

KAMILA FERNANDA ROSSATI

DETECÇÃO DE *Planococcus citri* EM CAFEEIRO POR 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. Dra. Vanessa Andaló Mendes de Carvalho

Co-orientador

Prof. Dr. George Deroco Martins

MONTE CARMELO  
MINAS GERAIS - BRASIL

2022

KAMILA FERNANDA ROSSATI

DETECÇÃO DE *Planococcus citri* EM CAFEEIRO POR 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".

APROVADO em 27/07/2022.

Profª. Dr(a). Vanessa Andaló Mendes de Carvalho - Universidade Federal de Uberlândia - UFU

Prof. Dr. George Demeo Martins - Universidade Federal de Uberlândia - UFU

Prof. Dr. Flávio Lemes Fernandes - Univesidade Federal de Viçosa - UFV Rio Paranaíba

---

Profª. Dra. Vanessa Andaló Mendes de Carvalho

ICIAG- UFU

(Orientadora)

MONTE CARMELO - MG

JULHO-2022

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

R827  
2022 Rossati, Kamila Fernanda, 1996-  
Detecção de Planococcus citri em cafeeiro por  
imagens multiespectrais [recurso eletrônico] :  
Detecção de Planococcus citri em cafeeiro por  
imagens multiespectrais / Kamila Fernanda Rossati.  
- 2022.

Orientadora: Vanessa Andaló Mendes de Carvalho.  
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.2022.425>

Inclui bibliografia.

1. Agronomia. I. Carvalho, Vanessa Andaló Mendes de ,  
1977-, (Orient.). II. Martins, George Deroco, 1987-,  
(Coorient.). III. Universidade Federal de Uberlândia.  
Pós-graduação em Agricultura e Informações Geoespaciais.  
IV. Título.

CDU: 631

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



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**  
 Coordenação do Programa de Pós-Graduação em Agricultura e Informações  
 Geoespaciais  
 Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-MG, CEP 38.500-000  
 Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	27/07/2022	Hora de início:	08:00	Hora de encerramento:	10:30
Matrícula do Discente:	32012AIG007				
Nome do Discente:	Kamila Fernanda Rossati				
Título do Trabalho:	Detecção de Planococcus citri em cafeeiro por 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 (<https://meet.google.com/yop-cujt-vcw>) a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. George Deroco Martins (UFU), Dr. Flávio Lemes Fernandes (Universidade Federal de Viçosa/Campus Rio Paranaíba), Dra. Vanessa Andaló Mendes de Carvalho (UFU) – orientadora da candidata.

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

A seguir 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

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 **Vanessa Andalo Mendes de Carvalho, Professor(a) do Magistério Superior**, em 27/07/2022, às 10:26, 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 **Flávio Lemes Fernandes, Usuário Externo**, em 27/07/2022, às 10:53, 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 27/07/2022, às 11:08, 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](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3789717** e o código CRC **3F0643E8**.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus e a Nossa Senhora pela a realização desse mestrado.

Aos meus pais, Marcos e Maria, minha irmã Kellin, que me auxiliaram como puderam.

Ao meu namorado Rafael, que esteve ao meu lado em todos os momentos de fraqueza me dando força para não desistir e conseguir chegar até o final deste sonho.

A minha orientadora Dr<sup>a</sup>. Vanessa Andaló Mendes de Carvalho, que não mediu esforços e dedicação para a realização deste trabalho.

Ao coorientador Dr. George Deroco Martins pela orientação e ensinamentos necessários para a realização desse trabalho.

Ao professor Flávio, da UFV de Rio Paranaíba pela disponibilidade em participar da minha banca e acrescentar informações no trabalho.

Aos produtores Osmar Junior Schicariou e Leandro Rodrigues pela disponibilização das áreas para a realização deste estudo.

Ao servidor Ms. Renan Zampiroli pela paciência na realização de todos os voos.

As integrantes do grupo de pesquisa NEPEA (Núcleo de Estudos em Entomologia Agrícola), Letícia pelo apoio na realização deste trabalho e por tornar as idas às fazendas mais divertidas.

E a todos aqueles que direta e indiretamente auxiliaram na realização deste trabalho.

Gratidão a todos!!!

## **BIOGRAFIA**

Kamila Fernanda Rossati – nascida em 15 de fevereiro de 1996 na cidade de Monte Carmelo – MG, filha de Maria Aparecida da Rocha Rossati e Marcos Antonio Rossati. Foi diplomada em Agronomia em 20 de agosto de 2019, pela Universidade Federal de Uberlândia – Campus Monte Carmelo. Durante a graduação foi bolsista na área de Microbiologia Agrícola do Programa Institucional de Bolsas de Iniciação Científica PIBIC/CNPq/UFU. Em março de 2020, na mesma Universidade, ingressou no curso de Pós Graduação em Agricultura e Informações Geospaciais, linha de pesquisa Sistemas Integrados de Produção Vegetal, subárea Entomologia Agrícola, submetendo-se à defesa da dissertação de julho de 2022.

## SUMÁRIO

RESUMO .....	i
ABSTRACT .....	ii
1. INTRODUÇÃO .....	1
2. REFERENCIAL TEÓRICO .....	3
2.1. Cultura do cafeeiro .....	3
2.2 <i>Planococcus citri</i> .....	5
2.3. Aprendizado de Máquina.....	6
2.3.1. <i>Redes Neurais Artificiais</i> .....	7
2.3.2. <i>Support Vector Machine (SMO)</i> .....	8
2.3.3. <i>Florestas aleatórias</i> .....	10
3. MATERIAL E MÉTODOS .....	11
3.1 Áreas de estudo.....	12
3.2 Aquisição das imagens .....	14
3.3 Coleta da reflectância das plantas.....	14
3.4 Classificação supervisionada.....	15
4. RESULTADOS E DISCUSSÃO .....	16
5. CONCLUSÕES.....	22
REFERÊNCIAS .....	23



## LISTA DE ILUSTRAÇÕES

FIGURA 1: Arquitetura de rede neural artificial

FIGURA 2: Hiperplanos para dados separáveis linearmente (a). Hiperplano e vetore suporte ótimos (b).

FIGURA 3: Fluxograma de uma floresta aleatória.

FIGURA 4: Fluxograma do desenvolvimento do estudo.

FIGURA 5: Croquis de distribuição das plantas amostradas para as áreas de Monte Carmelo (1); Coromandel- área sem cochonilha (2) e Coromandel- área com cochonilha (3).

FIGURA 6: Comportamento espectral de plantas de cafeeiro sadias e infestadas, calculados a partir de reflectância dos dosséis saudáveis e infestados.

FIGURA 7: Mapas de representação das plantas de sadias e infestadas, validação e classificadas incorretamente pelos algoritmos Redes Neurais Artificiais (RNA) e *Support Vector Machine* (SMO), para as áreas de Monte Carmelo (1); Coromandel (sadia-2) e Coromandel (infestada-3).

## LISTA DE TABELAS

TABELA 1: Intervalo de Kappa e concordância entre as classificações esperadas e observadas.

TABELA 2: Classificação supervisionada de plantas saudas e infestadas por *Planococcus citri* para diferentes classificadores para as áreas de Monte Carmelo e Coromandel – MG (plantas infestadas e saudas).

TABELA 3: Matriz de confusão por meio dos classificadores: Redes Neurais Artificiais, *Support Vector Machine* (SMO) e Florestas Aleatórias para as áreas de Monte Carmelo e Coromande – MG.

## RESUMO

ROSSATI, KAMILA FERNANDA. **Detecção de *Planococcus citri* em cafeeiro por imagens multiespectrais**. 2022. 39 f. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) - Universidade Federal de Uberlândia, Monte Carmelo, Minas Gerais, Brasil<sup>1</sup>.

A cultura do cafeeiro proporciona cerca de 125 milhões de empregos. No cafeeiro a cochonilha *Planococcus citri* é encontrada em reboleiras, e podem infestar ramos, folhas, botões florais e frutos, chegando a infestar todas as rosetas da planta e levando ao chochamento parcial ou perda total destes ramos. A amostragem não é realizada em função do custo e do tempo demandado para essa prática, por isso as aplicações ocorrem em área total. Dessa forma se faz necessário a introdução de tecnologias que possibilitem o fornecimento de informações para a melhor tomada de decisão no seu manejo. O estudo teve-se como objetivo verificar o potencial de uso de imagens multiespectrais de baixo custo na discriminação de plantas de cafeeiro infestadas por *P. citri*. Foram utilizadas três áreas de estudo, sendo a primeira no município de Coromandel, MG, uma com alta infestação de cochonilha e a segunda com ausência de cochonilha e uma área no município de Monte Carmelo, MG, com presença e ausência de cochonilha nas plantas avaliadas. Em cada área de estudo foram amostradas aleatoriamente 50 plantas, com distância mínima de 10 metros entre plantas, avaliando a quantidade de cochonilhas presentes em 2 ramos plagiotrópicos localizados no terço médio das plantas. As imagens foram obtidas utilizando um drone acoplado a uma câmera Mapir Survey 3W a uma altura de 100 metros. As classificações foram feitas utilizando os algoritmos Redes Neurais Artificiais (RNA), *Support Vector Machine* (SMO) e Florestas Aleatórias. Os resultados confirmaram a possibilidade de discriminação entre plantas saudáveis e infestadas por *P. citri* utilizando algoritmos baseados em aprendizado de máquina. Com relação à discriminação de plantas saudáveis e infestadas, o algoritmo Random Forest apresentou o melhor resultado em áreas com variabilidade de infestação (EG=90% e K=0,80), seguido pelo SMO (EG=83,34% e K=0,67) e RNA (EG=73,34% e K= 0,47).

**Palavras-chave:** aprendizado de máquina, cafeicultura, cochonilha-da-roseta, detecção de pragas, imagens multiespectrais.

## ABSTRACT

ROSSATI, KAMILA FERNANDA. **Detection of *Planococcus citri* in coffee by multispectral imaging**. 2022. 39 f. Dissertation (Master Program in Agriculture and Geoespacial Information) – Federal University of Uberlândia, Monte Carmelo, Minas Gerais, Brazil<sup>1</sup>.

Coffee growing provides around 125 million jobs. In the coffee plant, the mealybug *Planococcus citri* is found in reboleiras, and can infest branches, leaves, flower buds and fruits, reaching the point of infesting all the rosettes of the plant and leading to partial stunting or total loss of these branches. Sampling is not performed due to the cost and time required for this practice, so the applications occur in the total area. In this way, it is necessary to introduce technologies that allow the provision of information for better decision-making in its management. The objective of this study was to verify the potential of using low-cost multispectral images in the discrimination of coffee plants infested by *P. citri*. Three study areas were used, the first in the municipality of Coromandel, MG, one with a high infestation of cochineal and the second with no cochineal and an area in the municipality of Monte Carmelo, MG, with presence and absence of cochineal in the evaluated plants. . In each study area, 50 plants were randomly sampled, with a minimum distance of 10 meters between plants, evaluating the amount of mealybugs present in 2 plagiotropic branches located in the middle third of the plants. The images were obtained using a drone coupled to a Mapir Survey 3W camera at a height of 100 meters. The classifications were made using the algorithms Artificial Neural Networks (ANN), Support Vector Machine (SMO) and Random Forests. The results confirmed the possibility of discrimination between healthy and *P. citri* infested plants using algorithms based on machine learning. Regarding the discrimination of healthy and infested plants, the Random Forest algorithm showed the best result in areas with infestation variability (EG=90% and K=0.80), followed by SMO (EG=83.34% and K= 0.67) and RNA (EG=73.34% and K=0.47).

**Keywords:** machine learning, coffee growing, rosette mealybug, pest detection, multispectral imaging.

## 1. INTRODUÇÃO

A cultura do cafeeiro é uma das *commodities* mais negociadas em todo o mundo, somente no ano de 2017, 70% da produção total de café exportada somou um valor de US\$19 bilhões (ICO, 2019a; SALADO, 2018). Nesse mesmo ano, o setor teve um valor de mercado de varejo de US\$ 83 bilhões, proporcionando empregos para 125 milhões de pessoas (FAIRTRADE FOUNDATION, 2018; SALADO, 2018). O cafeeiro é cultivado em 12,5 milhões de fazendas em todo o mundo, das quais 67-80% são pequenas propriedades localizadas principalmente em países em desenvolvimento, incluindo 22 Países de Baixo Desenvolvimento Humano (PBDHs) (ICO, 2019b; PANHUYSSEN; JOOST, 2018). Os maiores países produtores e exportadores no ano de 2017, independentemente do nível de desenvolvimento humano, foram Brasil, Vietnã e Colômbia, enquanto que os maiores importadores em 2017 foram Estados Unidos, Alemanha e França, resultando em um excedente global de café de cerca de 250.000 toneladas métricas.

Considerando o aumento da população mundial, a produção agrícola terá que aumentar cerca de 60% em sua produtividade até o ano de 2050 em decorrência da diminuição da área agricultável por habitante (FAO, 2015). A busca por aperfeiçoamento das tecnologias através de sistemas inteligentes, a melhoria de processos e o manejo adequado da cultura são ferramentas utilizadas para aumentar a produtividade das lavouras (ARTIOLI; BELONI, 2016).

No cafeeiro, a cochonilha *Planococcus citri* (Risso) (Hemiptera: Pseudococcidae), causa danos das rosetas desde a floração até a colheita, sugando a seiva do botões florais (SANTA-CECÍLIA; REIS; SOUZA, 2002), contudo, podem se mobilizar para as raízes em função das condições ambientais (SANTA-CECILIA; SOUZA, 2005). Dessa forma, novas ferramentas para monitoramento de pragas se fazem necessárias, a fim de evitar a utilização irracional de inseticidas.

O controle de *P. citri* tem sido realizado basicamente utilizando defensivos agrícolas sintéticos, porém métodos alternativos naturais fazem-se necessários em virtude da necessidade de se dispor de novos compostos para o seu controle (SANTA-CECÍLIA et al., 2010). Os produtos existentes para o controle da praga possuem dificuldade para agirem sobre o inseto, que geralmente fica abrigado na planta e apresenta uma cobertura cerosa sobre o seu corpo (DEMIRCI et al., 2011). As aplicações de inseticidas para o controle de *P. citri* são realizadas, principalmente considerando os índices populacionais que poderiam ser obtidos por meio da amostragem convencional realizadas nas fazendas (monitoramento *in loco*). Entretanto, o

produtor não tem adotado essa prática de amostragem alegando problemas com altos custos e o tempo demandado para essa prática. Com isso, as aplicações ocorrem na maioria das vezes em área total e com intervalos de tempo determinados por calendários de aplicação, levando a um aumento de custos de produção, sendo que poderiam ter sido evitadas ou direcionadas à reboleira.

Diante dos entraves para o monitoramento populacional de *P. citri* realizado de forma convencional no cafeeiro e dos problemas decorrentes da sua presença, percebe-se a necessidade da introdução de tecnologias que possibilitem o fornecimento de informações para a melhor tomada de decisão no seu manejo, bem como reduzir os custos com insumos, visando uma produção adequada quanto aos critérios ecológicos e econômicos (FORMAGGIO; SANCHES, 2017). Entre essas ferramentas, a utilização de imagens aéreas, correlacionadas com às características agrônômicas das plantas, podem contribuir para a obtenção de uma agricultura mais sustentável (RESENDE et al., 2020).

A partir de imagens multiespectrais e da utilização de algoritmos baseados em aprendizado de máquina, além de informações coletadas *in situ*, aparadas com a caracterização favorável do ambiente ao desenvolvimento da praga, objetiva identificar um conjunto de atributos que facilitem a discriminação da praga no cafeeiro, sendo esses atributos submetidos posteriormente, ao processo de classificação supervisionada (WEISS; JACOB; DUVEILLER, 2020).

A utilização de aprendizado de máquina em doenças de plantas, é encontrado na literatura para detecção da podridão da antracnose utilizando o algoritmo k-vizinhos mais próximos (KNN) na China e nos Estados Unidos, utilizando o algoritmos Redes Neurais Artificiais para prever o fungo *Verticillium* sp. (LU et al., 2017; WHEELER et al., 2019). No entanto, pouco tem sido desenvolvido utilizando algoritmos para prever pragas e doenças no cafeeiro.

Insetos-praga vêm causando redução na qualidade de produção do café e produtividade no Brasil (SPONGOSKI; REIS; ZACARIAS, 2005). Existem poucos estudos sobre índices de pragas em cafeeiro, não só no Brasil, mas em todos os países onde a planta é cultivada. A estratégia mais comum para o controle de pragas é a aplicação de inseticidas foliares, dependendo da intensidade na região. Com o uso de algoritmos de aprendizado de máquina, os dados obtidos são aplicados para auxiliar na tomada de decisão de maior precisão quanto aos locais e momento adequado de aplicação para o controle das pragas (OLIVEIRA APARECIDO et al., 2020).

Sabe-se que é possível discriminar pragas em diversas culturas utilizando imagens, porém será possível discriminar plantas do cafeeiro infestadas com *P. citri* utilizando imagens multiespectrais?

Diante disso, tem-se como objetivo verificar o potencial de uso de imagens multiespectrais de baixo custo na discriminação de plantas do cafeeiro infestadas por *P. citri*.

## 2. REFERENCIAL TEÓRICO

### 2.1. Cultura do cafeeiro

O cafeeiro (*Coffea arabica* L.), pertence à família Rubiaceae, ordem Gentianales, com centro de origem na Etiópia, África. Existem mais de 500 gêneros e mais de 8.000 espécies desta família (PINO; VEGRO, 2008) e apresenta ampla distribuição nas Américas do Sul e Central, África e leste da Ásia, no qual o Brasil é o país onde se concentra a maior parte do cultivo, no qual 98% da produção está concentrada nos estados de Minas Gerais, São Paulo, Espírito Santo, Paraná e Bahia (DAMATTA; COCHICHO RAMALHO, 2006; FERRÃO et al., 2007).

A área plantada de café arábica no país soma 1,75 milhão de hectares, o que corresponde a 81,3% da área existente com lavouras de café. No ano de 2020, estima-se que a área plantada seja 1,4% em relação à safra passada. O estado de Minas Gerais concentra a maior área com a espécie, 1,22 milhão de hectares, o que corresponde, nesta safra, a 72,1% da área ocupada com café arábica em âmbito nacional. Nas regiões Triângulo, Alto Paranaíba e Noroeste mineiro, a área em produção teve um incremento de 4,2% em relação à safra de 2019, saindo de 185.688,2 para 193.472,6 de hectares, respectivamente. Nesta safra de 2020, a estimativa é que a produtividade se situe entre 28,53 e 30,36 sacas ha<sup>-1</sup>. A produtividade nas regiões Triângulo, Alto Paranaíba e Noroeste de Minas representaram 24,73 sacas ha<sup>-1</sup> na safra 2019, enquanto que na safra 2020, a produtividade representou 31,4 sacas ha<sup>-1</sup>. O café arábica representa cerca de 75% da produção total (arábica e conilon) de café do país. Estima-se que nessa safra, sejam colhidas entre 43,0 e 45,98 milhões de sacas. Essa previsão sinaliza aumento entre 26% e 34,1%, respectivamente, quando comparada à temporada anterior. Na safra 2020, a produção

deve chegar a 6074,9 mil sacas, enquanto que na safra 2019, a produção foi de 4591,9 mil sacas (CONAB, 2020).

O cafeeiro é um arbusto que apresenta crescimento contínuo, com dimorfismo de ramos, atingindo entre 2 a 4 metros de altura, variando conforme a espécie e as condições climáticas da região; as folhas são pareadas e opostas, ovais e de coloração verde escura (RENA; MAESTRI, 1986). O cafeeiro possui caule cilíndrico, lenho duro, branco amarelado e dois tipos principais de ramos: ortotrópico (do grego *orthós*: reto, normal) e plagiotrópicos (do grego *plágios*: oblíquo, transversal) (RENA; MAESTRI, 1986).

O cafeeiro é um cultivo muito sensível às condições climáticas (APARECIDO; ROLIM; SOUZA, 2015). A variabilidade climática causa forte impacto nas atividades agrícolas (JÚNIOR et al., 2012), sendo o principal fator responsável pelas flutuações e oscilações da produtividade de grãos de café (CAMARGO, 2010). Os elementos meteorológicos críticos na produção agrícola são a temperatura do ar, a radiação solar e a precipitação (HOOGENBOOM, 2000). Para o cafeeiro, a precipitação é um dos elementos que proporcionam maior interferência na fenologia do cafeeiro (CAMARGO, 2010).

Entre as pragas encontradas no cafeeiro, a cochonilha *P. citri*, possui uma rápida disseminação em lavouras cafeeiras, uma vez que, tanto os adultos quanto as ninfas são móveis e podem ser lavadas pelo vento ou migrando, através de locomoção própria, para outras plantas. Ao sugarem a seiva dessas plantas, esses insetos eliminam o excesso de seiva, conhecido como *honeydew* que atraem formigas as quais auxiliam na sua dispersão (WILLIAMS; WILLINK, 1992). A população dessa praga aumenta sensivelmente a partir de setembro, época de início das irrigações para indução do florescimento do cafeeiro, e se prolonga até março/abril, período no qual a ocorre diminuição da população dessa praga. Os prejuízos podem atingir 100% da produção em lavouras que possuem alta infestação, devido à sua uniforme distribuição no campo (FORNAZIER et al., 2000).

Para o controle dessa praga, utiliza-se o controle com produtos químicos, por meio da utilização de pulverizações na parte aérea das plantas. Atualmente, todos os inseticidas registrados para a cultura pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) são do grupo químico dos organofosforados, a base do ingrediente ativo clorpirifós. Entretanto, apesar desses produtos apresentarem boa eficácia, são tóxicos ao ser humano e ao ambiente, além de afetarem a população de inimigos naturais das pragas. Assim, surge como necessidade a implantação de métodos alternativos, que não apresentem os mesmos problemas, como é o caso do controle biológico (BORGHI et al., 2019).



## 2.2 *Planococcus citri*

A cochonilha *P. citri*, também conhecida como cochonilha-branca ou cochonilha-branca-das-rosetas, consiste em uma praga severa de grande quantidade de plantas economicamente importantes em todo o mundo (COX, 1981). No cafeeiro, podem causar danos desde a floração até a colheita, sugando a seiva dos frutos e dos botões florais (SANTA-CECÍLIA; REIS; SOUZA, 2002), no entanto, podem se mobilizar para as raízes em função das condições ambientais (SANTA-CECILIA; SOUZA, 2005).

*Planococcus citri* foi constatada como problema para a cafeicultura desde a safra 1999/2000 causando quedas de flores e frutos recém formados de café Robusta (FORNAZIER; MARTINS; PRATISSOLI, 2015; RUNG; MILLER; SCHEFFER, 2009). Atualmente sua importância tem aumentado pela ocorrência e elevação dos níveis populacionais nas lavouras. Por se tratar de uma praga de ocorrência esporádica, pouco se tem conhecimento de sua biologia em cultivares de cafeeiro cultivados em condições brasileiras (SANTA-CECÍLIA et al., 2009).

A cochonilha-branca é conhecida por sua elevada ocorrência em lavouras cafeeiras em diversas regiões de cultivo. As fêmeas desses insetos medem cerca de 2,5 a 4 mm de comprimento, apresentam formato oval, corpo com tegumento mole, geralmente coloração castanha amarelada e recoberto por uma secreção pulverulenta de cera branca, que lhes confere um aspecto de terem sido envolvidas por farinha. As fêmeas adultas vivem por cerca de 90 dias, podendo depositar de 200 a 400 ovos durante esse período (SANTA-CECÍLIA et al., 2005).

A cochonilha fêmea possui três estágios ninfais, denominados de instares, sendo cada estágio larval separado por uma muda. A ninfa se assemelha à fêmea adulta na aparência, exceto pelo fato de ser menor. O primeiro estágio ninfal dura entre 7 a 17 dias, o segundo de 5 a 13 dias e o terceiro de 5 a 14 dias. Podem começar a pôr os ovos entre 15 a 26 dias em sua vida adulta.

O macho de *P. citri* possui quatro estágios ninfais durante o seu desenvolvimento e cada estágio ninfal é separado por uma muda. A ninfa masculina é mais alongada ou estreita e geralmente ocorre em um casulo frouxo. Como base em estudos realizados com folha de café, a primeira fase da ninfa masculina dura entre 7 a 14 dias, a segunda de 6 a 16 dias, a terceira de 2 a 3 dias e a quarta de 1 a 6 dias. Aproximadamente 4 dias após o início do segundo ínstar, uma coloração preta que é facilmente discernível se desenvolve ao redor do corpo do inseto. Dois dias após, a ninfa começa a girar em seu casulo. Este casulo é continuamente girado,

aumentando em densidade até que a cochonilha alada adulta esteja pronta para emergir duas mudas depois. O macho adulto é um minúsculo inseto parecido com um mosquito de duas asas. Possui corpo alongado, de cor avermelhada e dois longos filamentos na extremidade posterior. Os cochonilhas machos vivem de 2 a 4 dias após a muda da larva final (inseto de vida curta) (ASIEDU; AFUN; KWOSEH, 2014).

Esses insetos vivem em colônias constituídas por indivíduos em vários estádios de desenvolvimento e, tanto as ninfas como as fêmeas adultas sugam a seiva dos botões florais e dos frutos em desenvolvimento, ocasionando assim, danos nas rosetas desde a floração até a colheita. Os frutos atacados caem de forma prematura, podendo em uma alta infestação de cochonilhas causar prejuízos de aproximadamente 100% (SANTA-CECÍLIA et al., 2005). Os danos decorrentes do ataque de *P. citri* são observados desde até a colheita e ocasiona o chocamento ou queda dos botões florais e frutos, conhecido pelo produtor como “roseta banguela” (SANTA-CECÍLIA et al., 2008).

### **2.3. Aprendizado de Máquina**

O aprendizado de máquina é o campo científico que atribui às máquinas a capacidade de aprender sem ser estritamente programado (SAMUEL, 2000). É considerada uma das principais áreas da Inteligência artificial. Para uma máquina se tornar inteligente como a mente humana, ela precisa primeiro pensar e aprender como um humano, uma vez que, a mente humana aprende com dados e experiências passadas às quais é exposta e com base em quais decisões tomar no futuro. Por sua vez, para uma máquina exibir inteligência, ela precisa interpretar os dados de entrada e os resultados, além de simplesmente seguir as instruções nesses dados. Isso é o que os algoritmos de aprendizado de máquina fazem (DURGABAI; BHARGAVI; JYOTHI, 2018).

As tarefas de aprendizado de máquina são geralmente classificadas em diversas categorias, como o tipo de aprendizagem (supervisionado/não supervisionado) e a técnica de aprendizagem (ex.: classificação, regressão, agrupamento, redução de dimensionalidade etc.). Para isso, a partir de modelos de aprendizado de máquina, como: 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).

Alguns artigos demonstram a utilidade do aprendizado de máquina em sistemas de produção agrícola, tais como manejo das culturas (previsão de produção, detecção de doenças, detecção de plantas daninhas, qualidade da cultura e reconhecimento de espécies), gestão de gado (bem-estar animal e produção de gado), gestão de água e também no manejo do solo (LIAKOS et al., 2018).

Diferentes abordagens de aprendizado de máquina para fenotipagem de estresse biótico e abiótico e melhoramento de plantas, que podem ser implantados na identificação, classificação, qualificação e também na previsão, a partir de diferentes plataformas e sensores remotos para a obtenção de imagens (SINGH et al., 2016).

Comparando os métodos de aprendizado de máquina, foram avaliados a viabilidade da detecção de grandes áreas com Huanglongbing (HLB) ou greening, a partir de imagens multiespectrais RGN obtidas por VANT. Baseados 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 (LAN et al., 2020).

### 2.3.1. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) é um mecanismo de processamento de dados e recebe esse nome, pois compartilha algumas características de funcionamento com as redes artificiais biológicas (GALVÃO et al., 2018). As redes neurais apresentam neurônios artificiais que imitam o comportamento dos neurônios biológicos. Esse neurônio artificial possui várias entradas, que representam as conexões sinápticas com outras unidades semelhantes a ele, e uma saída, na qual o valor depende de modo direto da soma ponderada de todas as saídas de neurônios ligados a esse neurônio (MATSUNAGA, 2012) (Figura 1).




FIGURA 1: Arquitetura de rede neural artificial. Fonte: Bre; Gimenez; Fachinotti (2018).

O sistema é composto por um grande número de elementos de processamento altamente interconectados denominados de neurônios, que trabalham em conjunto para resolver um problema e transmitir informações por meio de sinapses (conexões eletromagnéticas). Os neurônios estão intimamente interligados e organizados em camadas. A camada de entrada (input layer) recebe os dados, enquanto que a camada de saída (output layer) gera o resultado. Entre as duas camadas, uma ou duas camadas ocultas (hidden layer) são tipicamente intercaladas (DASTRES; SOORI, 2021).

### 2.3.2. Support Vector Machine (SMO)

Máquina de Vetores Suporte (do inglês *Support Vector Machine* – SMO), é uma técnica de aprendizado de máquina supervisionada que é amplamente utilizada para reconhecimento,

classificação ou regressão de padrões (CORTES; VAPNIK, 1995; UMADEVI; MARSELINE, 2017).

O SMO baseia-se na teoria de aprendizagem estatística em que determina a localização dos limites de decisão (hiperplanos) que proporcionam a separação ótima de classes (VAPNIK, 1995).

No reconhecimento de padrões de duas classes, por exemplo, que são linearmente separáveis, o SMO, entre vários hiperplanos possíveis que podem separar duas classes (Figura 2), seleciona somente um hiperplano capaz de fornecer uma margem máxima entre as duas classes (Figura 2b), denominado de hiperplano ótimo (Optimum Hyper Plane). Os pontos que delimitam a largura da margem, que são utilizados para medir a margem, denominam-se vetores de suporte (Support Vectors) (KAVZOGLU; COLKESEN, 2009; VAPNIK, 1995).

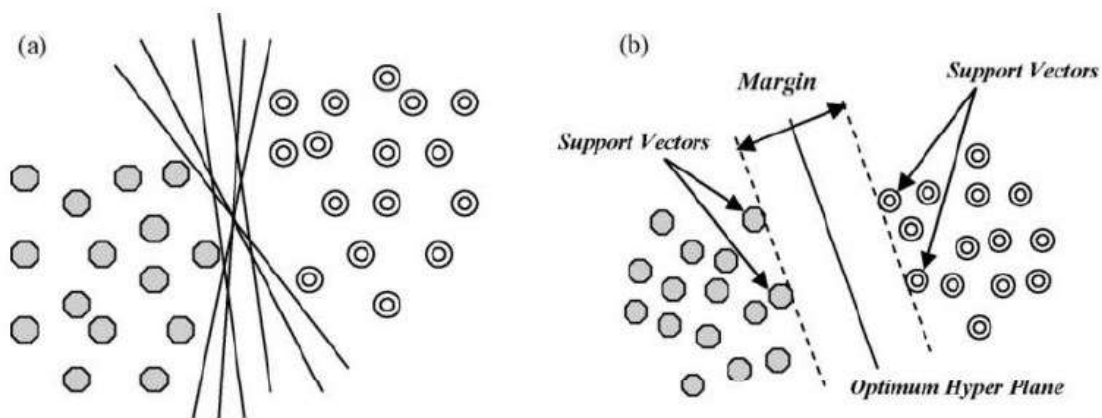


FIGURA2: Hiperplanos para dados separáveis linearmente (a). Hiperplano e vetore suporte ótimos (b). Fonte: Kavzoglu e Colkesen (2009).

O SMO, uma das abordagens mais influentes na comunidade de pesquisa, presente entre os 10 principais algoritmos de mineração de dados (WU 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 plantas daninhas, qualidade da cultura, manejo do solo e também na detecção de doenças (LIAKOS et al., 2018).

Existem vários modelos e técnicas para a extração de características, segmentação e classificação de padrões de folhas, a fim de identificar doenças foliares de plantas e estimativa

de severidade, sendo o SMO considerado significativo para classificação de doenças e sua gravidade (PUKKELA; BORRA, 2018).

### 2.3.3. Florestas aleatórias

Florestas aleatórias é um método de aprendizagem conjunto que opera por construir um grande número de árvores de decisão durante o processo de treinamento (BREIMAN, 2001). Uma árvore de decisão é um modelo não paramétrico, que é descrito por um gráfico em forma de árvore e é utilizado em tarefas de classificação e regressão. Em uma árvore de decisão, a relação entre os recursos e a variável de destino é representada por uma série de condições conjuntas que são organizadas em uma estrutura semelhante a uma árvore de cima para baixo (REIS; BARON; SHAHAF, 2018) (Figura 3).

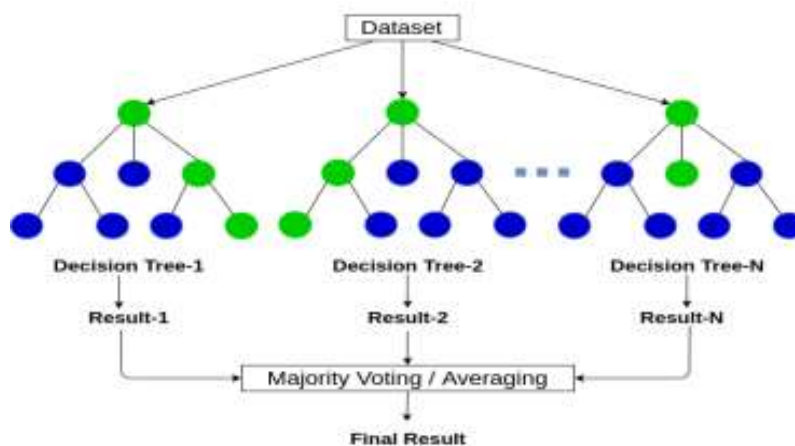


FIGURA 3: Fluxograma de uma floresta aleatória. Fonte: Abdulkareem; Abdulazeez (2021).

As florestas aleatórias é um método não paramétrico de classificação avançada e árvore de regressão que tem sido amplamente adotado em muitos campos científicos, inclusive para prever habitat adequado de várias espécies de plantas e animais (CUTLER et al., 2007; MARMION et al., 2009; MORIN; THUILLER, 2009; PRASAD et al., 2006) e interpretação da expressão gênica (BUREAU et al., 2005; DÍAZ-URIARTE; ALVAREZ DE ANDRÉS, 2006; LUNETTA et al., 2004). A maioria das aplicações das florestas aleatórias tem se

concentrado em sua utilidade como ferramenta de classificação, com apenas estudos limitados explorando suas capacidades de regressão para prever a produtividade do ecossistema ou da cultura (FUKUDA et al., 2013; MUTANGA; ADAM; CHO, 2012; VINCENZI et al., 2011).

Vários estudos apontaram para uma série de vantagens promissoras, bem com com desvantagens das florestas aleatórias como ferramenta de regressão sobre os modelos de regressão tradicionais (BERK, 2008; BREIMAN, 2001; GROMPING, 2009). Até o momento, as aplicações de regressão de florestas aleatórias nas áreas de agronomia e ciência agrícola permanecem escassas, com poucas exceções (FUKUDA et al., 2013).

### 3. MATERIAL E MÉTODOS

A Figura 4 consta o fluxograma geral de como o estudo foi realizado, sendo as etapas desenvolvidas detalhadas posteriormente.

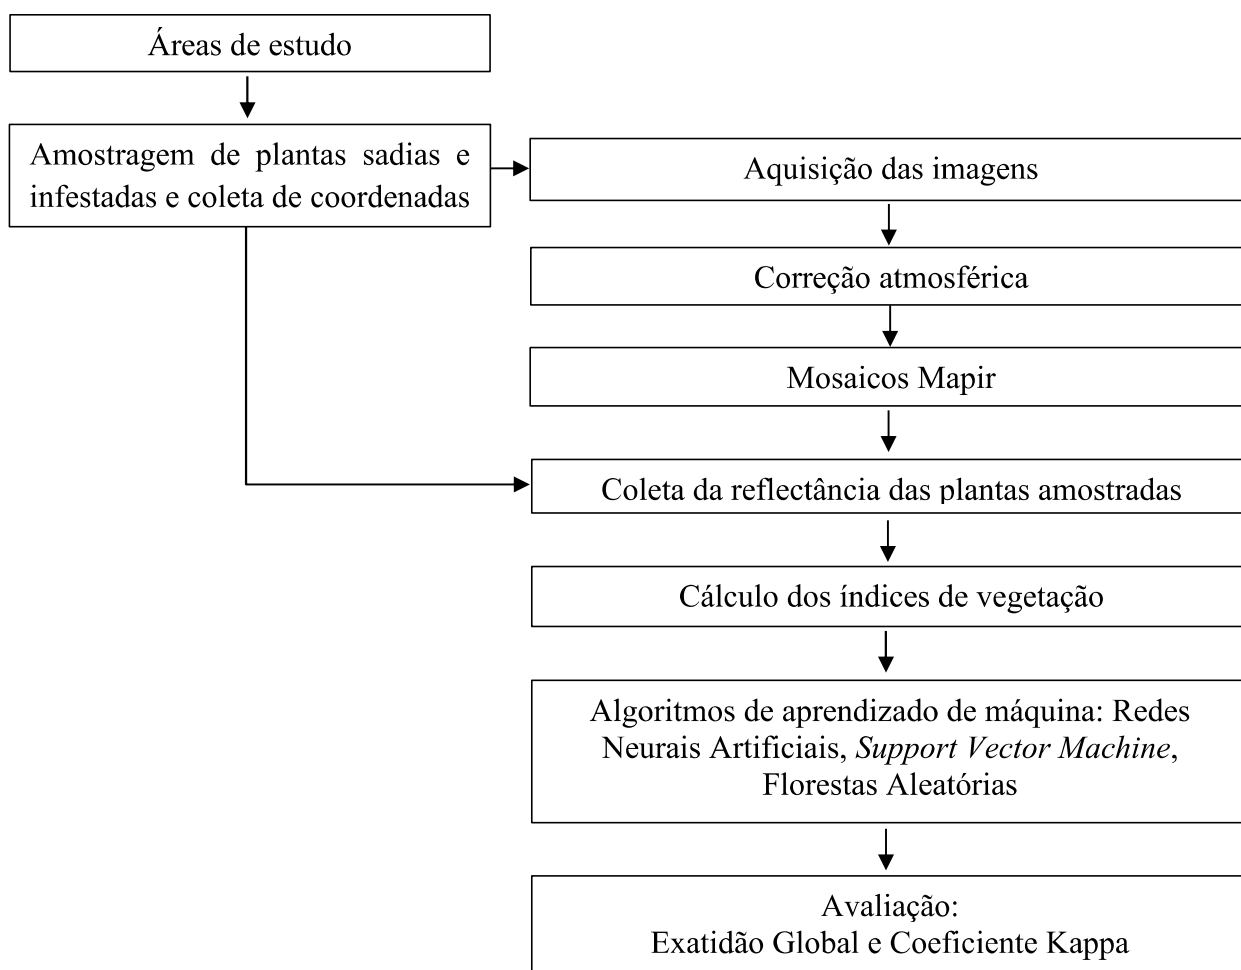


FIGURA 4: Fluxograma do desenvolvimento do estudo.

### 3.1 Áreas de estudo

O estudo foi realizado em três áreas cafeeiras pertencentes à espécie *C. arabica*, localizadas nos municípios de Coromandel e Monte Carmelo, MG. No município de Monte Carmelo, a lavoura é constituída por cafeeiros da variedade Arara com 3 anos de idade e aproximadamente 46 hectares, sendo caracterizada pela presença e ausência de plantas infestadas com cochonilha-da-roseta. No município de Coromandel, o estudo ocorreu em duas áreas, sendo a primeira constituída de cafeeiro da variedade Topázio com 4,5 anos de idade, aproximadamente 17 hectares e caracterizada pela ausência de cochonilha-da-roseta. A segunda área em Coromandel possui cafeeiro da mesma variedade e idade, porém com aproximadamente 6,4 hectares e apresenta alta incidência de cochonilha-da-roseta (Figura 5).

Em ambas as áreas foi realizada a amostragem aleatória das plantas, além da coleta das coordenadas geográficas (latitude e longitude) de cada ponto. Em cada área foram avaliados 50 plantas aleatoriamente, com uma distância mínima entre plantas de 10 metros. A amostragem foi realizada em ziguezaque, na qual foram avaliadas a quantidade de cochonilhas presente em 2 ramos plagiotrópicos das plantas localizados no terço médio das plantas.






FIGURA 5: Croquis de distribuição das plantas amostradas para as áreas de Monte Carmelo (1); Coromandel- área sem cochonilha (2) e Coromandel- área com cochonilha (3).

### 3.2 Aquisição das imagens

Os voos foram realizados entre 11 e 13 horas em ambas as áreas. As imagens foram obtidas utilizando um veículo aéreo não tripulado (VANT) Phantom 4 Pro da DJI (Dà-Jiang Innovations Science and Technology Co), o qual possui câmera visível convencional com os canais azul (480 nm), verde (550 nm) e vermelho (650 nm) (RGB). Acoplada ao VANT, a câmera Mapir Survey 3W com resolução de 12 megapixels, com canais correspondes ao verde (550 nm), vermelho (660 nm) e infravermelho próximo (850 nm).

Em todos os voos, o planejamento do voo foi realizado utilizando o software DroneDeploy©, com altitude de 100 metros, velocidade de 4 m s<sup>-1</sup>, sobreposição longitudinal e lateral de 75% e 70%, respectivamente.

Após a aquisição das imagens, estas foram submetidas ao software Mapir Camera Control (MCC) para correção atmosférica.

### 3.3 Coleta da reflectância das plantas

No software Envi 5.3 (Environment for Visualizing Images), por meio da ferramenta Pixel Locator foi localizada cada planta amostrada com as respectivas coordenadas (latitude e longitude) coletadas em campo. Com auxílio da função ROI Tool (Region of Interest), cada planta teve sua área foliar delimitada, sendo posteriormente, coletada as reflectâncias das bandas 1, 2 e 3 (IVP, vermelho e verde, respectivamente).

Com o valor das reflectâncias das plantas sadias e infestadas de cada área, calculou-se dois índices de vegetação (Equações 1 e 2), que são índices sensíveis à clorofila das plantas, a fim de que compusessem os dados de classificação.

$$\text{NDVI} = \frac{\text{IVP} - \text{vermelho}}{\text{IVP} + \text{vermelho}} \quad (1)$$

Onde: NDVI = Índice de vegetação por diferença normalizada; IVP = infravermelho próximo

$$\text{GNDVI} = \frac{\text{IVP} - \text{verde}}{\text{IVP} + \text{verde}} \quad (2)$$

Onde: GNDVI = Índice de vegetação por diferença normalizada verde; IVP = infravermelho próximo.

O índice da diferença normalizada, do inglês Normalized Difference Vegetation Index (NDVI) foi desenvolvido para pastagens, com a finalidade de mostrar a correlação com a biomassa verde acima do solo (ROUSE et al., 1973).

Dada a capacidade de análise do NDVI em plantas, existe alta correlação entre o índice NDVI adquirido por VANT e os sintomas foliares de doença de videira e também a discriminação entre plantas sintomáticas e assintomáticas (DI GENNARO et al., 2016). Esse índice também apresenta o melhor desempenho para detectar 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 (ZHANG et al., 2018).

O índice de vegetação por diferença normalizada verde, do inglês Green Normalized Difference Vegetation Index (GNDVI), mostrou ser muito preciso para avaliar o conteúdo de clorofila (GITELSON; KAUFMAN; MERZLYAK, 1996). A utilização do GNDVI pode ser considerado um preditor confiável da biomassa e absorção de nitrogênio de forragem e também do rendimento e absorção de nitrogênio de grãos de trigo de inverno (MOGES et al., 2004).

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

### **3.4 Classificação supervisionada**

Para a discriminação de plantas saudáveis e infestadas por *P. citri*, foram realizadas classificações utilizando os algoritmos Redes Neurais Artificiais, Support Vector Machine e Florestas Aleatórias, implementado no programa Waikato Environment for Knowledge Analysis – Weka 3.9.5.

Para a classificação no software Weka, foram considerados como classes plantas saudáveis (plantas com ausência de cochonilha) e cochonilha (plantas com a presença da praga).

Para a classificação foram utilizados 80% dos dados para treinamento e 20% para teste para todos os algoritmos. Para tanto, deve-se ressaltar que foram utilizadas para treinamento e validação da classificação 60 e 15 plantas para cada classe, respectivamente.

A performance dos algoritmos foi analisada utilizando a exatidão global (EG) (equação 3) e o coeficiente Kappa (equação 4) (JENSEN, 2016). Os intervalos do coeficiente Kappa e a

respectiva concordância (WANG et al., 2020) estão apresentados na tabela 1. Esses elementos de avaliação foram calculados pelo software Weka.

$$EG = \frac{\sum_{i=1}^k n_{ii}}{N} \quad (3)$$

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

$$K = \frac{N * \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_i * x_{+i})}{N^2 - \sum_{i=1}^k (x_i * x_{+i})} \quad (4)$$

Onde:  $K$  = número de linhas das matriz de confusão;  $x_{ii}$  = valor na linha  $i$  e coluna  $i$ ;  $x_i$  e  $x_{+i}$  são totais para a linha  $i$  e coluna  $i$ , respectivamente e  $N$  = número total de amostras.

TABELA 1: 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; Koch (1977).

Anteriormente às classificações, os espectros médios foram analisados e representados graficamente a partir dos espectros médios das plantas infestadas e saudáveis.

#### 4. RESULTADOS E DISCUSSÃO

Ao analisar o comportamento espectral das plantas avaliadas, pode-se observar uma diferença entre os valores de reflectância de plantas saudáveis e infestadas por *P. citri* no infravermelho próximo em decorrência da perda de biomassa e do índice de área foliar das plantas afetadas (Figura 6).

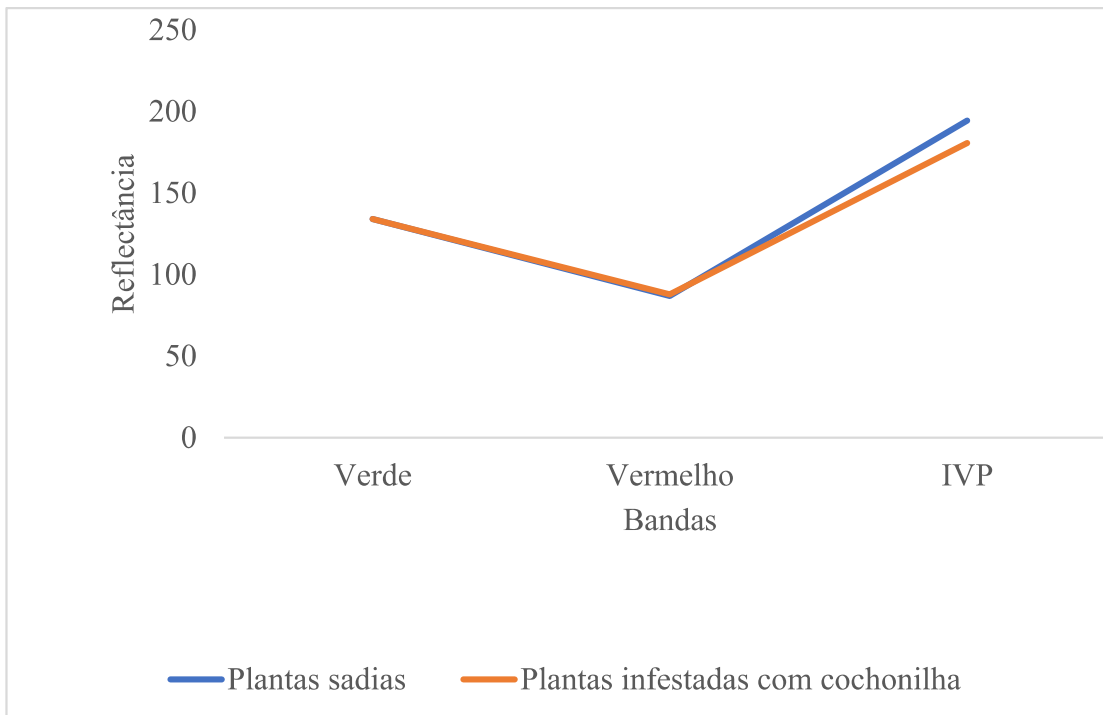


FIGURA. 6. Comportamento espectral de plantas de cafeeiro sadias e infestadas, calculados a partir de reflectância dos dosséis saudáveis e infestados.

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 assim, a reflectância (WEST et al., 2010).

Por meio de UAV para a detecção de pereiras infectadas com *Erwinia amylovora*, as bandas do infravermelho próximo, bem como as bandas do vermelho e verde, foram consideradas adequadas; no entanto, como não há sintoma visual no primeiro estágio de infecção, a faixa do infravermelho próximo pode ser considerada mais adequada para a detecção precoce, uma vez que, a estrutura interna da folha altera a absorção de luz (BAGHERI, 2020). Dados espectrais no intervalo do infravermelho próximo, podem auxiliar na detecção de plantas de amendoim (WANG et al., 2020) em estágio inicial de murcha bacteriana (*Ralstonia solanacearum*), em que o xilema está ligeiramente afetado e as folhas ainda verdes (CHEN et al., 2020).

O classificador Random Forest, obteve uma acurácia de 90% e um índice kappa de 0,8, representando uma concordância substancial (WANG et al., 2020), demonstrando assim, a capacidade de detecção, distinção entre plantas sadias e infectadas. Os classificadores Redes

Neurais Artificiais e *Support Vector Machine*, obtiveram uma exatidão global de 73,34% e 83,33%, respectivamente. Os índices kappa foram de 0,47 para o classificador Redes Neurais, demonstrando uma concordância moderada. Já para o classificador o índice Kappa de 0,67, o que significa uma concordância substancial (WANG et al., 2020) (Tabela 2).

TABELA 2: Classificação supervisionada de plantas sadias e infestadas por *Planococcus citri* para diferentes classificadores para as áreas de Monte Carmelo e Coromandel – MG (plantas infestadas e sadias).

Índices	Classificadores		
	RNA	SMO	RF
Exatidão global	73,34	83,33	90
Índice Kappa	0,47	0,67	0,8

RNA: Redes Neurais Artificiais; SMO: *Support Vector Machine*; RF: Random Forest

Trabalhos mapeando a incidência de nematoides na cultura cafeeira o índice kappa e a exatidão global apresentarem valores de 0,72 e 81%, respectivamente. Conforntando o valor do índice Kappa calculado com os intervalor apresentados na tabela de referência, a classificação pode ser definida como “substancial”. Da mesma forma, a exatidão global também apresentou um resultado considerável, sendo este acima de 80% (ABREU JÚNIOR et al., 2020).

Para constatar a validade da classificação MAXVER, para imagens obtidas a partir de uma câmera Mapir também foram determinados os valores de índice Kappa e exatidão global, sendo estes iguais a 0,75 e 84%, resprescitivamente. De acordo com os valores de referência, através de Kappa pode-se determinar a classificação como “substancial”, visto que, seu valor está compreendido entre 0,6 e 0,8. O valor de exatidão global também retornou um valor significativo, sendo este um pouco maior que o índice Kappa, uma vez que, ele é mais criterioso no seu cálculo (ABREU JÚNIOR et al., 2020).

Avaliando o potencial de imagens multiespectrais na detecção de nematoides em cafeeiros, analisando as combinações nas bandas do vermelho e IVP, e IVP e NDVI, apresentaram índice Kappa acima de 0,9 e exatidão global superior a 90%, assim, estas

combinações podem ser classificadas como quase perfeitas (WANG et al., 2020; XAVIER et al., 2019).

Na combinação das bandas do vermelho limítrofe, apresentou um índice Kappa de 0,554, demonstrando uma combinação moderada (WANG et al., 2020), e uma exatidão global acima de 70% (XAVIER et al., 2019).

Os dados radiométricos e os parâmetros agronômicos das plantas saudas e infectadas com *Pectobacterium carotovorum* subsp. *carotovorum*, classificados por dois algoritmos de aprendizado de máquina (SMO e Naive Bayes) em sete intervalos de avaliação do experimento (4, 8, 12, 16, 20, 24, 28 dias após a inoculação), demonstram que a exatidão global variou para o classificador SMO de 29,41 a 100% , e o coeficiente Kappa variou de -0,42 a 1 (CARMO et al., 2021).

No geral, aos 24 dias após inoculação foi possível observar os melhores resultados, tanto para os subconjuntos multiespectrais, quanto para o sensor visível. Exceto o subconjunto dos índices multiespectrais, todos os demais classificadores, obtiveram exatidão global de 100% (k=1), o que corresponde uma concordância perfeita (WANG et al., 2020). Já os parâmetros agronômicos obtiveram uma concordância substancial (k=0,76) (CARMO et al., 2021).

Por fim, aos 28 DAI o coeficiente Kappa abaixo de zero foram os mais comuns, ou seja concordância pobre, enquanto os parâmetros agronômicos foram superiores e indicaram concordância moderada (k=0,41 a 0,6) (CARMO et al., 2021; WANG et al., 2020).

Para as áreas avaliadas, o classificador Random Forest obteve uma acurácia de 90%, uma vez classificou corretamente 27 plantas (14 saudas e 13 infectadas), porém uma planta sadia foi classificada como infectada por *P. citri* e 2 plantas infectadas foram classificadas como saudas. O algoritmo Redes Neurais Artificiais classificou corretamente 22 plantas, enquanto 8 foram classificadas incorretamente, sendo 3 classificadas como saudas e 5 como infectadas. Já para o classificador SMO, foram classificadas corretamente 25 plantas, sendo 5 plantas saudas classificadas como infectadas (Tabela 3).

TABELA 3: Matriz de confusão por meio dos classificadores: Redes Neurais Artificiais, *Support Vector Machine* (SMO) e Florestas Aleatórias para as áreas de Monte Carmelo e Coromande – MG.

Matriz de confusão	Classificadores					
	Redes Neurais		SMO		Random Forest	
	a	b	a	b	A	b
a	12	3	10	5	14	1
b	5	10	0	15	2	13

a: plantas saudáveis; b: plantas infestadas com cochonilha

Na Figura 7 é possível distinguir as plantas que foram utilizadas para treino e para validação do modelo, bem como as plantas que foram classificadas incorretamente pelos algoritmos Redes Neurais Artificiais e *Support Vector Machine*.



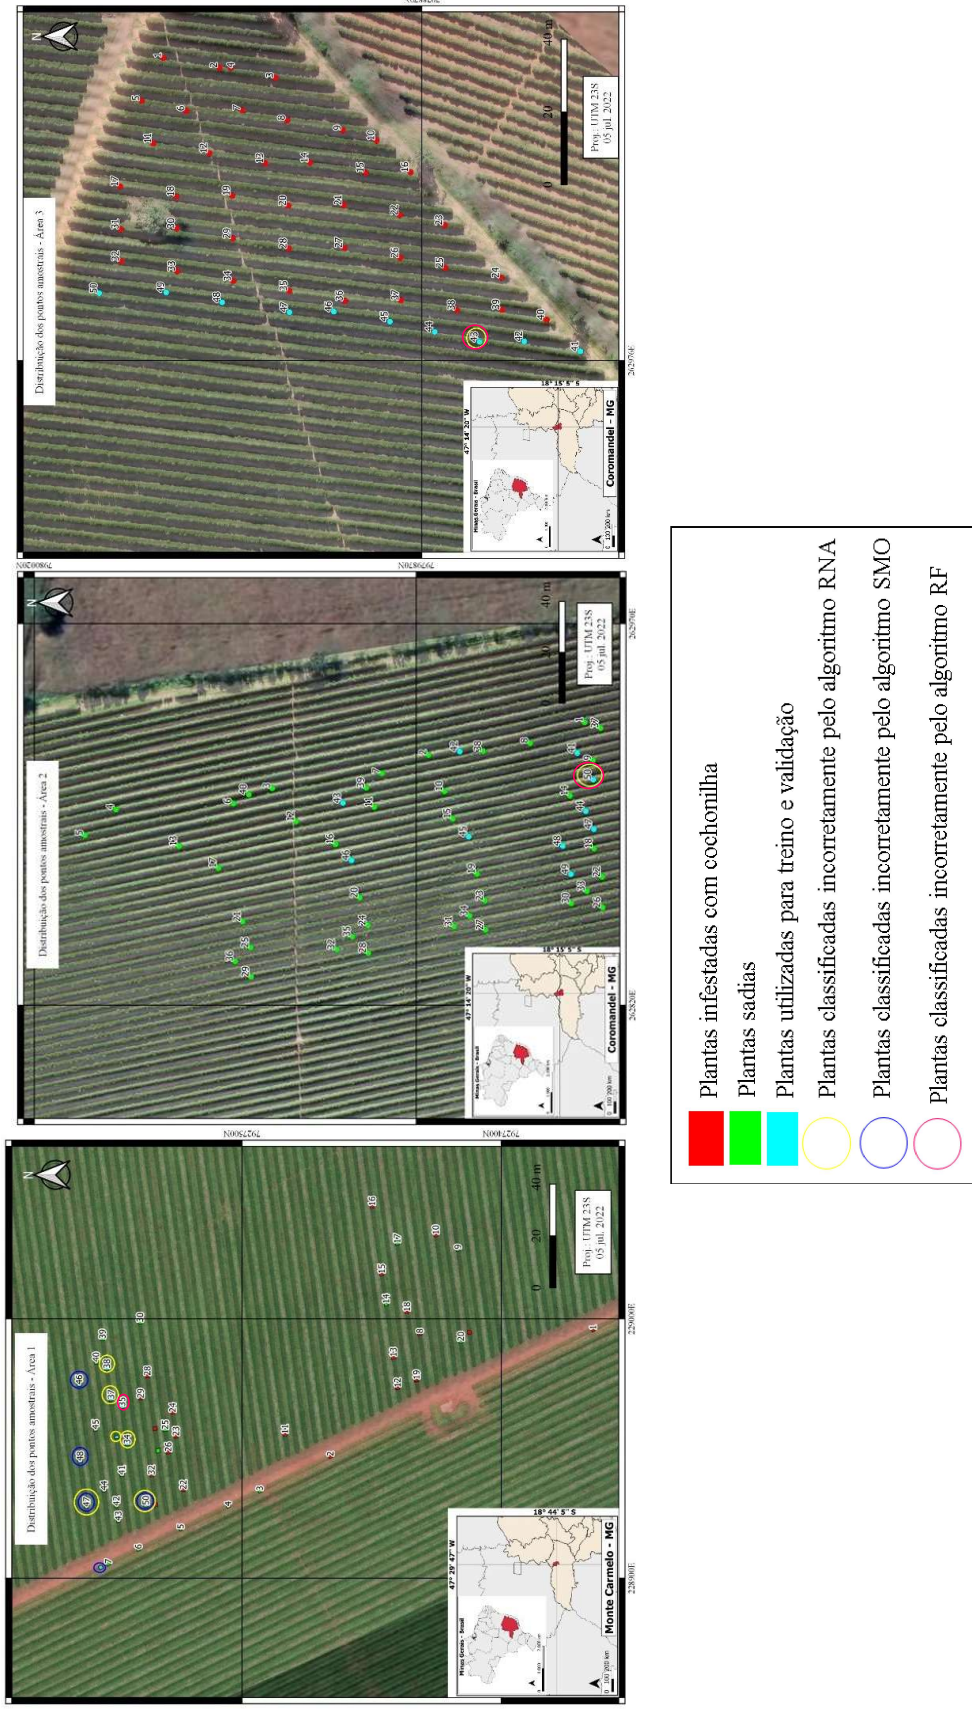


FIGURA 7: Mapas de representação das plantas de sadias e infestadas, validação e classificadas incorretamente pelos algoritmos Redes Neurais Artificiais (RNA) e *Support Vector Machine* (SMO), para as áreas de Monte Carmelo (1); Coromandel (sadia-2) e Coromandel (infestada-3).

O algoritmo Random Forest é considerado como um método de aprendizado de máquina eficaz para atender a problemas relacionados à agricultura, conforme demonstrado em alguns estudos (JEONG et al., 2016; OSCO et al., 2020; RAMOS et al., 2020) (Tabela 1).

## **5. CONCLUSÕES**

Existe a possibilidade de discriminação entre plantas saudáveis e infestadas por cochonilha, utilizando algoritmos baseados em aprendizado de máquina.

O algoritmo Random Forest possui alta capacidade de discriminação entre plantas saudáveis e infestadas em áreas com alta variabilidade.

## REFERÊNCIAS

- ABDULKAREEM, N. M.; ABDULAZEEZ, A. M. Machine learning classification based on random forest algorithm: a review. **International Journal of Science and Business**, v. 5, n. 2, p. 128–142, 2021. DOI: <https://doi.org/10.5281/zenodo.4471118>
- 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>
- ABREU JÚNIOR, C. A. M. et al. Mapeamento de nematoides na cultura cafeeira a partir de imagens multiespectrais obtidas por aeronaves remotamente pilotadas. **Revista Caminhos de Geografia**, v. 21, n. 76, p. 72–84, 2020. DOI: <https://doi.org/10.14393/RCG217651255>
- APARECIDO, L. E. DE O.; ROLIM, G. DE S.; SOUZA, P. P. S. Sensitivity of newly transplanted coffee plants to climatic conditions at altitudes of Minas Gerais, Brazil. **Australian Journal of Crop Science**, v. 9, n. 2, p. 160–167, 2015.
- ARTIOLI, F.; BELONI, T. Diagnóstico do perfil do usuário de drones no agronegócio brasileiro. **Revista IPecege**, v. 2, n. 3, p. 40–56, 14 jul. 2016. DOI: <https://doi.org/10.22167/r.ipecege.2016.3.40>
- ASIEDU, E.; AFUN, J. V. K.; KWOSEH, C. Biology of *Planococcus citri* (Risso) (Hemiptera: Pseudococcidae) on five yam varieties in storage. **Advances in Entomology**, v. 02, n. 04, p. 167–175, 2014. DOI: <https://doi.org/10.4236/ae.2014.24025>
- BAGHERI, N. Application of aerial remote sensing technology for detection of fire blight infected pear trees. **Computers and Electronics in Agriculture**, v. 168, 1 jan. 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105147>
- BERK, R. A. **Statistical Learning from a Regression Perspective**. New York, NY: Springer Verlag, 2008. v. 17. DOI: <https://doi.org/10.1007/978-0-387-77501-2>
- BORGHI, E. J. A. et al. Utilização de fungos entomopatogênicos no controle da cochonilha-da-roseta em cultivos de café Conilon. **X Simpósio de Pesquisa dos Cafés do Brasil**, p. 5, 2019.
- BRE, F.; GIMENEZ, J. M.; FACHINOTTI, V. D. Prediction of wind pressure coefficients on building surfaces using artificial neural networks. **Energy and Buildings**, v. 158, p. 1429–1441, 2018. DOI: <https://doi.org/10.1016/j.enbuild.2017.11.045>
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: <https://doi.org/10.1023/A:1010933404324>
- BUREAU, A. et al. Identifying SNPs predictive of phenotype using random forests. **Genetic Epidemiology**, v. 28, n. 2, p. 171–182, fev. 2005. DOI: <https://doi.org/10.1002/gepi.20041>
- CAMARGO, M. B. P. The impact of climatic variability and climate change on *Arabic coffee* crop in Brazil. **Bragantia**, v. 69, n. 1, p. 239–247, 2010. DOI: <https://doi.org/10.1590/S0006-87052010000100030>

CARMO, G. J. DOS S. et al. Detection of lesions in lettuce caused by *Pectobacterium carotovorum* subsp. *carotovorum* by supervised classification using multispectral images. **Canadian Journal of Remote Sensing**, v. 48, n. 2, p. 144–157, 2021. DOI: <https://doi.org/10.1080/07038992.2021.1971960>

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, 1 out. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105708>

CONAB. **Acompanhamento da safra brasileira- primeiro levantamento**. Brasília. Disponível em: <<http://www.conab.gov.br>>.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, set. 1995. DOI: <https://doi.org/10.1007/BF00994018>

COX, J. M. Identification of *Planococcus citri* (Homoptera: Pseudococcidae) and the description of a new species. **Systematic Entomology**, v. 6, n. 1, p. 47–53, 1981. DOI: <https://doi.org/10.1111/j.1365-3113.1981.tb00012.x>

CUTLER, D. R. et al. Random forests for classification in ecology. **Ecology**, v. 88, n. 11, p. 2783–2792, nov. 2007. DOI: <https://doi.org/10.1890/07-0539.1>

DAMATTA, F. M.; COCHICHO RAMALHO, J. D. **Impacts of drought and temperature stress on coffee physiology and production: a review** **Brazilian Journal of Plant Physiology** Sociedade Brasileira de Fisiologia Vegetal, , 2006. DOI: <https://doi.org/10.1590/S1677-04202006000100006>

DASTRES, R.; SOORI, M. Artificial neural network systems. **International Journal of Imaging and Robotics**, v. 21, n. 2, p. 13–25, 2021.

DEMIRCI, F. et al. Laboratory evaluation of the effectiveness of the entomopathogen; *Isaria farinosa*, on citrus mealybug, *Planococcus citri*. **Journal of Pest Science**, v. 84, n. 3, p. 337–342, 12 set. 2011. DOI: <https://doi.org/10.1007/s10340-011-0350-9>

DI GENNARO, S. F. 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, 29 jul. 2016. DOI: [https://doi.org/10.14601/Phytopathol\\_Mediterr-18312](https://doi.org/10.14601/Phytopathol_Mediterr-18312)

DÍAZ-URIARTE, R.; ALVAREZ DE ANDRÉS, S. Gene selection and classification of microarray data using random forest. **BMC Bioinformatics**, v. 7, n. 1, p. 1–13, 6 jan. 2006. DOI: <https://doi.org/10.1186/1471-2105-7-3>

DURGABAI, R. P. L.; BHARGAVI, P.; JYOTHI, S. Pest management using machine learning algorithms: a review. **International Journal of Computer Science Engineering and Information Technology Research**, v. 8, n. 1, p. 13–22, 2018. DOI: <https://doi.org/10.24247/ijcseitrfeb20182>

FAIRTRADE FOUNDATION. **Coffee farmers** . Disponível em: <<https://www.fairtrade.org.uk/Farmers-and-Workers/Coffee/>>. Acesso em: 18 ago. 2022.

FAO. **Organização das Nações Unidas para a Alimentação e a Agricultura**. Disponível em: <[http://www.fao.org/fileadmin/templates/wsfs/docs/Issues\\_papers/HLEF2050\\_Global\\_](http://www.fao.org/fileadmin/templates/wsfs/docs/Issues_papers/HLEF2050_Global_)>. Acesso em: 17 ago. 2022.

FERRÃO, M. A. G. et al. **Origem, dispersão geográfica, taxonomia e diversidade genética de *Coffea canephora***. Vitória: Incaper, 2007.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. 1. ed. São Paulo: Oficina de Textos, 2017.

FORNAZIER, M. J. et al. Cochonilha branca da roseta em café conilon (*Coffea canephora*) no Espírito Santo. **Congresso Brasileiro de Pesquisas Cafeeiras**, p. 176–177, 2000.

FORNAZIER, M. J.; MARTINS, D. S.; PRATISSOLI, D. Café Conilon: do plantio à colheita. In: FONSECA, A. F. A.; SAKYIAMA, N. S.; BORÉM, A. (Eds.). **Manejo Integrado de Pragas**. Viçosa: Editora UFV, 2015. p. 138–161.

FUKUDA, S. et al. Random Forests modelling for the estimation of mango (*Mangifera indica* L. cv. Chok Anan) fruit yields under different irrigation regimes. **Agricultural Water Management**, v. 116, p. 142–150, 1 jan. 2013. DOI: <https://doi.org/10.1016/j.agwat.2012.07.003>

GALVÃO, G. et al. Visão computacional para detecção de doenças fúngicas na agricultura. **Única Cadernos Acadêmicos** , v. 2, n. 1, p. 20, 2018.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289–298, 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

GROMPING, U. Variable importance assessment in regression: linear regression versus random forest. **American Statistical Association**, v. 63, n. 4, p. 308–319, 2009. DOI: <https://doi.org/10.1198/tast.2009.08199>

HOOGENBOOM, G. Contribution of agrometeorology to the simulation of crop production and its applications. **Agricultural and Forest Meteorology**, v. 103, n. 1–2, p. 137–157, 1 jun. 2000. DOI: [https://doi.org/10.1016/S0168-1923\(00\)00108-8](https://doi.org/10.1016/S0168-1923(00)00108-8)

ICO. Coffee market report. **International Coffee Organization**, p. 7, 2019a.

ICO. Report of the 16th meeting of the statistics committee held on 27 March 2019. **International Coffee Organization**, p. 4, 2019b.

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

JEONG, J. H. et al. Random forests for global and regional crop yield predictions. **PLoS ONE**, v. 11, n. 6, p. 15, 1 jun. 2016. DOI: <https://doi.org/10.1371/journal.pone.0156571>

JÚNIOR, A. S. et al. Application of the Köppen classification for climatic zoning in the state of Minas Gerais, Brazil. **Theoretical and Applied Climatology**, v. 108, n. 1–2, p. 1–7, 27 ago. 2012. DOI: <https://doi.org/10.1007/s00704-011-0507-8>

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, p. 352–359, 1 out. 2009. DOI: <https://doi.org/10.1016/j.jag.2009.06.002>

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. 1–11, 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, n. 1, p. 147–159, 1 mar. 1977. DOI: <https://doi.org/10.2307/2529310>

LIAKOS, K. G. et al. Machine learning in agriculture: a review. **Sensors**, v. 18, n. 8, p. 29, 2018. DOI: <https://doi.org/10.3390/s18082674>

LU, J. et al. Field detection of anthracnose crown rot in strawberry using spectroscopy technology. **Computers and Electronics in Agriculture**, v. 135, p. 289–299, 1 abr. 2017. DOI: <https://doi.org/10.1016/j.compag.2017.01.017>

LUNETTA, K. L. et al. Screening large-scale association study data: exploiting interactions using random forests. 2004.

MARMION, M. et al. Evaluation of consensus methods in predictive species distribution modelling. **Diversity and Distributions**, v. 15, n. 1, p. 59–69, 1 jan. 2009. DOI: <https://doi.org/10.1111/j.1472-4642.2008.00491.x>

MATSUNAGA, V. Y. **Curso de redes neurais utilizando o MATLAB**. Belém - PA.

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>

MORIN, X.; THUILLER, W. Comparing niche- and process-based models to reduce prediction uncertainty in species range shifts under climate change. **Ecology**, v. 90, n. 5, p. 1301–1313, maio 2009. DOI: <https://doi.org/10.1890/08-0134.1>

MUTANGA, O.; ADAM, E.; CHO, M. A. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. **International Journal of Applied Earth Observations and Geoinformation**, v. Complete, n. 18, p. 399–406, 2012. DOI: <https://doi.org/10.1016/j.jag.2012.03.012>

OLIVEIRA APARECIDO, L. E. et al. Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. **International Journal of Biometeorology**, v. 64, n. 4, p. 671–688, 1 abr. 2020. DOI: <https://doi.org/10.1007/s00484-019-01856-1>

OSCO, L. P. et al. Leaf nitrogen concentration and plant height prediction for maize using UAV-based multispectral imagery and machine learning techniques. **Remote Sensing**, v. 12, n. 19, p. 1–17, 1 out. 2020. DOI: <https://doi.org/10.3390/rs12193237>

PANHUYSEN, S.; JOOST, P. Coffee barometer. **Raamweg** 16, p. 36, 2018.

PINO, F. A.; VEGRO, C. L. R. **Café - Um Guia do apreciador**. 4. ed. São Paulo: Saraiva, 2008.

PRASAD, A. et al. Newer classification and regression tree techniques: bagging and random forests for ecological prediction. **Ecosystems**, v. 9, n. 2, p. 181–199, mar. 2006. DOI: <https://doi.org/10.1007/s10021-005-0054-1>

PUKKELA, P.; BORRA, S. Machine learning based plant leaf disease detection and severity assessment techniques: State-of-the-Art. In: DEY, N.; ASHOUR, A. S.; BORRA, S. (Eds.). **Lecture Notes in Computational Vision and Biomechanics**. 26. ed. [s.l.] Springer Netherlands, 2018. v. 26p. 199–226. DOI: [https://doi.org/10.1007/978-3-319-65981-7\\_8](https://doi.org/10.1007/978-3-319-65981-7_8)

RAMOS, A. P. M. et al. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. **Computers and Electronics in Agriculture**, v. 178, 1 nov. 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105791>

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, n. 1, p. 585–605, 1 jan. 2019. DOI: <https://doi.org/10.1016/j.compag.2018.12.006>

REIS, I.; BARON, D.; SHAHAF, S. Probabilistic random forest: a machine learning algorithm for noisy data sets. **The Astronomical Journal**, v. 157, n. 1, p. 12, 2018. DOI: <https://doi.org/10.3847/1538-3881/aaf101>

RENA, A. B.; MAESTRI, M. Fisiologia do cafeeiro. **Associação Brasileira de Pesquisa da Potassa e do Fosfato**, v. 2, p. 13–85, 1986.

RESENDE, D. B. et al. Uso de imagens tomadas por aeronaves remotamente pilotadas para detecção da cultura do milho infestada por *Spodoptera frugiperda*. **Revista Brasileira de Geografia Física**, v. 13, p. 156–166, 2020. DOI: <https://doi.org/10.26848/rbgf.v13.1.p156-166>

ROUSE, J. W., J. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium, Proceedings, NASA SP-351**, v. 1, p. 309–317, 1973.

RUNG, A.; MILLER, D. R.; SCHEFFER, S. J. Polymerase chain reaction-restriction fragment length polymorphism method to distinguish three mealybug Groups within the *Planococcus citri* - *P. minor* species complex (Hemiptera: Coccoidea: Pseudococcidae). **Journal of Economic Entomology**, v. 102, n. 1, p. 8–12, 1 fev. 2009. DOI: <https://doi.org/10.1603/029.102.0102>

SALADO, A. Five most promising markets in coffee. **Euromonitor Internacional**, p. 22, 2018.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3, n. 3, p. 206–226, jul. 2000. DOI: <https://doi.org/10.1147/rd.441.0206>

SANTA-CECILIA, L. V. C.; SOUZA, B. Controle biológico de cochonilhas-farinhas em cultivos protegidos. **Informe Agropecuário**, v. 26, n. 225, p. 24–30, 2005.

SANTA-CECÍLIA, L. V. C. et al. Cochonilhas-farinhas em cafeeiros: reconhecimento e controle. **EPAMIG. Circular Técnica**, 189, p. 4, 2005.

SANTA-CECÍLIA, L. V. C. et al. Cochonilhas-farinhas em cafeeiros: bioecologia, danos e métodos de controle. **EPAMIG**, p. 52, 2008.

SANTA-CECÍLIA, L. V. C. et al. Desenvolvimento de *Planococcus citri* (Risso, 1813) (Hemiptera: Pseudococcidae) em cafeeiros. **Acta Scientiarum - Agronomy**, v. 31, n. 1, p. 13–15, 2009. DOI: <https://doi.org/10.4025/actasciagron.v31i1.6603>

SANTA-CECÍLIA, L. V. C. et al. Extratos de plantas no controle de *Planococcus citri* (Risso, 1813) (Hemiptera: Pseudococcidae) em cafeeiro. **Coffee Science**, v. 5, n. 3, p. 283–293, 2010. DOI: <https://doi.org/10.4025/actasciagron.v31i1.6603>

SANTA-CECÍLIA, L. V. C.; REIS, P. R.; SOUZA, J. C. Sobre a nomenclatura das espécies de cochonilhas-farinhas do cafeeiro nos estados de Minas Gerais e Espírito Santo. **Neotropical Entomology**, v. 31, n. 2, p. 333–334, 2002. DOI: <https://doi.org/10.1590/S1519-566X2002000200024>

SINGH, A. et al. Machine learning for high-throughput stress phenotyping in plants. **Trends in Plant Science**, v. 21, n. 2, p. 110–124, 1 fev. 2016. DOI: <https://doi.org/10.1016/j.tplants.2015.10.015>

SPONGOSKI, S.; REIS, P. R.; ZACARIAS, M. S. Acarofauna of cerrado's coffee crops in Patrocínio, Minas Gerais. **Ciência e Agrotecnologia**, v. 29, n. 1, p. 9–17, 2005. DOI: <https://doi.org/10.1590/S1413-70542005000100001>

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>

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. Springer: New York-Verlag, 1995. DOI: <https://doi.org/10.1007/978-1-4757-2440-0>

VINCENZI, S. et al. Application of a Random Forest algorithm to predict spatial distribution of the potential yield of *Ruditapes philippinarum* in the Venice lagoon, Italy. **Ecological Modelling**, v. 222, n. 8, p. 1471–1478, 24 abr. 2011. DOI: <https://doi.org/10.1016/j.ecolmodel.2011.02.007>

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, p. 1–18, 2020. DOI: <https://doi.org/10.3390/rs12152453>



WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 12, n. 15, p. 1–18, 1 jan. 2020. DOI: 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. **Precision Crop Protection - The Challenge and Use of Heterogeneity**, p. 135–149, 2010. DOI: [https://doi.org/10.1007/978-90-481-9277-9\\_9](https://doi.org/10.1007/978-90-481-9277-9_9)

WHEELER, D. L. et al. Evidence of a trans-kingdom plant disease complex between a fungus and plant-parasitic nematodes. **PloS one**, v. 14, n. 2, 1 fev. 2019. DOI: <https://doi.org/10.1371/journal.pone.0211508>

WILLIAMS, D. J.; WILLINK, M. C. G. Mealybugs of Central and South America. **CAB International**, p. 635, 1992.

WU, X. 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>

XAVIER, L. C. M. et al. Potencial de imagens multiespectrais sentinel 2 na detecção de nematoides na cultura cafeeira. **Revista Brasileira de Geomática**, v. 7, n. 2, p. 095, 2019. DOI: <https://doi.org/10.3895/rbgeo.v7n2.8701>

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, p. e0187470, 1 maio 2018. DOI: <https://doi.org/10.1371/journal.pone.0187470>

