGUEIRA SILVA

IMAGENS MULTIESPECTRAIS PARA DIFERENCIAÇÃO DE PLANTAS DE ALFACE
INOCULADAS COM FUNGO SOLUBILIZADOR DE FOSFATO SOB DIFERENTES
DOSES DE FÓSFORO

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.

Orientador: Prof. Dr. George Deroco Martins
Coorientador: Prof. Dr. Gilberto de Oliveira Mendes

MONTE CARMELO

2025

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

S586 Silva, Monara Nogueira, 1997-
2025 Imagens multiespectrais para diferenciação de plantas de alface
 inoculadas com fungo solubilizador de fosfato sob diferentes doses
 de fósforo [recurso eletrônico] / Monara Nogueira Silva. - 2025.

Orientador: George Deroco Martins.

Coorientador: Gilberto de Oliveira Mendes.

Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Agricultura e Informações Geoespaciais.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2025.292>

Inclui bibliografia.

Inclui ilustrações.

1. Agronomia. I. Martins, George Deroco, 1987-, (Orient.). II.
Mendes, Gilberto de Oliveira, 1983-, (Coorient.). III. Universidade
Federal de Uberlândia. Pós-graduação em Agricultura e
Informações Geoespaciais. 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:	23/05/2025	Hora de início:	14:00	Hora de encerramento:	16:30
Matrícula do Discente:	32312AIG017				
Nome do Discente:	Monara Nogueira Silva				
Título do Trabalho:	Imagens Multiespectrais para Diferenciação de Plantas de Alface Inoculadas com Fungo Solubilizador de Fosfato sob Diferentes Doses de Fósforo				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Desenvolvimento e aplicações de métodos em informações geoespaciais				
Projeto de Pesquisa de vinculação:	Mapeamento de doenças e variáveis agrícolas em culturas agrícolas a partir de dados de sensoriamento remoto				

Reuniu-se na sala virtual , a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, composta pelos professores doutores George Deroco Martins (UFU), orientador da candidata, Charles Cardoso Santana (Instituto Tecnológico de Agropecuária de Pitangui - EPAMIG ITAP), e Ana Flávia de Freitas (Instituto Tecnológico de Agropecuária de Pitangui-ITAP).

Iniciando os trabalhos o presidente da mesa, Dr. George Deroco Martins, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu à discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

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

Aprovada com louvor

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 **George Deroco Martins, Professor(a) do Magistério Superior**, em 27/05/2025, às 09:19, 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 **Ana Flávia de Freitas, Usuário Externo**, em 27/05/2025, às 10:06, 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 **Charles Cardoso Santana, Usuário Externo**, em 27/05/2025, às 13:06, 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 **6362892** e o código CRC **B301B3D6**.

AGRADECIMENTOS

Agradeço a Deus, pelas bênçãos que tem me proporcionado e pela minha saúde. Sou imensamente grata aos meus pais, Valdir e Lenice, por sempre me apoiarem e me incentivarem a estudar. Ao meu esposo, Marcelo, e ao meu filho, José Pedro, por estarem sempre ao meu lado, oferecendo amor e suporte emocional. À minha irmã, Lorena, e à minha avó, Maria, que sempre me motivaram e estiveram comigo nessa caminhada. Agradeço à minha amiga Maria Cecília pela amizade, pelo apoio, pelas horas de estudos e pelos momentos de descontração. Agradeço aos meus colegas de estudo pela convivência e amizade. Agradeço ao meu orientador, George Deroco Martins, por sua dedicação, paciência e pelos ensinamentos que contribuíram para o meu crescimento acadêmico e profissional. Agradeço à FAPEMIG pelo apoio financeiro, por meio da bolsa de estudos, ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais e à Universidade Federal de Uberlândia (UFU), pela oportunidade de realizar minha formação acadêmica, tanto na graduação quanto no mestrado.

BIOGRAFIA

Monara Nogueira Silva, filha de Valdir Alves Nogueira e Lenice Cristina Silva Nogueira, nasceu em 1997, na cidade de Patos de Minas, Mina Geral. Graduiu-se em Engenharia de Agrimensura e Cartográfica pela Universidade Federal de Uberlândia (UFU), no campus de Monte Carmelo. Em 2023, ingressou no Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da UFU, dando continuidade à trajetória acadêmica.

SUMÁRIO

1	INTRODUÇÃO	1
2	REFERENCIAL TEÓRICO	2
2.1	Cultura da Alface.....	2
2.2	Sensoriamento remoto na horticultura	4
2.3	Aprendizado de máquina.....	5
3	MATERIAL E MÉTODOS.....	6
3.1	Área de estudo.....	6
3.2	Montagens do experimento.....	7
3.3	Resumo gráfico	9
3.4	Análise temporal do experimento	9
3.5	Pré-processamento de imagens	10
3.6	Índices de vegetação	11
3.7	Criação de classes para classificação	11
3.8	Classificação	14
3.9	Avaliação da classificação	16
4	RESULTADOS.....	18
4.1	Desempenho dos modelos	18
4.2	Matriz de confusão dos melhores resultados de cada cenário.....	21
5	DISCUSSÃO	27
6	CONCLUSÃO.....	30
	REFERÊNCIAS	30

RESUMO

Tecnologias avançadas, como o sensoriamento remoto, destacam-se no monitoramento de diversas culturas agrícolas. No entanto, poucos estudos investigam o potencial de sensores multiespectrais de baixo custo para a discriminação de tratamentos com aplicação de bioinsumos, especialmente na cultura da alface (*Lactuca sativa*). O objetivo foi avaliar o potencial das imagens multiespectrais obtidas por sensores de baixo custo, aliadas a técnicas de aprendizado de máquina, na discriminação de tratamentos aplicados à alface, considerando diferentes formas de inoculação do fungo *Aspergillus niger* e variações nas doses de adubação fosfatada. O experimento foi conduzido em 2021 e seguiu um esquema fatorial de 6 x 3, com seis formas de inoculação de *A. niger* (sem inoculação; tratamento de sementes com suspensão de conídios; inoculação granular com 4×10^2 e 4×10^6 conídios g^{-1} no transplantio; e inoculação com suspensão de conídios a 4×10^2 e 4×10^6 conídios mL^{-1} no transplantio) e três doses de fósforo (0, 50 e 100%). Durante o desenvolvimento das plantas, foram capturadas imagens com a câmera RGB e com a câmera multiespectral MAPIR Survey 3W nos dias 5, 12, 19, 26 e 33 após o transplantio. Para discriminação dos tratamentos, foram extraídos os valores médios de refletância das bandas espectrais e calculados os índices de vegetação. A classificação foi realizada utilizando algoritmos de aprendizados de máquina no software Weka, considerando três cenários distintos. Os resultados demonstraram desempenho superior do modelo *Random Forest*, especialmente com a combinação dos atributos dos sensores RGB-RGN, atingindo acurácias globais de 65,35%, 79,57% e 94,24% nos respectivos cenários. Esse estudo reforça o potencial do uso de imagens espectrais para o monitoramento e a gestão das culturas agrícolas.

Palavras-chave: Bioinsumos; classificação; hortaliças; índices de vegetação; *Lactuca sativa*.

ABSTRACT

Advanced technologies such as remote sensing stand out in the monitoring of various agricultural crops. However, few studies have investigated the potential of low-cost multispectral sensors for the discrimination of treatments involving the application of biological inputs, especially in lettuce (*Lactuca sativa*) cultivation. The objective of this study was to evaluate the potential of multispectral images obtained from low-cost sensors, combined with machine learning techniques, for discriminating treatments applied to lettuce, considering different forms of *Aspergillus niger* inoculation and variations in phosphorus fertilization doses. The experiment was conducted in 2021, following a 6×3 factorial design, with six *A. niger* inoculation methods (no inoculation; seed treatment with conidial suspension; granular inoculation with 4×10^2 and 4×10^6 conidia g^{-1} at transplanting; and inoculation with conidial suspension at 4×10^2 and 4×10^6 conidia mL^{-1} at transplanting) and three phosphorus doses (0, 50, and 100%). During plant development, images were captured using an RGB camera and a MAPIR Survey 3W multispectral camera on days 5, 12, 19, 26, and 33 after transplanting. For treatment discrimination, mean reflectance values from the spectral bands were extracted and vegetation indices were calculated. Classification was performed using machine learning algorithms in the Weka software, considering three distinct scenarios. The results demonstrated superior performance of the Random Forest model, especially when combining attributes from both RGB and RGN sensors, achieving overall accuracies of 65.35%, 79.57%, and 94.24% in the respective scenarios. This study reinforces the potential of spectral imaging for agricultural crop monitoring and management.

Keywords: Biological inputs; classification; *Lactuca sativa*; vegetables; vegetation indices.

1 INTRODUÇÃO

A horticultura é uma das principais áreas do setor agrícola. Desempenha papel significativo na economia, na geração de empregos e na segurança alimentar. O avanço nessa área demanda a adoção de práticas de gestão mais eficientes, o que inclui o uso de tecnologias para monitoramento das culturas em campo (Usha; Singh, 2013). Entre essas tecnologias, o sensoriamento remoto se destaca como uma ferramenta amplamente empregada na agricultura de precisão (Mulla, 2013), por possibilitar o monitoramento das culturas de maneira indireta (Martins *et al.*, 2019), além de viabilizar a avaliação da saúde vegetal, a estimativa de produtividade e a detecção de pragas e doenças (Khanal *et al.*, 2020).

A utilização de aeronaves remotamente pilotadas (ARPs) na horticultura representa uma alternativa eficiente e econômica em comparação aos métodos tradicionais (Handique *et al.*, 2020). Essas aeronaves podem ser equipadas com sensores, como câmeras RGB, multiespectrais e hiperespectrais, que abrangem diferentes comprimentos de onda, desde as regiões do visível até o infravermelho (Maes; Steppe, 2019). Isso possibilita o desenvolvimento de índices de vegetação baseados em combinações de diferentes bandas do espectro eletromagnético (Galvanin *et al.*, 2014), os quais auxiliam na análise de alterações fisiológicas, biofísicas e bioquímicas nas plantas, como mudanças nas estruturas internas das folhas e no teor de clorofila, que podem ser detectadas por meio da resposta espectral (Mahajan *et al.*, 2014; Gabriel *et al.*, 2017).

A aplicação de imagens espectrais demonstra potencial para estimar características fenotípicas das plantas (Grzybowski *et al.*, 2021; Feng *et al.*, 2021), oferecendo uma alternativa aos métodos tradicionais de fenotipagem. Embora esses métodos sejam simples, geralmente são destrutivos, demandam tempo, recursos e mão de obra, e nem sempre são eficazes na detecção de variações sutis entre genótipos (Sousa, 2014). Por outro lado, o uso de sensores remotos possibilita análises não destrutivas, precoces e em larga escala (Dhondt *et al.*, 2013).

Na cultura da alface, o sensoriamento remoto tem sido empregado em diversas aplicações, como a estimativa de antocianinas (Kim; Van Iersel, 2023), a previsão de crescimento e taxa de colheita (Ribeiro *et al.*, 2023), a detecção de doenças (Carmo *et al.*, 2021; Sirakov *et al.*, 2023), a análise de fertilização (Eshkabilov; Simko, 2024) e o monitoramento nutricional (Eshkabilov *et al.*, 2021).

Entre os fatores que podem influenciar o desenvolvimento da alface e, portanto, serem monitorados por sensoriamento remoto, o uso de bioinsumos tem se mostrado relevante,

especialmente no contexto da agricultura sustentável (Duque *et al.*, 2024). Microrganismos como o fungo *Aspergillus niger*, que possui capacidade de solubilizar fosfato (Mendes *et al.*, 2014), têm demonstrado potencial como bioinsumos agrícolas na promoção do crescimento da alface (Silva *et al.*, 2022; Mundim; Maciel; Mendes, 2022). A avaliação fenotípica do efeito de diferentes formas de inoculação, associadas a doses variadas de fósforo, é essencial para compreender a resposta das plantas. No entanto, há uma carência de estudos que avaliem o uso de imagens multiespectrais para a discriminação de tratamentos com aplicação de bioinsumos na cultura da alface.

Diante da hipótese de que sensores multiespectrais de baixo custo, aliados a técnicas de aprendizado de máquina, são capazes de discriminar eficientemente os tratamentos aplicados na cultura da alface, considerando diferentes formas de inoculação do fungo *Aspergillus niger* e variações nas doses de adubação fosfatada, este estudo teve como objetivo avaliar o potencial dessas imagens, em conjunto com o aprendizado de máquina, na discriminação dos tratamentos. Para isso, foram definidos os seguintes objetivos específicos:

1. Avaliar o desempenho dos sensores RGB e RGN separadamente e em combinação, incluindo índices de vegetação específicos, na discriminação dos tratamentos.
2. Comparar a eficácia dos algoritmos *Random Forest* e *Multilayer Perceptron* para classificar tratamentos da alface a partir dos dados multiespectrais.
3. Identificar qual combinação de sensores e índices de vegetação proporciona melhor desempenho na classificação dos diferentes tratamentos aplicados.
4. Analisar os resultados obtidos pelas classificações por meio da matriz de confusão e métricas estatísticas de desempenho, identificando tratamentos com maior e menor capacidade de discriminação pelas imagens multiespectrais.

2 REFERENCIAL TEÓRICO

2.1 Cultura da Alface

A alface (*Lactuca sativa*), pertencente à família Asteraceae, tem origem na região do Mediterrâneo, sudoeste da Ásia (Vries, 1997). É considerada a hortaliça folhosa mais consumida no Brasil e no mundo, sendo essencial na alimentação humana devido ao seu valor nutricional e características de consumo (Sala; Costa, 2012).

Seu consumo, predominantemente in natura, traz diversos benefícios à saúde por ser um vegetal rico em fibras, folato, vitaminas e sais minerais. Dentre outros benefícios, essa hortaliça apresenta baixo valor calórico, sendo recomendada em dietas para tratamento e prevenção de doenças crônicas, cardiovasculares e obesidade, apresentando potenciais efeitos antioxidantes, anti-inflamatórios e anticancerígenos (Kim *et al.*, 2016; Shi *et al.*, 2022).

A alface apresenta ampla variabilidade fenotípica, refletida na diversidade de cultivares disponíveis no mercado. No Brasil, essas cultivares são classificadas em seis principais grupos morfológicos, com base na formação da cabeça e no tipo de folhas: Repolhuda Lisa, Repolhuda Crespa ou Americana, Solta Lisa, Solta Crespa, Tipo mimosa e Tipo Romana. Entre elas, as variedades crespas e lisas são as mais populares e consumidas no país (Henz; Suinaga, 2009).

Morfologicamente, trata-se de uma planta herbácea com caule diminuto, cujas folhas, lisas ou crespas, crescem em roseta ao redor do caule, podendo formar ou não uma cabeça. A coloração varia entre tons de verde e roxo, dependendo da cultivar, fator que influencia diretamente na preferência dos consumidores. O sistema radicular é superficial, com raiz pivotante e intensa ramificação (Filgueira, 2008).

O ciclo de vida da alface divide-se em duas fases. Durante a fase vegetativa, ocorrem a germinação e o desenvolvimento da planta, incluindo a formação da roseta ou da cabeça, mantendo o caule reduzido. Na fase reprodutiva, há o alongamento do caule (pendoamento), seguido pelo florescimento e pela produção de sementes, cuja maturação ocorre entre 12 e 14 dias após a abertura das flores (Ryder, 1996).

O desempenho produtivo da alface está diretamente associado às condições climáticas. Sala e Costa (2012) relataram que um dos principais desafios no Brasil foi adaptar essa cultura ao clima tropical, caracterizado por altas temperaturas e elevada pluviosidade. Esses fatores induzem o pendoamento precoce e favorecem o desenvolvimento de doenças fúngicas e bacterianas, resultando em perdas significativas no cultivo.

De acordo com Sala e Costa (2012), a produção dessa cultura em clima tropical teve mais sucesso a partir da obtenção e liberação de cultivares adaptadas por meio dos programas de melhoramento genético de alface conduzidos por instituições de pesquisa e empresas nacionais. O que permitiu aos produtores o cultivo de cultivares com maior tolerância ao pendoamento precoce e resistência às principais doenças, promovendo maior sustentabilidade à alface cultura.

Além disso, nos últimos anos, o sensoriamento remoto tem se destacado na agricultura e se tornado um aliado para melhoristas de plantas em estudos de fenotipagem de alto

rendimento, por ser uma tecnologia que adquire uma grande quantidade de dados rápidos e precisos, possibilitando realizar medições indiretas e não destrutivas (Anand *et al.*, 2023). As imagens de sensores são usadas não apenas na seleção de genótipos promissores, mas também para detectar precocemente estresses bióticos e abióticos, acompanhar o desenvolvimento das culturas e outras características de interesse.

2.2 Sensoriamento remoto na horticultura

O sensoriamento remoto refere-se à aquisição de informações sobre um objeto ou fenômeno à distância, por meio de um instrumento ou um sensor instalado em uma plataforma aérea, terrestre ou espacial que é capaz de medir a radiação eletromagnética (REM) refletida ou emitida pelo alvo (Weiss; Jacob; Duveiller, 2020).

Para sua aplicação na horticultura, é importante entender o processo de interação da radiação eletromagnética com a vegetação. Para isso, Ponzoni *et al.* (2012) descreve três fenômenos principais de interação da REM referente ao espectro óptico com uma folha: reflectância, absorbância e transmissão da radiação. Esses processos, que compõem o estudo do comportamento espectral da vegetação, são influenciados por fatores estruturais (como a organização dos tecidos foliares) e químicos (como a presença de pigmentos fotossintetizantes e água).

A reflectância das folhas varia conforme a região do espectro eletromagnético. Em folhas saudáveis, os valores são relativamente baixos na região do visível (400 – 700 nm, VIS), devido à absorção de radiação pelos pigmentos fotossintetizantes (clorofila, carotenos, xantofilas) para o processo de fotossíntese. No infravermelho próximo (700 – 1300 nm, NIR), a reflectância é mais elevada, sendo determinada principalmente pela estrutura da folha. Já no infravermelho médio (1300 – 2500 nm, SWIR), há uma redução nos valores de reflectância devido à quantidade de água, proteína e outros compostos bioquímicos no interior da folha (Homolová *et al.*, 2013; Ponzoni *et al.*, 2012).

Essas características espectrais, especialmente nas regiões do visível e do infravermelho próximo, têm incentivado diversos estudos que utilizam índices de vegetação (IVs) para explorar as propriedades espectrais da vegetação. Esses índices são empregados para avaliar atributos das copas das plantas, como índice de área foliar (IAF), biomassa, teor de clorofila, teor de nitrogênio (Mulla, 2013), além de reduzir os efeitos de iluminação da cena, da topografia

e da geometria de aquisição que podem influenciar os valores de reflectância da vegetação (Ponzoni *et al.*, 2012).

No caso das culturas hortícolas, os estágios de crescimento e fenologia ainda não são completamente compreendidos. No entanto, ao correlacionar os IVs com características físicas dos dosséis das plantas, é possível avaliar e prever as mudanças nas características da vegetação ao longo de seu ciclo de crescimento (Usha; Singh, 2013).

Além disso, pesquisas na área da horticultura têm explorado o uso de sensoriamento remoto para otimizar a gestão das culturas e melhorar a eficiência do uso de insumos, como água, fertilizantes e defensivos agrícolas. Imagens hiperespectrais e multiespectrais vêm sendo empregadas para monitorar a variabilidade espacial e temporal das condições das plantas, incluindo estresse hídrico (Alordzinu *et al.*, 2021) e incidência de doenças (Chang *et al.*, 2020). A eficácia dessas tecnologias na discriminação de variáveis agrônômicas já foi demonstrada em culturas como tomate (Fullana-Pericàs *et al.*, 2022), alface (Clemente *et al.*, 2021) e repolho (Martins *et al.*, 2023), evidenciando sua aplicabilidade em diferentes contextos produtivos.

O sensoriamento remoto também tem sido integrado a técnicas de aprendizado de máquina para análise e classificação de dados agrícolas. Modelos de inteligência artificial vêm sendo utilizados para interpretar imagens multiespectrais e hiperespectrais, possibilitando detectar e prever as condições de saúde das plantas, o que permite uma tomada de decisão mais rápida e precisa.

2.3 Aprendizado de máquina

O aprendizado de máquina (AM) é uma abordagem empírica eficaz para tarefas de classificação e regressão de sistemas não lineares, multivariados e não paramétricos. Pode abranger uma variedade de algoritmos como redes neurais, máquina de vetores de suporte, árvores de decisão, florestas aleatórias etc. (Lary *et al.*, 2016).

Na classificação, uma das vantagens dos algoritmos de AM é a capacidade de modelarem classes complexas, além de poderem aceitar uma variedade de dados preditores de entrada e não fazerem suposições sobre a distribuição dos dados, o que os tornam não paramétricos (Maxwell *et al.*, 2018).

Dentre os algoritmos empregados em AM, *Random Forest* (RF) tornou-se popular na comunidade de sensoriamento remoto devido a precisão de suas classificações e a facilidade de processamento (Belgiu; Drăguń, 2016). Proposto por Breiman, é um método supervisionado

baseado em conjuntos de árvores de decisão, onde utiliza um grande número de árvores para superar as fraquezas de uma única árvore (Breiman, 2001). RF é considerado bastante flexível e pode lidar com diferentes cenários, como número limitado de amostras de treinamento, grandes números de atributos e conjunto de dados grandes ou pequenos. Além disso, outra vantagem desse classificador é que ele é robusto ao ruído nos rótulos de treinamento (Ghamisi *et al.*, 2017)

Outro classificador amplamente utilizado no aprendizado de máquina é o *Multilayer Perceptrons* (MP), um modelo de Rede Neural Artificial (RNA). O MP consiste em um sistema de neurônios interconectados simples, ou nós, onde é composto por uma camada de entrada, formada por nós sensoriais que recebem os dados, uma ou mais camadas ocultas responsáveis pelo processamento, e uma camada de saída, que gera a predição final com base nas informações processadas pelas camadas anteriores. O sinal de entrada se propaga dentro da rede em uma direção, da entrada para a saída. Por meio de seu treinamento de maneira supervisionada com um algoritmo de retropropagação de erro, o MLP tem sido aplicado em problemas complexos (Haykin, 2001).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

O experimento foi realizado entre abril e junho de 2021, na Estação Experimental de Hortaliças da Universidade Federal de Uberlândia, localizada no município de Monte Carmelo, Minas Gerais, Brasil (18°42'43,2" S; 47°29'55,8" W) (Figura 1). O clima da região é caracterizado de acordo com Köppen como sendo Aw-tropical, onde os verões são quentes e úmidos e os invernos secos e amenos.

Durante o período experimental, a temperatura média diária foi de 21,1 °C, com média mínima de 14,9 °C e máxima de 27,3 °C. A umidade relativa do ar apresentou média de 65,6%, com variação entre 44,9% e 86,4% (SISMET, 2021).

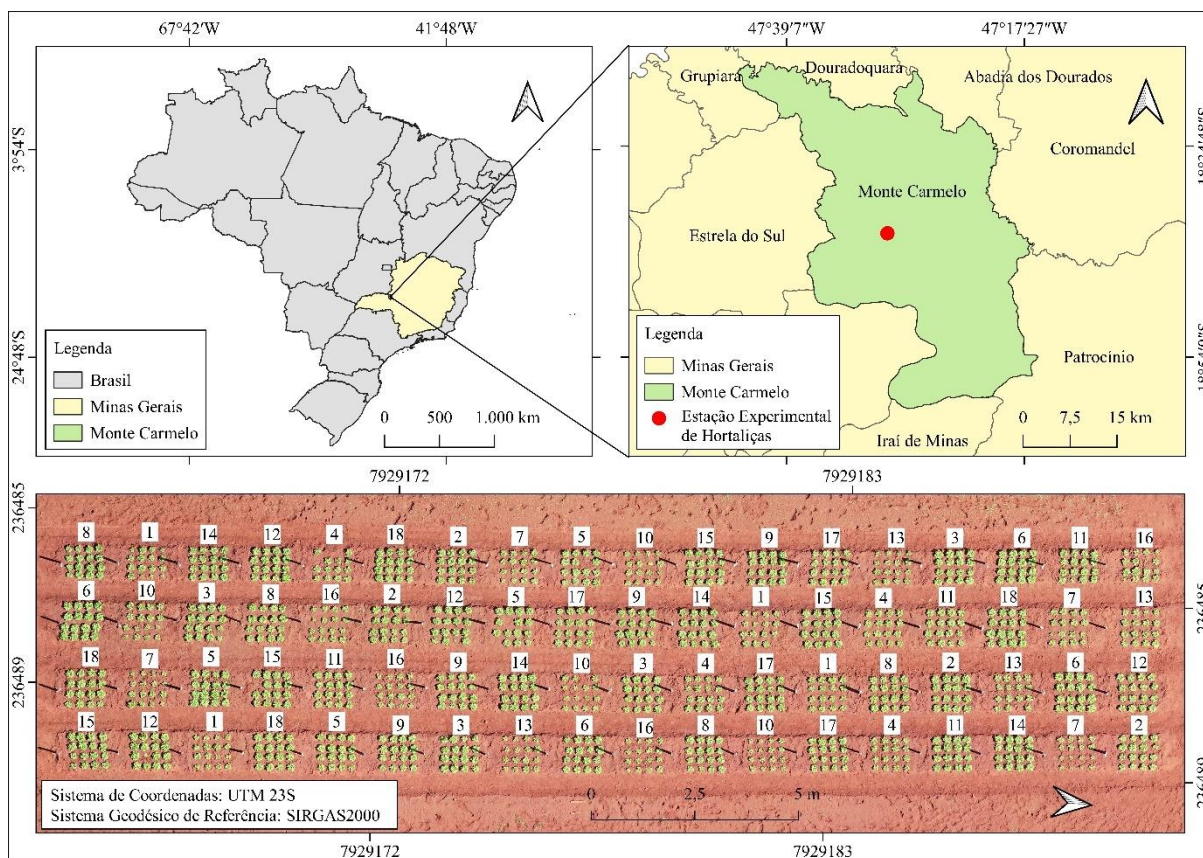


FIGURA 1 Mapa de localização e distribuição dos tratamentos em campo; 1: NI-0; 2: NI-50; 3: NI-100; 4: TS-0; 5: TS-50; 6: TS-100; 7: GR2-0; 8: GR2-50; 9: GR2-100; 10: GR6-0; 11: GR6-50; 12: GR6-100; 13: SC2-0; 14: SC2-50; 15: SC2-100; 16: SC6-0; 17: SC6-50; 18: SC6-100. NI – Não inoculado; TS – Tratamento de sementes; GR2 – Granular 10^2 conídios grama⁻¹; GR6 – Granular 10^6 conídios grama⁻¹; SC2 – Suspensão de conídios 10^2 conídios mL⁻¹; SC6 – Suspensão de conídios 10^6 conídios mL⁻¹; 0, 50 e 100 - % de P

3.2 Montagens do experimento

O experimento foi conduzido em blocos casualizados, com esquema fatorial 6 x 3, com 18 tratamentos e 4 repetições, resultando em 72 parcelas. Cada parcela foi composta por 16 plantas. No total, foram plantadas 1152 alfaces, das quais 1094 foram avaliadas.

Os tratamentos envolveram dois fatores. O primeiro fator correspondeu às seis formas de inoculação do fungo *Aspergillus niger*: sem inoculação (NI); tratamento de sementes com inoculação líquida (TS); inoculação do substrato durante o transplante da muda (48 dias após a semeadura), com aplicação granular em duas concentrações, 10^2 (GR2) e 10^6 (GR6) conídios de *A. niger* FS1, bem como suspensão de conídios em duas concentrações, 10^2 (SC2) e 10^6 (SC6) conídios de *A. niger* FS1 por cédula de bandeja. O segundo fator consistiu na aplicação de três doses de adubação fosfatada: ausência de fósforo (0%), aplicação de 50% da dose recomendada de P_2O_5 para a cultura (equivalente a 150 kg ha^{-1} de P_2O_5) e aplicação de 100%

da dose recomendada (300 kg ha⁻¹ de P₂O₅). Utilizou-se como fonte o superfosfato triplo, com concentração de 43,45% de P₂O₅. A Tabela 1 apresenta a descrição completa dos tratamentos.

TABELA 1 Descrição dos tratamentos

Descrição	Inoculação	Dose P (%)
NI - 0	Não inoculado	0
NI - 50	Não inoculado	50
NI - 100	Não inoculado	100
TS - 0	Tratamento de sementes 10 ² conídios planta ⁻¹	0
TS - 50	Tratamento de sementes 10 ² conídios planta ⁻¹	50
TS - 100	Tratamento de sementes 10 ² conídios planta ⁻¹	100
GR2 - 0	Granular 10 ² conídios planta ⁻¹ no transplantio	0
GR2 - 50	Granular 10 ² conídios planta ⁻¹ no transplantio	50
GR2 - 100	Granular 10 ² conídios planta ⁻¹ no transplantio	100
GR6 - 0	Granular 10 ⁶ conídios planta ⁻¹ no transplantio	0
GR6 - 50	Granular 10 ⁶ conídios planta ⁻¹ no transplantio	50
GR6 - 100	Granular 10 ⁶ conídios planta ⁻¹ no transplantio	100
SC2 - 0	Suspensão 10 ² conídios planta ⁻¹ no transplantio	0
SC2 - 50	Suspensão 10 ² conídios planta ⁻¹ no transplantio	50
SC2 - 100	Suspensão 10 ² conídios planta ⁻¹ no transplantio	100
SC6 - 0	Suspensão 10 ⁶ conídios planta ⁻¹ no transplantio	0
SC6 - 50	Suspensão 10 ⁶ conídios planta ⁻¹ no transplantio	50
SC6 - 100	Suspensão 10 ⁶ conídios planta ⁻¹ no transplantio	100

Fonte: Silva (2022)

As mudas de alface utilizadas eram do genótipo UFU-197#2#1#1, provenientes do Programa de Melhoramento Genético de Alface Biofortificada da UFU. A semeadura foi realizada em bandejas de poliestireno com 128 células de 40 cm³ cada, preenchidas com substrato de fibra de coco. As mudas foram cultivadas em casa de vegetação, sob irrigação diária e fertirrigação semanal. O solo da área experimental foi analisado e corrigido antes do transplantio. O transplante ocorreu 48 dias após a semeadura, com espaçamento de 0,25 x 0,25 m entre plantas e 0,5 m entre canteiros e parcelas.

Os tratamentos inoculados com a formulação granular foram aplicados no momento de transplantio, consistindo em um grânulo por planta, diretamente em contato com a raiz. No

tratamento das mudas com suspensão de conídios, foram adicionados 3 mL de solução por célula, 30 minutos antes do transplante. Já o tratamento de sementes com suspensão de conídios foi realizado 2 horas antes da semeadura, via pipetagem. A irrigação foi realizada diariamente e os tratamentos culturais foram semelhantes para todos os tratamentos.

3.3 Resumo gráfico

A imagem abaixo ilustra o gráfico que detalha a metodologia adotada nesta pesquisa (Figura 2). Para execução do método foi permeada as seguintes etapas: 1 - Definição da área experimental; 2 - Montagem do experimento; 3 - Aquisição de Imagens Multiespectrais (sensor RGB e Câmera Multiespectral Mapir Survey 3W); 4 - Criação de ortomosaicos a partir das imagens capturadas; 5 - Calibração dos ortomosaicos da câmera Mapir; 6 - Extração dos valores médios de reflectância das bandas espectrais de cada ortomosaico (ferramenta ROI); 7 - Cálculo dos índices de vegetação; 8 - Série temporal dos valores de reflectância extraídos e dos índices calculados; 9 - Criação de classes conforme categoria e cenário; 10 - Classificação de cada categoria (*Multilayer Perceptron* e *Random Forest*); 11- Avaliação das classificações.

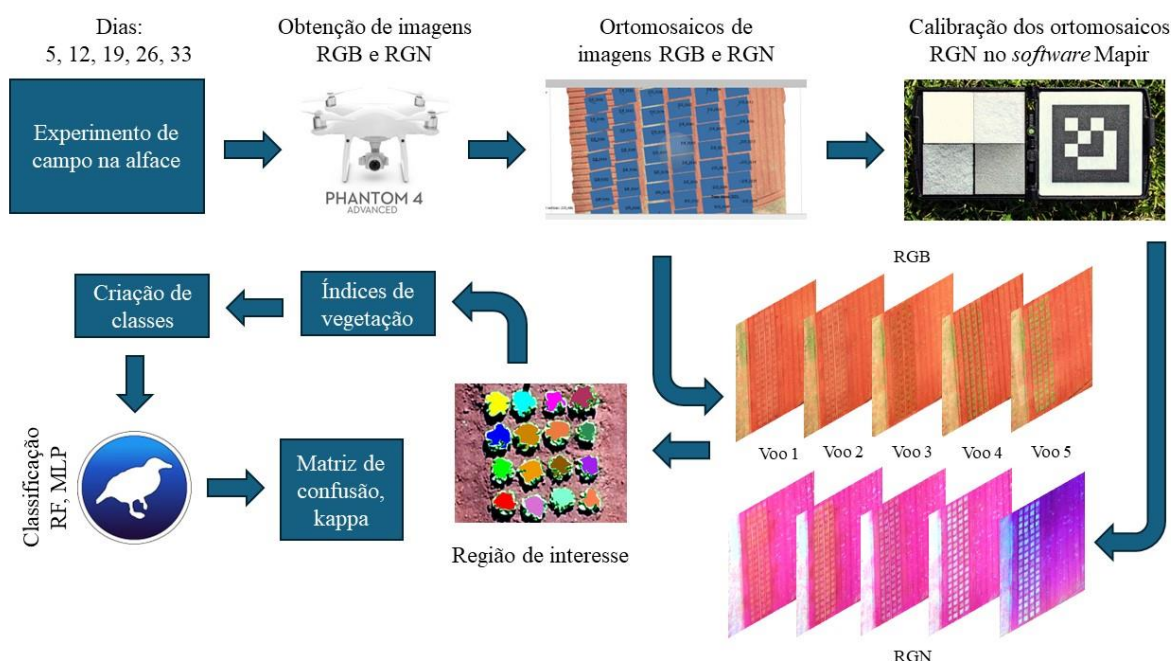


FIGURA 2 Gráfico detalhado da metodologia empregada

3.4 Análise temporal do experimento

Voos para aquisição de imagens multiespectrais foram realizados nos dias 5, 12, 19, 26 e 33 após o transplante. As coletas foram feitas com uma ARP modelo Phantom 4 Pro, fabricada pela DJI (China), equipada com uma câmera RGB com operacionalidade nas faixas de comprimentos de onda do espectro visível. Adicionalmente, foi acoplada à aeronave uma câmera Mapir Survey 3W, fabricada pela MAPIR (Estados Unidos), com resolução de 12 megapixels, sensível às regiões espectrais do vermelho (660 nm), verde (550 nm) e infravermelho próximo (850 nm), formando o conjunto espectral RGN.

O planejamento e a execução dos voos foram realizados por meio dos softwares DJI GO (DJI) e DroneDeploy (DroneDeploy, Estados Unidos). Os parâmetros adotados incluíram altura de voo de 20 metros, sobreposição lateral e longitudinal de 80%, direção de voo de -93° , e velocidade de 3 m s^{-1} .

As imagens foram capturadas entre 11h00 e 13h00, período de maior incidência de radiação solar, a fim de assegurar maior absorção e refletância da radiação eletromagnética pelas plantas. Também foi evitada a presença de nuvens que pudessem causar sombreamento e interferir na qualidade das imagens.

3.5 Pré-processamento de imagens

Foram gerados os ortomosaicos das imagens obtidas pelas câmeras RGB e RGN no software Agisoft Metashape, desenvolvido pela Agisoft (Rússia). Durante esse processo, as imagens foram alinhadas com base em pontos comuns, resultando em uma nuvem de pontos densa e na construção de um modelo digital de superfície 3D. Ao todo, foram produzidos 10 ortomosaicos, 5 correspondentes às imagens da câmera RGB e 5 da câmera RGN.

Os ortomosaicos da câmera RGN passaram por calibração radiométrica para redução dos efeitos atmosféricos. Para isso, utilizou-se o software Mapir Camera Control (MAPIR, Estados Unidos), no qual foram inseridas informações específicas, como modelo da câmera, tipo de lente, filtro utilizado e imagem de referência do alvo de calibração, registrada antes de cada voo.

Os valores médios de refletância das bandas RGB e RGN foram extraídos de cada planta com a ferramenta *Region of Interest* (ROI) no software ENVI 5.1 (NV5 Geospatial, Estados Unidos). Polígonos irregulares foram desenhados sobre as copas das alfaces em cada ortomosaico (Figura 3), permitindo a obtenção dos valores médios de refletância. Esses dados

foram organizados em uma planilha mantendo a ordem dos tratamentos e o momento em que as imagens foram capturadas.

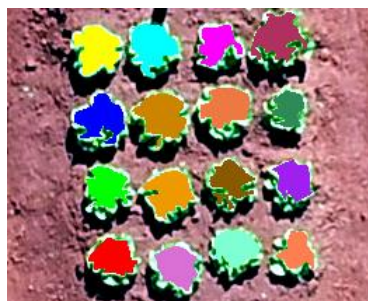


FIGURA 3 Delimitação das copas das alfaces pela ferramenta ROI

3.6 Índices de vegetação

Após organizar os valores de reflectância em uma planilha, foram calculados os índices de vegetação para todos os ortomosaicos (Tabela 2). Esses índices são resultados de operações matemáticas entre valores de reflectância de duas ou mais bandas, o que amplia a capacidade de discriminar características presentes na vegetação. Os índices NDVI e GNDVI foram calculados a partir dos dados de reflectância das bandas RGN, já os índices VARI e TGI foram calculados usando os valores das bandas RGB.

TABELA 2 Índices de vegetação

Índice	Equação		Fonte
Normalized Difference Vegetation Index	$NDVI = \frac{(NIR - R)}{(NIR + R)}$	Biomassa	Rouse <i>et al.</i> (1973)
Green Normalized Difference Vegetation Index	$GNDVI = \frac{(NIR - G)}{(NIR + G)}$	Teor de clorofila, estresse	Gitelson, Kaufman e Merzlyak (1996)
Visible Atmospherically Resistant Index	$VARI = \frac{(G - R)}{(G + R - B)}$	Cobertura foliar	Gitelson <i>et al.</i> (2002)
Triangular Greenness Index	$TGI = G - (0,39 * R) - (0,61 * B)$	Estimar clorofila	Hunt <i>et al.</i> (2013)

NIR – infravermelho próximo; R – banda do vermelho; G – banda do verde; B – banda do azul.

3.7 Criação de classes para classificação

Neste tópico, as etapas empregadas para a criação de classes são apresentadas no fluxograma abaixo (Figura 4).

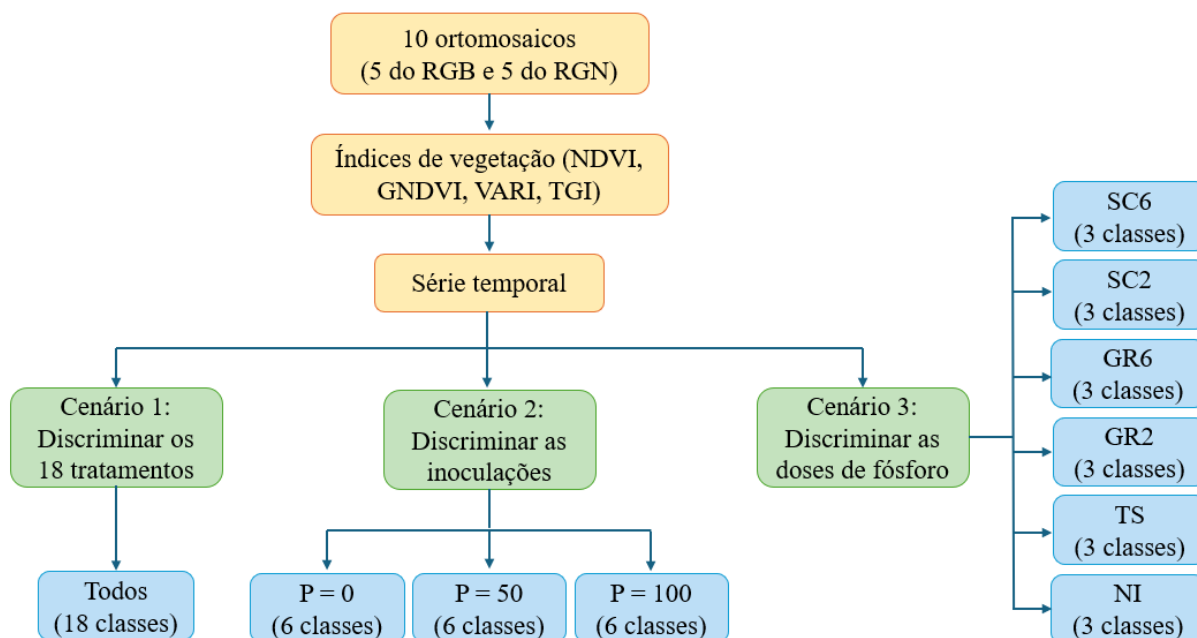


FIGURA 4 Fluxograma com as divisões de cenários, suas categorias e a quantidade de classes utilizadas

Os valores de refletância extraídos dos 10 ortomosaicos (5 do sensor RGB e 5 do sensor RGN), juntamente com os índices de vegetação calculados, foram reunidos em uma única planilha, formando uma série temporal. A partir dessa planilha, foram definidos três cenários principais, cada um com categorias específicas a serem classificadas. As classes de cada categoria e de cada cenários foram descritas a seguir.

Cenário 1 – Discriminação dos 18 tratamentos

Este cenário teve como objetivo a classificação dos 18 tratamentos com o intuito de discriminá-los entre si. Para isso, foi utilizada a planilha contendo os dados em série temporal. Um total de 18 classes foram estabelecidas para uma única categoria.

Categoria (Todos os tratamentos): Incluiu todas as classes do estudo.

- Classes: NI₀, NI₅₀, NI₁₀₀, TS₀, TS₅₀, TS₁₀₀, GR₂₀, GR₂₅₀, GR₂₁₀₀, GR₆₀, GR₆₅₀, GR₆₁₀₀, SC₂₀, SC₂₅₀, SC₂₁₀₀, SC₆₀, SC₆₅₀, SC₆₁₀₀.

Cenário 2 – Discriminação das inoculações do fungo *Aspergillus niger* por dose de fósforo

Neste cenário, o objetivo foi discriminar as cinco inoculações do fungo *A. niger* e o tratamento controle conforme a dose de fósforo. A partir da planilha de série temporal, foram selecionados apenas os dados da categoria a ser classificada, excluindo-se os demais. O mesmo processo foi repetido para as outras categorias. Como houve três tipos de adubação fosfatada (0%, 50%, 100% de P), cada categoria corresponde a uma dessas dosagens, e as classes representam os tipos de inoculação do fungo para aquela dosagem específica.

Categoria (P = 0): considerou apenas os tratamentos com dose de fósforo 0%.

- Classes: NI₀, TS₀, GR₂₀, GR₆₀, SC₂₀, SC₆₀.

Categoria (P = 50): considerou apenas os tratamentos com dose de fósforo 50%.

- Classes: NI₅₀, TS₅₀, GR₂₅₀, GR₆₅₀, SC₂₅₀, SC₆₅₀.

Categoria (P = 100): considerou apenas os tratamentos com dose de fósforo 100%.

- Classes: NI₁₀₀, TS₁₀₀, GR₂₁₀₀, GR₆₁₀₀, SC₂₁₀₀, SC₆₁₀₀.

Cenário 3: Discriminação das doses de fósforo para cada tipo de inoculação do fungo

O objetivo deste cenário consistiu em discriminar as dosagens de fósforo para cada aplicação do fungo *A. niger* e o tratamento controle. Assim como no cenário 2, os dados foram mantidos em série temporal, porém isolados para cada categoria específica. Neste caso, foram definidas seis categorias, cada uma representa um tipo de inoculação e, dentro de cada categoria, se tem as classes correspondentes às três doses de fósforo aplicadas (0%, 50% e 100%).

Categoria (NI): utilizou apenas os tratamentos não inoculados NI.

- Classes: NI₀, NI₅₀, NI₁₀₀.

Categoria (TS): considerou somente os tratamentos com inoculação de sementes.

- Classes: TS₀, TS₅₀, TS₁₀₀.

Categoria (GR2): utilizou somente os tratamentos com inoculação granular 10² conídios planta⁻¹.

- Classes: GR2₀, GR2₅₀, GR2₁₀₀.

Categoria (GR6): considerou apenas os tratamentos com inoculação granular 10⁶ conídios planta⁻¹.

- Classes: GR6₀, GR6₅₀, GR6₁₀₀.

Categoria (SC2): usou somente os tratamentos com inoculação por suspensão 10² conídios planta⁻¹.

- Classes: SC2₀, SC2₅₀, SC2₁₀₀.

Categoria (SC6): utilizou somente os tratamentos com inoculação por suspensão 10⁶ conídios planta⁻¹.

- Classes: SC6₀, SC6₅₀, SC6₁₀₀.

3.8 Classificação

O potencial das imagens multiespectrais para discriminar os tratamentos aplicados à alface foi avaliado por meio de classificações supervisionadas, utilizando algoritmos de aprendizado de máquina no ambiente do software Weka, uma plataforma de código aberto desenvolvido pela Universidade de Waikato, Nova Zelândia.

Para cada categoria avaliada, foi criada uma planilha individual, mantendo a estrutura de série temporal da planilha original, mas excluindo os tratamentos que não correspondiam à respectiva categoria. As planilhas foram convertidas para o formato *Attribute - Relation File Format* (ARFF), padrão aceito pelo Weka, para viabilizar a análise.

O arquivo de entrada nesse formato é composto por um cabeçalho, que inclui a definição das classes e a lista de atributos com seus respectivos tipos (numéricos, nominais ou datas), em sequência, uma seção de dados separados por vírgulas, onde se apresenta o nome de cada classe e os valores de cada atributo (Figura 5).

```

@relation clasalface
@attribute classe {1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18}
@attribute R_mapir numeric
@attribute G_mapir numeric
@attribute N_mapir numeric
@attribute NDVI numeric
@attribute GNDVI numeric
@attribute R numeric
@attribute G numeric
@attribute B numeric
@attribute TGI numeric
@attribute VARI numeric
@attribute R_mapir_2 numeric
@attribute G_mapir_2 numeric
@attribute N_mapir_2 numeric
@attribute NDVI_2 numeric
@attribute GNDVI_2 numeric
@attribute R_2 numeric
@attribute G_2 numeric
@attribute B_2 numeric
@attribute TGI_2 numeric
@attribute VARI_2 numeric
@attribute R_mapir_3 numeric
@attribute G_mapir_3 numeric
@attribute N_mapir_3 numeric
@attribute NDVI_3 numeric
@attribute GNDVI_3 numeric
@attribute R_3 numeric
@attribute G_3 numeric
@attribute B_3 numeric
@attribute TGI_3 numeric
@attribute VARI_3 numeric
@attribute R_mapir_4 numeric
@attribute G_mapir_4 numeric
@attribute N_mapir_4 numeric
@attribute NDVI_4 numeric
@attribute GNDVI_4 numeric
@attribute R_4 numeric
@attribute G_4 numeric
@attribute B_4 numeric
@attribute TGI_4 numeric
@attribute VARI_4 numeric
@attribute R_mapir_5 numeric
@attribute G_mapir_5 numeric
@attribute N_mapir_5 numeric
@attribute NDVI_5 numeric
@attribute GNDVI_5 numeric
@attribute R_5 numeric
@attribute G_5 numeric
@attribute B_5 numeric
@attribute TGI_5 numeric
@attribute VARI_5 numeric
@data
8,53618,45098,32746,92157,20125,11765,-0.4541865,-0.238723607,217.351852,235.388889,158.351852,54.8
8,51493,4,33202,2,20271,-0.435068084,-0.241825812,228.529412,243.588235,169.176471,51.26411701,0.04
8,54973,6383,33121,04255,21639,17021,-0.435103069,-0.209675452,211.306122,227.469388,155.918367,49.
8,53308,21739,33891,17391,21775,69565,-0.419963751,-0.217642529,225.028571,240.914286,166.771429,51
8,52761,74627,32988,61194,21919,47761,-0.412985581,-0.201593871,225.055556,244.833333,163.944444,57

```

FIGURA 5 Exemplo de arquivo formato ARFF

Após a conversão para o formato ARFF, teve início a preparação e aplicação dos algoritmos de classificação. A configuração dos parâmetros de cada classificador exerce influência direta sobre a acurácia dos modelos gerados. Ainda que a literatura traga recomendações amplamente utilizadas quanto a valores padrão, é fundamental a realização de testes práticos para identificar os ajustes mais adequados ao contexto específico da base de dados. Desta forma, antes de definir os parâmetros utilizados nas classificações, foram conduzidos testes preliminares com diferentes configurações, visando identificar aquelas que proporcionassem o melhor desempenho para este estudo.

Dois algoritmos de aprendizado de máquina foram empregados: Multilayer Perceptron (MP) e Random Forest (RF). Para o MP, após os testes exploratórios, manteve-se os parâmetros padrão do Weka, incluindo o número de camadas ocultas (a), taxa de aprendizado de 0,3, termo de momento de 0,2 e 500 ciclos de treinamento. Já o RF, foi configurado para utilizar 200 árvores, com o número de variáveis consideradas em cada divisão equivalente a raiz quadrada do total de variáveis de entrada. De acordo com Maxwell, Warner e Fang (2018), um mínimo de 100 árvores já é considerado adequado para esse tipo de abordagem.

As variáveis utilizadas (atributos) incluíram as bandas RGB e RGN, além dos índices NDVI, GNDVI, VARI, TGI. Considerando as cinco datas de avaliação do experimento, obteve-

se um total de 50 atributos. Para cada classificação, foram testados três conjuntos desses atributos disponíveis:

1. Classificação com apenas os dados do sensor RGB: incluiu as bandas RGB e os índices VARI e TGI em série temporal, totalizando 25 atributos.
2. Classificação com apenas os dados da câmera Mapir (RGN): utilizou as bandas RGN e os índices NDVI e GNDVI em série temporal, também somando 25 atributos.
3. Classificação multissensor com os dados RGB e os dados RGN: incluiu as bandas RGB e RGN, além dos índices de vegetação (VARI, TGI, NDVI e GNDVI), combinando todos os 50 atributos.

Desta forma, as categorias definidas na seção 3.7 foram avaliadas para cada um dos conjuntos de atributos. No cenário 1, foram realizadas um total de seis classificações, três para o MP e três para o RF. O mesmo processo foi repetido para o cenário 2, resultando em 18 classificações, e para o cenário 3, um total de 36 classificações. Ao todo, foram executadas 60 análises, 30 para cada algoritmo.

As classificações foram conduzidas na aba “*Classify*” do Weka, utilizando o método de validação cruzada. Esse método divide aleatoriamente o conjunto de dados de treinamento em k subconjuntos distintos. O modelo é então executado k vezes, onde, em cada vez, um dos subconjuntos é retido para validação, enquanto os $k-1$ restantes são usados para treinamento. Os resultados de cada execução são avaliados com base nos dados retidos para validação e, ao final, a média dos desempenhos obtidos em todas as k interações é calculada (Maxwell; Warner; Fang, 2018).

Para este estudo, foram amostradas 1094 plantas no total. No entanto, o número de amostras utilizadas em cada classificação variou conforme as categorias de cada cenário. Para validação dos modelos, adotou-se o método de validação cruzada de 10 vezes (*Cross-Validation*), onde o conjunto de dados foi divididos em 10 partes. Em cada interação, 90% dos dados foram utilizados para treinamento e 10% para teste, repetindo-se esse processo alternadamente ao longo das 10 execuções.

3.9 Avaliação da classificação

Ao avaliar o desempenho de um modelo de classificação, destaca-se sua capacidade de prever corretamente ou distinguir com precisão as diferentes classes. A matriz de confusão ou

matriz de erro, é uma matriz quadrada composta por números organizados em linhas e colunas, que compara os resultados de uma classificação com os dados reais de campo (Congalton; Green, 2008). A partir dela, é possível extrair métricas estatísticas, como a Acurácia Global (AG) e o coeficiente Kappa, usados para avaliar os modelos classificadores, além das métricas de Erro de Omissão (EO), Erro de Inclusão (EI), *Precision*, *Recall* e *F-score*.

A Acurácia Global é a métrica de avaliação mais comum para verificar a acurácia de um modelo. Seu cálculo consiste na soma dos valores da diagonal principal da matriz de confusão (acertos) dividida pelo número total de amostras avaliadas na matriz (Equação 1) (Congalton; Green, 2008).

$$AG = \frac{\sum_{i=1}^c x_{ii}}{n} * 100 \quad (1)$$

Onde: AG = acurácia global; $\sum_{i=1}^c x_{ii}$ = soma da diagonal principal na matriz de confusão; n = número total de amostras.

O coeficiente Kappa (Equação 2) é uma medida estatística de concordância e precisão usada para avaliar o grau de concordância na classificação de imagens. Seu valor pode variar entre 0 e 1, sendo que quanto maior o valor, maior o grau de concordância na classificação (Jog; Dixit, 2016). Entretanto, o desempenho da classificação pode ser interpretado a partir de intervalos de valores de Kappa. Desta forma, classificação com valor Kappa de 0 a 0,2 apresenta desempenho ruim, entre 0,2 e 0,4 o desempenho é razoável, de 0,4 a 0,6 tem desempenho bom, de 0,6 a 0,8 é considerado muito bom e classificações com valores entre 0,8 e 1,0 são excelentes (Fonseca, 2000).

$$Kappa = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (2)$$

Onde: $\sum_{i=1}^c x_{ii}$ = soma da diagonal principal na matriz de confusão; x_{i+} é a soma da linha i ; x_{+i} é a soma da coluna i ; n = número total de amostras.

O erro de inclusão (Equação 3) ocorre quando uma área é incluída em uma categoria incorreta na matriz de confusão. Já o erro de omissão (Equação 4) acontece quando uma área é excluída da categoria à qual realmente pertence (Congalton; Green, 2008).

$$EI = \frac{X_{+i} - X_{ii}}{X_{+i}} \quad (3)$$

Onde: EI = erro de inclusão; X_{+i} corresponde a marginal da coluna na matriz de confusão e X_{ii} representa a diagonal daquela coluna.

$$EO = \frac{X_{i+} - X_{ii}}{X_{i+}} \quad (4)$$

Onde: EO = erro de omissão; X_{i+} representa a marginal da linha na matriz de confusão e X_{ii} corresponde à diagonal daquela linha.

A *Precision* refere-se à proporção de amostras classificadas como positivas que realmente pertencem àquela classe. É calculada pelo valor total de amostras classificadas corretamente naquela classe dividido pelo valor total de amostras daquela classe (Equação 5). O *Recall*, por sua vez, mede a proporção de amostras positivos reais que são classificados positivos corretamente (Equação 6). O *F-score* (Equação 7) é a média harmônica de Precisão e Recall, onde seu valor pode variar de 0 a 1, em que 1 representa o melhor desempenho possível e 0 o pior (Powers, 2008).

$$Precision = \frac{VP}{VP + FP} \quad (5)$$

$$Recall = \frac{VP}{VP + FN} \quad (6)$$

$$F - score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (7)$$

Onde: VP = verdadeiro positivo; FP = falso positivo; FN = falso negativo

4 RESULTADOS

4.1 Desempenho dos modelos

O desempenho dos classificadores *Multilayer Perceptron* (MP) e *Random Forest* (RF) para três conjuntos de atributos (RGB-RGN, RGB, RGN) foi demonstrado em tabelas específicas para cada cenário. Vale ressaltar que cada conjunto de atributos inclui seus respectivos índices de vegetação. A avaliação dos resultados foi realizada por meio de métricas de Acurácia Global (AG) e Índice Kappa.

Cenário 1

Neste cenário, o objetivo da classificação foi discriminar os 18 tratamentos entre si. Os resultados das classificações para as abordagens comparadas estão presentes na Tabela 3.

TABELA 3 Desempenho dos classificadores MP e RF para discriminar 18 tratamentos

Métricas	MP			RF		
	RGB-RGN	RGB	RGN	RGB-RGN	RGB	RGN
Acurácia Global (%)	48,720	16,545	41,956	65,356	24,406	63,254
Kappa	0,457	0,116	0,385	0,633	0,199	0,611

Os valores destacados em vermelho indicam as maiores acurácias globais e os maiores coeficientes Kappa obtidos para a categoria.

De maneira geral, os resultados indicam que a escolha dos conjuntos de atributos influenciou o desempenho dos classificadores. A combinação RGB-RGN foi mais eficaz para discriminar os tratamentos, enquanto o conjunto RGB apresentou os piores desempenhos para ambos os modelos.

O RF demonstrou desempenho significativamente superior ao MP para todos os conjuntos de atributos testados. O maior valor de AG foi registrado pela combinação RGB-RGN e seus índices de vegetação, com 65,36% de acerto para o RF, acompanhado de um índice Kappa de 0,633. Em seguida, o conjunto RGN do RF também obteve destaque (AG = 63,25%). Para o MP, o melhor desempenho foi alcançado com a combinação RGB-RGN, atingindo 48,72% de AG e 0,45 de índice Kappa.

Cenário 2

No segundo cenário, a avaliação focou na discriminação das diferentes inoculações e do tratamento controle dentro de cada dose de fósforo (P). Os desempenhos dos classificadores para os três conjuntos de atributos estão apresentados na Tabela 4.

TABELA 4 Desempenho dos classificadores MP e RF para discriminar inoculações

Categoria	Métricas	MP			RF		
		RGB-RGN	RGB	RGN	RGB-RGN	RGB	RGN
P = 0%	AG (%)	65,395	29,428	64,578	73,297	41,144	74,659
	Kappa	0,584	0,153	0,575	0,679	0,294	0,696
P = 50%	AG (%)	70,699	29,301	65,054	79,569	29,57	79,301
	Kappa	0,648	0,15	0,58	0,755	0,153	0,751
P = 100%	AG (%)	72,676	39,155	60,845	75,211	43,099	72,113
	Kappa	0,672	0,269	0,529	0,702	0,315	0,665

Os valores destacados em vermelho indicam os maiores coeficientes Kappa obtidos para cada categoria.

Em uma análise geral das três categorias, o modelo RF mostrou-se superior em todas as classificações. Quanto aos atributos, a combinação RGB-RGN apresentou os melhores desempenhos para ambos os modelos, com exceção na categoria P = 0 para o RF, onde RGN se destacou. Por outro lado, os atributos RGB apresentaram os piores resultados.

Nas classificações dos tratamentos com dose P = 0, o melhor desempenho foi registrado pelo conjunto RGN no classificador RF, com 74,66% de AG e 0,696 de índice Kappa. No MP, o melhor resultado foi obtido com RGB-RGN (AG = 65,39%).

No desempenho das classificações da categoria P = 50, RF manteve-se superior, com melhor AG para os atributos RGB-RGN (79,57%). MP também teve melhor desempenho com esse conjunto RGB-RGN (70,70%).

Na categoria P = 100, o RF seguiu com a melhor performance, registrando 75,21% de AG e índice Kappa de 0,702 com RGB-RGN. Já o MP teve uma melhora nas classificações dessa categoria em relação as anteriores, exceto para o conjunto RGN, que foi inferior na dose de P = 50.

Cenário 3

Neste cenário, as inoculações foram avaliadas separadamente para discriminar as doses de fósforo (P = 0, P = 50, P = 100). Desta forma, cada classificação envolveu três classes. A Tabela 5 apresenta o desempenho dos modelos MP e RF com diferentes conjuntos de atributos.

TABELA 5 Desempenho dos classificadores MP e RF para discriminar doses de P

Categoria	Métricas	MP			RF		
		RGB-RGN	RGB	RGN	RGB-RGN	RGB	RGN

NI	AG (%)	83,240	62,011	85,474	82,681	62,011	85,475
	Kappa	0,748	0,430	0,781	0,739	0,430	0,781
TS	AG (%)	90,810	69,189	91,891	91,351	65,946	93,513
	Kappa	0,862	0,537	0,878	0,87	0,489	0,903
GR2	AG (%)	90,909	67,045	89,773	90,340	63,068	89,773
	Kappa	0,863	0,505	0,846	0,855	0,445	0,846
GR6	AG (%)	87,709	73,743	89,385	89,385	72,626	89,944
	Kappa	0,815	0,605	0,840	0,840	0,588	0,849
SC2	AG (%)	84,239	71,739	88,043	84,239	74,456	85,326
	Kappa	0,763	0,575	0,821	0,763	0,617	0,779
SC6	AG (%)	92,670	62,827	94,764	94,241	65,969	94,764
	Kappa	0,890	0,442	0,921	0,914	0,489	0,921

Os valores destacados em vermelho indicam os maiores coeficientes Kappa obtidos para cada categoria.

Foi observado que a maioria das classificações, usando os atributos combinados RGB-RGN e os atributos RGN, apresentaram desempenhos excelentes ($> 0,8$ em Kappa) demonstrando serem superiores ao RGB. A redução dos números de classes, em relação aos demais cenários, evidenciou uma melhora para discriminar os tratamentos em ambos os modelos.

Os atributos do sensor RGN apresentaram os melhores resultados para os dois modelos classificadores, com exceção da categoria GR2, na qual a combinação RGB-RGN se sobressaiu.

Os algoritmos RF e MP apresentaram desempenhos semelhantes na maioria dos casos. A melhor performance foi observada na categoria SC6, onde ambos os classificadores atingiram o mesmo resultado ao utilizarem os atributos RGN, com AG de 94,76 e índice Kappa de 0,92. A categoria TS também se destacou, registrando AG de 91,89% para o MP e AG de 93,51% para o RF.

4.2 Matriz de confusão dos melhores resultados de cada cenário

A matriz de confusão, acompanhada pelos erros de omissão (EO) e inclusão (EI), revela onde as classes foram confundidas, destacando as principais áreas de acerto e falha do modelo. Para uma análise detalhada, foram selecionadas as melhores classificações de cada categoria dos cenários 1, 2 e 3.

No cenário 1, o modelo RF apresentou a melhor classificação ao utilizar a combinação dos sensores RGB-RGN, alcançando uma Acurácia Global de 65,35%. Dentre as 1.094

instâncias avaliadas, 715 foram classificadas corretamente e 379 apresentaram erro de classificação (Tabela 6).

TABELA 6 Matriz de confusão gerada para a melhor classificação do cenário 1

	NI 0	NI 50	NI 100	TS 0	TS 50	TS 100	GR2 0	GR2 50	GR2 100	GR6 0	GR6 50	GR6 100	SC2 0	SC2 50	SC2 100	SC6 0	SC6 50	SC6 100	Total	EO
NI 0	45	0	0	8	0	0	2	1	0	1	0	0	0	0	0	2	0	0	59	0,237
NI 50	1	31	0	0	1	3	3	2	2	0	7	2	5	2	1	0	1	3	64	0,516
NI 100	0	1	31	1	1	4	0	3	3	1	4	1	1	3	0	0	1	1	56	0,446
TS 0	1	0	0	43	1	0	0	3	0	4	1	0	0	2	0	0	3	2	60	0,283
TS 50	1	0	0	0	32	0	1	0	6	1	1	1	1	2	3	3	0	9	61	0,475
TS 100	0	0	0	0	4	49	1	0	0	0	3	0	1	4	1	0	0	1	64	0,234
GR2 0	2	1	0	0	1	1	42	1	0	6	1	0	7	0	1	1	0	0	64	0,343
GR2 50	0	0	2	4	0	2	1	36	0	2	0	1	0	0	0	0	6	2	56	0,357
GR2 100	0	1	1	1	5	0	0	0	37	1	1	0	2	2	1	0	4	0	56	0,339
GR6 0	2	0	0	2	1	0	2	1	0	48	0	0	3	0	0	2	1	1	63	0,238
GR6 50	0	0	2	0	4	3	3	0	0	1	40	1	2	1	1	3	0	2	63	0,365
GR6 100	0	6	0	0	0	0	0	1	1	0	1	35	1	3	0	0	0	5	53	0,339
SC2 0	4	2	0	3	0	0	5	0	2	4	0	0	29	0	0	8	1	0	58	0,500
SC2 50	0	2	6	0	5	9	0	0	0	2	2	0	0	37	0	0	0	1	64	0,421
SC2 100	2	0	0	1	3	3	0	1	0	0	0	2	0	4	36	0	5	5	62	0,419
SC6 0	0	0	0	1	1	0	0	0	2	3	0	0	6	0	0	50	0	0	63	0,206
SC6 50	0	0	0	0	4	0	0	3	1	0	0	0	2	1	1	0	52	0	64	0,187
SC6 100	1	3	1	0	3	2	0	1	0	0	3	4	0	1	3	0	0	42	64	0,343
Total	59	47	43	64	66	76	60	53	54	74	64	47	60	62	48	69	74	74	1094	
EI	0,237	0,34	0,279	0,328	0,515	0,355	0,300	0,321	0,315	0,351	0,375	0,255	0,517	0,403	0,250	0,275	0,297	0,432		
Precision	0,763	0,66	0,721	0,672	0,485	0,645	0,700	0,679	0,685	0,649	0,625	0,745	0,483	0,597	0,750	0,725	0,703	0,568		
Recall	0,763	0,484	0,554	0,717	0,525	0,766	0,656	0,643	0,661	0,762	0,635	0,66	0,5	0,578	0,581	0,794	0,813	0,656		
F-score	0,763	0,559	0,626	0,694	0,504	0,700	0,677	0,661	0,673	0,701	0,630	0,700	0,492	0,587	0,655	0,758	0,754	0,609		

Tons mais vermelhos – valores mais altos; Tons mais amarelos – valores intermediários; Sem cor – valores baixos ou nulos; Diagonal principal – classificações corretas; Fora da diagonal principal – erros de classificações; EO – Erro de omissão; EI – Erro de inclusão.

A análise da matriz de confusão mostra uma variação dos erros de omissão de 0,187 (SC6 50) a 0,516 (NI 50) e dos erros de inclusão de 0,237 (NI 0) a 0,517 (SC2 0).

Dentre as classes avaliadas, a NI 0 apresentou o melhor desempenho, com *Precision* de 0,763, *Recall* de 0,763, e *F-score* de 0,763, o que é demonstrado com valores baixos de omissão e inclusão (0,237; 0,237). Em seguida, destacaram-se as classes SC6 0 e SC6 50, com *F-score* de 0,758 e 0,754 respectivamente.

Por outro lado, a classe com pior desempenho geral foi a SC2 0, com menor valor em *F-score* (0,492). Seus erros de omissão (0,5) e inclusão (0,517) indicam que uma parcela significativa de suas amostras foi classificada incorretamente.

No cenário 2, foi selecionada a categoria P = 0 classificada com o algoritmo RF com atributos do sensor RGN, e as categorias P = 50 e P = 100 utilizando os atributos RGB-RGN (Tabela 7).

TABELA 7 Matrizes de confusão para cada categoria do cenário 2. (a) P = 0%; (b) P = 50%; (c) P = 100%.

(a) Categoria P = 0%								
	NI 0	TS 0	GR2 0	GR6 0	SC2 0	SC6 0	Total	EO
NI 0	41	11	3	2	1	1	59	0,305
TS 0	5	49	1	3	0	2	60	0,183
GR2 0	1	1	48	3	9	2	64	0,25
GR6 0	3	7	1	46	4	2	63	0,27
SC2 0	3	2	6	3	40	4	58	0,31
SC6 0	1	3	0	4	5	50	63	0,206
Total	54	73	59	61	59	61	367	
EI	0,241	0,329	0,186	0,246	0,322	0,18		
<i>Precision</i>	0,759	0,671	0,814	0,754	0,678	0,82		
<i>Recall</i>	0,695	0,817	0,75	0,73	0,69	0,794		
<i>F-score</i>	0,726	0,737	0,78	0,742	0,684	0,806		

(b) Categoria P = 50%								
	NI 50	TS 50	GR2 50	GR6 50	SC2 50	SC6 50	Total	EO
NI 50	48	2	2	7	2	3	64	0,25
TS 50	0	57	0	1	3	0	61	0,066
GR2 50	3	0	44	0	1	8	56	0,214
GR6 50	3	12	0	44	4	0	63	0,302
SC2 50	0	8	3	6	44	3	64	0,313
SC6 50	0	3	1	0	1	59	64	0,078
Total	54	82	50	58	55	73	372	
EI	0,111	0,305	0,12	0,241	0,2	0,192		
<i>Precision</i>	0,889	0,695	0,88	0,759	0,8	0,808		

<i>Recall</i>	0,75	0,934	0,786	0,698	0,688	0,922		
<i>F-score</i>	0,814	0,797	0,83	0,727	0,739	0,861		

(c) Categoria P = 100%

	NI 100	TS 100	GR2 100	GR6 100	SC2 100	SC6 100	Total	EO
NI 100	41	2	8	0	1	4	56	0,268
TS 100	1	52	6	1	1	3	64	0,188
GR2 100	4	2	48	0	1	1	56	0,143
GR6 100	2	1	4	36	4	6	53	0,321
SC2 100	1	5	4	0	45	7	62	0,274
SC6 100	1	4	2	7	5	45	64	0,297
Total	50	66	72	44	57	66	355	
EI	0,18	0,212	0,333	0,182	0,211	0,318		
<i>Precision</i>	0,82	0,788	0,667	0,818	0,789	0,682		
<i>Recall</i>	0,732	0,813	0,857	0,679	0,726	0,703		
<i>F-score</i>	0,774	0,8	0,75	0,742	0,756	0,692		

Tons mais vermelhos – valores mais altos; Tons mais amarelos – valores intermediários; Sem cor – valores baixos ou nulos; Diagonal principal – classificações corretas; Fora da diagonal principal – erros de classificações; EO – Erro de omissão; EI – Erro de inclusão.

Ao analisar as matrizes de confusão das três categorias, observou-se menores erros de omissão e inclusão para a categoria P = 50, visto que ela apresentou o maior valor de AG (79,569) para esse cenário.

De forma geral, ao analisar os valores de *Precisão*, *Recall* e *F-score* para cada categoria, foram verificadas que as classes SC6 0 (P = 0), SC6 50 (P = 50) e TS 100 (P = 100) se destacaram, com *F-score* de 0,806, 0,861 e 0,8 respectivamente, refletindo um melhor equilíbrio entre precisão e *recall*. Por outro lado, as classes menos assertivas foram SC2 0, GR6 50 e SC6 100, o que pode ser evidenciado com erros de omissão e inclusão mais elevados.

O terceiro cenário alcançou resultados semelhantes entre os classificadores MP e RF. Embora o RF tenha mantido uma leve superioridade. Para a análise, foram selecionadas as categorias NI, TS, GR6 SC2, SC6 usando os atributos do sensor RGN e a categoria GB2 para a combinação RGB-RGN (Tabela 8).

TABELA 8 Matrizes de confusão para cada categoria do cenário 3. (a) NI; (b) TS; (c) GR2; (d) GR6; (e) SC2; (f) SC6

(a) Categoria NI						(b) Categoria TS					
	NI 0	NI 50	NI 100	Total	EO		TS 0	TS 50	TS 100	Total	EO
NI 0	55	4	0	59	0,068	TS 0	57	1	2	60	0,05
NI 50	3	55	6	64	0,141	TS 50	1	60	0	61	0,016

NI 100	2	11	43	56	0,232
Total	60	70	49	179	
EI	0,083	0,214	0,122		
<i>Precision</i>	0,917	0,786	0,878		
<i>Recall</i>	0,932	0,859	0,768		
<i>F-score</i>	0,924	0,821	0,819		

TS 100	2	6	56	64	0,125
Total	60	67	58	185	
EI	0,05	0,104	0,034		
<i>Precision</i>	0,95	0,896	0,966		
<i>Recall</i>	0,95	0,984	0,875		
<i>F-score</i>	0,95	0,938	0,918		

(c) Categoria GR2

	GR2 0	GR2 50	GR2 100	Total	EO
GR2 0	59	1	4	64	0,078
GR2 50	4	50	2	56	0,107
GR2 100	5	1	50	56	0,107
Total	68	52	56	176	
EI	0,132	0,038	0,107		
<i>Precision</i>	0,868	0,962	0,893		
<i>Recall</i>	0,922	0,893	0,893		
<i>F-score</i>	0,894	0,926	0,893		

(d) Categoria GR6

	GR6 0	GR6 50	GR6 100	Total	EO
GR6 0	59	2	2	63	0,063
GR6 50	5	55	3	63	0,127
GR6 100	2	4	47	53	0,113
Total	66	61	52	179	
EI	0,106	0,098	0,096		
<i>Precision</i>	0,894	0,902	0,904		
<i>Recall</i>	0,937	0,873	0,887		
<i>F-score</i>	0,915	0,887	0,895		

(e) Categoria SC2

	SC2 0	SC2 50	SC2 100	Total	EO
SC2 0	54	1	3	58	0,069
SC2 50	3	54	7	64	0,156
SC2 100	4	9	49	62	0,21
Total	61	64	59	184	
EI	0,115	0,156	0,169		
<i>Precision</i>	0,885	0,844	0,831		
<i>Recall</i>	0,931	0,844	0,79		
<i>F-score</i>	0,908	0,844	0,81		

(f) Categoria SC6

	SC6 0	SC6 50	SC6 100	Total	EO
SC6 0	60	2	1	63	0,048
SC6 50	2	62	0	64	0,031
SC6 100	3	2	59	64	0,078
Total	65	66	60	191	
EI	0,077	0,061	0,017		
<i>Precision</i>	0,923	0,939	0,983		
<i>Recall</i>	0,952	0,969	0,922		
<i>F-score</i>	0,938	0,954	0,952		

Tons mais vermelhos – valores mais altos; Tons mais amarelos – valores intermediários; Sem cor – valores baixos ou nulos; Diagonal principal – classificações corretas; Fora da diagonal principal – erros de classificações; EO – Erro de omissão; EI – Erro de inclusão.

As matrizes de confusão indicaram que os erros de omissão e inclusão permaneceram menores que 0,25 para todas as classes, indicando leves confusões. A categoria SC6 apresentou os menores erros de omissão e inclusão em relação às demais categorias. Esse resultado é condizente com os valores mais altos de Acurácia Global e Kappa obtidos pelo RF ao utilizar os atributos do sensor RGN (Tabela 5).

No que diz respeito aos valores de *Precision*, *Recall* e *F-score*, as classes NI 0, TS 0, GR2 50, GR6 0, SC2 0 e SC6 50 foram as mais bem classificadas, com os melhores desempenhos para cada categoria. No entanto, as classes NI 100, TS 100, GR2 100, GR6 50,

SC2 100 e SC6 0 tiveram desempenho inferior, o que pode ser visto em seus valores menores de *F-score*.

5 DISCUSSÃO

Neste estudo, foram comparados os resultados de dois algoritmos, RF e MP, combinados com dados de sensores RGB, RGN e seus respectivos índices de vegetação, para discriminar tratamentos aplicados à alface. Três cenários de classificações foram estabelecidos, e métricas estatísticas foram empregadas para avaliar o desempenho de cada um.

O desempenho inferior no cenário 1 mostra uma maior dificuldade dos algoritmos em separar os tratamentos quando todos os fatores são considerados simultaneamente. Essa dificuldade está associada à similaridade espectral entre algumas inoculações e entre as doses de fósforo, conforme observado por Silva *et al.* (2022) que identificaram semelhanças entre a inoculação com suspensão de conídios e a inoculação de sementes, bem como entre a formulação granular e a ausência de inoculação, além da ausência de diferenças entre as doses de 50% e 100% de fósforo em uma mesma inoculação. Assim, torna-se mais difícil para os classificadores estabelecerem padrões claros de separação.

No cenário 2, ao considerar apenas as inoculações dentro de uma mesma dose de fósforo, os algoritmos demonstraram maior precisão. No entanto, ainda houve confusão entre algumas inoculações devido às semelhanças mencionadas anteriormente. Já no cenário 3, o desempenho dos classificadores foi ainda melhor, resultado das diferenças espectrais entre as plantas adubadas e não adubadas com fósforo. O fósforo é essencial para o desenvolvimento da planta, influenciando processos metabólicos como fotossíntese, respiração e transporte de energia dentro das células, além de ter papel importante na função das proteínas (Raghothama, 2015). Sua deficiência pode resultar em menor crescimento das plantas (Vilar; Vilar, 2013), o que foi confirmado por Silva (2022), que observou menores valores nos parâmetros agrônômicos para a dose 0% de P. A diferença entre as plantas sem adubação e as demais doses foi capturada pelos sensores, esse fato analisado de forma isolada para apenas uma inoculação por vez e, conseqüentemente, a redução do número de classes, contribuiu nos melhores desempenhos dos classificadores nesse cenário.

Ao comparar os classificadores, o algoritmo RF demonstrou maior eficiência na distinção dos tratamentos em relação ao MP, principalmente nos cenários 1 e 2, atingindo valores superiores de Acurácia Global e índice Kappa. Essa diferença é atribuída à robustez do

RF em lidar com dados heterogêneos e a sua capacidade de generalizar padrões complexos (Maxwell; Warner; Fang, 2018). Por outro lado, MP pode necessitar da otimização de parâmetros para alcançar melhores desempenhos.

Estudos anteriores corroboram a superioridade do RF em relação a outros algoritmos. Lee, Wang e Leblon (2020) comparam métodos de regressão linear simples/múltipla, RF e regressão de vetor de suporte (SVR) para prever o peso do nitrogênio na copa do milho, usando imagens multiespectrais de veículos aéreos não tripulados, concluindo que o RF apresentou o melhor desempenho. Siedliska *et al.* (2021) compararam RF, Rede Neural de Retropropagação, Naive Bayes e SVM na classificação de plantas sob diferentes adubações fosfatadas, observando maior desempenho do RF, com acurácia superior a 70% em plantas de morango e mais de 80% para aipo. Hu *et al.* (2025) utilizaram os modelos RF, SVM e K-Nearest Neighbors (KNN) para classificar cultivos de hortaliças no nordeste da China, com o RF superando os demais métodos (Acurácia Global de 0,87 e Kappa de 0,93), registrou ganhos entre 4% a 9% em relação a KNN e SVM.

A combinação dos sensores RGB-RGN com os índices de vegetação proporcionou os melhores resultados gerais. A combinação desses sensores aproveita os benefícios das bandas visíveis (informações relacionadas à cor e saúde geral das plantas) e da região do infravermelho próximo (informações mais sensíveis sobre a estrutura interna das folhas, incluindo o conteúdo de água e alterações nutricionais), para complementar o conjunto de dados com informações que facilitam a discriminação entre as classes (Pozoni *et al.*, 2012).

Os sensores de forma isolada e seus respectivos índices de vegetação revelaram aspectos interessantes. Os atributos do sensor RGN apresentaram desempenhos comparáveis à combinação RGB-RGN nos cenários 1 e 2 e foram superiores no cenário 3. Esse comportamento pode ser explicado pela maior sensibilidade das bandas do RGN na detecção de variações na vegetação. A banda vermelha, por exemplo, pode ser influenciada por fatores relacionados à fotossíntese, como clorofila *a* (Jensen, 2009), enquanto a banda verde que é sensível à pigmentação da vegetação, e a banda do infravermelho próximo está associada à área foliar (Rezende, 2023). O que pode ser aplicado também aos índices de vegetação, como o NDVI, amplamente reconhecido por sua sensibilidade à biomassa das plantas (Carmo *et al.*, 2021). Esses achados sugerem que os atributos do sensor RGN podem reduzir o uso e dependência de combinações mais complexas.

Estudos prévios reforçaram essa constatação. Mahajan *et al.* (2014) mostraram que a reflectância na faixa do NIR foi significativamente correlacionada com as doses de fósforo no

trigo, indicando que essa região é responsiva a variedades de concentrações de P na planta. Siedliska *et al.* (2021) também identificaram variações significativas na faixa do infravermelho próximo (750 – 1300 nm) em resposta a diferentes concentrações de P em culturas como aipo, beterraba sacarina e morango. Enquanto a região do verde (500 – 560) não foi significativamente afetada, porém, houve mudanças expressivas na concentração de clorofila *a*, pigmento esse, que é sensível ao comprimento de onda na região vermelha. O que reforça a importância das bandas R e NIR no sensor RGN para a classificação de tratamentos com P.

Por outro lado, os resultados inferiores obtidos com as bandas RGB e seus índices de vegetação evidenciam um menor potencial desses atributos na discriminação dos tratamentos de alface quando comparados ao RGN ou a combinação RGB-RGN. Esse fato pode estar relacionado à aparência típica da vegetação verde saudável exibida nas amostras, o que faz com que as culturas reflitam a mesma quantidade de comprimento de onda verde, dificultando a diferenciação entre os tratamentos (Martins *et al.*, 2021; Lee; Wang; Leblon, 2020).

Todos os três cenários apresentaram um desempenho superior na discriminação do tratamento SC6 50. Esse resultado pode estar relacionado ao fato de que os tratamentos com a inoculação por suspensão de conídios 10^6 conídios mL⁻¹ foram os únicos que diferiram significativamente entre todas as doses de P nos parâmetros agronômicos e na taxa de crescimento das alfaces (Silva, 2022). Além disso, o tratamento SC6 50 foi agrupado separadamente dos demais tratamentos na análise de dendrograma realizada por Silva (2022), sugerindo uma dissimilaridade em relação aos outros tratamentos.

Os tratamentos com dose 0% de fósforo também apresentaram maior facilidade de discriminação em relação aos demais, como observado no cenário 1, com as classes NI 0 e SC6 0, e no cenário 3, com as classes NI 0, TS 0, GR6 0 e SC2 0. De acordo com Silva (2022), os parâmetros agronômicos avaliados mostraram valores mais baixos na ausência de fósforo e sem diferença significativa entre as doses 50 e 100%, indicando que as doses 50% foram suficientes para atingir os valores superiores, o que pode explicar a dificuldade do classificador RF em distinguir principalmente as doses 100% (NI 100, TS 100, GR2 100, SC2 100) no cenário 3.

As imagens em série temporal possibilitam a captura de informação ao longo do tempo sobre a cultura, como padrões de crescimento, variações no desenvolvimento da biomassa, mudanças na reflectância das plantas, como também alteração fisiológicas (Vuolo *et al.*, 2018). Em muitas situações, as diferenças causadas pelos tratamentos podem ser pequenas demais para serem detectadas em um único momento, tornando-se evidentes apenas em análises posteriores. Estudos como Feng *et al.* (2020), alcançaram uma precisão de 92,80% usando imagens

multitemporal de veículos aéreos não tripulados para classificação de culturas hortícolas na cidade de Shenzhou, na China. Resultados semelhantes também foram relatadas por Kwak e Park (2019), onde imagens multitemporal sobressaíram melhores nas classificações.

6 CONCLUSÃO

O uso de imagens multiespectrais, integrada a modelos de aprendizado de máquina, possibilitou a discriminação de tratamentos na cultura da alface. A partir dessas imagens e de seus índices de vegetação, foi possível diferenciar inoculações do fungo *Aspergillus niger*, bem como as dosagens de fósforo (P) aplicadas em cada tratamento.

A combinação de atributos dos sensores RGB e RGN proporcionou os melhores desempenhos nas classificações. No entanto, o sensor RGN teve papel fundamental, com maior contribuição para os resultados obtidos, o que o torna essencial nesse tipo de análise.

O algoritmo *Random Forest* demonstrou um desempenho superior para classificar os diferentes tratamentos em comparação ao *Multilayer Perceptron*, destacando-se, especialmente, nos cenários 1 e 2.

Além disso, as imagens multiespectrais tornaram-se uma alternativa de baixo custo, permitindo o monitoramento de culturas em larga escala e reduzindo o tempo necessário para coleta de dados em campo.

REFERÊNCIAS

- ALORDZINU, K. E.; LI, J.; LAN, Y.; APPIAH, S. A.; AASMI, A. A.; WANG, H.; LIAO, J.; SAM-AMOA, L. K.; QIAO, S. Ground-Based Hyperspectral Remote Sensing for Estimating Water Stress in Tomato Growth in Sandy Loam and Silty Loam Soils. **Sensors**, v. 21, n. 17, p. 5705, 2021. MDPI AG. DOI: <http://dx.doi.org/10.3390/s21175705>
- ANAND, K. J.; NAGRE, S. P.; SHRIVASTAVA, M. K.; AMRATE, P. K.; PATEL, T.; KATARA, V. K. Enhancing Crop Improvement through Synergistic Integration of Advanced Plant Breeding and Proximal Remote Sensing Techniques: A Review. **International Journal of Plant & Soil Science**, v. 35, n. 19, p. 121–138, 2023. DOI:10.9734/ijpss/2023/v35i193533. Disponível em: <https://journalijpss.com/index.php/IJPSS/article/view/3533>. Acesso em: out. 2024.
- BELGIU, M.; DRĂGĂŢ, L. Random Forest in remote sensing: a review of applications and future directions. **Isprs Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2016.01.011>

Breiman, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, 2001.
<https://doi.org/10.1023/A:1010933404324>

CARMO, G. J. D. S.; CASTOLDI, R.; MARTINS, G. D.; JACINTO, A. C. P.; TEBALDI, N. D.; CHARLO, H. C. D. O.; ZAMPIROLI, R. Detection of Lesions in Lettuce Caused by *Pectobacterium carotovorum* Subsp. *carotovorum* by Supervised Classification Using Multispectral Images. **Canadian Journal of Remote Sensing**, v. 48, n. 2, p. 144-157, 2021. Informa UK Limited. <http://dx.doi.org/10.1080/07038992.2021.1971960>

CHANG, A.; YEOM, J.; JUNG, J.; LANDIVAR, J. Comparison of Canopy Shape and Vegetation Indices of Citrus Trees Derived from UAV Multispectral Images for Characterization of Citrus Greening Disease. **Remote Sensing**, v. 12, n. 24, p. 4122, 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12244122>

CLEMENTE, A. A.; MACIEL, G. M.; SIQUIEROLI, A. C. S.; GALLIS, R. B. de A.; PEREIRA, L. M.; DUARTE, J. G. High-throughput phenotyping to detect anthocyanins, chlorophylls, and carotenoids in red lettuce germplasm. **International Journal of Applied Earth Observation and Geoinformation**, v. 103, p. 102533, 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2021.102533>

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and practices**. CRC press, 2008.

DHONDT, S.; WUYTS, N.; INZÉ, D. Cell to whole-plant phenotyping: the best is yet to come. **Trends In Plant Science**, v. 18, n. 8, p. 428-439, 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.tplants.2013.04.008>.

DUQUE, T. S.; PINHEIRO, R. A.; SOUZA, I. M.; SILVA, G. G.; SOARES, M. A.; SANTOS, J. B. D. Herbicides and bio-inputs: compatibility and challenges for sustainable agriculture. **Chemosphere**, v. 369, p. 143878, 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.chemosphere.2024.143878>.

ESHKABILOV, S.; SIMKO, I. Assessing Contents of Sugars, Vitamins, and Nutrients in Baby Leaf Lettuce from Hyperspectral Data with Machine Learning Models. **Agriculture**, v. 14, n. 6, p. 834, 2024. MDPI AG. <http://dx.doi.org/10.3390/agriculture14060834>

ESHKABILOV, S.; LEE, A.; SUN, X.; LEE, C. W.; SIMSEK, H. Hyperspectral imaging techniques for rapid detection of nutrient content of hydroponically grown lettuce cultivars. **Computers and Electronics in Agriculture**, v. 181, p. 105968, 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105968>

FENG, L.; CHEN, S.; ZHANG, C.; ZHANG, Y.; HE, Y. A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenotyping. **Computers and Electronics in Agriculture**, v. 182, 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106033>

FENG, Q.; YANG, J.; LIU, Y.; OU, C.; ZHU, D.; NIU, B.; LIU, J.; LI, B. Multi-Temporal Unmanned Aerial Vehicle Remote Sensing for Vegetable Mapping Using an Attention-Based Recurrent Convolutional Neural Network. **Remote Sensing**, v. 12, n. 10, p. 1668, 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12101668>

FILGUEIRA, F. A. R. **Novo manual de olericultura: agrotecnologia moderna na produção e comercialização de hortaliças**, 2008, Viçosa, MG: UFV, 421 p.

FONSECA, L. M. G. **Processamento digital de imagens. Instituto Nacional de Pesquisas Espaciais (INPE)**, 2000. 105 p.

FULLANA-PERICÀS, M.; CONESA, M. À.; GAGO, J.; RIBAS-CARBÓ, M.; GALMÉS, J. High-throughput phenotyping of a large tomato collection under water deficit: combining uavs remote sensing with conventional leaf-level physiologic and agronomic measurements. **Agricultural Water Management**, v. 260, p. 107283, 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.agwat.2021.107283>

GABRIEL, J. L.; ZARCO-TEJADA, P. J.; LÓPEZ-HERRERA, P. J.; PÉREZ-MARTÍN, E.; ALONSO-AYUSO, M.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems Engineering**, v. 160, p. 124-133, 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.biosystemseng.2017.06.003>

GALVANIN, E. A. D. S.; NEVES, S. M. A. D. S.; CRUZ, C. B. M.; NEVES, R. J.; JESUS, P. H. H. D.; KREITLOW, J. P. Avaliação dos Índices de Vegetação NDVI, SR e TVI na discriminação de fitofisionomias dos ambientes do Pantanal de Cáceres/MT. **Ciência Florestal**, 24, 707-715, 2014. <https://doi.org/10.1590/1980-509820142403018>

GHAMISI, P.; PLAZA, J.; CHEN, Y.; LI, J.; PLAZA, A. J. Advanced Spectral Classifiers for Hyperspectral Images: a review. **IEEE Geoscience and Remote Sensing Magazine**, v. 5, n. 1, p. 8-32, 2017. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/mgrs.2016.2616418>

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76-87, 2002. Elsevier BV. [http://dx.doi.org/10.1016/s0034-4257\(01\)00289-9](http://dx.doi.org/10.1016/s0034-4257(01)00289-9)

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289-298, 1996. Elsevier BV. [http://dx.doi.org/10.1016/s0034-4257\(96\)00072-7](http://dx.doi.org/10.1016/s0034-4257(96)00072-7)

GRZYBOWSKI, M.; WIJEWARDANE, N. K.; ATEFI, A.; GE, Y.; SCHNABLE, J. C. Hyperspectral reflectance-based phenotyping for quantitative genetics in crops: progress and challenges. **Plant Communications**, v. 2, n. 4, p. 100209, 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.xplc.2021.100209>

HANDIQUE, B. K.; GOSWAMI, C.; GUPTA, C.; PANDIT, S.; GOGOI, S.; JADI, R.; JENA, P.; BORAH, G.; RAJU, P. L. N. Hierarchical classification for assessment of horticultural crops in mixed cropping pattern using uav-borne multi-spectral sensor. **The International Archives of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, v. 3, 2020, p. 67-74, 2020. <http://dx.doi.org/10.5194/isprs-archives-xliii-b3-2020-67-2020>

HAYKIN, S. **Redes Neurais: princípios e práticos**. 2. ed. Porto Alegre: Bookman, 2001. 899

HENZ, G. P., SUINAGA, F. A. Comunicado Técnico: Tipos de Alface Cultivados no Brasil. **EMBRAPA**. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/783588/tipos-de-alfacecultivados-no-brasil>. Acesso em: out. 2024. 2009.

HOMOLOVÁ, L.; MALENOVSKÝ, Z.; CLEVERS, J. G. P. W.; GARCÍA-SANTOS, G.; SCHAEPMAN, M. E. Review of optical-based remote sensing for plant trait mapping. **Ecological Complexity**, v. 15, p. 1-16, 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.ecocom.2013.06.003>

HU, J.; LU, H.; SONG, K.; ZHU, B. Vegetable Fields Mapping in Northeast China Based on Phenological Features. **Agronomy**, v. 15, n. 2, p. 307, 2025. MDPI AG. <http://dx.doi.org/10.3390/agronomy15020307>

HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.T.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2012.07.020>

JENSEN, J. R. **Remote sensing of the environment: A perspective on terrestrial resources**. São José dos Campos: Parenthesis, 2009. 672p.

JOG, S; DIXIT, M. Supervised classification of satellite images. **2016 Conference on Advances in Signal Processing (Casp)**, p. 93-98, 2016. IEEE. <http://dx.doi.org/10.1109/casp.2016.7746144>

KHANAL, S.; KC, K.; FULTON, J. P.; SHEARER, S.; OZKAN, E. Remote Sensing in Agriculture—Accomplishments, Limitations, and Opportunities. **Remote Sensing**, v. 12, n. 22, p. 3783, 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12223783>

KIM, C.; VAN IERSEL, M. W. Image-based phenotyping to estimate anthocyanin concentrations in lettuce. **Frontiers in Plant Science**, v. 14, p. 1-12, 2023. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2023.1155722>

KIM, M. J.; MOON, Y.; TOU, J. C.; MOU, B.; WATERLAND, N. L. Nutritional value, bioactive compounds and health benefits of lettuce (*Lactuca sativa* L.). **Journal of Food Composition and Analysis**, v. 49, p. 19-34, 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.jfca.2016.03.004>

KWAK, Geun-Ho; PARK, No-Wook. Impact of Texture Information on Crop Classification with Machine Learning and UAV Images. **Applied Sciences**, v. 9, n. 4, p. 643, 2019. MDPI AG. <http://dx.doi.org/10.3390/app9040643>

LARY, D. J.; ALAVI, A.H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.gsf.2015.07.003>

LEE, H.; WANG, J.; LEBLON, B. Using Linear Regression, Random Forests, and Support Vector Machine with Unmanned Aerial Vehicle Multispectral Images to Predict Canopy

Nitrogen Weight in Corn. **Remote Sensing**, v. 12, n. 13, p. 2071, 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12132071>

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, v. 24, n. 2, p. 152-164, 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.tplants.2018.11.007>

MAHAJAN, G. R.; SAHOO, R. N.; PANDEY, R. N.; GUPTA, V. K.; KUMAR, Dinesh. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision Agriculture**, v. 15, n. 5, p. 499-522, 9 fev. 2014. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-014-9348-7>

MARTINS, G. D. et al. **Mapeamento do teor clorofila total em áreas com a cultura do milho a partir de imagens multiespectrais tomadas por aeronaves remotamente pilotadas**. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, v. 19, 96282, 2019.

MARTINS, G. D.; SANTOS, L. C. S.; CARMO, G. J. D. S.; SILVA NETO, O. F. D.; CASTOLDI, R.; MACHADO, A. I. M. R.; CHARLO, H. C. D. O. Multispectral images for estimating morphophysiological and nutritional parameters in cabbage seedlings. **Smart Agricultural Technology**, v. 4, p. 100211, 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.atech.2023.100211>

MARTINS, G. D.; SILVA NETO, O. F. D.; CARMO, G. J. D. S.; CASTOLDI, R.; SANTOS, L. C. S.; CHARLO, H. C. D. O. Estimation of biometric, physiological, and nutritional variables in lettuce seedlings using multispectral images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 10, p. 689-695, 2021. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1807-1929/agriambi.v25n10p689-695>

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784-2817, 2018. Informa UK Limited. <http://dx.doi.org/10.1080/01431161.2018.1433343>

MENDES, G. DE O.; FREITAS, A. L. M. DE; PEREIRA, O. L.; SILVA, I. R. DA; VASSILEV, N. B.; COSTA, M. D. Mechanisms of phosphate solubilization by fungal isolates when exposed to different P sources. **Annals Of Microbiology**, v. 64, n. 1, p. 239-249, 2013. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s13213-013-0656-3>

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358-371, 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>

MUNDIM, G. D. S. M.; MACIEL, G. M.; MENDES, G. D. O. *Aspergillus niger* as a Biological Input for Improving Vegetable Seedling Production. **Microorganisms**, v. 10, n. 4, p. 674, 2022. MDPI AG. <http://dx.doi.org/10.3390/microorganisms10040674>

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. 160 p

POWERS, D. M. W. Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation. **Mach. Learn. Technol**, 2, 2008. DOI: <https://doi.org/10.48550/arXiv.2010.16061>

RAGHOTHAMA, K. G. Phosphorus and Plant Nutrition: an overview. **Agronomy Monographs**, p. 353-378, 2015. American Society of Agronomy, Crop Science Society of America, and Soil Science Society of America. <http://dx.doi.org/10.2134/agronmonogr46.c11>

REZENDE, C. I. P.; ASSIS, G. A. D.; MARTINS, G. D.; CARVALHO, F. J.; FRANCO, M. H. R.; ARAUJO, N. O. D. Multispectral images for discrimination of sources and doses of fertilizer in coffee plants. **Revista Ceres**, v. 70, n. 3, p. 54-63, 2023. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0034-737x202370030006>

RIBEIRO, A. L. A.; MACIEL, G. M.; SIQUIEROLI, A. C. S.; LUZ, J. M. Q.; GALLIS, R. B. D. A.; ASSIS, P. H. D. S.; CATÃO, H. C. R. M.; YADA, R. Y. Vegetation Indices for Predicting the Growth and Harvest Rate of Lettuce. **Agriculture**, v. 13, n. 5, p. 1091, 2023. MDPI AG. <http://dx.doi.org/10.3390/agriculture13051091>

ROUSE, J. W., HASS, R. H., SCHELL, J. A., DEERING, D. W. **Monitoring vegetation systems in the great plains with ERTS. In: Third Earth Resources Technology Satellite-1 Symposium**. Washington, DC. Proceedings. Washington, NASA SP-351, 1974, v. 1, p. 309-317

RYDER, E. J. **Ten lettuce genetic stocks with early flowering genes Ef-1ef-1 and Ef-2ef-2**. **HortScience**, Alexandria, v. 31, n. 3, p. 473-475, 1996

SALA, F. C.; COSTA, C. P. D. Retrospectiva e tendência da alfacicultura brasileira. **Horticultura Brasileira**, v. 30, n. 2, p. 187-194, 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0102-05362012000200002>

SHI, M.; GU, J.; WU, H.; RAUF, A.; EMRAN, T. B.; KHAN, Z.; MITRA, S.; ALJOHANI, A. S. M.; ALHUMAYDHI, F. A.; AL-AWTHAN, Y. S. Phytochemicals, Nutrition, Metabolism, Bioavailability, and Health Benefits in Lettuce—A Comprehensive Review. **Antioxidants**, v. 11, n. 6, p. 1158, 2022. MDPI AG. <http://dx.doi.org/10.3390/antiox11061158>

SIEDLISKA, A.; BARANOWSKI, P.; PASTUSZKA-WOŹNIAK, J.; ZUBIK, M.; KRZYSZCZAK, J. Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. **Bmc Plant Biology**, v. 21, n. 1, p. 1-15, 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1186/s12870-020-02807-4>

SILVA, P. V. **Caracterização e uso de formulação de biofertilizante à base de *Aspergillus niger*: Produção de alface inoculada com *Aspergillus niger* sob diferentes doses de fósforo**. 2022. 77 f. Dissertação (Mestrado) - Curso de Pós-Graduação em Agricultura e Informações Geoespaciais, Universidade Federal de Uberlândia, Monte Carmelo, 2022. Disponível em: <https://repositorio.ufu.br/handle/123456789/34418>

SILVA, P. V.; PEREIRA, L. M.; MUNDIM, G. D. S. M.; MACIEL, G. M.; GALLIS, R. B. D. A.; MENDES, G. D. O. Field evaluation of the effect of *Aspergillus niger* on lettuce growth using conventional measurements and a high-throughput phenotyping method based on aerial

images. **Plos One**, v. 17, n. 9, p. 1-11, 2022. Public Library of Science (PLOS).
<http://dx.doi.org/10.1371/journal.pone.0274731>

SIRAKOV, I.; VELICHKOVA, K.; DINEV, T.; SLAVCHEVA-SIRAKOVA, D.; VALKOVA, E.; YORGOV, D.; VELEVA, P.; ATANASOV, V.; ATANASSOVA, S. Detection of Fungal Diseases in Lettuce by VIR-NIR Spectroscopy in Aquaponics. **Microorganisms**, v. 11, n. 9, p. 2348, 2023. MDPI AG. <http://dx.doi.org/10.3390/microorganisms11092348>

SOUSA, C. A. F. de. **Fenotipagem de plantas: uma nova abordagem para um velho problema**. 2014. Disponível em:
<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/991030/1/cot06.pdf>

USHA, K.; SINGH, B. Potential applications of remote sensing in horticulture - A review. **Scientia Horticulture**, v. 153, p. 71-83, 2013. Elsevier BV.
<http://dx.doi.org/10.1016/j.scienta.2013.01.008>

VILAR, C. C.; VILAR, F. C. M. Comportamento do Fósforo em Solo e Planta. **Revista Campo Digital**, v. 8, n. 2, 2013. Disponível em:
<https://revista2.grupointegrado.br/revista/index.php/campodigital/article/view/1664>

VRIES, I. M. Origin and domestication of *Lactuca sativa* L. **Genetic Resources and Crop Evolution**, p. 165–174 (1997). <https://doi.org/10.1023/A:1008611200727>

VUOLO, F.; NEUWIRTH, M.; IMMITZER, M.; ATZBERGER, C.; NG, Wai-Tim. How much does multi-temporal Sentinel-2 data improve crop type classification? **International Journal of Applied Earth Observation and Geoinformation**, v. 72, p. 122-130, 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2018.06.007>

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, v. 236, p. 111402, 2020. Elsevier BV.
<http://dx.doi.org/10.1016/j.rse.2019.111402>