

GLECIA JÚNIA DOS SANTOS CARMO

DETECÇÃO DE PODRIDÃO MOLE EM ALFACE POR *Pectobacterium carotovorum*
subsp. *carotovorum* POR ALGORITMOS DE APRENDIZADO DE MÁQUINA
A PARTIR 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
2021

GLECIA JÚNIA DOS SANTOS CARMO

DETECÇÃO DE PODRIDÃO MOLE EM ALFACE POR *Pectobacterium carotovorum*
subsp. *carotovorum* POR ALGORITMOS DE APRENDIZADO DE MÁQUINA
A PARTIR 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”.

APROVADA em 14 de julho de 2021.

Banca examinadora

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

Prof. Dr. George Deroco Martins - UFU

Prof. Dr. Adley Camargo Ziviani - Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro - IFTM

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

MONTE CARMELO
MINAS GERAIS - BRASIL
2021

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

C287 2021	<p>Carmo, Glecia Júnia dos Santos, 1995- Detecção de podridão mole em alface por <i>Pectobacterium carotovorum</i> subsp. <i>carotovorum</i> por algoritmos de aprendizado de máquina a partir de imagens multiespectrais [recurso eletrônico] / Glecia Júnia dos Santos Carmo. - 2021.</p> <p>Orientador: Renata Castoldi. Coorientador: George Deroco Martins. 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.2021.354 Inclui bibliografia.</p> <p>1. Agronomia. I. Castoldi, Renata, 1982-, (Orient.). II. Martins, George Deroco, 1987-, (Coorient.). III. Universidade Federal de Uberlândia. Pós-graduação em Agricultura e Informações Geoespaciais. IV. Título.</p> <p style="text-align: right;">CDU: 631</p>
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



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:	14/07/2021	Hora de início:	08:35	Hora de encerramento:	11:20
Matrícula do Discente:	31922AIG004				
Nome do Discente:	Glecia Júnia dos Santos Carmo				
Título do Trabalho:	Detecção de podridão mole em alface por <i>Pectobacterium carotovorum subsp. carotovorum</i> por algoritmos de aprendizado de máquina a partir de imagens multiespectrais				
Área de concentração:	Informações Geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Sistemas integrados de produção vegetal				

Reuniu-se na sala virtual Google Meet (meet.google.com/wbm-ztcp-ffd) a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Adley Camargo Ziviani (Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro - IFTM, Campus Uberaba), Dr. George Deroco Martins (UFU), Dra. Renata Castoldi (UFU) – orientadora da candidata.

Iniciando os trabalhos o(a) presidente da mesa, Dra Renata Castoldi, apresentou a Comissão Examinadora e o candidato(a), 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 o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

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 **Renata Castoldi, Professor(a) do Magistério Superior**, em 14/07/2021, às 16:03, 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 **George Deroco Martins, Professor(a) do Magistério Superior**, em 15/07/2021, às 09:36, 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 **Adley Camargo Ziviani, Usuário Externo**, em 15/07/2021, às 10:36, 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 **2905285** e o código CRC **8C3572E4**.

AGRADECIMENTOS

À Deus Uno e Trino, à Santíssima Virgem Maria e ao meu Anjo da Guarda.

Aos meus pais, Geni dos Santos Carmo e Fernando Aparecido do Carmo que me auxiliaram como puderam.

À Professora Dr^a. Renata Castoldi pela orientação e dedicação, que não mediu esforços para a realização deste trabalho.

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

À Professora Dr^a. Nilvanira Donizete Tebaldi por fornecer o isolado *Pectobacterium carotovorum* subsp. *carotovorum* UFU A7.

Ao servidor e Ms. Renan Zampiroli pela realização dos voos.

Ao grupo de pesquisa NUPOL (Núcleo de Pesquisa em Olericultura) que me auxiliou na condução do experimento.

Ao senhor José Marques Vilela da Estação Experimental de Hortaliças da UFU e ao operador de máquinas Ivan dos Santos Vieira, pela prestatividade.

Aos técnicos dos laboratórios LAMIF, LBIO, LAFIT e ENGAS pela disponibilidade de equipamentos e/ou espaço.

Gratidão a todos!

BIOGRAFIA

Glecia Júnia dos Santos Carmo - nascida em 18 de junho de 1995 na cidade de Serra Azul de Minas - MG, filha de Geni dos Santos Carmo e Fernando Aparecido do Carmo. Foi diplomada em Engenharia Agrônômica em 07 de fevereiro de 2018, pela Universidade Federal de Uberlândia – Campus Monte Carmelo. Durante a graduação foi bolsista na área de Microbiologia Agrícola do Programa Institucional de Iniciação Científica Voluntária PIVIC/UFU, do Programa Institucional de Bolsas de Iniciação Científica PIBIC/FAPEMIG/UFU e do Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação PIBITI/CNPq/UFU. Em agosto de 2019, na mesma Universidade, ingressou no curso de mestrado em Agricultura e Informações Geoespaciais, linha de pesquisa Sistemas Integrados de Produção Vegetal, subárea Olericultura, submetendo-se à defesa de dissertação em julho de 2021.

SUMÁRIO

RESUMO	i
ABSTRACT	ii
1 INTRODUÇÃO	1
2 REFERENCIAL TEÓRICO.....	3
3 MATERIAL E MÉTODOS.....	22
4 RESULTADOS	33
5 DISCUSSÃO	38
6 CONCLUSÕES	42
7 REFERÊNCIAS BIBLIOGRÁFICAS	43

RESUMO

CARMO, GLECIA JÚNIA DOS SANTOS. **Detecção de podridão mole em alface por *Pectobacterium carotovorum* subsp. *carotovorum* por algoritmos de aprendizado de máquina a partir de imagens multiespectrais.** 2021. 59p. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) – Universidade Federal de Uberlândia, Campus Monte Carmelo, Minas Gerais, Brasil¹.

A alface é a hortaliça folhosa mais consumida e de maior importância econômica mundial, entretanto a produção é dificultada por inúmeros patógenos, dentre eles, a *Pectobacterium carotovorum* subsp. *carotovorum*, causadora da podridão mole em alface. Dessa forma, este estudo teve por objetivos: identificar a melhor época e o melhor sensor para detecção da doença causada por *Pectobacterium carotovorum* subsp. *carotovorum* em alface, usando imagens obtidas por sensores multiespectrais em veículo aéreo não tripulado (VANT). Para isso, instalou-se um experimento em casa de vegetação na Universidade Federal de Uberlândia, Campus Monte Carmelo, contendo 392 vasos de cinco litros cada, sendo que, em cada vaso transplantou-se uma plântula de alface. Aos 27 dias após o transplante, 196 plantas foram inoculadas com *Pectobacterium carotovorum* subsp. *carotovorum* e 196 plantas não foram inoculadas. Aos 4, 8, 12, 16, 20, 24 e 28 dias após a inoculação (DAI), as plantas inoculadas foram avaliadas quanto as lesões e, tanto plantas inoculadas quanto não inoculadas foram avaliadas quanto aos parâmetros agrônômicos. No mesmo intervalo de tempo também foram realizados voos na área, entre 12 e 13 horas. Foram utilizados os classificadores Support Vector Machine (SVM) e Naive Bayes (NB), a fim de avaliar grupos de dados compostos de bandas espectrais, índices de vegetação e a combinação de bandas e índices obtidos de uma câmara visível convencional e de uma câmara multiespectral Mapir Survey3W, bem como parâmetros agrônômicos. Os resultados confirmaram a possibilidade de detecção pré-sintomática de *Pectobacterium carotovorum* subsp. *carotovorum* em alface. Para a detecção de plantas de alface infectadas por classificação supervisionada, os melhores resultados foram obtidos aos 4 e 8 DAI, principalmente utilizando-se subconjuntos derivados da câmara Mapir Survey3W (sensor RGN), para ambos classificadores. Os subconjuntos derivados do sensor visível convencional (sensor RGB) apresentaram os melhores resultados nos intervalos de 20 e 24 DAI.

Palavras-chave: Classificação supervisionada, Diagnose de doença, *Lactuca sativa*, Veículo aéreo não tripulado.

¹ Orientadora: Renata Castoldi – UFU

ABSTRACT

CARMO, GLECIA JÚNIA DOS SANTOS. **Detection of soft rot in lettuce by *Pectobacterium carotovorum* subsp. *carotovorum* by machine learning algorithms using multispectral images.** 2021. 59p. Dissertation (Master Program Agriculture and Geospatial Information) – Federal University of Uberlândia, Monte Carmelo, Minas Gerais, Brazil¹.

Lettuce is the most consumed leafy vegetable and has the greatest economic importance worldwide, however production is hampered by numerous pathogens, including *Pectobacterium carotovorum* subsp. *carotovorum*, which causes soft rot in lettuce. Thus, this study aimed to identify the best sensor and determine the optimal stage to detect disease caused by *Pectobacterium carotovorum* subsp. *carotovorum* in lettuce, using images obtained by multispectral sensors mounted on an unmanned aerial vehicle (UAV). For this, an experiment was installed in a greenhouse at the Federal University of Uberlândia, Campus Monte Carmelo, containing 392 plastic pots of five liters each, and in each pot a lettuce seedling was transplanted. At 27 days after transplanting, 196 plants were inoculated with *Pectobacterium carotovorum* subsp. *carotovorum* and 196 plants were not inoculated. At 4, 8, 12, 16, 20, 24 and 28 days after inoculation (DAI), lesions of plants inoculated were assessed and plants inoculated or not were assessed for agronomic parameters. At the same time interval, flights were also carried out in the area, between 12 and 13 hours. Were used the Support Vector Machine (SVM) and Naive Bayes (NB) classifiers to analyze data groups consisting of spectral bands, vegetation indices and a combination of bands and indices obtained from a conventional visible camera and Mapir Survey3W multispectral camera, as well as agronomic parameters. The results confirmed the possibility of pre-symptomatic detection of *Pectobacterium carotovorum* subsp. *carotovorum* in lettuce. With respect to identifying infected lettuce plants by supervised classification, the best results were obtained at 4 and 8 DAI, especially when using the subsets derived from the Mapir Survey3W camera (RGN sensor), for both classifiers. The subsets obtained with the conventional visible sensor (RGB sensor) produced the best results at 20 and 24 DAI.

Key-words: Supervised classification, Diagnosis disease, *Lactuca sativa*, Unmanned aerial vehicle.

² Orientadora: Renata Castoldi – UFU

1 INTRODUÇÃO

A alface (*Lactuca sativa* L.) é a hortaliça folhosa de maior importância econômica mundial. No Brasil, apresenta contínuo aumento de estabelecimentos produtores e volume produzido (ANUÁRIO BRASILEIRO DE HORTI&FRUTI 2020, 2019).

No entanto, sua produtividade pode ser drasticamente reduzida em razão da ocorrência de inúmeros fitopatógenos, que afetam desde o sistema radicular até as folhas. Nazerian et al. (2013) relataram que mais de 15% de danos em campo, incluindo estufas, e também no armazenamento de alface, foram causados por bactérias do gênero *Pectobacterium* spp.

A enterobactéria *Pectobacterium carotovorum* subsp. *carotovorum*, causadora da doença conhecida por Podridão mole, é considerada uma das dez fitobactérias de maior importância científica e econômica (MANSFIELD et al., 2012), não existindo, entretanto, produtos químicos registrados para seu controle no Brasil, tampouco variedades resistentes (AGROFIT, 2020).

Inicialmente os sintomas da doença são caracterizados por murcha e despigmentação das folhas mais velhas. Progressivamente a medula do caule torna-se encharcada, macerada e esverdeada, podendo ocasionar apodrecimento total da planta (COLARICCIO; CHAVES, 2017), o que reflete em perdas e, conseqüentemente, prejuízos ao produtor. A visualização dos sintomas iniciais da doença é difícil e, quando detectado, o seu controle torna-se quase impossível. Dessa forma, qualquer estratégia que vise detectar tais anomalias no estágio inicial de desenvolvimento é de fundamental importância, já que a doença é agressiva e a alface apresenta ciclo curto.

O Sensoriamento Remoto (SR) possui várias aplicações na agricultura (WEISS; JACOB; DUVEILLERC, 2020). Na revisão de Usha e Singh (2013), foram relatadas potenciais aplicações do SR, dentre estas, detecção de doenças em olerícolas como tomate, beterraba, pepino e batata; medição de volume de copa em tomate; estimativa de área e obtenção de informações de produção em batata e repolho.

O desenvolvimento e as aplicações do SR na agricultura deve-se ao conhecimento da reflectância das folhas ou do dossel, o que possibilita o cálculo de índices de vegetação e, desta forma, permitem avaliar parâmetros agronômicos, tais como, estado nutricional, biomassa, área foliar, estresse hídrico (HATFIELD et al., 2008), além de ajudar na detecção e monitoramento de doenças de plantas (GOGOI; DEKA; BORA, 2018).

Vários trabalhos apresentam o uso de diferentes sensores para estudos de doenças de

plantas, como sensores de reflectância multiespectral e hiperespectral, do visível (RGB), termografia e fluorescência, que podem ser instalados em diferentes plataformas, como em Veículos Aéreos Não Tripulados (VANTs) (MAHLEIN, 2016; MAES; STEPPE, 2019; OERKE, 2020).

Aliado ao SR, tem-se o aprendizado de máquina, o qual tem sido amplamente utilizado na agricultura, por meio de modelos de aprendizagem como classificação, regressão, agrupamento, modelos bayesianos, modelos baseados em instâncias, árvores de decisão, redes neurais artificiais e máquinas de vetores de suporte (LIAKOS et al., 2018). Dessa forma, o processamento de dados utilizando aprendizado de máquina pode auxiliar em trabalhos para detecção de infecção bacteriana em plantas de melão por *Dickeya dadantii* (PINEDA; PÉREZ-BUENO; BARÓN, 2018), cercosporiose (*Cercospora beticola* Sacc.) em beterraba sacarina (OZGUVEN; ADEM, 2019), separação de folhas saudáveis de folhas doentes por Murcha-de-fusarium (*Fusarium solani* sp.) em pimenteiras (KARADAG et al., 2018), detecção da requeima da batata (*Phytophthora infestans*) a nível de folha e dossel (FERNÁNDEZ et al., 2020), investigação de diferenças fisiológicas da requeima entre cultivares de batata (GOLD et al., 2019) e a detecção precoce e classificação do vírus da clorose em tomateiro (*Tomato chlorosis virus* - ToCV) (MORELLOS et al., 2020).

Para a cultura da alface algoritmos têm sido utilizados para detectar deficiência de ferro, zinco e nitrogênio (HETZRONI et al., 1994), avaliar teor de clorofila (ODABAS et al., 2016), estimar teor de nitrogênio (JUN et al., 2013; MAO et al., 2015; GAO et al., 2015), determinar o estado nutricional de plantas submetidas à diferentes condições de irrigação e adubação (REN; TRIPATHI; LI, 2017), efeito do estresse hídrico (KIZIL et al., 2012), determinação de resíduos de pesticidas (SUN et al., 2018), predição do teor de chumbo (ZHOU et al., 2019), inspeção da concentração de potássio (XIONG et al., 2020), detecção espectral de cádmio (XIN et al., 2020) e detecção e avaliação da contaminação microbiana a fim de garantir o consumo de alface fresca (RAHI et al., 2020).

Entretanto, nenhum trabalho mostra o uso do SR e/ou aprendizado de máquina para detecção de doenças de caule e sistema radicular que afetam a cultura da alface, sendo de extrema necessidade a obtenção e utilização de ferramentas que consigam detectar o aparecimento dessas doenças no estágio inicial, pois possibilita o seu controle e, conseqüentemente, minimiza perdas econômicas.

Portanto, os objetivos deste trabalho foram identificar a melhor época e o melhor sensor para detecção de podridão mole causada por *Pectobacterium carotovorum* subsp.

carotovorum em alface, usando imagens obtidas por sensores multiespectrais em veículo aéreo não tripulado (VANT).

2 REFERENCIAL TEÓRICO

2.0 A cultura da alface (*Lactuca Sativa* L.)

A alface cultivada (*Lactuca sativa* L.) é descendente da alface selvagem (*Lactuca serriola* L.), originária da bacia do Mediterrâneo, com evidência de cultivo inicial no Egito, cerca de 4500 a.c. (LINDQVIST, 1960).

A hortaliça é a salada folhosa mais popular do mundo (RAID, 2004), inclusive considerada a mais popular folhosa na mesa dos brasileiros (LOPES; QUEZADO-DUVAL; REIS, 2010).

No último Censo Agropecuário, realizado pelo IBGE em 2017, a alface ocupou a primeira posição entre as hortaliças folhosas, apresentando o maior número de estabelecimentos produtores (108.382 mil), maior produção (671.509 toneladas), e ocupou a quinta posição entre os principais produtos da horticultura (ANUÁRIO BRASILEIRO DE HORTI&FRUTI 2020, 2019). Em termos de área e produção, o cultivo convencional a campo (tradicional) é o mais importante (HENZ; SUINAGA, 2009).

A cultura apresenta-se, também, socialmente e economicamente importante, uma vez que é cultivada tradicionalmente por pequenos produtores (VILLAS BÔAS et al., 2004), contribuindo na geração de renda.

Para a saúde e nutrição humana, é fonte de vitaminas e minerais. Os minerais presentes na alface incluem cálcio, magnésio, fósforo, ferro, sódio, potássio, zinco e várias vitaminas, como tiamina, riboflavina, folato, niacina, vitaminas B6, C, E, A e K (DAS; BHATTACHARJEE, 2020).

A planta tem porte herbáceo e possui caule pequeno, onde as folhas crescem em forma de roseta, crespas ou lisas, formando ou não uma “cabeça”, e coloração em diferentes tonalidades de verde e roxo, variando de acordo com a cultivar (FILGUEIRA, 2003). Existem diversas cultivares, que são agrupadas/classificadas em cinco tipos: americana, crespa, lisa, mimosa e romana (HENZ; SUINAGA, 2009), sendo a crespa o principal segmento cultivado no Brasil (SALA; COSTA, 2012).

Assim como qualquer outra cultura, a alface é suscetível a várias doenças - mais de 75

doenças no mundo já foram relatadas - as quais podem ocorrer na parte aérea, raiz e caule, causadas por microrganismos como fungos, nematoides, vírus e bactérias (LOPES; QUEZADO-DUVAL; REIS, 2010).

2.1 *Pectobacterium carotovorum* subsp. *carotovorum*

A podridão mole em alface é causada pela bactéria *Pectobacterium carotovorum* subsp. *carotovorum*, pertencente ao Filo Proteobacteria, Classe Gamaproteobacteria, Ordem Enterobacteriales e à Família Enterobacteriaceae (CARVALHO FILHO; MELO, 2008).

Em pesquisa realizada por Mansfield et al. (2012) entre fitopatologistas, a *P. carotovorum* foi considerada uma das dez fitobactérias de grande importância científica e econômica. O patógeno é amplamente distribuído no Brasil e no mundo (BERIAM, 2007; NAZERIAN et al., 2013; CARIDDI; SANZANI, 2013; GAŠIĆ et al., 2014; MORETTI et al., 2015; NAAS et al., 2018). No Brasil, levantamentos da ocorrência de patógenos na cultura da alface são escassos e insuficientes, porém Silva et al. (2007) em estudos com levantamento da intensidade da doença em alface e couve-chinesa em Pernambuco, encontraram prevalência de *P. carotovorum* subsp. *carotovorum* em 42,9% das áreas avaliadas.

Segundo Carvalho Filho e Melo (2008), a *Pectobacterium carotovorum* subsp. *carotovorum* e demais subespécies, produzem grandes quantidades de enzimas pectolíticas ou pectinases, que causam a degradação dos tecidos parênquimatosos em várias plantas hospedeiras, sobretudo em dicotiledôneas de ciclo curto e anual. Na alface, os sintomas da podridão mole, inicialmente, apresentam-se com a murcha das folhas externas da planta, a qual é mais suscetível próximo à colheita (na maturidade ou perto), devido a períodos de umidade mais extensos. A murcha é resultado da degradação dos tecidos vasculares, promovendo a descoloração dos mesmos. Assim, progressivamente, a medula do caule encharca-se de água, torna-se macerada e esverdeada, o que pode ocasionar o apodrecimento total da planta (RAID, 2004).

Para a ocorrência de *Pectobacterium* spp. vários fatores são predisponentes, como: elevada umidade do solo, temperatura do solo entre 25° e 35°C, solo mal drenado e pouco arejado, elevada precipitação pluviométrica, excesso de nitrogênio no solo, estresse nutricional da planta, estresse da planta por salinidade, ataque de patógenos, material de propagação infectado pelo patógeno, plantio adensado, ferimentos no colo ou raízes da planta, monocultura, irrigação leve e constante, água contaminada pelo patógeno, solo infestado com

nematoides, utensílios infestados, manutenção de plantas infectadas e restos culturais no campo (MICHEREFF; PERUCH; ANDRADE, 2005).

Não há produtos químicos registrados para o controle de *Pectobacterium carotovorum* subsp. *carotovorum* e variedades resistentes para a cultura da alface (AGROFIT, 2020). Logo, para seu controle algumas práticas/medidas podem ser tomadas, tais como: escolher área de plantio livre do patógeno, usar materiais propagativos inspecionados e certificados (livres do patógeno), solarização do solo, evitar plantio adensado e sombreado, desinfestar ferramentas e implementos, fazer rotação de culturas, usar água de qualidade, evitar ferimentos no colo e raízes das plantas, eliminar plantas doentes, remover e destruir restos culturais, alterar o tipo e/ou da frequência de irrigação e também proporcionar drenagem adequada do solo (MICHEREFF; PERUCH; ANDRADE, 2005).

Além disso, alguns pesquisadores tem desenvolvido estudos a fim de controlar os sintomas do ataque do patógeno em distintas culturas suscetíveis. Ren, Petcoldt e Dickson (2001), avaliaram a resistência genética e melhoramento populacional de couve-chinesa à podridão mole. Dong et al. (2004) estudaram a ação de *Bacillus* no controle da podridão mole da batata. Benelli et al. (2004) e Félix et al. (2014) fizeram avaliação quanto à resistência de cultivares de batata e de genótipos de alface, respectivamente. O efeito de óleos essenciais e de extratos vegetais no controle da podridão mole em alface foram testados por Silva et al. (2012). Em pimentão, Silva et al. (2014) fizeram o uso de antagonistas (*Bacillus* spp e *Leveduras*) e produtos alternativos (Fosfito de potássio e cálcio, Fontes de cálcio, fungicida/bactericida orgânico Antica® e o antibiótico Kasumin®) no manejo pós-colheita de podridão mole.

2.2 Sensoriamento Remoto (SR)/Fotogrametria

A American Society for Photogrammetry e Remote Sensing (ASPRS), em 1988, adotou uma definição combinada em que Fotogrametria e Sensoriamento Remoto são a arte, ciência e tecnologia que, sem contato, sistemas de sensores obtém informações de objetos físicos e meio ambiente, por meio do registro, medição e interpretação de imagens e representações digitais de padrões de energia (JENSEN, 2016).

Um tema amplo no SR é o monitoramento da agricultura, o qual é abordado em aplicações específicas (ex.: agricultura de precisão, previsão de produção), por meio de vários sensores (ex.: visível, multiespectral, térmico, microondas, hiperespectral), plataformas para

locais específicos (ex.: nível orbital, aéreo ou terrestre) e diferentes contextos climáticos (WEISS; JACOB; DUVEILLERC, 2020).

Para o estudo da vegetação, é necessário compreender sua interação com a radiação eletromagnética (REM). Esta é dita como uma onda eletromagnética que viaja pelo espaço na velocidade da luz. O comprimento de onda (λ) da REM é definido como a distância média entre máximos (ou mínimos) de um padrão aproximadamente periódico e é medido em micrômetros (μm) ou nanômetros (nm) (JENSEN, 2016).

As ondas eletromagnéticas que compõem o campo de radiação de um determinado alvo é chamado de espectro. Logo, o espectro eletromagnético é dividido em regiões distintas, as quais representam todo o conjunto de comprimentos de onda conhecidos, desde os raios gama até ondas de rádio (Figura 1) (NOVO, 2010).

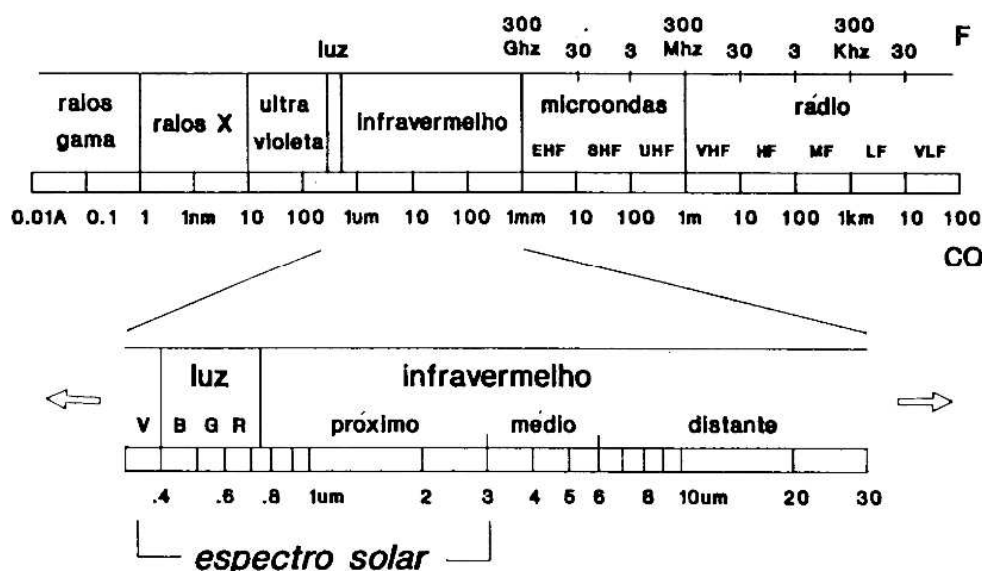


FIGURA 1: Representação do espectro eletromagnético. Fonte: Novo e Ponzoni (2001).

Na faixa do visível – VIS (RGB), compreendido entre 0,4 a 0,72 μm , os principais pigmentos absorvedores de luz são: clorofila a e b, carotenóides, xantofilas e polifenóis. A energia radiante interage com a estrutura foliar por absorção e por espalhamento. Os pigmentos predominantes absorvem radiação na região do azul, mas somente a clorofila absorve na região do vermelho, ou seja, bandas de forte absorção, enquanto na região do verde há reflectância máxima. Já na faixa do infravermelho próximo (Near infrared: N), que compreende a região de 0,72 a 1,1 μm , há pequena absorção da REM e a reflectância e a transmitância atingem seus valores máximos devido considerável espalhamento interno nas interfaces ar-célula-água dentro das folhas. Além disso, a absorção da água é geralmente

baixa nessa região (PONZONI; SHIMABUKURO; KUPLICH, 2012; SAHOO; RAY; MANJUNATH, 2015).

Portanto, a interação da REM é descrita por três processos, os quais dependem das características biofísicas e bioquímicas do vegetal. As propriedades ópticas das folhas são caracterizadas pela transmissão de luz, absorção de luz por produtos químicos (como, pigmentos, água, açúcares, lignina e aminoácidos), e pela luz refletida de estruturas foliares internas ou refletidas diretamente (MAHLEIN, 2016).

A extração de informações por sensores remotos, revela-se potencialmente útil na agricultura. Com foco na agricultura de precisão Sishodia, Ray e Singh (2020), relataram estudos na gestão da água de irrigação, estudos de estresse hídrico, evapotranspiração, umidade do solo, gestão de nutrientes, gestão de doenças, manejo de ervas daninhas e no monitoramento de safra e rendimento.

Khanal et al. (2020) revisaram a literatura entre 2000 e 2019, e destacaram a aplicação de tecnologias de SR na produção de algumas culturas, desde o planejamento até a pós colheita, a fim de dar apoio à tomada de decisão nas diferentes etapas produtivas. Segundo tais autores, houve aumento acentuado nas aplicações de sistemas aéreos não tripulados após 2015.

Com relação a VANTs, Barbedo (2019a) apresentou avanços com diferentes sensores, com a finalidade de monitorar água nas lavouras (seca), nutrientes, doenças e pragas, ervas daninhas e danos causados por temperatura extrema. Além destas aplicações, estudos comprovam o potencial desses sensores na avaliação do crescimento e biomassa de plantas, previsão de rendimento (MAES; STEPPE, 2019) e fenotipagem de plantas (YANG et al., 2017; MACIEL et al., 2019).

Pacumbaba e Beyl (2011), observaram mudanças nas assinaturas de reflectância hiperespectral de folhas de alface em resposta a deficiências de macronutrientes. Pishchik et al. (2016), por meio de medições de reflectância mostraram o efeito sinérgico de fertilizante húmico e de *Bacillus Subtilis* na qualidade e vitalidade das plantas. Já Breure et al. (2020) relacionaram, em campos de cultivo de alface, espectros de reflectância infravermelho do solo com diâmetro de plantas.

2.2.1 Índices de vegetação

Índices de vegetação, os quais são adimensionais, são fórmulas matemáticas baseadas em várias combinações de bandas do espectro eletromagnético (CARNEIRO et al., 2020). São propostos com a finalidade de explorar as propriedades espectrais da vegetação, em especial nas regiões do visível e do infravermelho próximo (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Os índices de vegetação tem inúmeros usos na agricultura de precisão (SISHODIA; RAY; SINGH, 2020), podendo fornecer informações sobre a estrutura e condições da planta, usando diferentes plataformas (XUE; SU, 2017).

Existem inúmeros índices compostos por comprimentos de onda do azul, verde, vermelho, e infravermelho próximo. Entretanto, só serão apresentados aqueles utilizados no estudo em questão.

Segundo Oerke (2020), as doenças ocasionam mudanças no estado fisiológico das plantas, o que pode ser detectado utilizando índices de vegetação. Para facilitar essa detecção, índices específicos têm sido desenvolvidos, porém demora um longo tempo para serem produzidos para todas as doenças e estágios de interesse, uma vez que a especificidade deve ser avaliada em relação a outras doenças que ocorrem em diferentes espécies de cultivo.

O índice da diferença normalizada, do inglês Normalized Difference Vegetation Index (NDVI), foi desenvolvido por Rouse et al. (1973) em pastagens, a fim de mostrar a correlação com biomassa verde acima do solo. Já Zarate-Valdez et al. (2012) mostraram alta correlação do índice de área foliar com o NDVI. Wiegand et al. (1991) afirmam que o índice é capaz de medir a dimensão fotossintética das copas das plantas e também prever rendimentos, o que também foi confirmado por Zhou et al. (2017), que baseados em imagens multiespectrais mostraram relação linear com o rendimento de grãos de arroz.

Dada a capacidade de análise do NDVI em plantas, Di Gennaro et al. (2016) mostraram alta correlação entre o índice NDVI adquirido por VANT e os sintomas foliares de doença da videira e também a discriminação entre plantas sintomáticas e assintomáticas. Zhang D. et al. (2018) também consideraram como o índice de melhor desempenho para detectar diferentes níveis de severidade da mancha da bainha do arroz, demonstrando que o NDVI baseado em imagens é um meio eficaz para detectar uma doença e quantificá-la em escala de campo.

O índice de folha verde, do inglês Green Leaf Index (GLI), foi desenvolvido por Louhaichi, Borman e Johnson (2001), com a proposta de mapear a extensão e a intensidade de impactos e degradação em campos de trigo e, estimar a cobertura vegetal. Ballesteros et al.

(2018), com o objetivo de avaliarem a precisão do uso combinado de informações agroclimáticas e produtos de câmeras RGB montadas em VANT, apontaram o GLI como um dos melhores índices para predições de biomassa em milho. A relação deste índice com parâmetros biofísicos da planta, permitiram que Bhandari et al. (2020) obtivesse em seus resultados relação linear com o coeficiente de infecção da ferrugem da folha do trigo.

O índice da diferença normalizada do verde e vermelho, do inglês Normalized Green Red Difference Index (NGRDI), foi proposto por Tucker (1979) e, dentre os trabalhos em que foi utilizado, exibiu altas correlações com biomassa e com o índice de área foliar (HUNT JUNIOR et al., 2005; ELAZAB et al., 2016) e também com rendimento de grãos de milho (ELAZAB et al., 2016). Na detecção de doenças, o índice NGRDI apresentou diferenças significativas entre plantas controle de oliveira e àquelas inoculadas com *Verticillium Wilt* em relação ao crescimento das plantas (SANCHO-ADAMSON et al., 2019).

Gitelson et al. (2002) desenvolveram o índice de vegetação da reflectância de carotenoide 1, do inglês Carotenoid Reflectance Index 1 (CRI1), para estimativa não destrutiva do conteúdo de carotenóide em folhas. Após idealização e validação, foi possível concluir que a reflectância estava intimamente relacionada ao conteúdo total de pigmento nas folhas. Em Sapate e Deshmukh (2019), o índice CRI1 foi capaz de demonstrar anormalidade no funcionamento dos pigmentos em folhas doentes de tomateiro quando comparado à folhas saudáveis.

Gamon, Peñuelas e Field (1992) apresentaram o índice da reflectância fotoquímica, do inglês Photochemical Reflectance Index (PRI), a partir de medidas espectrais de copas de girassol, o qual apresentou correlações com o estado de epoxidação dos pigmentos do ciclo da xantofila, com a eficiência fotossintética e também estresse por nitrogênio.

No estudo de doenças de plantas, Huang et al. (2007) investigando a relação entre a ferrugem amarela do trigo e o índice PRI, obtiveram coeficientes de determinação superiores a 0,9, após aplicação da equação de regressão PRI aos dados espectrais, mostrando potencial em quantificar a doença. Abdulridha et al. (2020) observaram que, em condições de laboratório, o índice PRI foi capaz de detectar e classificar com precisão médio em estágios de desenvolvimento assintomático, inicial e final em plantas de abóbora.

Hunt Junior et al. (2011) propuseram o índice de verdor triangular, do inglês Triangular Greenness Index (TGI), o qual é baseado na área de um triângulo, em que seus vértices são determinados pela reflectância do vermelho, verde e do azul. Os resultados obtidos pelos autores mostraram correlação do índice com o conteúdo de clorofila, o que

possibilitou que Sancho-Adamson et al. (2019) obtivessem diferenças significativas do efeito da inoculação de *Verticillium Wilt* em plantas de oliveira.

McKinnon e Hoff (2017) analisando o sensor de uma câmera CMOS e considerando seus comprimentos de onda, descreveram a equação para o TGI. A partir da mesma, Starý et al. (2020) obtiveram alta precisão na estimativa de área de dossel verde em jardim de plantas de lúpulo.

O índice da razão simples, do inglês Simple Ratio (SR), foi o primeiro índice de vegetação utilizado (JORDAN, 1969) para medir o índice de área foliar de uma floresta. Zhu et al. (2008) concluíram que o SR, também chamado de RVI (Ratio Vegetation Index), pode monitorar o acúmulo de nitrogênio no trigo e no arroz. Com esse índice, Sun, Zhang e Jiang (2011) também puderam estimar o índice de área foliar, teor de clorofila foliar e biomassa seca. Junto a todas essas aplicações, Fletcher, Escobar e Skaria (2004), observaram dentre outros índices, ser o SR o mais responsivo na identificação de árvores cítricas infectadas com podridão (*Phytophthora parasitica* Dast).

Gitelson, Kaufman e Merzlyak (1996) desenvolveram o índice de vegetação por diferença normalizada do verde, do inglês Green Normalized Difference Vegetation Index (GNDVI), o qual mostrou ser muito preciso para avaliar o conteúdo de clorofila. Moges et al. (2004) mostraram que o uso do GNDVI deve ser um preditor confiável da biomassa e absorção de nitrogênio da forragem e também do rendimento e absorção de nitrogênio de grãos de trigo de inverno. Já Hunt Junior et al. (2010) encontraram boa correlação entre o índice de área foliar e o índice GNDVI.

Com relação a doenças de plantas, dentre outros índices, o GNDVI tanto em condições de laboratório quanto campo, possibilitou detectar míldio em diferentes estágios, em plantas de abóbora (ABDULRIDHA et al., 2020).

Desenvolvido por Tucker (1979), o índice índice de vegetação de diferença, do inglês Difference Vegetation Index (DVI), mostrou sensibilidade à biomassa fotossinteticamente ativa presente no dossel da planta. O DVI foi apontado por Díaz e Blackburn (2003) como um índice de vegetação espectral ideal para estimar propriedades biofísicas, pois apresentou relações lineares com o índice de área foliar. Já Zhu et al. (2008) dentre outros índices, apontou o DVI como eficaz na detecção de acúmulo de nitrogênio na cultura do trigo e do arroz.

Em relação a estresse biótico, o índice DVI mostrou correlação positiva com a severidade da ferrugem em soja (CUI et al., 2009), e com o nível de infecção de oídio, em três estágios de crescimento de trigo (CAO et al., 2013).

O índice da reflectância de absorção de clorofila modificado 1, do inglês Modified Chlorophyll Absorption in Reflectance Index (MCARI1), foi proposto por Haboudane et al. (2004) a fim de que houvesse menor sensibilidade aos efeitos da clorofila e maior sensibilidade às mudanças de índice de área foliar. Além disso, tal índice também já foi utilizado em trabalhos envolvendo doenças de plantas, como em Bagheri et al. (2018), em que o MCARI1 foi considerado como capaz de discriminar folhas de árvores de pereira infectadas por *Erwinia amylovora*, de folhas não sintomáticas, através de espectrometria de infravermelho próximo visível; além de ser adequado para detecção da doença na fase inicial.

O MCARI1 em Marin et al. (2018), apresentou os maiores valores de coeficiente de correlação com a incidência de crestamento bacteriano em áreas cafeeiras. Loladze et al. (2019) mostrou a forte relação com valores da área sob a curva de progresso de doença (Tar Spot Complex) na cultura do milho com o índice MCARI1.

2.3 Estudo de doenças de plantas utilizando técnicas de Sensoriamento Remoto

As doenças parasitárias, têm como fatores causais micro ou macroorganismos parasitas, como fungos, bactérias, vírus, micoplasma, algas e animais parasitas, que causam doenças em plantas hospedeiras (SAWICKA et al., 2020). Doenças que modificam processos fisiológicos nas plantas e as variações fenotípicas podem afetar a interação da folha ou do dossel com a luz (ZHANG, Y. et al., 2018).

O SR demonstra capacidade de monitorar as condições de estresse na vegetação e, por consequência, os efeitos de doenças de plantas. O SR possui vantagens como a grande quantidade de dados da resposta espectral, por diferentes escalas espaciais, com resolução de sensor desde o nível de folha até uma grande região (MARTINELLI et al., 2014).

De acordo com Oerke (2018), sensores para doenças de plantas podem ser classificados de acordo com a faixa do espectro eletromagnético (visível, infravermelho próximo, infravermelho de ondas curtas, infravermelho térmico e radar); com a escala/plataforma utilizada (aertransportado e espacial, VANTs, terrestre/proximal e microscópico); com o princípio de registro (sensores passivos e ativos) e quanto ao tipo de registro de dados (por imagem ou não imagem). Vários trabalhos apresentam o uso desses

sensores na detecção de doenças (SANKARAN et al., 2010; MAHLEIN et al., 2012; MAHLEIN, 2016; GOGOI; DEKA; BORA, 2018; ALI et al. 2019; FARBER et al. 2019; SINGH; SHARMA; SINGH, 2020), com contribuição de técnicas de processamento e análise de dados, como algoritmos na aprendizagem de máquina (Machine learning) (HAHN, 2009; MARTINELLI et al., 2014; ZHANG et al., 2019; OERKE, 2020).

A planta, sob condições de estresse induzido pela doença, reage com mecanismos de proteção, que levam ao crescimento abaixo do ideal, refletindo em mudanças em variáveis como: conteúdo de clorofila ou temperatura superficial e índice de área foliar (IAF); o que resulta em uma resposta espectral distinta da vegetação saudável (MARTINELLI et al., 2014). Portanto, mudanças na reflectância é resultado de modificações de características biofísicas e bioquímicas do tecido vegetal. Sob estresse, a produção de clorofila pode diminuir, resultando em menor absorção nas faixas azuis e vermelhas nas células paliçádicas. Dessa forma, juntamente com a faixa verde, são refletidas as faixas vermelhas e azuis (RGB). Já as bandas do infravermelho próximo em plantas estressadas ou doentes, não são refletidas pelas células do mesófilo, mas são absorvidas pelas células estressadas ou mortas (GOGOI; DEKA; BORA, 2018).

Hillnhütter et al. (2010) afirmam que diminuições no conteúdo de água, clorofila, carotenoides e níveis de antocianina nas folhas podem ser causadas devido a perturbação ou a destruição do funcionamento normal da raiz por nematoides ou patógenos do solo, levando a alterações na reflectância do espectro eletromagnético ou mudanças na temperatura da folha. Os autores ainda complementam que o uso de reflectância no espectro infravermelho próximo, pode ser usado para detectar os sintomas da doença antes mesmo de serem visíveis.

Segundo Oerke (2020), as doenças radiculares podem ser avaliadas indiretamente por sensores, à medida que o metabolismo da planta for afetado pelas atividades do patógeno. Zhang et al. (2019) afirmam que algumas doenças transmitidas pelo solo e doenças radiculares, que causam efeitos sistêmicos na fisiologia das plantas também podem ser detectadas por um sensor ou sistemas de sensores específicos, a partir de uma determinada resposta do vegetal.

Chiwaki, Nagamori e Inoue (2005) usando imagem termal, foram capazes de determinar a infecção bacteriana por *Ralstonia solanacearum* em plantas de tomateiro, quatro dias antes da identificação visual dos sintomas, uma vez que a redução da transpiração e consequente aumento da temperatura foliar é devido a invasão dos feixes vasculares pela multiplicação da bactéria. Pineda et al. (2017), utilizando medições de fluorescência térmica e

multicolor, também observaram aumento na temperatura foliar de abobrinha, inoculadas com o patógeno *Dickeya dadantii*, em relação às folhas controle.

Sandmann, Grosch e Graefe (2018), a partir de recursos de fluorescência, termografia e imagem NDVI, em condições ambientais controladas, estudaram a detecção não destrutiva de *Rhizoctonia solani* em plantas jovens de alface e puderam discriminar algumas mudas como doentes, antes dos sintomas da infecção tornarem-se visíveis.

Bauriegel et al. (2014), a partir de imagens de fluorescência de clorofila obtidas de uma FluorCAM 700MF, e por meio de operações/análises de pixel no software FluorCam, obtiveram imagens de Fv/Fm (rendimento quântico máximo), sendo tal proposta considerada adequada para o reconhecimento de discos de folhas infectados com míldio de cultivares de alface, contribuindo para a aceleração do programa de melhoramento de cultivares de alface resistentes a *Bremia lactucae*.

Matsuo et al. (2006) desenvolveram uma configuração experimental (composta por câmera hiperespectral, controle deslizante linear, lâmpadas halógenas, um computador e um processador de conversão de sinal) para capturar imagens de alface americana, inoculadas com patógeno bacteriano causador de podridão mole (não identificado pelos autores), e observaram que a intensidade de reflexão do infravermelho próximo da parte morta foi inferior à da parte saudável da planta.

Hillnhütter et al. (2011) calcularam índices de vegetação após obterem imagens aéreas hiperespectrais e classificação supervisionada, e conseguiram detectar o estresse ocasionado por *Heterodera schachtii* e *Rhizoctonia solani* em campos de beterraba sacarina, o que permitiu que pudessem elaborar mapas da distribuição espacial dos patógenos em campo.

Reynolds et al. (2012) classificaram os sintomas da podridão da coroa e da raiz (*Rhizoctonia solani*) em beterraba sacarina e puderam correlacionar com a reflectância do verde, vermelho, infravermelho próximo e índices de vegetação, resultando em fortes regressões não lineares. Os valores de índices de vegetação mantiveram-se constantes até que 26 a 50% da superfície da raiz apodreceu e, em seguida, diminuíram significativamente, quando as classificações da doença aumentaram e as plantas começaram a morrer.

Experimentos em casa de vegetação foram conduzidos por Chávez et al. (2012), para testar a capacidade de um método de diagnóstico suportado por análises multiespectral Visível-Infravermelho próximo (Vis-NIR) e multifractal do sinal de reflectância, e puderam detectar plantas de batata sintomáticas e com infecção latente com murcha bacteriana

(*Ralstonia solanacearum*), sendo as regiões do azul e vermelho mais adequadas para detectar a infecção.

Candiago et al. (2015) avaliando vinhedos atacados por *Armillaria mellea* e tomateiros com a presença de mancha bacteriana por meio de imagens multiespectrais (RGN) obtidas por VANT e índices de vegetação derivados, puderam apontar as partes saudáveis e não saudáveis dos campos cultivados.

Sugiura et al. (2016) apresentaram um procedimento de otimização de threshold (transformação da cor da imagem RGB e classificação em pixels) para avaliar a gravidade da requeima da batata (*Phytophthora infestans*) usando imagens de VANT e obtiveram resultados relativamente precisos entre o cálculo da área abaixo da curva de progresso da doença (AACPD) a partir da avaliação visual e das imagens.

Mattupalli et al. (2018) demonstraram a utilidade da classificação supervisionada para monitorar a propagação de podridão radicular por *Phymatotrichopsis omnivora* na alfafa.

Franceschini et al. (2019) indicaram que a detecção da requeima da batata e da severidade da doença, a partir de imagens no visível e infravermelho próximo obtidas por VANT, deve-se principalmente à mudanças que o patógeno causa nas características estruturais da planta e, em menor grau, ao conteúdo de pigmento.

Su et al. (2018) obtiveram bom desempenho de algoritmos na separação de plantas nas classes: saudável, moderada e grave da ferrugem amarela do trigo; bem como, para a separação de plantas infectadas e saudáveis através de índices de vegetação, demonstrando que as bandas espectrais mais eficazes na detecção da doença foram a do infravermelho próximo e a vermelha.

Gu et al. (2019) usando a técnica de imagem hiperespectral e algoritmos de aprendizado de máquina para detecção de sintomas do vírus *Tomato spotted wilt virus* (TSWV) em tabaco, mostraram que a região espectral do infravermelho próximo foi importante para a diferenciação de folhas infectadas e folhas saudáveis. Da mesma forma que Vijver et al. (2019), também evidenciaram que foi a mais discriminativa para detecção das lesões de *Alternaria solani* em culturas de batata, por plataforma de detecção proximal.

2.4 Aprendizado de Máquina

O Aprendizado de Máquina (AM) é o campo científico que atribui às máquinas a capacidade de aprender sem ser estritamente programado (SAMUEL, 2000). É uma ferramenta importante e frequentemente aplicada para a interpretação e análise de dados de

Sensoriamento Remoto (SR), com metodologias diversas (SCHEUNDERS; TUIA; MOSER, 2018).

As tarefas de AM são normalmente classificadas em diferentes categorias, como o tipo de aprendizagem (ex.: supervisionado/não supervisionado) e a técnica de aprendizagem (ex.: classificação, regressão, agrupamento, redução de dimensionalidade, etc). Para isso, a partir de modelos de AM (ex.: redes neurais artificiais, modelos bayesianos, aprendizado profundo, árvores de decisão, máquina de vetores de suporte, etc), seus algoritmos associados (ex.: MLP - MultiLayer Perceptron, NB - Naive Bayes, KNN - k-Nearest Neighbor, RF - Random Forest, etc.) realizam a tarefa (LIAKOS et al., 2018).

Com relação às contribuições do AM para a análise de dados de SR, Scheunders, Tuia e Moser (2018) compreendem o aprendizado supervisionado como a tarefa mais difundida, no qual um algoritmo aprende um modelo que mapeia entradas em saídas desejadas. Assim, dados e seus rótulos, ou seja, a saída desejada, são fornecidos. Quando as saídas são variáveis discretas, os rótulos indicam classes predefinidas e os métodos são chamados de métodos de classificação.

Liakos et al (2018) a partir dos artigos consultados, demonstraram a utilidade do AM em sistemas de produção agrícola, como no manejo de culturas (previsão de produção, detecção de doenças, detecção de ervas daninhas, qualidade da cultura e reconhecimento de espécies), gestão de gado (bem-estar animal e produção de gado), gestão da água e também no manejo do solo.

Singh et al. (2016) relatam o uso de diferentes abordagens do AM para fenotipagem de estresse biótico e abiótico e melhoramento de plantas, que podem ser implantadas na identificação, classificação, quantificação e também na previsão, a partir de diferentes plataformas e sensores remotos para obtenção de imagens, dados. Osco et al. (2019) demonstraram que é possível detectar estágios iniciais de estresse hídrico em plantas de alface com alta precisão com base em uma abordagem de AM aplicada a dados hiperespectrais.

Pal, Jaiswal e Chauhan (2016), demonstraram a aplicação do AM na pesquisa de interação planta-patógeno, para prever proteínas de resistência de plantas com base em características extraídas de sequências de aminoácidos de proteínas, atingindo boa precisão. Trabalho este que contribuiu para que Yang e Guo (2017) apresentassem a aplicabilidade do AM na descoberta de genes de resistência de plantas e classificação de doenças de plantas.

Ip et al. (2018) também fornecem uma visão geral das tecnologias e aplicações potenciais em proteção de lavouras (gerenciamento de doenças de plantas, ervas daninhas e outras pragas), usando Big data e abordagens de AM.

Bienkowski et al. (2019) demonstraram que por meio do treinamento supervisionado de medições de reflectância espectral de folhagens de batata, pode-se detectar e distinguir doenças com excelente acurácia, como a requeima (*Phytophthora infestans*) e com boa acurácia, como a canela preta (*Pectobacterium atrosepticum*).

Comparando métodos de aprendizado de máquina, Lan et al. (2020) avaliaram a viabilidade da detecção de grandes áreas com Huanglongbing (HLB) ou greening, a partir de imagens multiespectrais RGN obtidas por VANT. Os autores, com base na extração dos valores de intensidade das bandas por regiões de interesse (Region Of Interest - ROI) do centro do dossel de plantas doentes e saudáveis, a combinação dos valores de números digitais e índices de vegetação derivados, obtiveram melhora da acurácia e a convergência da maioria dos algoritmos na classificação.

O uso de imagens proximais e AM também é muito utilizado para a detecção de deficiências nutricionais em plantas (BARBEDO et al., 2019b). Eshkabilov et al. (2021) utilizaram técnicas de imagem hiperespectral para detecção rápida do teor de nutrientes de cultivares de alface cultivadas hidroponicamente e desenvolveram um algoritmo para medir os níveis de nutrientes dos tecidos foliares.

Além disso, o AM tem se mostrado promissor na detecção de defeitos em produtos hortícolas como: danos mecânicos, defeitos internos, distúrbios fisiológicos, patológicos e morfológicos (NTURAMBIRWE; OPARA, 2020) bem como, na detecção qualitativa de espécies olerícolas, como teor de sólidos solúveis em frutos de melancia (CHAWGIEN; KIATTISIN, 2021).

Gaitán (2020) relata o uso do AM para impactos agrícolas, uma vez que, atividades agrícolas podem ser prejudicadas por fatores climáticos, tais como: secas, inundações, ondas de calor, geadas, granizo, bem como surtos de pragas. Barbedo et al. (2020) relatam o uso de imagem proximal e AM para a detecção e classificação de pragas em plantações.

Bischoff et al. (2021) apresentaram uma revisão de 2008 a 2019 sobre a detecção e previsão de doenças de plantas, a fim de fornecer uma percepção e conhecimento sobre o assunto. Dentre os artigos estudados, 41% aplicaram técnicas de aprendizado de máquina para detectar doenças, 32% utilizaram sensores de imagem para identificar sintomas relacionados a doenças de plantas, 30% propõem novos modelos de aprendizado de máquina para detectar

doenças, 34% eram estudos de avaliação e, 71% desses estudos foram publicados em revistas científicas demonstrando a importância dessa técnica em estudos de vegetais de uma forma geral.

2.4.1 Support vector machine (SVM)

Proposta por Cortes e Vapnik (1995), Máquina de Vetores de Suporte (Support Vector Machine - SVM) é uma técnica de aprendizado de máquina supervisionada que é amplamente utilizada para reconhecimento, classificação ou regressão de padrões (UMADEVI; MARSELINE, 2017).

Segundo Vapnik (1995), o SVM baseia-se na teoria de aprendizagem estatística para determinar a localização dos limites de decisão (hiperplanos) que proporcionam a separação ótima de classes.

No reconhecimento de padrões de duas classes, por exemplo, em que são linearmente separáveis, o SVM, entre vários hiperplanos possíveis que podem separar duas classes (Figura 2a), seleciona somente um hiperplano, aquele que fornece margem máxima entre as duas classes (Figura 2b), que é chamado de hiperplano ótimo (Optimum Hyper Plane). Aqueles pontos que delimitam a largura da margem, que são usados para medir a margem, chamam-se vetores de suporte (Support Vectors) (VAPNIK, 1995; KAVZOGLU; COLKESEN, 2009).

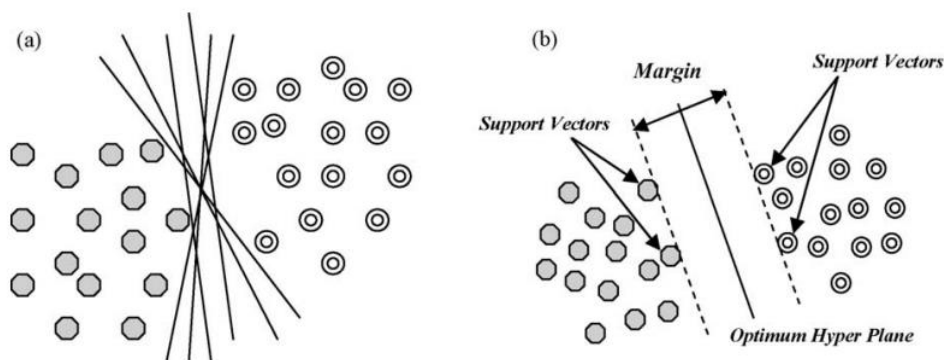


FIGURA 2. Hiperplanos para dados separáveis linearmente (a). Hiperplano e vetores de suporte ótimos (b). Fonte: Kavzoglu e Colkesen (2009).

Quando as amostras não são linearmente separáveis, as funções de kernel são um dos principais truques do SVM. Algumas opções de escolha desta função são: o kernel linear, polinomial, sigmoidal, RBF (Radial Basis Function) e Puk (Pearson VII universal kernel). Assim, os truques do kernel estendem as amostras de entrada para o caso não linear,

mapeando as amostras do espaço de entrada (Input space) em um recurso de alta dimensão (Feature space), a fim de que as amostras ganhem estrutura linear significativa (Figura 3) (AMAMI, AYED, ELLOUZE, 2013).




FIGURA 3: Mapeamento para o espaço de alta dimensão com uma função kernel. Fonte: Kavzoglu e Colkesen (2009).

Um Kernel Puk é caracterizado pela seguinte equação 1:

$$K(x_i, x_j) = \frac{1}{\left[1 + \left(\frac{2 \sqrt{\|x_i - x_j\|^2 \sqrt{2^{\frac{1}{\omega}} - 1}}}{\sigma} \right)^2 \right]^{\omega}} \quad (1)$$

Fonte: Üstün, Melssen e Buydens (2006).

Neste kernel dois parâmetros podem ser variados pelo usuário: o sigma (σ), que controla a largura de Pearson (largura do pico) e o ômega (ω), que controla o fator de cauda do pico (comportamento da cauda). Inerente à função, para qualquer par arbitrário de vetores de suporte (x_i e x_j), são atribuídos valores entre 0 e 1 (ÜSTÜN; MELSSEN; BUYDENS, 2006).

Outro parâmetro importante para o SVM, é a constante de margem suave, também chamada por parâmetro de penalidade C, que é escolhido pelo usuário e controla a compensação entre a margem e os erros de classificação (BYUN; LEE, 2002). Portanto, é um

parâmetro que permite um equilíbrio entre a maximização de margem e a minimização de erros de classificação (FOODY; MATHUR, 2004).

Para a maximização da margem, técnicas de otimização de programação quadrática (Quadratic Programming - QP) podem ser usadas (VAPNIK, 1995). No entanto, o problema de QP implica em alta complexidade de tempo de treinamento. Portanto, acelerar o treinamento é necessário, e para isso muitos métodos já foram desenvolvidos para reduzir tal complexidade computacional (LIU et al., 2016).

Um algoritmo para resolver rapidamente o problema de QP decorrente da aprendizagem SVM, é o algoritmo de Otimização Mínima Sequencial (ou Sequential Minimal Optimization - SMO). Algoritmo simples, que pode decompor o problema QP geral em subproblemas, resolvendo o problema geral rapidamente. Dessa forma, o SMO possui a vantagem de resolver o problema de forma analítica, evitando a otimização numérica de QP (PLATT, 1998).

De modo geral, de acordo com Nghaiwat e Arora (2014), SVMs têm vantagens como alta precisão de previsão e funcionamento robusto, mesmo quando os exemplos de treinamento possuem erros, o que é corroborado por Satyanarayana, Ramalingaswamy e Ramadevi (2014), mas que possuem limitações como a seleção de kernel e o ajuste de parâmetros.

O SVM, uma das abordagens mais influentes na comunidade de pesquisa, presente entre os 10 principais algoritmos de mineração de dados (XINDONG et al., 2008), é utilizado em várias áreas de conhecimento, inclusive em diferentes áreas agrícolas (REHMAN et al., 2019) como na previsão de rendimento, produção animal, detecção de ervas daninhas, qualidade da cultura, manejo do solo e também na detecção de doenças (LIAKOS et al., 2018).

Pukkela e Borra (2018) fornecem uma visão geral de vários métodos e técnicas para extração de características, segmentação e classificação de padrões de folhas, a fim de identificar doenças foliares de plantas e estimativas de sua severidade, sendo o SVM considerado significativo para classificação de doenças e sua gravidade.

A partir de dados espectroscópicos do visível e do infravermelho próximo, Rumpf et al. (2010) utilizaram SVM e índices de vegetação para a detecção precoce e diferenciação de doenças como a mancha foliar, ferrugem da folha e oídio em beterraba sacarina. De forma pré-sintomática, Römer et al. (2011) utilizando espectros de fluorescência, demonstraram que o SVM é capaz de detectar ferrugem da folha em plantas de trigo. Raza et al. (2015)

utilizaram imagens visíveis e térmicas, e plantas infectadas com oídio de tomateiro puderam ser identificadas com alta acurácia. Em Fernández et al. (2020) o classificador SVM aplicado à reflectância do vermelho e red edge foi capaz de classificar plantas de batata saudáveis e infectadas por *Phytophthora infestans* através de medições da folha e também dossel.

Garcia-Ruiz et al. (2013), na detecção de árvores infectadas por Huanglongbing (HLB) em pomar de citros, a partir de plataforma aérea equipada com sensor de imagem hiperespectral e outra plataforma com sensor de imagem multibanda, os SVMs foram superiores entre outros métodos. Bagheri (2020) utilizando SR aéreo e imagem multiespectral, consideraram a aprendizagem SVM confiável para detecção em estágio inicial, de pereiras infectadas com o patógeno *Erwinia amylovora* causadora do fogo bacteriano. Poblete et al. (2020) avaliando árvores de oliveira a partir de imagens aéreas multiespectrais e térmicas, constataram que o SVM foi mais preciso e, portanto, foi selecionado para modelar classes assintomáticas e sintomáticas por *Xylella fastidiosa*, usando conjuntos de bandas e conjunto de índices como entradas.

Cao et al. (2018) construíram uma plataforma de simulação de SR de baixa altitude de VANT para detecção de *Sclerotinia sclerotiorum* em folhas de colza, por meio de imagens térmicas, multiespectrais e RGB, adquiridas antes e depois da inoculação. Quatro modelos de aprendizado de máquina foram utilizados, dentre eles o SVM, o qual obteve melhor acurácia na classificação da gravidade da doença (amostras saudáveis, infecção moderada e infecção grave).

Entre outras aplicações, a partir de imagens hiperespectrais, a combinação de índices de vegetação em um modelo SVM, pôde realizar a discriminação de plantas de cevada bem irrigadas de plantas estressadas pela seca (BEHMANN; STEINRÜCKEN; PLÜMER, 2014), assim como o SVM também demonstrou o potencial da técnica de imagem hiperespectral para a detecção de lesões por frio em pepinos (CEN et al., 2016) e a previsão da germinação de sementes de beterraba sacarina (YANG et al., 2021).

2.4.2 Naive Bayes (NB)

Proposto por John e Langley (1995), o algoritmo possui abordagem simples e clara, para aprender conhecimento probabilístico. Foi planejado para uso em tarefas de indução supervisionada, tendo como meta de desempenho a previsão, com precisão, da classe de instâncias.

O NB também já foi relatado em Xindong et al. (2008), entre os 10 principais algoritmos de mineração de dados mais influentes na comunidade de pesquisa, e que, apesar de antigo é atrativo, devido sua simplicidade, porém de alta eficácia.

É chamado de Naive Bayes porque é baseado na regra de Bayes (Thomas Bayes) e de forma “ingênua” supõe que os atributos são independentes entre si (dada a classe). Apesar do nome, funciona de forma muito eficaz quando utilizado em conjuntos de dados reais, em particular quando combinado com alguns dos procedimentos de seleção de atributos, eliminando atributos redundantes. Em muitos conjuntos de dados o NB pode alcançar resultados impressionantes, superando até mesmo classificadores mais sofisticados (WITTEN; FRANK; HALL, 2011).

Portanto, a aprendizagem refere-se à construção de um modelo probabilístico bayesiano que atribui uma probabilidade de classe a uma instância, baseando-se no Teorema de Bayes, que pode ser expresso de acordo com a equação 2 (BERRAR, 2018):

$$P(A/B) = \frac{P(B/A)P(A)}{P(B)} \quad (2)$$

Onde: a probabilidade de A ocorrer desde que B ocorreu é igual à probabilidade de B ocorrer desde que A ocorreu multiplicado pela probabilidade de A ocorrer dividido pela probabilidade de B ocorrer.

De acordo com Farid et al. (2014) o NB possui vantagens, como: facilidade de uso, apenas uma verificação dos dados de treinamento são necessários para a geração de probabilidade, e lida facilmente com valores de atributos ausentes. Satyanarayana, Ramalingaswamy e Ramadevi (2014) diz que o NB melhora o desempenho, removendo recursos irrelevantes e possui curto tempo computacional.

Sabe-se que o AM tem várias aplicações na agricultura e com o algoritmo NB, especificamente, não é diferente (REHMAN et al., 2019). Phadikar, Sil e Das (2012), com base em alterações morfológicas (características de cor e forma) causadas por doenças no arroz, desenvolveram um sistema de classificação automatizado e o NB obteve o melhor resultado. Mondal, Kole e Roy (2017) utilizando características morfológicas de folhas (coloração e textura), conseguiram investigar o sintoma do *Yellow Vein Mosaic Virus* (YVMV) a partir de imagens foliares de plantas de quiabo e cabaça, onde o NB, conseguiu classificar a doença em diferentes graus de infestação (livre, baixa, moderada e grave).

Karadag et al. (2019) a partir das reflexões obtidas nas folhas de pimenta com auxílio de espectrorradiômetro, observaram que o NB pode distinguir plantas de pimentas saudáveis e doentes por Fusarium, assim como classificar quatro grupos de folhas de pimentas (saudáveis, doentes por Fusarium, fungo micorrízico e, Fusarium e fungo micorrízico juntos). Miranda et al. (2020), a partir de imagens de satélite também apresentaram os melhores resultados para classificar a incidência de necrose do café.

Várias outras aplicações do NB na agricultura podem ser encontradas, como na classificação de solos agrícolas (BHARGAVI; JYOTHI, 2009), sugestão de fertilizantes (PADALALU et al., 2017), classificação de plantas daninhas (MURSALIN et al., 2013), predição de proteínas efetoras de fungos (SPERSCHNEIDER et al., 2015), criação de tipologias agrícolas (PAAS; GROOT, 2017), previsão do rendimento em lavouras (FITHRI; LATIFAH, 2018), detecção rápida e não destrutiva de infecções de tubérculos de batata e bulbos de cebola inoculados com *P. carotovorum* subsp. *carotovorum* e *Burkholderia cepacia*, respectivamente (SINHA et al., 2018) e recomendação de tipos de culturas alimentares para cultivo (SETIADI et al., 2020).

3 MATERIAL E MÉTODOS

Na figura 4 consta o fluxograma geral de como o estudo foi desenvolvido, sendo as etapas detalhadas posteriormente.

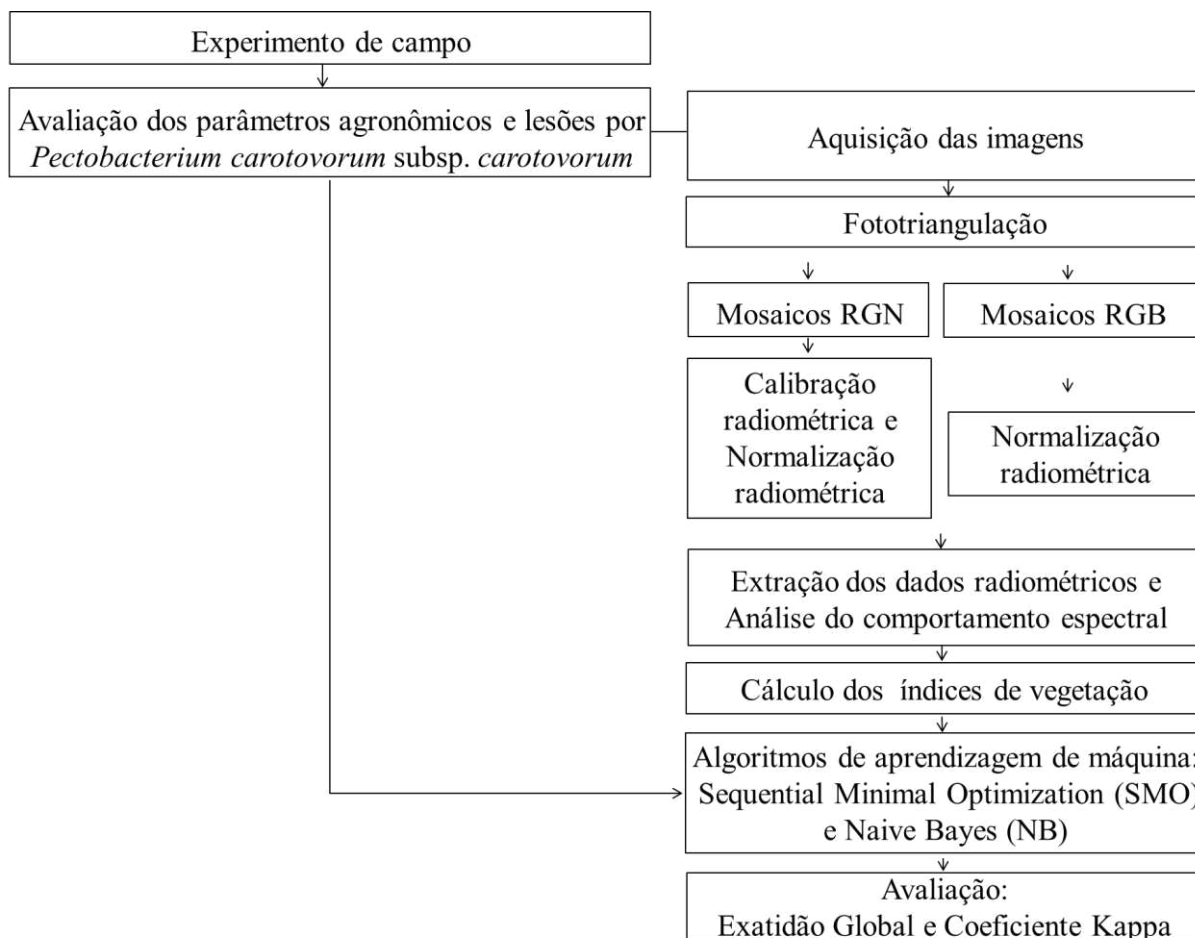


FIGURA 4. Fluxograma do desenvolvimento do estudo.

3.1 Experimento de campo

O experimento foi conduzido na Universidade Federal de Uberlândia (UFU), Campus Monte Carmelo, cujas coordenadas geográficas são: 18° 43' 26.77271" latitude Sul, 47° 31' 25.66202" longitude Oeste e altitude de 912,469 m. O clima da região, segundo a classificação de Köppen, é temperado úmido, caracterizado por verões quentes e invernos secos (EMBRAPA, 2006).

A cultivar de alface utilizada foi a Solaris®, do tipo crespa, a qual é classificada como suscetível à *Pectobacterium carotovorum* subsp. *carotovorum* (FÉLIX et al., 2014).

A semeadura foi realizada em bandejas de poliestireno expandido de 200 células, preenchidas com substrato comercial a base de casca de pinus. As mudas foram mantidas em casa de vegetação, coberta com plástico transparente anti UV de 150 micra e irrigadas diariamente para manter o substrato sempre úmido e ideal para o desenvolvimento das mudas.

Decorridos cerca de 25 dias após sementeira, as mudas foram transplantadas para vasos plásticos de cinco litros, preenchidos com solo, e mantidas inicialmente em casa de vegetação e sob tela de sombreamento. O solo utilizado foi coletado de área de barranco, peneirado, calcareado e adubado, conforme análise de solo realizada após a coleta (Tabela 1) e recomendações para a cultura (FONTES et al., 1999).

TABELA 1. Caracterização química do solo.

Prof. (cm)	pH Água (1:2,5)	P meh mg/dm ³	K ⁺	H ⁺ +Al ³⁺	Al ³⁺	Ca ⁺²	Mg ⁺²	SB	T	t	V %
			-----				cmolc/dm ³		-----		
0 - 20	4,8 ^B	0,5 ^B	0,07 ^B	4,10 ^M	0,14 ^{MB}	1,15 ^B	0,62 ^M	1,85 ^M	5,94 ^M	1,99 ^B	31 ^B

B: Baixo; M: Médio; MB: muito baixo.

Para a inoculação, foi utilizado o isolado de *Pectobacterium carotovorum* subsp. *carotovorum* UFU A7, cedido pelo Laboratório de Bacteriologia Vegetal (LABAC), da Universidade Federal de Uberlândia. O isolado foi cultivado em placas de Petri contendo meio de cultura 523 (KADO; HESKETT, 1970) por 24h à temperatura de 28°C. Para preparo da suspensão bacteriana, água filtrada estéril foi adicionada à placa e, após flambagem da alça de Drigalski, foi realizada a raspagem das colônias. A suspensão foi ajustada em espectrofotômetro para $A_{570} = 1,8 (5 \times 10^9 \text{ UFC mL}^{-1})$.

Após 27 dias do transplantio, 196 plantas foram inoculadas com 100µl da suspensão bacteriana por planta na região central do caule, utilizando-se uma seringa descartável de 1 mL. Após a inoculação, as plantas foram mantidas em câmara úmida por 12 horas, com auxílio de sacos plásticos. A mesma quantidade de plantas, ou seja, 196 plantas, não foram inoculadas, sendo estas, consideradas, ao longo do experimento como plantas saudáveis.

Aos quatro dias após a inoculação, as plantas foram realocadas em área externa à estufa, sendo o solo coberto com plástico preto (Figura 5) e, as plantas protegidas por tela de sombreamento preta, instalada a 2,0 m de altura em relação ao solo, a qual proporcionava de 40 a 45% de sombreamento para as plantas.

As plantas, com base na Figura 5, foram dispostas da seguinte forma: plantas não inoculadas correspondiam às duas fileiras duplas superiores e as plantas inoculadas correspondiam às duas fileiras inferiores.



FIGURA 5. Disposição das plantas de estudo.

As lesões foram avaliadas aos 4, 8, 12, 16, 20, 24 e 28 dias após a inoculação. Para avaliação do comprimento da lesão, em cada intervalo de tempo, 28 plantas inoculadas eram cortadas longitudinalmente, paralelamente à direção da inoculação e classificadas de acordo com a escala de notas proposta por Ren, Petzoldt e Dickson (2001), com adaptações, variando de 1 a 8, sendo: 1 = ausência de lesões no ponto de inoculação; 2 = lesões menores que 5 mm; 3 = lesões entre 5 e 10 mm; 4 = lesões maiores que 10 mm, não atingindo as folhas próximas da inoculação; 5 = lesões maiores que 10 mm, atingindo folhas próximas da inoculação; 6 = lesões maiores que 10 mm, atingindo folhas próximas e distantes da inoculação; 7 = planta inteira próxima a morte, e 8 = planta morta.

Nos mesmos intervalos descritos anteriormente, 28 plantas inoculadas e 28 plantas saudáveis também foram avaliadas quanto aos seguintes parâmetros agrônômicos: teor de clorofila, medido em quatro pontos no terço médio de cada planta em folhas recentemente maduras, usando o medidor de clorofila ClorofiLOG Falker Modelo CFL1030; massa fresca da planta e da raiz, utilizando balança digital Balmak Economic, sendo os dados apresentados em kg; diâmetro do caule, utilizando paquímetro digital em aço 150 mm-ZAAS, sendo os dados apresentados em mm e; comprimento da raiz (cm) utilizando régua milimetrada.

A irrigação foi realizada todos os dias, pela manhã e tarde, para manutenção da umidade do solo próximo à capacidade de campo, condição esta mais propícia para o desenvolvimento da doença.

3.2 Aquisição das imagens

Para cada obtenção das imagens, a tela de sombreamento preta instalada a 2,0 m de altura em relação ao solo era retirada.

Os voos eram realizados entre 12 e 13 horas (horário com maior radiação), no mesmo intervalo de tempo das avaliações agrônômicas e comprimento das lesões, ou seja, aos 4, 8,

12, 16, 20, 24 e 28 dias após a inoculação. Para tanto, primeiramente eram feitos os vôos e, logo em seguida, as plantas eram avaliadas com relação aos parâmetros agrônômicos e comprimento das lesões.

As imagens foram obtidas utilizando o veículo aéreo não tripulado (VANT) Phantom 4 Pro da DJI (Dà-Jiāng Innovations Science and Technology Co), o qual possui câmara visível convencional com os canais do azul (480 nm), verde (550 nm) e vermelho (650 nm) (RGB), com largura máxima a meia altura (do inglês Full Width at Half Maximum (FWHM)) de 10nm, e com resolução de 20 megapixels. Acoplada ao VANT, a câmara Mapir Survey3W com resolução de 12 megapixels, com canais correspondentes ao verde (550 nm), vermelho (660 nm) e infravermelho próximo (850 nm) (RGN), e FWHMs de 40, 60 e 80nm, respectivamente.

Em todos os voos, o planejamento do voo foi realizado utilizando o software DroneDeploy©, ficando estabelecido 5 faixas, com altitude de 20 metros; velocidade de 2m/s, sobreposição longitudinal e lateral de 75% e 70%, respectivamente, e tempo de voo de aproximadamente 4 minutos.

3.3 Pré-processamento das imagens

3.3.1 Fototriangulação

Após a captura das imagens pelos sensores RGB e RGN, os mosaicos foram construídos para cada um dos sete voos, no software AgisoftPhotoScan Professional. Neste software, as imagens passaram pelo alinhamento, encontrando a posição da câmara e os pontos comuns de cada imagem para combiná-las, formando uma nuvem de pontos esparsos. Posteriormente foi construída a nuvem de pontos densos, e com base nesta, foi gerada a superfície, utilizando o modelo de malha poligonal 3D, gerando os mosaicos de cada voo e sensor, totalizando 14 mosaicos.

3.3.2 Calibração radiométrica

A calibração radiométrica foi realizada apenas nos sete mosaicos gerados a partir das imagens da Mapir Survey3W, utilizando-se o software Mapir Camera Control (MCC). Para isso, antes de cada voo foi capturada com a câmara, uma foto do alvo, o qual possui quatro paletes (preta, cinza escuro, cinza claro e branca) de radiâncias conhecidas.

Logo, no software, foi especificado o modelo, a lente e o filtro da câmara Mapir Survey3W utilizados. Posteriormente, selecionou-se a imagem do alvo do respectivo dia do voo e detectou-se o código QR do alvo. Dessa forma, foram calculados os valores de calibração necessários para a câmara, e cada pasta de entrada contendo o mosaico foi carregada. Após o processo de calibração criou-se, automaticamente, a pasta do mosaico calibrado.

3.3.3 Normalização radiométrica

Sabendo que podem haver variações nos valores de reflectância dos objetos com o passar do tempo e, se tratando de imagens temporais, como são as do presente trabalho, realizou-se a normalização radiométrica para a caracterização espectral, de todos os mosaicos, tanto RGB (números digitais) quanto RGN (reflectância).

A técnica proposta por Hall et al. (1991), consiste em retificar imagens em relação a uma imagem de referência selecionada, dando o parecer que foram obtidas sob condições atmosféricas e de iluminação iguais àquela selecionada. Ainda segundo Hall et al. (1991), primeiro faz-se a obtenção dos conjuntos escuros e “brilhantes” com pouca ou nenhuma variação na reflectância média entre as imagens de estudo, e posteriormente faz-se a retificação das imagens por transformação linear para aproximar as médias da reflectância de cada banda aos dados da imagem de referência.

Na normalização, definiu-se como referência, a imagem do último voo, por apresentar maior nitidez, menor interferência atmosférica. Em todos os voos, o alvo de calibração da câmara Mapir Survey3W (Figura 6) foi colocado na área sobrevoada, e, desta forma, o mesmo foi utilizado para extrair as médias dos conjuntos claro e escuro de todas as imagens, já que sua radiância é estável.



FIGURA 6. Alvo de calibração da câmara Mapir Survey3W para extração dos valores médios dos conjuntos de pixels claro e escuro.

Na imagem de referência, bem como nas demais imagens, foram extraídos manualmente os valores de números digitais e reflectâncias do conjunto de pixels claro e do conjunto de pixels escuro na banda do vermelho (Red: R), verde (Green: G), azul (Blue: B) e infravermelho próximo (Near infrared: N), ou seja, das bandas RGB e RGN das imagens.

Posteriormente, para determinação dos coeficientes de uma transformação linear (PONZONI; SHIMABUKURO; KUPLICH, 2012) para cada banda espectral, empregou-se a equação 3:

$$T_i = m_i \times x_i + b_i \quad (3)$$

Onde: T_i = Número digital (RGB) e reflectância (RGN) da imagem normalizada; $m_i = (B_{ri} - D_{ri}) / (B_{si} - D_{si})$; x_i = banda espectral a ser normalizada; $b_i = (D_{ri} \times B_{si} - D_{si} \times B_{ri}) / (B_{si} - D_{si})$; B_{ri} = média do conjunto de referência clara; D_{ri} = média do conjunto de referência escura; B_{si} = média do conjunto claro a ser normalizado; D_{si} = média do conjunto escuro a ser normalizado; i = bandas do sensor em estudo.

No software ENVI 5.1 (Environment for Visualizing Images), por meio da ferramenta Band Math, a equação foi aplicada para cada banda das imagens, gerando camadas. Na ferramenta Layer Stacking, as três camadas geradas de cada imagem foram combinadas para formar uma única imagem, com valores similares aos da imagem de referência.

3.4 Extração dos dados radiométricos

Os dados radiométricos (valores médios de números digitais e reflectâncias nas bandas RGB e RGN, respectivamente) de 28 plantas inoculadas e de 28 plantas não inoculadas foram extraídos de cada mosaico (ou seja, intervalo de avaliação), utilizando a função Region of Interest (ROI) do software ENVI 5.1, a fim de que fizessem parte dos dados de entrada de classificação.

3.5 Cálculo dos índices de vegetação

Com os valores médios de números digitais (RGB) e reflectâncias (RGN) das alfaces saudáveis e daquelas inoculadas com a bactéria, calcularam-se cinco índices de vegetação (Equações de 4 a 13) no espectro do visível e cinco no espectro do infravermelho próximo (N) (Tabela 2), que são sensíveis a variações biofísicas e bioquímicas do vegetal, para que também compusessem os dados de classificação.

TABELA 2. Índices de vegetação calculados a partir de comprimentos de onda dos sensores de estudo; espectro do visível (R, G e B) e do infravermelho próximo (N), de alfaces inoculadas com *Pectobacterium carotovorum* subsp. *carotovorum* e não inoculadas. Monte Carmelo, 2020.

Índice de vegetação	Equação	Aplicação	Referência
Normalized Green Red Difference Index	$\text{NGRDI} = \frac{(B_{550} - B_{650})}{(B_{550} + B_{650})}$ (4)	Índice de área foliar (IAF), biomassa	(TUCKER, 1979; HUNT JUNIOR et al., 2005)
Carotenoid Reflectance Index 1	$\text{CRI1} = \frac{(1)}{(B_{480})} - \frac{(1)}{(B_{550})}$ (5)	Conteúdo de carotenoide	(GITELSON et al., 2002)
Photochemical Reflectance Index	$\text{PRI} = \frac{(B_{480} - B_{550})}{(B_{480} + B_{550})}$ (6)	Eficiência da fotossíntese	(GAMON; PEÑUELAS; FIELD, 1992; GARBULSKY et al., 2011)

...continua...

TABELA 2, Cont.

Triangular Greenness Index	$TGI = B_{550} - 0.39 \times B_{650} - 0.61 \times B_{480}$ (7)	Clorofila	(HUNT JUNIOR et al., 2011; MCKINNON; HOFF, 2017; STARÝ et al., 2020)
Green Leaf Index	$GLI = \frac{(2 * B_{550} - B_{650} - B_{480})}{(2 * B_{550} + B_{650} + B_{480})}$ (8)	Biomassa	(LOUHAICHI; BORMAN; JOHNSON, 2001; BALLESTEROS et al., 2018)
Normalized Difference Vegetation Index	$NDVI = \frac{(B_{850} - B_{660})}{(B_{850} + B_{660})}$ (9)	Biomassa, IAF, produtividade e radiação fotossinteticament e ativa.	(ROUSE et al., 1973; WIEGAND et al., 1991; ZARATE-VALDEZ et al., 2012)
Simple Ratio	$SR = \frac{B_{850}}{B_{660}}$ (10)	Clorofila, IAF	(JORDAN, 1969)
Green Normalized Difference Vegetation Index	$GNDVI = \frac{(B_{850} - B_{550})}{(B_{850} + B_{550})}$ (11)	Clorofila, IAF, biomassa, N absorvido e produtividade	(GITELSON KAUFMAN; MERZLYAK, 1996; HUNT JUNIOR et al., 2010; MOGES et al., 2004)
Difference Vegetation Index	$DVI = B_{850} - B_{660}$ (12)	Biomassa, IAF	(TUCKER 1979; DÍAZ; BLACKBURN, 2003)
Modified Chlorophyll Absorption Reflectance Index 1	$MCARI1 = 1.2 \times [2.5 \times (B_{850} - B_{660}) - 1.3 \times (B_{850} - B_{550})]$ (13)	Maior sensibilidade ao IAF e menor à clorofila	(HABOUDANE et al., 2004)

Canais do sensor RGB: vermelho (B_{650}), verde (B_{550}) e azul (B_{480}). Canais do sensor RGN: vermelho (B_{660}), verde (B_{550}) e infravermelho próximo (B_{850}). B: Banda.

3.6 Classificação supervisionada

Para a discriminação das alfaces saudáveis e infectadas, foram realizadas classificações supervisionadas com base no algoritmo probabilístico Naive Bayes (NB) e o não paramétrico Support Vector Machine (SVM), o qual é definido como algoritmo SMO (Sequential Minimal Optimization), implementado no programa Waikato Environment for Knowledge Analysis - Weka 3.9.4. Ambos classificadores já utilizados em trabalhos envolvendo doenças de plantas (TETILA et al., 2017; MONDAL, KOLE; ROY, 2017); POBLETE et al., 2020; ABDU; MOKJI; SHEIKH, 2020).

Os dados de entrada são mapeados de forma não linear para um espaço de alta dimensão, onde os vetores de suporte definem um hiperplano, tornando os dados linearmente separáveis (CORTES; VAPNIK, 1995). Para tanto, foi utilizado o kernel PUK (Pearson VII universal kernel) com Sigma (σ) = 1, Ômega (ω) = 1 e parâmetro de penalidade C = 1, após realização de testes prévios. Já o aprendizado NB, é baseado no Teorema de Bayes, assume a independência dos atributos e calcula as probabilidades de pertencer a classes distintas (BERRAR, 2018).

Para cada intervalo de avaliação, foram inseridas no conjunto de dados de entrada: as classes de plantas saudáveis e infectadas; os valores médios dos números digitais e reflectâncias das bandas RGB e RGN, respectivamente; índices de vegetação calculados e variáveis agronômicas avaliadas.

Para classificação no software Weka, as plantas não inoculadas (saudáveis) foram adotadas como classe 0; enquanto todas as plantas infectadas, nos seus diferentes níveis da doença obtidos em campo, foram consideradas como classe 1. Dessa forma, para não comprometer o treinamento dos classificadores e trabalhar com classes balanceadas (classes de alface com o mesmo número de indivíduos), teve-se 28 plantas saudáveis e 28 plantas infectadas.

Os subconjuntos selecionados para classificação em cada intervalo de avaliação foram: 1- apenas bandas (para cada câmara), 2- apenas índices e 3- a combinação entre bandas e índices. A classificação das variáveis agronômicas deu-se separadamente para comparação com as classificações obtidas pelas imagens. Para a classificação de cada subconjunto, foram utilizados 70% dos dados para treinamento e 30% para teste (ABDULRIDHA et al., 2020; CONRAD et al., 2020; SELVARAJ et al., 2020), tanto para o SVM quanto para o NB. Para

tanto, deve-se ressaltar que para o treinamento e validação da classificação, foram utilizadas 20 e 8 amostras para cada classe, respectivamente.

A performance dos algoritmos foi analisada usando a exatidão global (EG) (equação 14) e o coeficiente Kappa (K), calculado através da equação 15 (JENSEN, 2016). Os intervalos de Kappa e a respectiva concordância (WANG et al., 2020a) estão apresentados na tabela 3. Esses elementos de avaliação foram calculados pelo software Weka.

$$EG = \frac{\sum_{i=1}^k n_{ii}}{N} \quad (14)$$

Onde: n_{ii} = número total de observações classificadas corretamente (soma da diagonal na matriz de confusão); N = número total observações avaliadas na matriz de confusão.

$$K = \frac{N * \sum_{i=1}^k x_{ii} - \sum_1^k (x_{i+} * x_{+i})}{N^2 - \sum_1^k (x_{i+} * x_{+i})} \quad (15)$$

Onde: onde k é o número de linhas na matriz de confusão, x_{ii} é o valor na linha i e coluna i , e x_{i+} e x_{+i} são os totais para a linha i e coluna i , respectivamente, e N é o número total de amostras.

TABELA 3. Intervalo de Kappa e concordância entre as classificações esperadas e observadas.

Intervalo de Kappa	Concordância
Abaixo de 0,00	pobre
0,00 a 0,20	fraca
0,21 a 0,40	razoável
0,41 a 0,60	moderada
0,61 a 0,80	substancial
0,81 a 1,00	quase perfeita

Fonte: Adaptação de Landis e Koch (1977).

Anteriormente às classificações, os espectros médios foram analisados e aqueles mais decisivos foram representados graficamente a partir dos espectros médios adquiridos das plantas infectadas e saudáveis.

4 RESULTADOS

Após análise prévia dos espectros médios para os diferentes intervalos de avaliação, priorizou-se destacar os espectros médios derivados do sensor multiespectral aos 8 e 16 DAI de plantas infectadas e não infectadas (Figura 7). Aos 8 DAI a planta ainda não encontrava-se com sintomas visuais da doença, sendo possível intervenção agrônômica, sem prejuízo da lavoura e; aos 16 DAI o vegetal já encontrava-se com início dos sintomas visuais ou seja, grau de comprometimento intermediário.

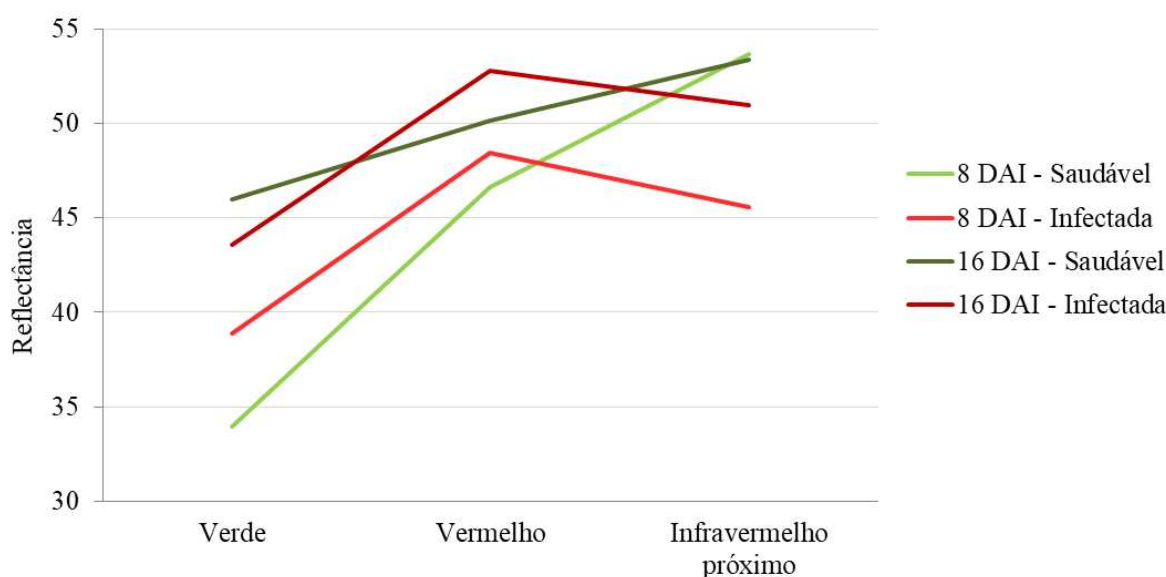


FIGURA 7: Comportamento espectral de plantas de alface saudáveis e infectadas, calculados a partir dos espectros médios adquiridos dos dosséis saudáveis e infectados em função do número de dias após a inoculação (DAI).

Ao analisar o comportamento espectral da vegetação saudável e infectada aos 8 DAI, observa-se maior diferença entre os valores de reflectância de plantas saudáveis e infectadas no infravermelho próximo (Figura 7), o que demonstra que nesse período as estruturas celulares das duas condições são diferentes e decisivas na discriminação espectral, conforme o desempenho apresentado pela classificação da câmara multiespectral (Tabela 4). Entretanto, observa-se que isto não foi possível com a câmara RGB para o mesmo período, uma vez que os sintomas relacionados à pigmentação (despigmentação/clorose) ainda não eram observados (Tabela 4).

TABELA 4. Classificação supervisionada de plantas saudáveis e infectadas, para os diferentes subconjuntos, em diferentes intervalos de avaliação.

Subconjuntos classificados	4 DAI		8 DAI				12 DAI				16 DAI					
	SVM		NB		SVM		NB		SVM		NB		SVM		NB	
	EG	K	EG	K	EG	K	EG	K	EG	K	EG	K	EG	K	EG	K
RGN	88,24	0,77	88,24	0,77	100	1	100	1	82,35	0,65	76,47	0,53	64,71	0,28	64,71	0,29
Índices	94,12	0,88	94,12	0,88	82,35	0,64	82,35	0,64	70,59	0,40	64,71	0,27	52,94	0,05	58,82	0,17
RGN e índices	100	1	100	1	100	1	94,12	0,88	76,47	0,53	76,47	0,53	58,82	0,17	58,82	0,17
R, N, NDVI, SR, GNDVI	100	1	100	1	94,12	0,88	88,24	0,76	58,82	0,17	64,71	0,28	58,82	0,17	58,82	0,17
R, G, DVI, MCARI1	100	1	94,12	0,88	100	1	100	1	88,24	0,76	76,47	0,53	52,94	0,06	52,94	0,06
RGB	76,47	0,52	58,82	0,17	82,35	0,65	76,47	0,53	64,71	0,30	58,82	0,19	94,12	0,88	94,12	0,88
Índices	76,47	0,52	64,71	0,28	82,35	0,65	82,35	0,65	70,58	0,41	58,82	0,20	88,24	0,76	88,24	0,76
RGB e índices	76,47	0,52	76,47	0,52	82,35	0,65	76,47	0,53	70,59	0,41	58,82	0,20	94,12	0,88	88,24	0,76
R, G, NGRDI, GLI, TGI	76,47	0,52	76,47	0,52	82,35	0,65	82,35	0,65	82,35	0,65	58,82	0,20	88,24	0,76	82,35	0,64
G, B, CRI1, PRI	70,59	0,40	70,59	0,40	82,35	0,65	64,71	0,28	70,59	0,42	58,82	0,19	88,24	0,76	88,24	0,76
Parâmetros agronômicos	88,24	0,77	82,35	0,65	94,12	0,88	94,12	0,88	82,35	0,65	88,24	0,77	64,71	0,28	58,82	0,17

DAI: Dias após inoculação; SVM: Support Vector Machine; NB: Naive Bayes; EG: Exatidão Global; K: Coeficiente Kappa.

...continua...

TABELA 4, Cont.

Subconjuntos classificados	20 DAI				24 DAI				28 DAI			
	SVM		NB		SVM		NB		SVM		NB	
	EG	K	EG	K	EG	K	EG	K	EG	K	EG	K
RGN	76,47	0,53	76,47	0,53	100	1	100	1	64,71	0,31	58,82	0,19
Índices	47,06	-0,06	47,06	-0,04	94,12	0,88	88,24	0,76	47,06	-0,04	58,82	0,20
RGN e índices	76,47	0,53	76,47	0,53	100	1	100	1	47,06	-0,06	58,82	0,20
R, N, NDVI, SR, GNDVI	76,47	0,53	76,47	0,53	100	1	100	1	47,06	-0,06	58,82	0,20
R, G, DVI, MCARI1	76,47	0,53	76,47	0,53	100	1	100	1	52,94	0,07	58,82	0,19
RGB	100	1	94,12	0,88	100	1	100	1	29,41	-0,42	29,41	-0,44
Índices	100	1	82,35	0,64	82,35	0,64	100	1	35,29	-0,29	35,29	-0,29
RGB e índices	100	1	82,24	0,76	100	1	100	1	41,18	-0,18	41,18	-0,18
R, G, NGRDI, GLI, TGI	88,24	0,77	94,12	0,88	100	1	100	1	41,18	-0,18	41,18	-0,18
G, B, CRI1, PRI	100	1	88,24	0,76	100	1	94,12	0,88	35,29	-0,31	35,29	-0,33
Parâmetros agronômicos	82,35	0,64	82,35	0,64	88,24	0,76	88,24	0,76	76,47	0,53	70,59	0,41

Aos 16 DAI, para as plantas infectadas, também houve maior reflectância da banda do vermelho (52,77) e menor reflectância na banda do infravermelho próximo (50,97). Porém, aos 16 DAI a diferença da banda do vermelho entre plantas saudáveis e infectadas foi cerca de 30% superior a diferença dessa mesma banda entre plantas saudáveis e infectadas aos 8 DAI (Figura 7), o que demonstra relação com a pigmentação da planta.

Já a diferença de reflectância para a banda do infravermelho próximo entre plantas saudáveis e infectadas foi 240% inferior dos 16 aos 8 DAI (Figura 7), demonstrando menor relação com a estrutura celular.

Aos 16 DAI, as plantas apresentaram sintomas visuais da doença, motivo que pode ter contribuído para que o sensor multiespectral apresentasse, em sua maioria, valores mais baixos de exatidão global e coeficiente kappa, e consequentemente os subconjuntos derivados da câmara RGB apresentassem melhor desempenho (Tabela 4).

Para os referidos intervalos de avaliação, o estresse causado pela bactéria causou redução de valores para a maioria dos parâmetros agronômicos avaliados, embora de forma sutil. Aos 8 DAI foi observado menores valores médios nas plantas infectadas para comprimento de raiz, massa fresca da planta, diâmetro do caule e teor de clorofila. Já aos 16 DAI houveram menores valores médios nas plantas infectadas para massa fresca da planta, diâmetro do caule e clorofila. Para os dois intervalos observa-se que a massa fresca da raiz apresentou médias iguais (Tabela 5).

TABELA 5: Média dos parâmetros agronômicos aos 8 e 16 dias após inoculação (DAI).

Parâmetros agronômicos	8 DAI		16 DAI	
	Saudável	Infectada	Saudável	Infectada
Comprimento da raiz (cm)	24,91	23,61	16,25	29,09
Massa fresca da planta (kg)	0,20	0,14	0,18	0,14
Massa fresca da raiz (kg)	0,02	0,02	0,02	0,02
Diâmetro do caule (mm)	15,22	13,42	15,90	13,88
Teor de clorofila	16,83	16,56	17,34	17,08

Os dados radiométricos e os parâmetros agronômicos das plantas sadias e infectadas foram classificados por dois algoritmos de aprendizado de máquina nos sete intervalos de avaliação do experimento (Tabela 4). Com base na classificação, a exatidão global variou para os classificadores SVM e NB de 29,41 a 100%, e o coeficiente Kappa de -0,42 a 1 para SVM e -0,44 a 1 para o NB (Tabela 4).

O classificador SVM obteve aos 4 DAI para os subconjuntos: RGN e índices; R, N, NDVI, SR, GNDVI e; R, G, DVI, MCARI1 exatidão global de 100% e coeficiente Kappa igual a 1. Pelo classificador NB, os dois primeiros subconjuntos citados anteriormente também apresentaram exatidão global de 100 % e kappa igual a 1, ou seja, concordância perfeita (WANG et al. 2020b), demonstrando a capacidade de detecção, distinção entre plantas saudáveis e infectadas. Os demais subconjuntos multiespectrais apresentaram concordância quase perfeita ($k=0,88$), exceto as bandas RGN. Os subconjuntos do sensor visível apresentaram concordância de fraca ($k=0,17$) a moderada ($k=0,52$); já os parâmetros agronômicos apresentaram concordância substancial ($k= 0,77$ e $0,65$, respectivamente para o classificador SVM e NB) (WANG et al. 2020b) (Tabela 4).

Aos 8 DAI, os subconjuntos: RGN e índices; R, G, DVI, MCARI1 e as bandas RGN pelo classificador SVM proporcionaram exatidão de 100% ($k=1$), o que também foi observado nesses dois últimos subconjuntos pelo NB (Tabela 4). Os demais subconjuntos multiespectrais obtiveram concordâncias substancial ($k=0,64$ e $0,76$) e quase perfeita ($k= 0,88$). Os subconjuntos do sensor visível obtiveram, em sua maioria, concordância substancial ($k=0,65$), enquanto os parâmetros agronômicos obtiveram concordância quase perfeita ($k=0,88$) (Tabela 4).

No intervalo de 12 DAI houve redução da exatidão e do coeficiente kappa para os dois classificadores, tanto nos subconjuntos multiespectrais quanto do sensor visível. Dentre os multiespectrais, apenas as bandas RGN ($k=0,65$) e R, G, DVI, MCARI1 ($k=0,76$) pelo classificador SVM, e o sensor visível com o R, G, NGRDI, GLI, TGI ($k=0,65$), que proporcionaram concordância substancial ($k=0,61$ a $0,8$) (WANG et al. 2020b), mesma concordância obtida pelos parâmetros agronômicos (Tabela 4).

Aos 16 DAI, as exatidões globais e kappa dos subconjuntos multiespectrais, tanto para o SVM quanto para o NB foram ainda menores ($k=0,05$ a $0,29$) do que aos 12 DAI, diferentemente dos subconjuntos do sensor visível, que aumentaram aos 16 DAI. Isso pode ter ocorrido, pois neste período, obteve-se lesões maiores que 10 mm, ou seja lesões atingindo folhas próximas da inoculação, o que pode ter ocasionado aumento da exatidão global e coeficiente kappa (Tabela 4).

As melhores classificações aos 16 DAI foram para as bandas RGB e; RGB e índices, com kappa igual a $0,88$ (concordância quase perfeita) pelo SVM, e as bandas RGB pelo NB (Tabela 4), embora os demais subconjuntos tenham coeficientes com concordância substancial ($k=0,61$ a $0,8$). A classificação dos parâmetros agronômicos demonstrou

concordância razoável ($k=0,28$) para o SVM e fraca ($k=0,17$) para o NB (WANG et al. 2020b), ou seja, a pior classificação comparada aos demais intervalos.

Aos 20 DAI, as bandas RGB; Índices; RGB e índices e; G, B, CRI1, PRI, por meio do classificador SVM obtiveram exatidão global de 100% e kappa igual a 1 (concordância perfeita), já para o classificador NB foram obtidas concordâncias substancial e quase perfeita (Tabela 4). Em contrapartida os subconjuntos multiespectrais mantiveram-se em sua maioria com concordância moderada ($k=0,53$) e os parâmetros agronômicos com concordância substancial ($k=0,64$).

No geral, aos 24 DAI observaram-se os melhores resultados, tanto para os subconjuntos multiespectrais, quanto para o sensor visível. Exceto o subconjunto dos índices multiespectrais, todos os demais, por um ou ambos classificadores, obtiveram exatidão global de 100% ($k=1$), o que corresponde a uma concordância perfeita (WANG et al. 2020b). Já os parâmetros agronômicos obtiveram concordância substancial ($k=0,76$) (Tabela 4).

Por fim, aos 28 DAI coeficientes kappa abaixo de zero foram mais comuns, ou seja, concordância pobre, enquanto os parâmetros agronômicos foram superiores e indicaram concordância moderada ($k=0,41$ a $0,6$) (WANG et al. 2020b).

5 DISCUSSÃO

Alguns subconjuntos multiespectrais demonstraram-se propícios para detecção precoce da doença (aos 4 e 8 DAI), usando os dois classificadores (Tabela 4). Isso ocorreu antes que os sintomas característicos da doença fossem visíveis (16 DAI) e sem haver necessidade de destruição da planta. Tal fato, demonstra que embora a doença esteja invisível a *olho nu*, a presença da bactéria na planta pode ocasionar algumas mudanças na fisiologia do vegetal, alterando sua reflectância, o que proporcionou bons resultados de classificação/identificação na primeira e segunda avaliação.

Doenças de plantas podem ocasionar modificações fisiológicas na taxa transpiratória, forma e coloração das folhas, além de mudanças na morfologia e densidade do dossel, alterando sua reflectância (WEST et al., 2010). Alteração que, no presente estudo, foi decorrente da ação de enzimas pectinolíticas (pectinases) produzidas pelo patógeno. Enzimas que degradam as substâncias pécticas presentes principalmente na lamela média, acarretando a separação e morte das células, ou seja, a maceração do tecido e, portanto, a destruição da integridade estrutural (PASCHOLATI; DALIO, 2018).

Aos 4 DAI, as bandas RGN e índices; R, N, NDVI, SR, GNDVI e; R, G, DVI, MCARI1 proporcionaram classificações com exatidão global de 100% (k=1) (Tabela 4), ou seja, detecção precoce da doença. Abdollahi et al. (2004) verificaram redução da proporção de clorofila a e b após 42h da inoculação *in vitro* de *Erwinia amylovora* em brotos de pera. Apesar desse relato, a detecção precoce relacionada à alterações dos pigmentos do vegetal não é muito comum, tanto que, aos 4 DAI, pelo sensor visível (RGB), os resultados das classificações foram inferiores ao da câmara multiespectral, ou seja, os pigmentos sensíveis ao visível ainda não eram determinantes para discriminar, com o mesmo potencial da estrutura celular, entre plantas saudáveis e infectadas (Tabela 4).

Os índices de vegetação podem ser mais correlacionados com a biomassa do que apenas a medição de vermelho ou infravermelho próximo (JENSEN, 2016). Dessa forma a combinação de bandas com índices de vegetação (Tabela 4) junto às suas aplicações já estudadas (Tabela 1) podem ter contribuído para o bom desempenho dos classificadores aos 4 DAI para a câmara multiespectral (Tabela 4).

Aos 8 DAI as bandas RGN; RGN e índices; e R, G, DVI, MCARI1 possibilitaram alcançar exatidões globais de 100% (k=1) (Tabela 4). Os espectros médios das bandas do vermelho e verde aumentaram e do infravermelho próximo reduziram em plantas infectadas (Figura 7). Isso corrobora com Ren, Tripathi e Li (2017), os quais mostraram que em espectros de reflectância para alface não saudável, há aumento nas regiões do azul, verde e vermelho e diminuição acentuada do infravermelho próximo.

Sandmann, Grosch e Graefe (2018), avaliando mudas de alface inoculadas com *Rhizoctonia solani* também obtiveram maior valor médio para a banda do vermelho e menor para infravermelho próximo, como observado aos 8 DAI no presente estudo (Figura 7).

Embora no estudo em questão observou-se que a massa fresca da raiz de plantas sadias e infectadas apresentaram médias iguais (Tabela 5), Osco et al. (2019) verificaram que o peso da massa seca da raiz de plantas de alface, induzidas por estresse hídrico, foi o parâmetro que apresentou maior correlação com o intervalo do infravermelho próximo.

Da mesma forma, Bagheri (2020) por meio de UAV para detecção de pereiras infectadas com *Erwinia amylovora*, consideraram as bandas do infravermelho próximo, bem como as bandas do vermelho e verde adequadas; porém, como não há sintoma visual no primeiro estágio da infecção, a faixa do infravermelho próximo pode ser considerada mais adequada para detecção precoce, uma vez que a estrutura interna da folha altera a absorção de luz. Chen et al. (2020) também corrobora com esta afirmação, em que dados espectrais no

intervalo do infravermelho próximo, podem auxiliar na detecção de plantas de amendoim em estágio inicial de murcha bacteriana (*Ralstonia solanacearum*), em que o xilema está ligeiramente afetado e as folhas ainda verdes. Portanto, partindo da capacidade do infravermelho, acredita-se que aos 8 DAI os resultados são mais confiáveis para a diferenciação das plantas saudáveis e infectadas (Tabela 4).

Os índices de vegetação derivados do sensor multiespectral (NDVI, DVI, GNDVI, SR, MCARI1) também contribuíram para detecção da presença ou ausência da doença nas plantas (Tabela 2), concordando com o relatado por Sandmann, Grosch e Graefe (2018), que obtiveram menor valor médio de NDVI para mudas doentes de alface por *Rhizoctonia solani* comparativamente a mudas saudáveis; bem como com vários outros estudos, que apontam que tais índices também estão relacionados com doenças de plantas (FLETCHER; ESCOBAR; SKARIA, 2004; CAO et al., 2013; ZHANG et al., 2018; BAGHERI, 2020; ABDULRIDHA et al., 2020).

Aos 12 DAI houve redução da exatidão e do coeficiente kappa para os dois sensores (Tabela 2), indicando que aos 8 DAI é a época limite para detecção de forma precoce.

Aos 16 DAI, embora haja alguma diferença do infravermelho próximo entre plantas saudáveis e infectadas (Figura 7), a maioria dos subconjuntos classificados apresentou concordância fraca (Tabela 4), o que pode ser devido à alta variabilidade de dados, fazendo com que os classificadores tenham confundido a classificação. Já o sensor visível, no início dos sintomas visuais, conseguiu melhor distinção das duas condições e proporcionou concordância substancial e também quase perfeita (Tabela 4).

Quanto aos parâmetros agronômicos, os quais são mais relacionados à estrutura celular, o pior desempenho foi observado aos 16 DAI ($k=0,17$ e $0,28$), assim como o sensor multiespectral no mesmo período, com baixos valores de kappa (Tabela 4). Já aos 4 e 8 DAI, os parâmetros agronômicos proporcionaram melhores exatidões globais e coeficientes kappa, com destaque aos 8 DAI com concordância quase perfeita ($k=0,88$) (Tabela 4), ou seja, mais um indício que a estrutura celular foi determinante para detecção precoce da doença.

Aos 16 DAI, as bandas RGB e; RBG e índices proporcionaram as melhores classificações (Tabela 4). Da mesma forma, Chávez et al. (2012) também relataram que o intervalo do visível, particularmente as bandas do azul e do vermelho, foram capazes de detectar os sintomas iniciais de murcha bacteriana em batata, causada por *Ralstonia solanacearum*. Portanto, nesta fase, os pigmentos podem ser mais importantes que a estrutura celular na discriminação entre plantas doentes e saudáveis.

Em Osco et al. (2019), os parâmetros clorofila, massa fresca e matéria seca da parte aérea de plantas de alface, induzidas por estresse hídrico, apresentaram as maiores correlações tanto negativas quanto positivas nas bandas do azul e do vermelho, ou seja, intervalos espectrais de absorção de clorofila a e b. Já em nosso estudo, aos 16 DAI, houve sutil redução de clorofila, massa fresca da planta e diâmetro do caule, entre plantas saudáveis e infectadas (Tabela 5).

Aos 20 e 24 DAI, os subconjuntos do sensor visível também destacaram-se (EG=100%, k=1), seja usando apenas as bandas, índices, ambos ou combinando bandas e índices (Tabela 4). Odabas et al. (2017) já observaram que usando os componentes RGB, por meio de um modelo treinado, foi possível estimar precisamente o pigmento clorofila em folha de alface.

Os índices derivados do sensor visível, relacionados com clorofila, biomassa, conteúdo de carotenoides e eficiência fotossintética do vegetal (Tabela 4), estão envolvidos em estudos de doenças de plantas (HUANG et al., 2007; SAPATE; DESHMUKH, 2019; SANCHO-ADAMSON et al., 2019; BHANDARI et al., 2020), por isso, podem ter contribuído para os bons resultados obtidos aos 20 e 24 DAI. A combinação de índices de vegetação, baseados em diferentes comprimentos de onda, os quais descrevem diferentes parâmetros fisiológicos, faz com que haja aumento do conteúdo da informação para uma classificação automática, além de melhorar a precisão da classificação (RUMPF et al. 2010).

Portanto, aos 4, 8, 20 e 24 DAI, baseado nos subconjuntos classificados com 100% (Tabela 4), ou seja, concordância perfeita (WANG et al., 2020b), o classificador SVM foi acurado ao distinguir entre plantas saudáveis e infectadas. Esses dados corroboram com os obtidos por outros autores, que também verificaram precisões relevantes na classificação de plantas e folhas saudáveis e infectadas ao utilizarem o classificador SVM (GARCIA-RUIZ et al., 2013; ABU-KHALAF; SALMAN, 2013).

Para o algoritmo NB, também foi obtida máxima exatidão global e k=1 aos 4, 8 e 24 DAI (Tabela 4), demonstrando a capacidade do algoritmo, assim como relatado por Karadag et al. (2018), que distinguiram plantas doentes e saudáveis com alta precisão, utilizando tal algoritmo. Além disso, o classificador NB também possibilita distinguir classes de doenças (MONDAL; KOLE; ROY, 2017).

Apesar das divergências, vale destacar que ambos classificadores possibilitaram maior quantidade de acertos aos 24 DAI.

Os piores resultados foram observados aos 28 DAI (Tabela 4). O patógeno inoculado é uma doença de raiz, que não se manifestou intensivamente na parte aérea das plantas de estudo, o que pode ter ocasionado variações nas respostas espectrais das plantas ao longo do tempo, dificultando uma classificação mais precisa. Tal fato também foi relatado por Bienkowski et al. (2019), ao obterem valores de R^2 consideravelmente menores quando plantas de batata foram inoculadas com *Pectobacterium atrosepticum*, comparando à inoculação com *Phytophthora infestans*. Isso ocorreu pois a ação do primeiro patógeno na folhagem é de forma indireta.

Portanto, a reflectância espectral de alface tem potencial na detecção da podridão mole causada por *Pectobacterium carotovorum* subsp. *carotovorum* e o aprendizado de máquina pode ser adequado no processamento de dados radiométricos e de parâmetros agrônômicos.

A detecção precoce da doença, permitirá que plantas infectadas sejam retiradas da área, evitando maiores perdas, uma vez que podem haver infecções secundárias.

O método apresentado neste trabalho, de detecção remota, pode ser aplicável em campo, tornando a avaliação de campo menos trabalhosa. Porém, necessita-se de profissionais que realizem tal trabalho e disponibilizem aos produtores.

6 CONCLUSÕES

Há possibilidade da detecção pré-sintomática de *Pectobacterium carotovorum* subsp. *carotovorum* em alface aos 4 e aos 8 DAI, especialmente quando faz-se o uso de diferentes subconjuntos derivados da câmara Mapir Survey3W (sensor RGN) com os classificadores SVM e o NB, antes mesmo da manifestação dos sintomas em campo (16 DAI), ou seja, quando as lesões causadas pela bactéria eram maiores que 10 mm e atingiam as folhas próximas da inoculação.

Aos 20 e 24 DAI as plantas sadias e doentes foram melhores discriminadas utilizando o sensor visível convencional (sensor RGB). Entretanto, aos 20 DAI a melhor discriminação ocorreu utilizando o classificador SVM; já aos 24 DAI a discriminação foi igual, independente do classificador utilizado (NB ou SVM).

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ABDOLLAHI, H. et al. In vitrosystem for studying the interaction between *Erwinia amylovora* and genotypes of pear. **Plant Cell Tissue and Organ Culture (PCTOC: Journal of Plant Biotechnology)**, v. 79, n. 2, p. 203–212. 2004. DOI: <https://doi.org/10.1007/s11240-004-0661-0>
- ABDU, A.M.; MOKJI, M.M.; SHEIKH, U.U. Automatic vegetable disease identification approach using individual lesion features. **Computers and Electronics in Agriculture**, v. 176, 105660. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105660>
- ABDULRIDHA, J. et al. Detecting powdery mildew disease in squash at different stages using UAV-based hyperspectral imaging and artificial intelligence. **Biosystems Engineering**, v. 197, p. 135–148. 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2020.07.001>
- ABU-KHALAF, N.; SALMAN, M. Detecting plant diseases using visible/near infrared spectroscopy. **NIR News**, v. 24, n. 4, p. 12-25. 2013. DOI: <https://doi.org/10.1255/nirn.1369>
- AGROFIT. **Sistemas de agrotóxicos fitossanitários**. Disponível em: <http://extranet.agricultura.gov.br/agrofit_cons/principal_agrofit_cons/>. Acesso em: 27 Jul. 2020.
- ALI, M. M. et al. Non-destructive techniques of detecting plant diseases: A review. **Physiological and Molecular Plant Pathology**, v. 108, p. 101426. 2019. DOI: <https://doi.org/10.1016/j.pmpp.2019.101426>
- AMAMI, R.; AYED, D.; ELLOUZE, N. Practical selection of SVM supervised parameters with different feature representations for vowel recognition. **International Journal of Digital Content Technology and its Applications**, v. 7, n. 9, p. 418-424. 2013.
- ANUÁRIO BRASILEIRO DE HORTI&FRUTI 2020. Gazeta Santa Cruz, Santa Cruz do Sul. 2019. 96 p.
- BAGHERI, N. Application of aerial remote sensing technology for detection of fire blight infected pear trees. **Computers and Electronics in Agriculture**, v. 168, p.105147. 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105147>
- BAGHERI, N. et al. Detection of Fire Blight disease in pear trees by hyperspectral data. **European Journal of Remote Sensing**, v. 51, n. 1, p. 1–10. 2018. DOI: <https://doi.org/10.1080/22797254.2017.1391054>
- BALLESTEROS, R. et al. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, p. 66-75. 2018. DOI: <https://doi.org/10.1016/j.jag.2018.05.019>
- 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. 2019a. DOI: <https://doi.org/10.3390/drones3020040>

- BARBEDO, J. G. A. Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. **Computers and Electronics in Agriculture**, v. 162, p. 482–492. 2019b. DOI: <https://doi.org/10.1016/j.compag.2019.04.035>
- BARBEDO, J.G. A. Detecting and classifying pests in crops using proximal images and machine learning: A Review. **Artificial Intelligence**, v. 1, n. 2, p. 312–328. 2020. DOI: <https://doi.org/10.3390/ai1020021>
- BAURIEGEL, E. et al. Chlorophyll fluorescence imaging to facilitate breeding of *Bremia lactucae*-resistant lettuce cultivars. **Computers and Electronics in Agriculture**, v. 105, p. 74–82. 2014. DOI: <https://doi.org/10.1016/j.compag.2014.04.010>
- BEHMANN, J.; STEINRÜCKEN, J.; PLÜMER, L. Detection of early plant stress responses in hyperspectral images. **Journal Photogrammetric Remote Sensing**, v. 93, p. 98–111, 2014. DOI: <https://doi.org/10.1016/j.isprsjprs.2014.03.016>
- BENELLI. A.I.H, et al. Reação de cultivares de batata à podridão mole causada por *Pectobacterium carotovorum* subsp. *atrosepticum*, por *P. carotovorum* subsp. *carotovorum* e por *P. chrysanthemi*. **Fitopatologia Brasileira**, v. 29, n. 2, p. 155-159. 2004. DOI: <https://doi.org/10.1590/S0100-41582004000200006>
- BERIAM, L. O. S. **Doenças bacterianas em hortaliças**. Instituto Biológico, São Paulo, v. 69, n. 2, p. 81-84. 2007.
- BERRAR, D. P. Bayes' Theorem and Naive Bayes Classifier. In: RANGANATHAN, S. et al. (Eds). **Encyclopedia of Bioinformatics and Computational Biology**, p. 403-412. 2018. DOI: <https://doi.org/10.1016/B978-0-12-809633-8.20473-1>
- BHANDARI, M. et al. Assessing winter wheat foliage disease severity using aerial imagery acquired from small Unmanned Aerial Vehicle (UAV). **Computers and Electronics in Agriculture**, v. 176, n. 6, p. 105665. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105665>
- BHARGAVI, P.; JYOTHI, S. Applying Naive Bayes Data Mining Technique for Classification of Agricultural Land Soils. **International Journal of Computer Science and Network Security**, v. 9, n.8, p.117-122. 2009.
- BIENKOWSKI, D. et al. Detection and differentiation between potato (*Solanum tuberosum*) diseases using calibration models trained with non-imaging spectrometry data. **Computers and Electronics in Agriculture**, v. 167, p.105056. 2019. DOI: <https://doi.org/10.1016/j.compag.2019.105056>
- BISCHOFF, V. et al. Technological support for detection and prediction of plant diseases: A systematic mapping study Citation Data. **Computers and Electronics in Agriculture**, v.181, n. 1, p.105922. 2021. DOI: <https://doi.org/10.1016/j.compag.2020.105922>
- BREURE, T. S. et al. Predicting the growth of lettuce from soil infrared reflectance spectra: the potential for crop management. **Precision Agriculture**, v. 22, n. 1, p. 226-248. 2020. DOI: <https://doi.org/10.1007/s11119-020-09739-x>

BYUN, H.; LEE, S-W. Applications of support vector machines for pattern recognition: A Survey. In: LEE, S-W; VERRI, A. **Pattern Recognition with Support Vector Machines**. Canada: Springer-Verlag Berlin Heidelberg. cap. 17, 2002. p. 213–236. DOI: https://doi.org/10.1007/3-540-45665-1_17

CANDIAGO, S. et al. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. **Remote Sensing**, v. 7, n. 4, p. 4026–4047. 2015. DOI: <https://doi.org/10.3390/rs70404026>

CAO, F. et al. Fast Detection of *Sclerotinia Sclerotiorum* on Oilseed Rape Leaves Using Low-Altitude Remote Sensing Technology. **Sensors**, v. 18, n. 12, 4464. 2018. DOI: <https://doi.org/10.3390/s18124464>

CAO, X. et al. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. **Crop Protection**, v. 45, p. 124–131. 2013. DOI: <https://doi.org/10.1016/j.cropro.2012.12.002>

CARIDDI, C.; SANZANI, S.M. A severe outbreak of bacterial lettuce soft rot caused BY *Pectobacterium carotovorum* subsp. *carotovorum* in Apulia (Italy). **Journal of Plant Pathology**, v. 95, n. 2, 441-446. 2013.

CARNEIRO, F. M. et al. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. **Precision Agriculture**, v. 21, p. 979-1007. 2020. DOI: <https://doi.org/10.1007/s11119-019-09704-3>

CARVALHO FILHO, R.C.; MELLO, S. C. M. *Pectobacterium carotovorum*: taxonomia, identificação, sintomatologia, epidemiologia e controle, Brasília: **Embrapa Recursos Genéticos e Biotecnologia**, 2008, 17 p.

CEN, H. et al. Nondestructive detection of chilling injury in cucumber fruit using hyperspectral imaging with feature selection and supervised classification. **Postharvest Biology and Technology**, v.111, p. 352–361. 2016. DOI: <https://doi.org/10.1016/j.postharvbio.2015.09.027>

CHAVEZ, P. et al. Detection of bacterial wilt infection caused by *Ralstonia solanacearum* in potato (*Solanum tuberosum* L.) through multifractal analysis applied to remotely sensed data. **Precision Agriculture**, v. 13, n. 2, p. 236–255. 2012. DOI: <https://doi.org/10.1007/s11119-011-9242-5>

CHAWGIEN, K.; KIATTISIN; S. Machine learning techniques for classifying the sweetness of watermelon using acoustic signal and image processing. **Computers and Electronics in Agriculture**, v. 181. 2021. DOI: <https://doi.org/10.1016/j.compag.2020.105938>

CHEN, T. et al. Early detection of bacterial wilt in peanut plants through leaf-level hyperspectral and unmanned aerial vehicle data. **Computers and Electronics in Agriculture**, v. 177, p.105708. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105708>

- CHIWAKI, K.; NAGAMORI, S.; INOUE, Y. Predicting bacterial wilt disease of tomato plants using remotely sensed thermal imagery. **Journal of Agricultural Meteorology**, v. 61, n. 3, p. 153–164. 2005. DOI: <https://doi.org/10.2480/agrmet.61.153>
- COLARICCIO, A.; CHAVES, A. L. R. **Aspectos Fitossanitários da Cultura da Alface**. 29. ed. São Paulo: Instituto Biológico, 2017. 127 p.
- CONRAD, A. O. et al. Machine Learning-Based Presymptomatic Detection of Rice Sheath Blight Using Spectral Profiles. **Plant Phenomics**. p. 1-10. 2020. DOI: <https://doi.org/10.34133/2020/8954085>
- CORTES, C.; VAPNIK; V. Support vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297. 1995. DOI: <https://doi.org/10.1007/BF00994018>
- CUI, D. et al. Detection of soybean rust using a multispectral image sensor. **Sensing and Instrumentation for Food Quality and Safety**, v. 3, n. 1, p. 49–56. 2009. DOI: <https://doi.org/10.1007/s11694-009-9070-8>
- DAS, R.; BHATTACHARJEE, C. Lettuce. In: JAISWAL, A. **Nutritional Composition and Antioxidant Properties of Fruits and Vegetables**. Academic Press, 2020. cap.9. p. 143-157. DOI: <https://doi.org/10.1016/B978-0-12-812780-3.00009-X>
- DI GENNARO et al. Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. **Phytopathologia Mediterranea**, v. 55, n. 2, p. 262–275. 2016. DOI: https://doi.org/10.14601/Phytopathol_Mediterr-18312
- DÍAZ, B. M., BLACKBURN, G. A. Remote sensing of mangrove biophysical properties: Evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices. **International Journal of Remote Sensing**, v. 24, n. 1, p. 53-73. 2003. DOI: <https://doi.org/10.1080/01431160305012>
- DONG, Y. H. et al. Insecticidal *Bacillus thuringiensis* silences *Erwinia carotovora* virulence by a new form of microbial antagonism, signal interference. **Applied and Environmental Microbiology**, Washington, v. 70, n. 2, p. 954-960, 2004. DOI: <https://doi.org/10.1128/AEM.70.2.954-960.2004>
- ELAZAB, A. et al. Detecting interactive effects of N fertilization and heat stress on maize productivity by remote sensing techniques. **European Journal of Agronomy**, v. 73, p. 11–24. 2016. DOI: <https://doi.org/10.1016/j.eja.2015.11.010>
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. Sistema brasileiro de classificação de solos. 2.ed. Rio de Janeiro: Embrapa Solos, 2006. 306p.
- ESHKABILOV, S. et al. Hyperspectral imaging techniques for rapid detection of nutrient content of hydroponically grown lettuce cultivars. **Computers and Electronics in Agriculture**, v. 181, p.105968. 2021. DOI: <https://doi.org/10.1016/j.compag.2020.105968>

- FARBER, C. et al. Advanced spectroscopic techniques for plant disease diagnostics. A Review. **Trends in Analytical Chemistry**, v. 118, p. 43-49. 2019. DOI: <https://doi.org/10.1016/j.trac.2019.05.022>
- FARID, D. Md. et al. Hybrid decision tree and Naïve Bayes classifiers for multi-class classification tasks. **Expert Systems with Applications**, v. 41, n. 4, p. 1937–1946. 2014. DOI: <https://doi.org/10.1016/j.eswa.2013.08.089>
- FÉLIX, K.C.S et al. Lettuce genotype resistance to “soft rot” caused by *Pectobacterium carotovorum* subsp. *carotovorum*. **Scientia Agricola**, Piracicaba, v. 71, n. 4, p. 287-291. 2014. DOI: <https://doi.org/10.1590/0103-9016-2013-0301>
- FERNÁNDEZ, C.I. et al. Potato Late Blight Detection at the Leaf and Canopy Levels Based in the Red and Red-Edge Spectral Regions. **Remote Sensing**, v. 12, n. 8, p.1292. 2020. DOI: <https://doi.org/10.3390/rs12081292>
- FILGUEIRA, F. A. R. **Novo manual de olericultura: agrotecnologia moderna na produção e comercialização de hortaliças**. 2ª ed., UFV, 2003.
- FITHRI, D.; LATIFAH, N. Prediction of determination of rice farming production using the naïve bayes method. **International Conference on Computer Science, Engineering and Technologies - ICCSET 2018**, p. 726-736. 2018. DOI: <https://doi.org/10.4108/eai.24-10-2018.2280524>
- FLETCHER, R. S.; ESCOBAR, D. E.; SKARIA, M. Technical Note: Response of ratio vegetation indices to foot rot-infected citrus trees. **International Journal of Remote Sensing**, v. 25, n. 19, p. 3967–3972. 2004. DOI: <https://doi.org/10.1080/01431160310001652367>
- FONTES, P.C.R. Alface. In: RIBEIRO, A.C.; GUIMARÃES. P.T.G.; ALVAREZ, V.H.A. (Eds). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5º aproximação**, Viçosa, p. 177. 1999.
- FOODY, G.M.; MATHUR, A. A relative evaluation of multiclass image classification by support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 6, p. 1335–1343. 2004. DOI: <https://doi.org/10.1109/TGRS.2004.827257>
- FRANCESCHINI, M. H. D. et al. Feasibility of Unmanned Aerial Vehicle Optical Imagery for Early Detection and Severity Assessment of Late Blight in Potato. **Remote Sensing**, v. 11, n. 3, 224. 2019. DOI: <https://doi.org/10.3390/rs11030224>
- GAITÁN, C. F. Machine learning applications agricultural impacts under extreme events. In: SILLMANN, J.; SIPPEL, S.; RUSSO, S. (Eds). **Climate Extremes and Their Implications for Impact and Risk Assessment**. San Francisco, 2020. cap 7. p.119–138. DOI: <https://doi.org/10.1016/B978-0-12-814895-2.00007-0>
- GAMON, J. A.; PEÑUELAS, J.; FIELD, C. B. A narrow-waveband spectral index that tracks diurnal changes in protosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44. 1992. DOI: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

- GAO, H.; MAO, H.; ZHANG, X. Determination of lettuce nitrogen content using spectroscopy with efficient wavelength selection and extreme learning machine. **Zemdirbyste**, v. 102, n. 1, p. 51-58.2015. DOI: <https://doi.org/10.13080/z-a.2015.102.006>
- GARCIA-RUIZ, F. et al. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106–115. 2013. DOI: <https://doi.org/10.1016/j.compag.2012.12.002>
- GARBULSKY, M.F. et al. The photochemical reflectance index (PRI) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies. A review and meta-analysis. **Remote Sensing of Environment**, v. 115, n. 2, p. 281-297. 2011. DOI: <https://doi.org/10.1016/j.rse.2010.08.023>
- GAŠIĆ, K.atarina et al. *Pectobacterium carotovorum* subsp. *carotovorum* – the causal agent of broccoli soft rot in Serbia. **Pesticides and Phytomedicine**, v. 29, n. 4, p. 249–255. 2014. DOI: <https://doi.org/10.2298/PIF1404249G>
- GITELSON, A.A.; KAUFMAN, Y.J.; MERZLYAK, M.N. Use of a channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289-298. 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- GITELSON, A.A. et al. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochemistry and Photobiology**, v.75, n. 3, p. 272-281. 2002. DOI: [https://doi.org/10.1562/0031-8655\(2002\)075<0272:ACCIPL>2.0.CO;2](https://doi.org/10.1562/0031-8655(2002)075<0272:ACCIPL>2.0.CO;2)
- GOGOI, N.K.; DEKA, B.; BORA, L.C., Remote sensing and its use in detection and monitoring plant diseases: A review. **Agricultural Reviews**, v. 39, n. 4, p. 307-313. 2018. DOI: <https://doi.org/10.18805/ag.R-1835>
- GOLD, K.M. et al. Investigating potato late blight physiological differences across potato cultivars with spectroscopy and machine learning. **Plant Science**, v. 295, p.110316. 2019. DOI: <https://doi.org/10.1016/j.plantsci.2019.110316>
- GU, Q. et al. Early detection of tomato spotted wilt virus infection in tobacco using the hyperspectral imaging technique and machine learning algorithms. **Computers and Electronics in Agriculture**, v. 167, p.105066. 2019. DOI: <https://doi.org/10.1016/j.compag.2019.105066>
- HABOUDANE, D. et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, n. 4, p. 337-352. 2004. DOI: <https://doi.org/10.1016/j.rse.2003.12.013>
- HAHN, F. Actual Pathogen Detection: Sensors and algorithms - a Review. **Algorithms**, v. 2, n. 1, p. 301–338. 2009. DOI: <https://doi.org/10.3390/a2010301>
- HALL, F. G. et al. Radiometric rectification: Toward a common radiometric response among multirate, 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)

HATFIELD, J. L. et al. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, v. 100, n. S3, p.S-117-S-131. 2008. DOI: <https://doi.org/10.2134/agronj2006.0370c>

HENZ, G. P.; SUINAGA, F. Tipos de alface cultivadas no Brasil. Brasília, DF: **Embrapa Hortaliças**, 2009. 7 p. (Comunicado Técnico, 75).

HETZRONI, A. et al. Machine vision monitoring of plant health. **Advances in Space Research**, v. 14, n. 11, p. 203-212. 1994. DOI: [https://doi.org/10.1016/0273-1177\(94\)90298-4](https://doi.org/10.1016/0273-1177(94)90298-4)

HILLNHÜTTER, C. et al. Remote sensing for the detection of soil-borne plant parasitic nematodes and fungal pathogens. In: OERKE, E. C. (Eds.), **Precision Crop Protection – the Challenge and Use of Heterogeneity**. London: Springer, Netherlands. p. 151-165. 2010. DOI: https://doi.org/10.1007/978-90-481-9277-9_10

HILLNHÜTTER, C. et al. Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. **Field Crops Research**, v. 122, n. 1, p. 70–77. 2011. DOI: <https://doi.org/10.1016/j.fcr.2011.02.007>

HUANG, W. et al. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. **Precision Agriculture**, v. 8, n. 4, p. 187–197. 2007. DOI: <https://doi.org/10.1007/s11119-007-9038-9>

HUNT JUNIOR, E. R. et al. Remote sensing leaf chlorophyll content using a visible band index. **Agronomy Journal**, v. 103, n. 4, p.1090-1099. 2011. DOI: <https://doi.org/10.2134/agronj2010.0395>

HUNT JUNIOR, E. R., Cavigelli, M., Daughtry, C.S.T., McMurtrey, J.E., Walthall, C.L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359-378. 2005. DOI: <https://doi.org/10.1007/s11119-005-2324-5>

HUNT JUNIOR, E.R. et al. Acquisition of NIR-Green-Blue digital photographs from unmanned aircraft for crop monitoring. **Remote Sensing**, v. 2, n. 1, p. 290-305. 2010. DOI: <https://doi.org/10.3390/rs2010290>

IP, R. H. L. et al. Big data and machine learning for crop protection. **Computers and Electronics in Agriculture**, v. 151, p. 376–383. 2018. DOI: <https://doi.org/10.1016/j.compag.2018.06.008>

JENSEN, J.R. **Introductory digital image processing: a remote sensing perspective**, 4. ed., Glenview, IL, USA. 2016.

JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in bayesian classifiers. In: **Eleventh Conference on Uncertainty in Artificial Intelligence**. San Mateo: Morgan Kaufmann, p. 338-345. 1995.

- JORDAN, C.F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, p. 663-666. 1969. DOI: <https://doi.org/10.2307/1936256>
- JUN, S. et al. Detecting nitrogen content in lettuce leaves based on hyperspectral imaging and multiple regression analysis. **Information Technology Journal**, v.12, n. 18, p. 4845-4851. 2013. DOI: <https://doi.org/10.3923/itj.2013.4845.4851>
- KADO, C. I.; HESKETT, M. G. Selective media for isolation of Agrobacterium, Corynebacterium, Erwinia, Pseudomonas and Xanthomonas. **Phytopathology**, v. 60, p. 969-976. 1970. DOI: <https://doi.org/10.1094/Phyto-60-969>
- KARADAG, K. et al. Detection of pepper fusarium disease using machine learning algorithms based on spectral reflectance. **Sustainable Computing: Informatics and Systems**, v. 28. 2018. DOI: <https://doi.org/10.1016/j.suscom.2019.01.001>
- KAVZOGLU, T.; COLKESEN, I. A kernel functions analysis for support vector machines for land cover classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 11, n. 5, 352–359. 2009. DOI: <https://doi.org/10.1016/j.jag.2009.06.002>
- KHANAL, S. et al. Remote sensing in agriculture - Accomplishments, limitations, and opportunities. **Remote Sensing**, v.12, n. 22, p.3783. 2020. DOI: <https://doi.org/10.3390/rs12223783>
- KIZIL, Ü. et al. Lettuce (*Lactuca sativa* L.) yield prediction under water stress using artificial neural network (ANN) model and vegetation indices. **Zemdirbyste**, v. 99, n. 4, p. 409-418. 2012.
- LAN, Y. et al. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. **Computers and Electronics in Agriculture**, v. 171, p.105234. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105234>
- LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, p. 159 -147. 1977. DOI: <https://doi.org/10.2307/2529310>
- LIAKOS, K. et al. Machine learning in agriculture: A Review. **Sensors**, v. 18, n. 8, p. 2674. 2018. DOI: <https://doi.org/10.3390/s18082674>
- LINDQVIST, K. On the origin of cultivated lettuce. **Hereditas**, v. 46, p. 319-350. 1960. DOI: <https://doi.org/10.1111/j.1601-5223.1960.tb03091.x>
- LIU, C. et al. Martin An efficient instance selection algorithm to reconstruct training set for support vector machine. **Knowledge-Based Systems**, v. 116, n.1. 2016. DOI: <https://doi.org/10.1016/j.knosys.2016.10.031>
- LOLADZE A. et al. Application of remote sensing for phenotyping tar spot complex resistance in maize. **Frontiers Plant Science**, v. 10, p.552. 2019. DOI: <https://doi.org/10.3389/fpls.2019.00552>

LOPES, C.A.; QUEZADO-DUVAL, A.M.; REIS, A. Doenças da alface. Brasília, DF: **Embrapa Hortaliças**, 2010. 68p.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65-70. 2001. DOI: <https://doi.org/10.1080/10106040108542184>

MACIEL, G. M. et al. Image phenotyping of inbred red lettuce lines with genetic diversity regarding carotenoid levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 81, p. 154–160. 2019. DOI: <https://doi.org/10.1016/j.jag.2019.05.016>

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. DOI: <https://doi.org/10.1016/j.tplants.2018.11.007>

MAHLEIN, A-K. Plant disease detection by imaging sensors – Parallels and specific demands for precision agriculture and plant phenotyping. **Plant Disease**, v. 100, n. 2, p. 241–251. 2016. DOI: <https://doi.org/10.1094/PDIS-03-15-0340-FE>

MAHLEIN, A-K et al. Recent advances in sensing plant diseases for precision crop protection. **European Journal of Plant Pathology**, v. 133, n.1, p. 197–209. 2012. DOI: <https://doi.org/10.1007/s10658-011-9878-z>

MANSFIELD, J. et al. Top 10 plant pathogenic bacteria in molecular plant pathology. **Mol. Plant Pathology**, v.13, p. 614-629. 2012. DOI: <https://doi.org/10.1111/j.1364-3703.2012.00804.x>

MAO, H. et al. Nondestructive measurement of total nitrogen in lettuce by integrating spectroscopy and computer vision. **Scientia Horticulturae**, v. 184, p. 1-7. 2015. DOI: <https://doi.org/10.1016/j.scienta.2014.12.027>

MARIN, D. B. et al. Multispectral radiometric monitoring of bacterial blight of coffee. **Precision Agriculture**, v. 20, n. 5, p.959-982. 2018. DOI: <https://doi.org/10.1007/s11119-018-09623-9>

MARTINELLI, F. et al. Advanced methods of plant disease detection. A review. **Agronomy for Sustainable Development**, v. 35, n.1, p.1–25. 2015. DOI: <https://doi.org/10.1007/s13593-014-0246-1>

MATSUO, K. et al. Development of Experimental Setup for Distinction of Disease Plant. ASABE. Paper Number: 063016. St. Joseph, Mich.: **American Society of Agricultural and Biological**, 2006.

MATTUPALLI, C. et al. Supervised classification of rgb aerial imagery to evaluate the impact of a root rot disease. **Remote Sensing**, v.10, n. 6, 917. 2018. DOI: <https://doi.org/10.3390/rs10060917>

MCKINNON, T., HOFF, P. Comparing RGB-based vegetation indices with NDVI for drone based agricultural sensing. **AgribotixLlcAgbx021-17**. p. 1-8. 2017.

MICHEREFF, S. J.; PERUCH, L. A. M.; ANDRADE, D.E.G.T. Manejo Integrado de Doenças Radiculares. In: **Ecologia e Manejo de patógenos radiculares em solos tropicais**. MICHEREFF, S. J.; ANDRADE, D. E. G. T.; MENEZES, M. (eds). Recife: UFRPE, 2005. cap 15, p. 367-388.

MIRANDA, J. R. et al. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal Of Applied Earth Observation**. Netherlands, v. 85, p.101893. 2020. DOI: <https://doi.org/10.1016/j.jag.2019.101983>

MOGES, S. M. et al. Evaluation of green, red, and near infrared bands for predicting winter wheat biomass, nitrogen uptake, and final grain yield. **Journal of Plant Nutrition**, v. 27, n. 8, p. 1431-1441. 2004. DOI: <https://doi.org/10.1081/PLN-200025858>

MONDAL, D.; KOLE, D. K.; ROY, K. Gradation of yellow mosaic virus disease of okra and bitter gourd based on entropy based binning and Naive Bayes classifier after identification of leaves. **Computers and Electronics in Agriculture**, v. 142, p. 485-493. 2017. DOI: <https://doi.org/10.1016/j.compag.2017.11.024>

MORELLOS, A. et al. Non-destructive early detection and quantitative severity stage classification of *Tomato Chlorosis Virus* (ToCV) infection in young tomato plants using Vis-NIR spectroscopy. **Remote Sensing**, v. 12, n. 12, p.1920. 2020. DOI: <https://doi.org/10.3390/rs12121920>

MORETTI, C. et al. *Pectobacterium aroidearum* and *Pectobacterium carotovorum* subsp. *carotovorum* as causal agents of potato soft rot in Lebanon. **European Journal of Plant Pathology**, v. 144, n. 1, p. 205–211. 2015. DOI: <https://doi.org/10.1007/s10658-015-0743-3>

MURSALIN, Md. et al. Performance analysis among different classifier including naive bayes, support vector machine and C4.5 for automatic weeds classification. **Global Journal of Computer Science and Technology Graphics & Vision**, v. 13, n. 3. 2013.

NAAS, H. et al. *Pectobacterium carotovorum* subsp. *brasiliense* and *Pectobacterium carotovorum* subsp. *carotovorum* as causal agents of potato soft rot in Algeria. **European Journal of Plant Pathology**, v. 151, n. 2, p. 1027–1034. 2018. DOI: <https://doi.org/10.1007/s10658-018-1438-3>

NAZERIAN, E. et al. Characterization of *Pectobacterium carotovorum* subsp. *carotovorum* as a new disease on Lettuce in Malaysia. Australas. **Plant Disease**, v. 8, p. 105-107. 2013. DOI: <https://doi.org/10.1007/s13314-013-0107-9>

NGHAIWAT, S.; ARORA, P. Detection and classification of plant leaf diseases using image processing techniques: A review. **International Journal Of Recent Advances In Engineering & Technology**, v. 2, n. 3, p. 2347-2812. 2014.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blucher Ltda, 2010. 387 p.

NOVO, E. M. L. M; PONZONI, F. J. **Introdução ao Sensoriamento Remoto**. São José dos Campos, SP: Instituto Nacional de Pesquisas Espaciais – INPE, 2001, 68 p. Disponível em: <http://www.dpi.inpe.br/Miguel/AlunosPG/Jarvis/SR_DPI7.pdf> Acesso em 15 de fev. 2021.

NTURAMBIRWE, J. F. I.; OPARA, U. L. Machine learning applications to non-destructive defect detection in horticultural products. **Biosystems Engineering**, v. 189, p. 60–83. 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2019.11.011>

ODABAS, M. S et al. Multilayer perceptron neural network approach to estimate chlorophyll concentration index of lettuce (*Lactuca sativa* L.). **Communications in Soil Science and Plant Analysis**, v. 48, n. 2, p. 162-169. 2016. DOI: <https://doi.org/10.1080/00103624.2016.1253726>

OERKE, E. C. Precision crop protection systems. In: STAFFORD, J. (Ed). **Precision Agriculture for Sustainability**. Cambridge, UK: Burleigh Dodds Science. 2018. cap. 15. p. 347–397. DOI: <https://doi.org/10.19103/AS.2017.0032.16>

OERKE, E. C. Remote Sensing of Diseases. **Annual Review of Phytopathology**, v. 58, n. 1, p. 225–252. 2020. DOI: <https://doi.org/10.1146/annurev-phyto-010820-012832>

OSCO et al. Modeling hyperspectral response of water-stress induced lettuce plants using artificial neural networks. **Remote Sensing**, v. 11, n. 23, 2797. 2019. DOI: <https://doi.org/10.3390/rs11232797>

OZGUVEN, M.M.; ADEM, K. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. **Physica A**, v.535, 122537. 2019. DOI: <https://doi.org/10.1016/j.physa.2019.122537>

PAAS, W.; GROOT, J. C. J. Creating adaptive farm typologies using Naive Bayesian classification. **Information Processing in Agriculture**, v. 4, n. 3, p. 220-227. 2017. DOI: <https://doi.org/10.1016/j.inpa.2017.05.005>

PACUMBABA JUNIOR, R.O.; C.A. BEYL. Changes in hyperspectral reflectance signatures of lettuce leaves in response to macronutrient deficiencies. **Advances in Space Research**, v. 48, n.1, p. 32–42. 2011. DOI: <https://doi.org/10.1016/j.asr.2011.02.020>

PADALALU, P. et al. Smart water dripping system for agriculture/farming. In: **2nd International Conference for Convergence in Technology (I2CT)**, p. 659–662. 2017. DOI: <https://doi.org/10.1109/I2CT.2017.8226212>

PAL, T.; JAISWAL, V; CHAUHAN, R. S. DRPPP: A machine learning based tool for prediction of disease resistance proteins in plants. **Computers in Biology and Medicine**, v.78,n. 1, p. 42-48. 2016. DOI: <https://doi.org/10.1016/j.combiomed.2016.09.008>

PASCHOLATI, S. F.; DALIO, R. J. D. Fisiologia do Parasitismo: Como os patógenos atacam as plantas. In: AMORIM, L.; REZENDE, J.A.M. & BERGAMIN FILHO, A (Eds). **Manual de Fitopatologia**. Volume 1 - Princípios e Conceitos. 5ª ed. Ouro Fino: Editora Agronômica Ceres, 2018. Cap. 34, p.319-419.

- PHADIKAR, S.; SIL, J.; DAS, A. K. Classification of rice leaf diseases based on morphological changes. **International Journal of Information and Electronics Engineering**, v. 2, n. 3, p. 460-463. 2012. DOI: <https://doi.org/10.7763/IJIEE.2012.V2.137>
- PINEDA, M.; PÉREZ-BUENO, M.L.; BARÓN, M., Detection of bacterial infection in melon plants by classification methods based on imaging data. **Frontiers in Plant Science**, v. 14, n. 9, 164. 2018. DOI: <https://doi.org/10.3389/fpls.2018.00164>
- PINEDA, M. et al. Use of multicolour fluorescence imaging for diagnosis of bacterial and fungal infection on zucchini by implementing machine learning. **Functional Plant Biology**, v. 44, n. 6, p.563-572. 2017. DOI: <https://doi.org/10.1071/FP16164>
- PISHCHIK, V. N. et al. Estimation of synergistic effect of humic fertilizer and *Bacillus subtilis* on lettuce plants by reflectance measurements. **Journal of Plant Nutrition**, v. 39, n. 8, p. 1074-1086. 2016. DOI: <https://doi.org/10.1080/01904167.2015.1061551>
- PLATT, J. Fast training of support vector machines using sequential minimal optimization. In: SCHOLKOPF, B.; BURGESS, C.; SMOLA, A. (Eds). **Advances in Kernel Methods – Support Vector Learning**, MIT Press. cap. 2. pag. 42-65. 1998.
- POBLETE, T. et al. Detection of *Xylella fastidiosa* infection symptoms with airborne multispectral and thermal imagery: Assessing bandset reduction performance from hyperspectral analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 162, p. 27-40. 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.02.010>
- PONZONI, F. J., SHIMABUKURO, Y. E., KUPLICH, T.M., 2012. **Sensoriamento Remoto da vegetação**, 2.ed. São Paulo: Oficina de Textos, 2012. 176p.
- PUKKELA, P.; BORRA, S. Machine learning based plant leaf disease detection and severity assessment techniques: State-of-the-Art. In: DEY, N. et al. **Lecture Notes in Computational Vision and Biomechanics**. 2018. cap.8, p. 199–226. DOI: https://doi.org/10.1007/978-3-319-65981-7_8
- RAHI, S. et al. Different Supervised and unsupervised classification approaches based on Visible/Near infrared. **Infrared Physics & Technology**, v. 108, p.103355. 2020. DOI: <https://doi.org/10.1016/j.infrared.2020.103355>
- RAID, R. N. Lettuce Diseases and their Management. In: NAQVI, S. A. M. H. (Ed.) **Diseases of Fruits and Vegetables**. **Kluwer Academic Publishers**. Printed in the Netherlands, p. 121-147. 2004. DOI: https://doi.org/10.1007/1-4020-2607-2_5
- RAZA, S-e-A. et al. Automatic detection of diseased tomato plants using thermal and stereo visible light images. **Plos One**, v. 10, n. 4, e0123262. 2015. DOI: <https://doi.org/10.1371/journal.pone.0123262>
- REHMAN, T. U et al. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. **Computers and Electronics in Agriculture**, v. 156, p. 585–605. 2019. DOI: <https://doi.org/10.1016/j.compag.2018.12.006>

- REN, D. D. W.; TRIPATHI, S.; LI, L. K. B. Low-cost multispectral imaging for remote sensing of lettuce health. **Journal of Applied Remote Sensing**, v. 11, n. 1, p. 016006. 2017. DOI: <https://doi.org/10.1117/1.JRS.11.016006>
- REN, J., PETZOLDT, R., DICKSON, M.H., Genetics and population improvement of resistance to bacterial soft rot Chinese cabbage. **Euphytica**, v. 118, n. 3, p. 271-280. 2001. DOI: <https://doi.org/10.1023/A:1017522501229>
- REYNOLDS, G. J. et al. Remote sensing for assessing Rhizoctonia crown and root rot severity in sugar beet. **Plant Disease**, v. 96, p. 497-505. 2012. DOI: <https://doi.org/10.1094/PDIS-11-10-0831>
- RÖMER, C. et al. Robust fitting of fluorescence spectra for pre-symptomatic wheat leaf rust detection with support vector machines. **Computers and Electronics in Agriculture**, v. 79, n. 2, p. 180–188. 2011. DOI: <https://doi.org/10.1016/j.compag.2011.09.011>
- ROUSE, W. J. et al. Monitoring vegetation systems in the great plains with ERTS. In: **Third Earth Resources Technology Satellite-1 Symposium**, Proceedings, NASA SP-351, NASA, Washington. 1973. v. 1, p. 309-317.
- RUMPF, T. et al. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. **Computers and Electronics in Agriculture**, v. 74, n. 1, p. 91–99. 2010. DOI: <https://doi.org/10.1016/j.compag.2010.06.009>
- SAHOO, R.N.; RAY S.S; MANJUNATH K.R. Hyperspectral remote sensing of agriculture. **Current Science**, v.108, p. 848-859. 2015.
- SALA, F. C.; COSTA, C. P. Retrospectiva e tendência da alfacicultura brasileira. **Horticultura Brasileira**, Brasília, v. 30, n. 2, p. 187-194, 2012. DOI: <https://doi.org/10.1590/S0102-05362012000200002>
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 44, n.1.2, p. 206–226. 2000. DOI: <https://doi.org/10.1147/rd.441.0206>
- SANCHO-ADAMSON, M. et al. Use of RGB vegetation indexes in assessing early effects of *Verticillium Wilt* of olive in asymptomatic plants in high and low fertility scenarios. **Remote Sensing**, v. 11, n. 6, 607, 2019. DOI: <https://doi.org/10.3390/rs11060607>
- SANDMANN, M.; GROSCH, R.; GRAEFE, J. The use of features from fluorescence, thermography, and NDVI imaging to detect biotic stress in lettuce. **Plant Disease**, v. 102, n. 6, p. 1101–1107. 2018. DOI: <https://doi.org/10.1094/PDIS-10-17-1536-RE>
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n.1, p. 1-13. 2010. DOI: <https://doi.org/10.1016/j.compag.2010.02.007>
- SAPATE, N. M.; DESHMUKH, R. R. Spectral and numerical analysis of hyper spectral data using vegetation indices. **International Journal of Engineering and Advanced Technology**, v. 8, n. 8, p. 2249 – 8958. 2019. DOI: <https://doi.org/10.35940/ijeat.F8578.088619>

SATYANARAYANA, N.; RAMALINGASWAMY, C.H.; RAMADEVI, Y. Survey of Classification Techniques in Data Mining. **International Journal of Innovative Science, Engineering & Technology**, v. 1, n. 9, p. 268-278. 2014.

SAWICKA, B. et al. Plant diseases, pathogens and diagnosis. In: EGBUNA, C.; SAWICKA, B. (Eds). **Natural Remedies for Pest, Disease and Weed Control**. cap. 2, p. 17-28. 2020. DOI: <https://doi.org/10.1016/B978-0-12-819304-4.00002-6>

SCHEUNDERS, P; TUIA, D.; MOSER, G. Contributions of machine learning to remote sensing data analysis. In: LIANG, S. (Ed.). **Comprehensive Remote Sensing**. cap. 2. p. 199–243. 2018. DOI: <https://doi.org/10.1016/B978-0-12-409548-9.10343-4>

SELVARAJ, M. G. et al. Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.169, p.110–124. 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.08.025>

SETIADI, T. et al. Implementation of Naïve Bayes method in food crops planting recommendation. **International Journal of Scientific & Technology Research**, v. 9, p. 4750-4755. 2020.

SILVA C. L. et al. Óleos essenciais e extratos vegetais no controle da podridão mole em alface crespa. **Horticultura Brasileira**, v. 30, p. 632-638. 2012. DOI: <https://doi.org/10.1590/S0102-05362012000400012>

SILVA, A. M. F. et al. Levantamento da intensidade da Podridão-mole em alface e couve-chinesa em pernambuco. **Caatinga**, v. 20, n.2, p.84-93, 2007.

SILVA, M. S. et al. Uso de antagonistas e produtos alternativos no manejo pós-colheita de podridão mole em pimentão. **Revista Ciência Agronômica**, v. 45, n. 4, p.718–725. 2014. DOI: <https://doi.org/10.1590/S1806-66902014000400009>

SINGH, A. et al. Machine Learning for High-Throughput Stress Phenotyping in Plants. **Trends in Plant Science**, v. 21, n. 2, p. 110-124. 2016. DOI: <https://doi.org/10.1016/j.tplants.2015.10.015>

SINGH, V.; SHARMA, N.; SINGH, S. A review of imaging techniques for plant disease detection. **Artificial Intelligence in Agriculture**, v. 4, p. 229–242. 2020. DOI: <https://doi.org/10.1016/j.aiaa.2020.10.002>

SINHA, R. et al. FAIMS based volatile finger printing for real-time postharvest storage infections detection in stored potatoes and onions. **Postharvest Biology and Technology**, v.135, p. 83–92. 2018. DOI: <https://doi.org/10.1016/j.postharvbio.2017.09.003>

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>

- SPERSCHNEIDER, J. et al. Effector P: predicting fungal effector proteins from secretomes using machine learning. **New Phytologist**, v. 210, n. 2, p. 743–761. 2015. DOI: <https://doi.org/10.1111/nph.13794>
- STARÝ, K. et al. Comparing RGB - based vegetation indices from UAV imageries to estimate hops canopy area. **Agronomy Research**, v.18, n. 4, p. 2592-2601. 2020.
- SU, J. et al. Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery. **Computers and Electronics in Agriculture**, v. 155, p.157–166. 2018. DOI: <https://doi.org/10.1016/j.compag.2018.10.017>
- SUGIURA, R. et al. Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. **Biosystems Engineering**, v. 148, p. 1-10. 2016. DOI: <https://doi.org/10.1016/j.biosystemseng.2016.04.010>
- SUN, J. et al. Identification of pesticide residues in lettuce leaves based on near infrared transmission spectroscopy. **Journal of Food Process Engineering**, v. 41, n. 6, p.12816. 2018. DOI: <https://doi.org/10.1111/jfpe.12816>
- SUN, Q.; ZHANG, X.; JIANG, M. Eco-environment variable estimation from remote sensed data and eco-environment assessment: models and system. **Acta Botanica Sinica**, v. 4, p. 1073-1080. 2011.
- TETILA, E. C. et al. Identification of soybean foliar diseases using unmanned aerial vehicle images. **Geoscience and Remote Sensing Letters**, v.14, n.12. 2017. DOI: <https://doi.org/10.1109/LGRS.2017.2743715>
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 150, 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)
- UMADEVI, S.; MARSELINE, K. S. J. A survey on data mining classification algorithms. **IEEE 2017 International Conference on Signal Processing and Communication**, p. 264–268. 2017. DOI: <https://doi.org/10.1109/CSPC.2017.8305851>
- USHA, K.; SINGH, B. Potential applications of remote sensing in horticulture - A review. **Scientia Horticulturae**, v. 153, p. 71-83. 2013. DOI: <https://doi.org/10.1016/j.scienta.2013.01.008>
- ÜSTÜN, B.; MELSSSEN, W.J.; BUYDENS, L.M.C. Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel. **Chemometrics and Intelligent Laboratory Systems**. v.81, n.1 p. 29–40. 2006. DOI: <https://doi.org/10.1016/j.chemolab.2005.09.003>
- VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995. 334 p. DOI: <https://doi.org/10.1007/978-1-4757-2440-0>

VIJVER et al. In-field detection of *Alternaria solani* in potato crops using hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 168, p.105106. 2019. DOI: <https://doi.org/10.1016/j.compag.2019.105106>

VILLAS BÔAS, R. L. et al. Efeitos de doses de compostos orgânicos na produção de alface em dois solos sob ambiente protegido. **Horticultura Brasileira**, v. 22, p. 28-34. 2004. DOI: <https://doi.org/10.1590/S0102-05362004000100006>

WANG, T. et al. Automatic Classification of Cotton Root Rot Disease Based on UAV Remote Sensing. **Remote Sensing**, v.12, n. 8, 1310. 2020a. DOI: <https://doi.org/10.3390/rs12081310>

WANG, T. et al. “A Plant-By-Plant Method to Identify and Treat Cotton Root Rot Based on UAV Remote Sensing.” **Remote Sensing**, v. 12, n. 15, 2453. 2020b. DOI: <https://doi.org/10.3390/rs12152453>

WEISS, M.; JACOB, F.; DUVEILLERC, 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>

WEST, J. S. et al. Detection of Fungal Diseases Optically and Pathogen Inoculum by Air Sampling. In: OERKE, E. C. et al. (Eds). **Precision Crop Protection - the Challenge and Use of Heterogeneity**. Springer Dordrecht Heidelberg, London. 2010. p. 135-149. DOI: https://doi.org/10.1007/978-90-481-9277-9_9

WIEGAND, C. L. et al. Vegetation indices in crop assessments. **Remote Sensing of Environment**, v. 35, n. 2-3, p. 105-119. 1991. DOI: [https://doi.org/10.1016/0034-4257\(91\)90004-P](https://doi.org/10.1016/0034-4257(91)90004-P)

WITTEN, I. H.; FRANK, E.; HALL, M. A. Algorithms: The Basic Methods. In: _____. **Data Mining: Practical Machine Learning Tools and Techniques**. 2011. cap. 4, p. 85–145. DOI: <https://doi.org/10.1016/B978-0-12-374856-0.00004-3>

YANG, X.; GUO, T. Machine learning in plant disease research. **European Journal of BioMedical Research**, v. 3, n.1, p. 6-9. 2017. DOI: <https://doi.org/10.18088/ejbmr.3.1.2017.pp6-9>

XIN, Z. et al. A deep learning based regression method on hyperspectral data for rapid prediction of cadmium residue in lettuce leaves. **Chemometrics and Intelligent Laboratory Systems**, v. 200, p.103996. 2020. DOI: <https://doi.org/10.1016/j.chemolab.2020.103996>

XINDONG, W. et al. Top 10 algorithms in data mining. **Knowledge and Information Systems**, v.14, n. 1, p.1-37. 2008. DOI: <https://doi.org/10.1007/s10115-007-0114-2>

XIONG, Y. et al. Application of the radial basis function neural networks to improve the nondestructive Vis/NIR spectrophotometric analysis of potassium in fresh lettuces. **Journal of Food Engineering**, v. 298, p.110417. 2020. DOI: <https://doi.org/10.1016/j.jfoodeng.2020.110417>

XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of Sensors**, p.1–17. 2017. DOI: <https://doi.org/10.1155/2017/1353691>

YANG, G. et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. **Frontiers in Plant Science**, v. 30, n. 8, 1111. 2017. DOI: <https://doi.org/10.3389/fpls.2017.01111>

YANG, J. et al. Hyperspectral prediction of sugarbeet seed germination based on gauss kernel svm. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 253. 2021.

ZARATE-VALDEZ, J. L. et al. Prediction of leaf area index in almonds by vegetation indexes. **Computers and Electronics in Agriculture**, v. 85, p. 24 -32. 2012. DOI: <https://doi.org/10.1016/j.compag.2012.03.009>

ZHANG, D. et al. Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. **Plos One**, v.13, n. 5. 2018. DOI: <https://doi.org/10.1371/journal.pone.0187470>

ZHANG, Y. et al. Vibrational Spectroscopy for Plant Varieties and Cultivars Characterization . In: DAMIA, B.; LOPES, J.; SOUSA, C. (Eds). **Disease Monitoring With Vibrational Spectroscopy**. 2018. cap 9, p. 227-251. DOI: <https://doi.org/10.1016/bs.coac.2018.03.006>

ZHANG, J. et al. Monitoring plant diseases and pests through remote sensing technology: A review. **Computers and Electronics in Agriculture**, v.165, p.104943. 2019. DOI: <https://doi.org/10.1016/j.compag.2019.104943>

ZHOU, X. et al. Development of deep learning method for lead content prediction of lettuce leaf using hyperspectral images, **International Journal of Remote Sensing**, v. 41, n. 6. 2019. DOI: <https://doi.org/10.1080/01431161.2019.1685721>

ZHOU, X. et al. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **Journal of Photogrammetry and Remote Sensing**, v. 130, p. 246–255. 2017. DOI: <https://doi.org/10.1016/j.isprsjprs.2017.05.003>

ZHU, Y. et al. Analysis of common canopy vegetation indices for indicating leaf nitrogen accumulations in wheat and rice. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, n.1, p. 1-10. 2008. DOI: <https://doi.org/10.1016/j.jag.2007.02.006>