

FERNANDO VASCONCELOS PEREIRA

**IMAGENS MULTIESPECTRAIS NO MONITORAMENTO DE
PARÂMETROS MORFOBIOMÉTRICOS DO CAFEEIRO SOB
TRATAMENTOS QUÍMICOS E BIOLÓGICOS CONTRA
FITONEMATOIDES**

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

Orientador
Prof. Dr. George Deroco Martins

**MONTE CARMELO
MINAS GERAIS - BRASIL
2021**

FERNANDO VASCONCELOS PEREIRA

**IMAGENS MULTIESPECTRAIS NO MONITORAMENTO DE
PARÂMETROS MORFOBIOMÉTRICOS DO CAFEEIRO SOB
TRATAMENTOS QUÍMICOS E BIOLÓGICOS CONTRA
FITONEMATOIDES**

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 29 de julho de 2021.

Banca examinadora

Prof. Dr. George Deroco Martins – Faculdade de Engenharia Civil (UFU)

Prof. Dr. Bruno Sérgio Vieira – Instituto de Ciências Agrárias (UFU)

Prof. Dr. Luiz Henrique Silva Rotta - Instituto de Criminalística – PC/Paraná (ICPC-PR)

Prof. Dr. George Deroco Martins
Faculdade de Engenharia Civil (UFU)
(Orientador)

**MONTE CARMELO
MINAS GERAIS - BRASIL
2021**

=`Z_X: XkXf^i}]ZXF e\`e\`[f\`J j\`Kd X\`[\`9`YcfKZXj\`[X\`L =L
 Zfd\`[X[f\`e]fid X[f\`g\`f\`ZXzgi\`gi\`f\`ZXzXI\`f\`i\`ZXz%
 G+*- G\`i\`iX#=\`ieXe[f\`Mj ZfeZ\`fj #(O/O\$
)'') @ X^\`ej\`d\`l\`d\`j g\`ZkXj\`ef\`d fe\`kiXd\`ekf\`[\`gXi\`d\`kifj
 d\`fj]f\`Y\`fd\`t\`k\`Zfj\`[f\`ZX]\`ifj f\`Y\`kXkXd\`ekfj\`hl\`S\`Zfj\`
 Yf\`c\`Zfj\`Zfe\`kX]f\`e\`d Xkf\`[\`R\`ZI ij f\`n\`d\`k\`e\`ZfT&
 =\`ieXe[f\`Mj ZfeZ\`fj\`G\`i\`iX%\$')(%
 F i\`e\`K[f\`i\`t\`>\`f\`i\`^;\` \`if Zf\`D X\`kej %
 ; j\`j\`i\`K\` f\`Z\`D\`j\`kX[f\`z\`L e\`m\`ij\`[X[\`=\`[\`iXc[\`
 L Y\`ic e[`X\`G\`j \\$\`iX[\`I X\` f\`n\`d\`8\`i\`ZI\`d\`iX\`@]fid X\`E\`j
 >\`f\`j g\`XZ\`Xj\` %
 Df[f\`[\`XZ\`j j f\`t\`@K\`ie\`K%
 ; j\`g\`f\`e\`S\`h\`c\`d T\`k\`g\`1\`f\`%i\`^&\` %\`+*\`O\`*&\`j\` %\`%'\`)(%, /
 @Z\`d\`Y\`Ycf\`iX]\`X%

 (%8\`if ef d\`X\`%&D X\`kej #>\`f\`i\`^;\` \`if Zf\`# O/. \\$#
 ZF i\`e\`k\`%&L e\`m\`ij\`[X[\`=\`[\`iXc[\`L Y\`ic e[`X\`G\`j \\$
 ^iX[\`I X\` f\`n\`d\`8\`i\`ZI\`d\`iX\`@]fid X\`E\`j\`>\`f\`j g\`XZ\`Xj\` %
 @Z\`K\`S\`d\`f\`%

 : ; L T-*()

9`YcfKZ} i\`fj\`i\`j g\`f\`e\`j\`m\`j\`g\`d\`j k\`i\`k\`iX\`[\`XZfi[f\`Zfd\`f\`88: I) 1

>\`q\`d\`:\`i\`j ke\`E\`e\`j\`[f\`:\`f\`l k\`f\`\$:\`I\`9\`-\`&\`O\`C


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:	29/07/2021	Hora de início:	13:30	Hora de encerramento:	16:30
Matrícula do Discente:	31922AIG003				
Nome do Discente:	Fernando Vasconcelos Pereira				
Título do Trabalho:	Imagens multiespectrais no monitoramento de parâmetros morfobiométricos do cafeeiro sob tratamentos químicos e biológicos contra fitonematoídes				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Aplicações e desenvolvimento de métodos em informações espaciais				

Reuniu-se na sala virtual <https://conferenciaweb.rnp.br/webconf/george-deroco-martins> a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Bruno Sérgio Vieira (UFU), Dr. Luiz Henrique da Silva Rotta (Instituto de Criminalística –Polícia Científica do Paraná), Dr. George Deroco Martins (UFU) orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. George Deroco Martins, apresentou a Comissão Examinadora e o candidato, 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(as) 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):

Aprovado(a).

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

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

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



Documento assinado eletronicamente por **George Deroco Martins, Professor(a) do Magistério Superior**, em 29/07/2021, às 18:19, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Bruno Sergio Vieira, Professor(a) do Magistério Superior**, em 29/07/2021, às 19:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luiz Henrique da Silva Rotta, Usuário Externo**, em 02/08/2021, às 14:52, 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 **2940421** e o código CRC **56C9D5A1**.

Dedico

*Aos meus pais Paulo e Valdeci, e a
minha irmã e sobrinha Danielle e Liz.*

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo dom da vida, por constantemente me abençoar e segurar minha mão em todos os meus caminhos, por ter me concedido muita saúde, vitalidade, paz no coração e força de vontade para superar todos os desafios e momentos difíceis que surgiram neste percurso.

Aos meus amados pais, Paulo e Valdeci, pela vida que me deram, por todo o seu amor incondicional, pelo carinho e afeto, por terem me ensinado a ser o homem que sou hoje, por me respeitarem e acolherem sempre de braços abertos, e por todo cuidado e incentivo a minha educação, amo vocês.

As minhas irmãs Danielle e Kênia, pela amizade, pelo amor incondicional, pelo companheirismo e apoio em tempos difíceis, e pelos esforços de me fazer sentir bem.

A minha sobrinha Liz por ser esse pontinho de luz na minha vida.

Ao Prof. Dr. George Deroco Martins, pela honra de ter sido seu orientando, por depositar sua confiança em mim e acreditar no meu potencial para concluir com êxito esta pesquisa primorosa, por compartilhar seu conhecimento sem barreiras, pela sua disposição e paciência em ensinar, e pelos conselhos dados durante essa jornada.

Ao meu amigo Vinicius Werneck por todo apoio durante este trajeto, pelo companheirismo e suporte nos dias sofridos no campo, por compartilhar seu conhecimento, pelos momentos de satisfação agraciados com sentimento de dever cumprido, pelas ligações de desabafos e pela forte amizade que criamos no decorrer do curso e que se estenderá pela vida.

Agradeço ao meu amigo Rogério, pelo incentivo e apoio durante esta jornada, e por sempre me encorajar nos momentos de pouca fé.

Agradeço ao Sr.^º João Oliveira Gomes pelo seu apoio e paciência em compreender e permitir a minha ausência durante os dias de trabalho para assistir as aulas do mestrado.

Agradeço a todos os meus amigos que contribuíram diretamente ou indiretamente para a realização desta importante etapa (Carita, Mirian, Karume, Rosângela, Michelly, Alberto, José, Luana, Renata, Rafaela, Frederico e Nayara).

A todos os colegas da primeira turma da pós-graduação, em especial Talita, Bruno, Glécia e Juliano, pela amizade, pelos bons momentos vividos fora e dentro da sala de aula, e pelo compartilhamento de experiências e conhecimentos.

Ao Prof. Dr. Bruno Sérgio Vieira por toda a orientação, apoio e suporte prestado durante o experimento, por sempre se mostrar disponível em auxiliar, por todo o ensinamento compartilhado, e pela sua importante contribuição na realização desta pesquisa.

A Prof.^a Dra. Gleice Aparecida de Assis por todo apoio e suporte prestado nas orientações em campo e em sala, pela sua disponibilidade e atenção em compartilhar o seu conhecimento, e por ter contribuído grandemente no aperfeiçoamento da escrita deste trabalho.

Agradeço ao Dr. Luiz Henrique da Silva Rotta pela sua disposição em atenciosamente aceitar o convite para ser membro da banca e contribuir para o desenvolvimento e enriquecimento desta pesquisa.

Aos colegas Leticia, Leidiane, Samuel, Pablo, Rafael, Carlos, Rafael, Talita, Alice e ao técnico Valdiney pelo apoio e suporte prestado nos levantamentos de campo.

Agradeço a Universidade Federal de Uberlândia, Campus de Monte Carmelo e ao Programa de Pós-graduação em Agricultura e Informações Geoespaciais, bem como todos os técnicos e demais professores, pela dedicação, pelos ensinamentos, pela paciência, pelo compartilhamento de experiências e suporte prestado, o apoio de vocês foi imensuravelmente essencial para a efetivação desta caminhada.

A Fazenda Juliana e seus colaboradores, por disponibilizar a área de estudo para a realização desta pesquisa, e por todo o suporte e apoio prestado.

Gratidão a todos!

BIOGRAFIA

Fernando Vasconcelos Pereira nasceu em Goiânia, Goiás, Brasil, no dia 07 de abril de 1989. Graduado em Curso Superior de Tecnologia em Geoprocessamento pelo Instituto Federal de Goiás (IFG), Goiás, Brasil em 2013. Especialista em Saúde e Saneamento Ambiental pela Universidade Federal de Goiás (UFG), Goiás em 2020. Seus interesses de pesquisa incluem a aplicação de técnicas de sensoriamento remoto em áreas agrícolas.

SUMÁRIO

RESUMO.....	i
ABSTRACT	ii
1. INTRODUÇÃO	1
2. MATERIAL E MÉTODOS	3
2.1 Área de estudo e condições gerais do experimento.....	3
2.2 Caracterização dos tratamentos	4
2.3 Caracterização e condições gerais da área experimental	5
2.4 Avaliação dos parâmetros agronômicos	8
2.5 Amostragem de solo para análises nematólogicas	9
2.6 Aquisição das imagens multiespectrais	9
2.7 Processamento digital de imagens.....	10
2.7.1 <i>Correções Geométricas e Atmosféricas</i>	10
2.7.2 <i>Normalização Radiométrica</i>	10
2.7.3 <i>Cálculo dos Índices de Vegetação</i>	11
2.8 Análise de agrupamento	13
2.9 Geração do modelo de predição	13
2.10 Métrica de avaliação dos modelos.....	15
2.11 Mapas de caracterização das taxas de crescimento	16
3. RESULTADOS E DISCUSSÃO	16
3.1 Análise de agrupamento para seleção da combinação de dados de entrada.....	16
3.2 Definição dos melhores algoritmos para modelos de estimativa	19
3.3 Mapas de Caracterização dos parâmetros.....	38
4. CONCLUSÕES	58
REFERÊNCIAS	59

PEREIRA, FERNANDO VASCONCELOS. Imagens multiespectrais no monitoramento de parâmetros morfobiométricos do cafeiro sob tratamentos químicos e biológicos contra nematoides. 2021. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) - Universidade Federal de Uberlândia, Campus Monte Carmelo, Minas Gerais, Brasil.

RESUMO

A cafeicultura desempenha um importante papel na economia brasileira. Assim como em outras culturas, a cafeicultura está exposta a diversas doenças e pragas que interferem diretamente em sua produtividade. Um exemplo são os nematoides, que parasitam o sistema radicular das plantas, e comprometem o seu desenvolvimento fisiológico. Em vista perdas causadas por este patógeno e a escassez de informações sobre a distribuição espacial em áreas infectadas, fazendo-se necessárias as adoções de tecnologias que possibilitem o monitoramento desta cultura durante o seu ciclo de crescimento. Neste sentido, o sensoriamento remoto associado a algoritmos de aprendizagem de máquinas é apresentado como uma potencial ferramenta para realizar monitoramento em culturas agrícolas utilizando imagens multiespectrais. Este estudo avalia diferentes algoritmos de aprendizagem de máquinas, utilizando conjuntos de dados de entrada, valores radiométricos de imagens multiespectrais obtidas por plataformas de sensoriamento remoto e identifica as melhores arquiteturas de algoritmos (Random Forest, Multilayer Perceptron, SMOreg e Linear Regression), conjuntos de dados de entrada (bandas espectrais, índices de vegetação e combinação de bandas e índices de vegetação, selecionados em análise de agrupamentos) e sensores remotos (ARP, MAPIR e satélite PLANET), para a estimativa de parâmetros agronômicos de produtividade na cultura cafeeira após a aplicação de 11 tratamentos para o manejo de nematoides. O melhor desempenho foi observado para as arquiteturas que apresentaram menores valores RMSE e RMSE%. Para o parâmetro Índice de clorofila total (Random Forest/ índices de vegetação/ ARP) com RMSE e RMSE% = 4,7975 e 9,0545. Altura das plantas (m), comprimento de ramos (sul) (m) e comprimento de ramos (norte) (m) (SMOreg/ bandas e índices de vegetação selecionados por análise de agrupamento/ ARP), respectivamente com RMSE e RMSE% = 0,1128 e 3,6929; 0,1329 e 15,3025; 0,1436 e 16,8162. Número de ramos e número de nós (sul), (Linear Regression/ bandas espectrais e índices de vegetação selecionados por análise de agrupamento/ ARP), com valores RMSE e RMSE% = 12,1711 e 16,4744; 5,0442 e 18,2725. Número de nós (norte) (Random Forest/ bandas espectrais/ PLANET), com RMSE e RMSE% = 7,5341 e 26,2917. Diâmetro de Copa (m) (SMOreg/ bandas espectrais/ PLANT), com RMSE e RMSE% = 0,1302 e 7,7374.

Palavras-chave: sensoriamento remoto. aprendizado de máquina. parâmetros agronômicos. nematoides.

PEREIRA, FERNANDO VASCONCELOS. **Multispectral images for monitoring morphobiometric parameters of coffee under chemical and biological treatments against nematodes.** 2021. Dissertation (Master's Degree in Agriculture and Geospatial Information) - Federal University of Uberlândia, Uberlândia, Minas Gerais, Brazil.

ABSTRACT

Coffee plays an important role in the Brazilian economy. Much like other crops, coffee is exposed to different pathogens and pests that directly affect yield. These include nematodes, which attack the roots of plants and compromise their physiological development. Given the losses caused by this pathogen and the lack of information on spatial distribution in infested areas, it is important to adopt technologies that enable crops under different management systems to be monitored during their growth cycle in order to reduce nematode populations. In this respect, remote sensing associated with machine learning algorithms is presented as a potential tool for monitoring agricultural crops using multispectral images. The present study assesses different machine learning algorithms, using radiometric values of multispectral images obtained by remote sensing platforms as input datasets, and identifies the best architectures (Random Forest, Multilayer Perceptron, SMOreg and Linear Regression), input datasets (spectral bands, vegetation indices, and combination of the two, selected in cluster analysis) and remote sensors (RPA, MAPIR and the PLANET platform) to estimate the agronomic parameters of yield in coffee crops submitted to 11 treatments for nematode management. The best-performing architectures were those that obtained the lowest RMSE and RMSE% values, as follows: total chlorophyll index (Random Forest/ vegetation indices/ RPA) with respective RMSE and RMSE% of 4.7975 and 9.0545; plant height (m), branch length (south-facing) (m) and branch length (north-facing) (m) (SMOreg/ bands and vegetation indices selected by cluster analysis / RPA), with respective RMSE and RMSE% of 0.1128 and 3.6929; 0.1329 and 15.3025; 0.1436 and 16.8162; number of branches and number of nodes (south-facing), (Linear Regression/ spectral bands and vegetation indices selected by cluster analysis/ RPA), with RMSE and RMSE% of 12.1711 and 16.4744; 5.0442 and 18.2725; number of nodes (north-facing) (Random Forest/ spectral bands/ PLANET), with RMSE and RMSE% of 7.5341 and 26.2917; canopy diameter (m) (SMOreg/ spectral bands/PLANET), with RMSE and RMSE% of 0.1302 and 7.7374..

Keywords: remote sensing. machine learning. agronomic parameters. nematodes.

1. INTRODUÇÃO

O Brasil desempenha um importante papel nas produções cafeeiras, se destacando no ranking mundial como maior produtor e exportador de café. Conforme dados apresentados pela OIC (2021), no ano de 2020, foram produzidos 63.400 milhões de sacas de café em bienalidade positiva e exportados cerca de 40.511 milhões de sacas de café no ano safra 19/20.

Em face da relevância econômica desempenhada pela cultura cafeeira, muitas técnicas de manejo são empregadas nas lavouras com o objetivo de influenciar diretamente em aspectos tais como: produtividade, custo de produção e qualidade do produto. Somado a isto, a cultura cafeeira, assim como outras culturas, está exposta a diversos distúrbios fisiológicos, bem como ocorrências de pragas e doenças, que afetam as plantas e causam, entre outros efeitos, a redução da produtividade das plantas e/ou inviabilizam a exploração econômica da lavoura (MESQUITA, 2016).

Um exemplo são os nematoides, microrganismos fitopatogênicos que vivem e se desenvolvem no solo e parasitam o sistema radicular das plantas comprometendo o desenvolvimento fisiológico das plantas durante todo o ciclo da cultura no campo, o que dificulta o crescimento e a produção do cafeiro. Entre os sintomas visíveis na parte aérea das plantas de cafeeiros parasitadas por estes patógenos, inclui o amarelecimento da planta, deficiências nutricionais, queda de folhas, seca dos ramos ponteiros ou até a morte da planta (REIS; CUNHA, 2010).

Alguns métodos têm sido empregados com o objetivo de reduzir os níveis populacionais de nematoides em diversas culturas. Entre estas técnicas estão o uso de cultivares resistente a determinados tipos de nematoides e o controle químico (FERRAZ; BROWN, 2016). Associado a isto, o uso do controle biológico com bionematicidas, com o uso de fungos e rizobactérias, são aplicados com eficácia na cultura cafeeira para redução e manejo da incidência de nematoides (ARPINI; LIMA; COSTA, 2018).

O alto custo das análises laboratoriais para quantificação dos níveis de infestação por nematoides e as perdas causadas por estes patógenos, traz a necessidade de novos métodos de detecção e quantificação desses patógenos na cultura cafeicultura (MARTINS; GALO; VIEIRA, 2017). Neste sentido, é preciso levar em consideração que apesar da escassez de dados sobre a distribuição espacial, manejo e ambientes circundantes das áreas infestadas, o monitoramento da cultura durante todo o seu ciclo de crescimento é vital para obter uma produção de alta qualidade (ALVES et al., 2016).

Em vista da necessidade de obter mais informações sobre os sistemas agrícolas, os avanços em tecnologias levaram ao uso de sensores remotos que permitem estimar potencialmente componentes da produção agrícola (ZERBATO et al., 2016). A partir da radiação refletida, coletada por estes sensores, é possível adquirir informações relacionadas ao tipo de cultura, condições fenológicas ou nutricionais da cultura e produtividade, bem como identificar a ocorrência de doenças e pragas (SHARIFI, 2020; FERREIRA et al., 2016; XIA et al., 2016; SANDRINI et al., 2019; PARK et al., 2016; ELAZAB et al., 2016; ARANTES et al., 2021; ABDULRIDHA et al., 2019; YE et al., 2020; YUAN et al., 2017; ORLANDO, 2020; DIAO, 2020; MARTINS et al., 2020).

Atualmente, técnicas avançadas de aprendizagem de máquinas têm sido empregadas com o objetivo de desenvolver modelos, utilizando diferentes variáveis, com a capacidade de relacionar a produtividade a fatores que influenciam no crescimento das culturas (BOCCA; RODRIGUES, 2016) Estas técnicas associadas a dados adquiridos por sensores remotos, tem abrangido estudos em diversas perspectivas no monitoramento e estimativas de parâmetros agronômicos (SINGHAL et al., 2019; RANDELOVIĆ et al., 2020; WANG et al., 2016; ZHA et al., 2020; WOLANIN et al., 2019; ZHOU et al., 2019; CANATA et al., 2021; SOUSA et al., 2021; SALVADOR et al., 2020; SHARIFI, 2020).

Dada esta gama de aplicações com imagens multiespectrais associadas a processos por algoritmos baseados em inteligência artificial, este trabalho busca comparar diferentes algoritmos de aprendizagem de máquinas, utilizando conjuntos de dados de entrada, construídos com dados de sensoriamento remoto e identificar as melhores combinações de algoritmos, estrutura de dados e sensores remotos, propondo por meio destas tecnologias, uma forma de monitoramento de parâmetros agronômicos sem medidas diretas e destrutivas na cultura do cafeeiro após a aplicação de diferentes tratamentos visando o manejo de nematoides. Estas tecnologias contribuem para a obtenção de informações rápidas, precisas e adequadas sobre as mais diversas áreas agrícolas por um menor custo benefício, uma vez que possibilita a tomada de decisões mais assertivas quanto ao manejo localizado e preciso de nematoides.

O monitoramento de tais parâmetros é de suma importância, pois desta forma poderá ser conhecida à distribuição espacial de variáveis relacionadas à produtividade, crescimento e vigor vegetativo das plantas em áreas infestadas por nematoides, submetidos a diferentes tratamentos químicos e biológicos na cultura cafeeira.

2. MATERIAL E MÉTODOS

No decorrer deste estudo foram definidas etapas que envolveram avaliações de campo com aquisição de dados agronômicos, de imagens e processamento de dados. Genericamente, as etapas foram definidas em: (1) delimitação da área de estudo; (2) avaliações de campo para aquisição dos parâmetros agronômicos; (3) aquisição de Imagens Multiespectrais; (4) processamento digital das imagens; (5) mineração de dados; (6) geração dos modelos de predição de variáveis agronômicas; (7) análise da acurácia dos modelos de predição; e (8) geração dos mapas de distribuição espacial dos parâmetros agronômicos.

A Figura 1 apresenta o fluxograma das atividades desenvolvidas nas etapas avaliativas, processamentos de dados e análise de resultados.

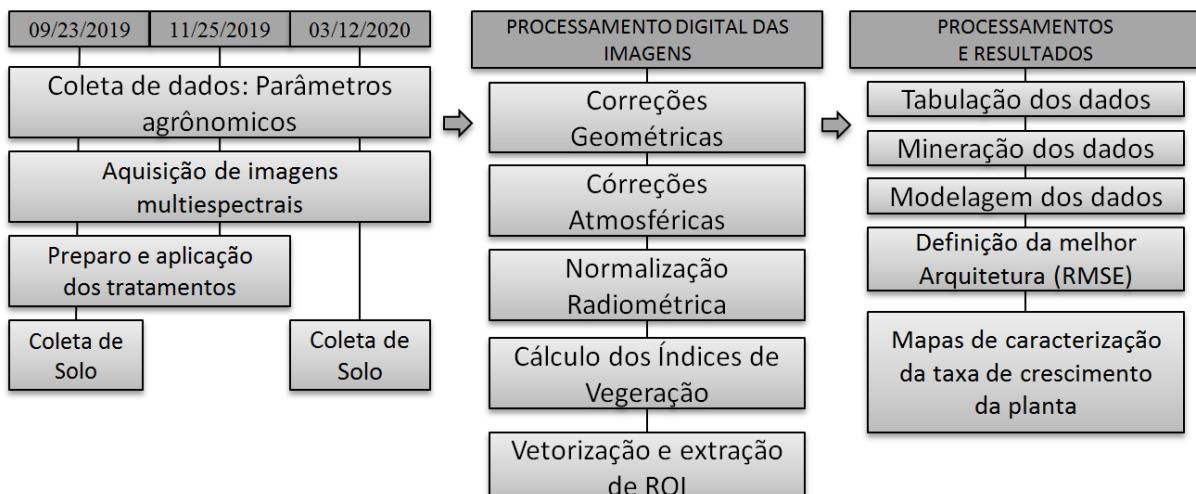


FIGURA 1 – Fluxograma de etapas desenvolvidas na pesquisa

2.1 Área de estudo e condições gerais do experimento

O experimento foi realizado na Fazenda Juliana, propriedade particular, localizada no município de Monte Carmelo – MG, mesorregião do Triângulo Mineiro e Alto Paranaíba, centralizada nas coordenadas geográficas Lat.: -18°41'59", Long.: -47°33'53" e altitude de 826m (Figura 2). O clima da região é Tropical com estação seca (Aw), conforme classificação climática de Köppen – Geiger.

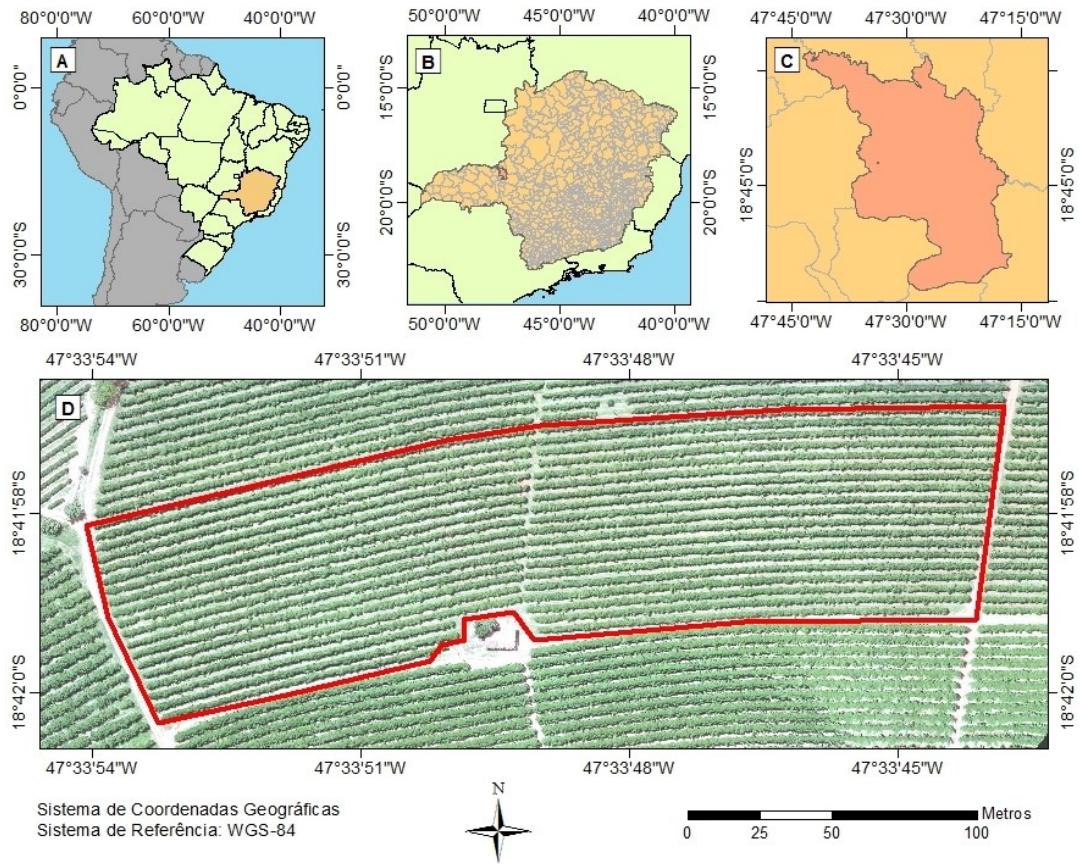


FIGURA 2 – Mapa de localização da área de estudo. (A) Brasil. (B) Estado de Minas Gerais. (C) Município de Monte Carmelo-MG, situado na mesorregião do Triângulo Mineiro e Alto Paranaíba. (D) Talhão experimental, em composição colorida natural (RGB) da imagem adquirida por aerolevantamento utilizando RPA, limitada no vermelho.

2.2 Caracterização dos tratamentos

Para o manejo de nematoides, foram aplicados 11 tratamentos no talhão experimental.

No controle biológico, foram selecionados sete isolados de *Bacillus* spp. não comerciais: *B. subtilis* (B18, B202 e B33); *B. thuringiensis* (B22); *B. methylotrophicus* (B05); *B. safensis* (B53); e *B. amyloliquefaciens* (B66). Os isolados foram cedidos pelo Laboratório de Microbiologia e Fitopatologia (LAMIF), da Universidade Federal de Uberlândia, Campus Monte Carmelo-MG e foram aplicados na dose de 4L ha⁻¹ e com concentração de 1 x 10⁹ UFC mL⁻¹. Foi aplicado também no talhão experimental um produto biológico comercial a base de *Bacillus subtilis* + *Bacillus licheniformis* (dose de 300 g produto ha⁻¹) (Q). Para os tratamentos com produtos químicos comerciais, foram selecionados 2 tratamentos: nematicida comercial fluensulfone (dose de 2 L ha⁻¹) (F); combinação de abamectina (primeira aplicação) (dose de 375 mL ha⁻¹) e produto comercial a base de *Bacillus subtilis* + *Bacillus licheniformis* (segunda aplicação) (dose de 300 g produto ha⁻¹) (AQ). Para o tratamento testemunha, foi utilizado água (T).

Os isolados bacterianos não comerciais foram repicados para placas Petri, em meio de cultura 523, proposto por Kado e Hescket (1970), com as seguintes especificações: 10g de sacarose, 8 g de caseína ácida hidrolisada, 4 g de extrato de levedura, 2 g de K₂HPO₄, 0,3g de MgSO₄ 7H₂O, 15 g de ágar e 1000 mL de água destilada. As placas foram mantidas em incubadora do tipo BOD pelo período de dois dias, em temperatura de 25°C. Após este período, 1 cm³ do meio colonizado foi transferido para erlenmeyers de 250 mL contendo meio de cultura 523 líquido. Os erlenmeyers foram mantidos sob agitação, por cinco dias, no escuro, em agitador orbital do tipo Shaker, a 25± 2 °C e 150 rpm.

As suspensões bacterianas foram calibradas, por meio de espectrofotômetro de luz ajustado para densidade óptica a 600 nm. Leituras iguais a 1,8 eram equivalentes à concentração de 1×10^9 UFC/mL.

As doses utilizadas seguiram as recomendações constantes nas bulas de cada produto, levando em consideração o tamanho da área da parcela experimental. Para a aplicação dos tratamentos foi utilizado um pulverizador costal, em superfície limpa e faixa de 50 cm de largura nos dois lados da linha de plantio do cafeeiro. Todos os isolados bacterianos e produtos comerciais biológicos e químicos foram aplicados em volume de calda de 500 L ha⁻¹. As aplicações foram realizadas diretamente na projeção da copa do cafeeiro, após remoção de matéria orgânica. Foram executadas duas aplicações dos tratamentos, com intervalo de dois meses entre as aplicações, realizado anteriormente ao início do período chuvoso, nas datas: 23/09/2019 (primeira aplicação) e 25/11/2019 (segunda aplicação).

2.3 Caracterização e condições gerais da área experimental

O talhão experimental abrange uma área de 15.113 m² com o cultivo de cafeeiro da espécie Coffea arabica L. cv. Bourbon Amarelo, estabelecido no ano de 2013. A área é irrigada com sistema de irrigação localizada por gotejamento, com espaçamento de 3,8 m entre linhas e 0,7 m entre plantas e apresentando histórico com alto índice de infestação por nematoides.

As análises nematológicas indicaram na área experimental a ocorrência de quatro gêneros de nematoides: *Meloidogyne*, *Pratylenchus*, *Rotylenchulus* e *Mesocriconema*. Entre estes, os gêneros *Meloidogyne* e *Pratylenchus*, são detectados com maior regularidade na cultura cafeeira, causando vários prejuízos econômicos nas lavouras.

A distribuição populacional de nematoides foram caracterizadas anterior e posterior as aplicações dos tratamentos, assim, foram gerados mapas de caracterização com base nos

resultados das análises laboratoriais para os gêneros *Meloidogyne* e *Pratylenchus*, encontrados com maior incidência na cultura cafeeira.

O método utilizado para interpolação dos resultados foi o inverso da distância (IDW), utilizando o software *ArcGis 10.5*.

O mapa de caracterização apresenta a distribuição populacional de nematoides inicial (anterior à aplicação dos tratamentos) gerados com base nos resultados das análises laboratoriais obtidas a partir das coletas de solo realizadas na primeira avaliação (23/09/2019) (Figura 3).

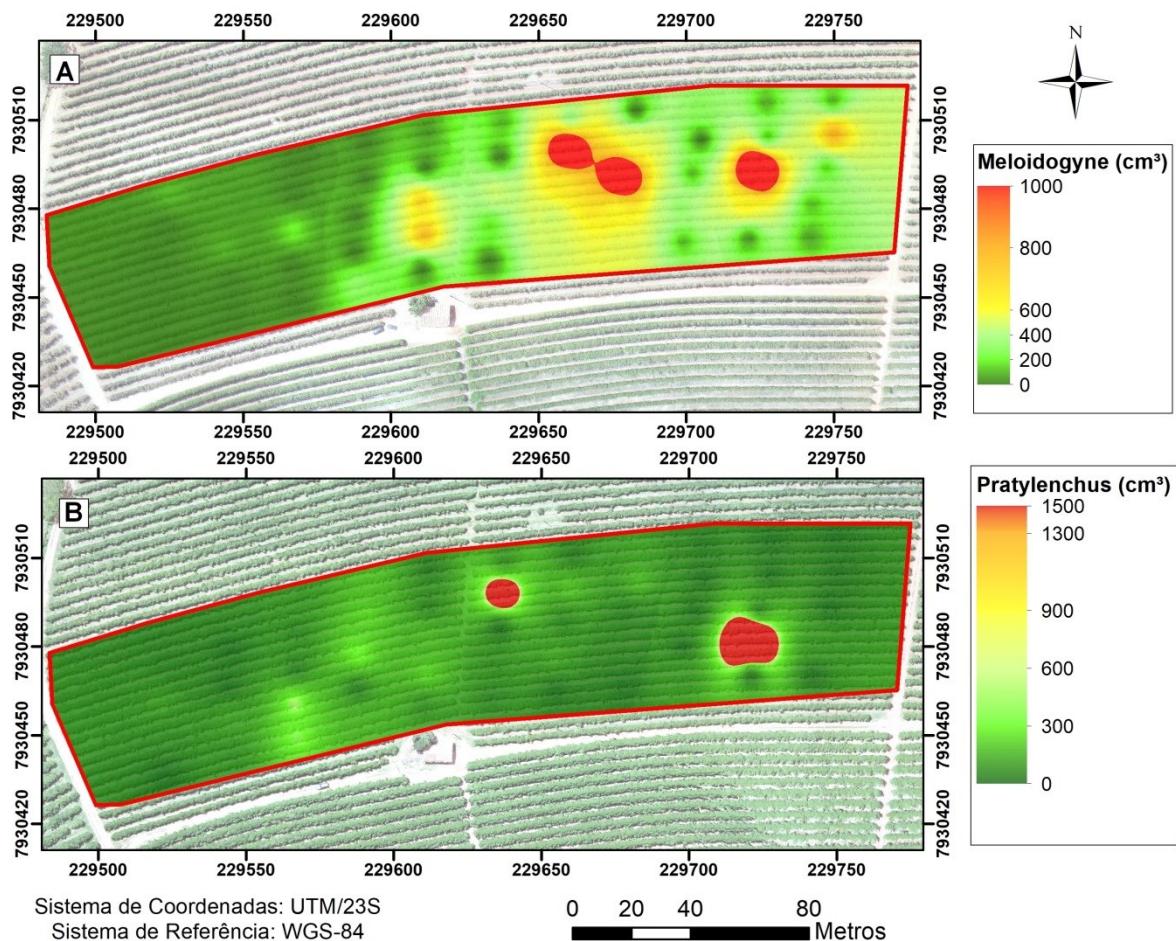


FIGURA 3 – Distribuição espacial populacional de nematoides na área experimental, anterior às aplicações dos tratamentos, para (A) *Meloidogyne* sp. (juvenis/150 cm³) e (B) *Pratylenchus* sp. (indivíduos/150 cm³) na primeira avaliação (23/09/2019)

Para *Meloidogyne* sp., (Figura 3-A) é possível observar que a região leste do talhão, apresenta maior concentração de juvenis/150 cm³ de solo, enquanto a região oeste apresenta menor concentração. Na região oeste, observam-se áreas com concentração populacional

entre 200 a 600 e 600 a 800 juvenis/150 cm³ de solo, destacando três pontos críticos, com concentrações de 800 a 1000 juvenis/150 cm³ de solo. Na região oeste, observam-se menores concentrações de juvenis/cm³ de solo em quase toda extensão do talhão, com concentrações populacionais entre 0 a 200 juvenis/150 cm³ de solo e alguns pontos com concentrações populacionais entre 200 a 600 e 600 a 800 juvenis/150 cm³ de solo, próximas à região leste do talhão.

Para *Pratylenchus* sp. (Figura 3-B), é possível observar-se concentração populacional entre 0 a 300 indivíduos/cm³ de solo em quase toda a extensão do talhão, com algumas áreas com concentrações entre 300 a 600 indivíduos/150 cm³ de solo. Na região leste do talhão, dois pontos críticos são observados, com concentrações entre 1300 a 1500 indivíduos/150 cm³ de solo.

O delineamento experimental definido para o experimento foi em blocos casualizados (DBC), onde cada bloco foi separado por duas linhas de cafeeiros, com a aplicação de 11 tratamentos para o manejo de nematoides, com cinco repetições. As parcelas foram compostas por 32 plantas de cafeeiro, sendo as duas plantas situadas nas extremidades de cada parcela consideradas plantas de bordadura, para evitar a interferência dos tratamentos aplicados nas parcelas vizinhas. Entre as plantas aptas para avaliação dos parâmetros agronômicos, foram selecionadas as três plantas centrais (Figura 4).

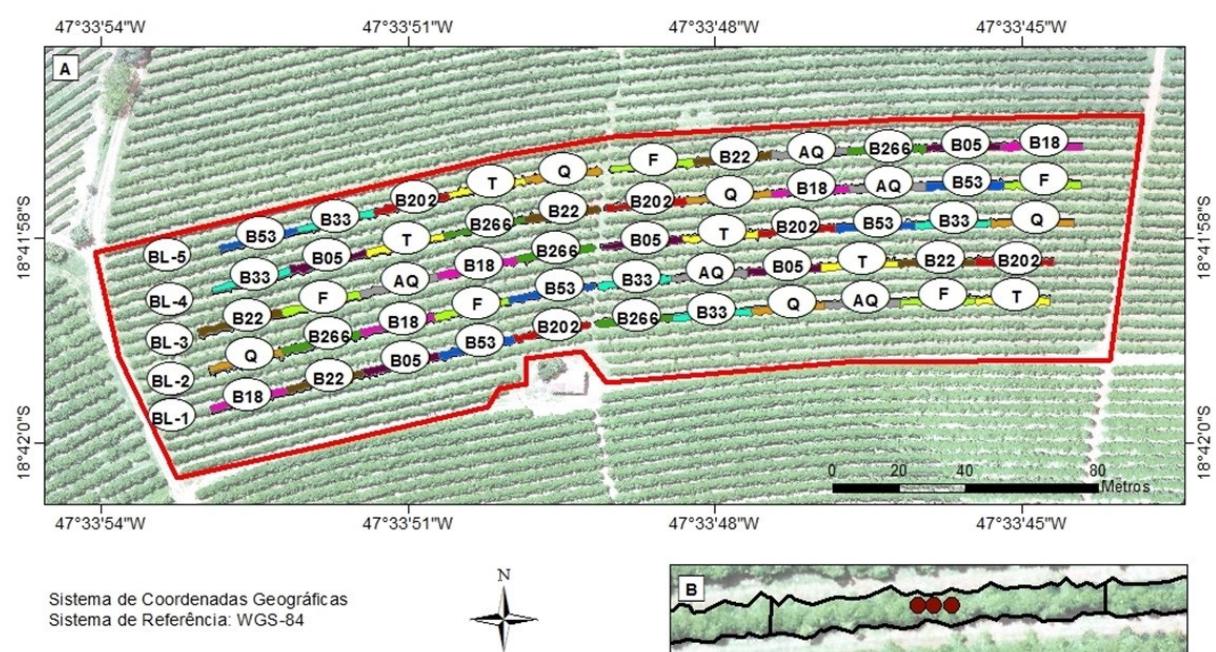


FIGURA 4 – Mapa de caracterização da área experimental. (A) Talhão experimental composto por 55 parcelas divididas em 05 blocos e distribuição dos tratamentos químicos e biológicos aplicados durante o experimento para o manejo de nematoides. (B) Croqui com localização das três plantas centrais avaliadas em cada parcela

Todas as parcelas foram delimitadas, utilizando fita zebra, sinalizando o início e o fim de cada parcela. Para a identificação das três plantas avaliadas, foram dispostas pequenas bandeiras fixadas ao solo e posicionadas em frente à planta central, permitindo a localização das plantas com maior facilidade. Para a identificação do par de ramos plagiotrópicos, foram utilizadas fitas vermelhas, atadas ao longo da base do ramo.

A área experimental, bem como as parcelas e plantas avaliadas, foram georreferenciadas utilizando as coordenadas obtidas por um par receptor GNSS de dupla frequência modelo Hiper V (L1/L2), pelo método de posicionamento RTK (Real Time Kinematic).

2.4 Avaliação dos parâmetros agronômicos

As coletas amostrais dos parâmetros agronômicos foram realizadas em três avaliações. Na 1^a avaliação realizada na semana do dia 23 de setembro de 2019, foram coletadas as amostras de solo por parcela para análise nematológica para quantificação inicial da população nematoides no talhão, sendo assim, ocorreu a 1^a aplicação dos tratamentos químicos e biológicos realizada na 1^a semana de outubro de 2019. Na 2^a avaliação realizada na semana do dia 25 de novembro de 2019, ocorrendo a 2^a aplicação dos tratamentos. Na 3^a avaliação, na semana do dia 12 de março de 2020, foi realizada a 2^a coleta de amostras de solo para quantificação populacional de nematoides após as aplicações dos tratamentos. A medição e avaliação de parâmetros agronômicos de crescimento das plantas e a aquisição de imagens multiespectrais foram realizadas em todas as etapas de avaliação.

Os parâmetros agronômicos medidos e avaliados foram os seguintes: altura das plantas (m), medida do colo da planta até a gema apical do ramo ortotrópico, com mira de encaixe de alumínio centimetrada e estadimétrica de 5 metros; número de ramos plagiotrópicos, obtidos por meio de contagem dos ramos produtivos ao longo do ramo ortotrópico; número de nós, obtidos por meio de contagem em par de ramos plagiotrópicos, na face de exposição do sol ao norte e sul, selecionado no terço médio da planta; comprimento dos ramos plagiotrópicos (m), medidos da base no ramo ortotrópico até o ápice do ramo plagiotrópico, na face de exposição do sol ao norte e sul, com trena de fibra de vidro; índice de clorofila total, coletados de folhas sadias no terço médio e superior das plantas, utilizando medidor eletrônico de clorofila portátil ClorofiLOG CFL 1030, marca Falker; diâmetro de copa (m), medidos a partir das imagens multiespectrais adquiridas por aerolevantamento.

Os dados amostrais coletados foram medidos e avaliados nas mesmas plantas em todas

as avaliações. Após as coletas, os dados foram tabelados e os valores considerados nas análises correspondem à média aritmética das três plantas avaliadas por parcela.

2.5 Amostragem de solo para análises nematólogicas

Para quantificar a população e identificar as espécies de nematoides no talhão experimental, foram feitas coletas de solos, com amostras de 500 g de solo, a 20 cm de profundidade. As amostragens de solo foram feitas em todas as parcelas experimentais, com amostras colhidas no meio da parcela, onde estavam localizadas as plantas avaliadas. As análises laboratoriais foram realizadas, em parceria com o Laboratório Brasileiro de Análises Ambientais e Agrícolas (LABRAS), localizado no município de Monte Carmelo-MG.

2.6 Aquisição das imagens multiespectrais

Como o intuito de estimar os parâmetros agronômicos avaliados a partir de imagens multiespectrais que evidenciam o desenvolvimento do cafeiro após aplicação de tratamentos para manejo de áreas com infestação por nematoides, concomitante as avaliações de crescimento, foram tomadas imagens multiespectrais sobre a área de estudo. Nesta perspectiva, considerou-se a aquisição de dados multiespectrais por meio de aerolevantamentos e por plataformas orbitais.

As imagens obtidas por aerolevantamento foram obtidas a partir de uma aeronave remotamente pilotada (ARP) com câmera nativa, que captura os comprimentos de onda do azul (B) (450 nm), verde (G) (560 nm) e vermelho (R) (660 nm), com resolução de 20MP.

Uma segunda câmera multiespectral também foi utilizada no aerolevantamento, modelo MAPIR Survay 3N, com sensor que captura os comprimentos de onda do vermelho (R) (660 nm), verde (G) (550 nm) e infravermelho próximo (NIR) (850 nm), com resolução de 12MP. A câmera MAPIR foi anexada junto à aeronave, o que permitiu a aquisição simultânea das imagens para os dois sensores no mesmo voo. As imagens foram tomadas em horários próximos ao meio dia.

As imagens orbitais multiespectrais de alta resolução foram obtidas por meio de sensores remotos orbitais da constelação de satélite PLANETScope, tomadas nas mesmas datas, ou datas próximas às avaliações, levando em consideração as condições meteorológicas da região. As imagens do satélite PLANET, possuem resolução espacial de 3 metros e resolução radiométrica de 12 bits. O sensor utilizado nesta constelação de satélites é do tipo

Bayer Mask CCD, instrumento PS2, que captura os comprimentos de onda azul (B) (455–515 nm), verde (G) (500 – 590 nm), vermelho (R) (590 – 670 nm) e infravermelho próximo (NIR) (780 – 860 nm). As imagens vêm configuradas no sistema de projeção UTM, datum horizontal WGS-84 e nível de correção 3B, oferecida com produto de imagem ortorretificado e corrigidas para valores de Surface Reflectance.

2.7 Processamento digital de imagens

2.7.1 Correções Geométricas e Atmosféricas

Após o aerolevantamento, as imagens foram processadas para a obtenção de um mosaico ortorretificado e georreferenciado, realizado de forma automática, utilizando os dados de localização integrados em todas as fotografias obtidas e pontos de apoio, por meio do software Agisoft PhotoScan Professional, desenvolvido pela Agisoft.

Mediante as imagens adquiridas por aerolevantamento, as correções foram realizadas de forma automática e simultânea com o processo de ortorretificação e georreferenciamento das imagens aéreas. Para as imagens do satélite PLANET, não foi necessário realizar as correções atmosféricas, visto que as imagens foram adquiridas no formato SR (Surface Reflectance). Neste formato, os produtos analíticos padrão (radiância) são processados para refletância do topo da atmosfera e em seguida, corrigidos atmosfericamente para refletância da superfície.

2.7.2 Normalização Radiométrica

Nesta etapa as imagens da primeira avaliação serviram como base para normalizar as imagens da segunda e terceira avaliação. A radiância para as imagens tomadas por ARP e o fator de reflectância de superfície da imagem PLANET foram extraídos de forma supervisionada, coletado nos mesmos alvos, em cada imagem a ser normalizada, pontos mais claros e mais escuros. Os valores extraídos foram aplicados na Equação 1 e processadas pela função Band Math, no software ENVI 5.1.

$$T_i = m_i * x_i + b_i \quad (1)$$

onde:

$$m_i = (Br_i * Dr_i) / (Bs_i - Ds_i);$$

$$b_i = (Dr_i * Bs_i - Ds_i * Br_i) / (Bs_i - Ds_i);$$

T_i = FRB da Imagem normalizada;

x_i = FRB da imagem original a ser normalizada;
 Br_i = média do conjunto de referência clara;
 Dr_i = média do conjunto de referência escura;
 Bs_i = média do conjunto claro a ser normalizado;
 Ds_i = média do conjunto escuro a ser normalizado;
 i = bandas do sensor em estudo

2.7.3 Cálculo dos Índices de Vegetação

O Cálculo se deu a partir de nove índices de vegetação com grande aplicação nas áreas agrícolas que foram selecionados como preditores para alimentar os modelos de predição dos parâmetros agronômicos, sendo eles: NDVI, CVI, VARI, TGI, ARVI, SICI, MPRI, SR e GNDVI (Tabela 1). Os índices foram aplicados para cada sensor, considerando as suas respectivas faixas espectrais.

TABELA 1 – Índices de vegetação aplicáveis em áreas agrícolas.

Índices de Vegetação	Referências	Fórmulas
NDVI - <i>Normalized Difference Vegetation</i>	Rouse et al. (1974)	$\frac{(NIR - R)}{(NIR + R)}$
MPRI - <i>Modified Photochemical Reflectance Index</i>	Yang et al. (2008)	$\frac{(G - R)}{(G + R)}$
GNDVI - <i>Green Normalized Difference Vegetation Index</i>	Gitelson et al. (1996)	$\frac{(NIR - G)}{(NIR + G)}$
ARVI - <i>Atmospherically Resistant Vegetation Index</i>	Kaufman e Tanré (1992)	$\frac{(NIR - (2 * R) + B)}{(NIR + (2 * R) + B)}$
VARI - <i>Visible Atmospherically Resistant Index</i>	Gitelson et al. (2002)	$\frac{(G - R)}{(G + R - B)}$
CVI - <i>Chlorophyll Vegetation Index</i>	Vincini et al. (2008)	$NIR * \frac{R}{G^2}$
SIPI - <i>Structure Insensitive Pigment Index</i>	Peñuelas et al. 1995	$\frac{(NIR - B)}{(NIR - R)}$
TGI - <i>Green Triangular Index</i>	Hunt et al. (2011)	$G - (0,39 * R) - (0,61 * B)$
SR - <i>Simple Ratio</i>	Jordan (1969)	$\frac{(R)}{(NIR)}$

A letra R corresponde ao comprimento de onda do vermelho (590 – 670 nm); G corresponde ao comprimento de onda do verde (500 – 590 nm); B corresponde ao comprimento de onda do azul (455 – 515 nm); NIR corresponde ao comprimento de onda do infravermelho próximo (780 – 860 nm)

2.8 Análise de agrupamento

Ao definir a arquitetura para seleção do melhor modelo de predição, foram avaliadas várias estruturas, variando os algoritmos e conjunto de dados de entrada com bandas espectrais e índices de vegetação. Entre as estruturas de conjunto de dados de entrada utilizadas nesta pesquisa para a construção dos modelos preditivos, foi aplicada a análise de agrupamento de variáveis para definir combinações de bandas e índices diferentes entre si para cada sensor individualmente, utilizando o software *Minitab 19*.

Nesta etapa, o software foi configurado no método de ligação completa com medida de distância por correlação. Neste método as medidas de similaridade entre dois agrupamentos são definidas pela maior distância entre uma variável qualquer de um agrupamento e uma variável qualquer em outro agrupamento, calculadas por uma matriz de distância. Além disso, como critério de partição final dos agrupamentos, foi selecionado o nível de similaridade, utilizando o valor correspondente aos três σ (sigma), ou seja, 67%, estipulados pela regra empírica.

Os resultados finais desses agrupamentos foram apresentados por uma árvore de classificação denominada de dendrograma. Para cada agrupamento gerado, foram selecionados aleatoriamente bandas e índices de vegetação para compor esta etapa.

2.9 Geração do modelo de predição

Após cada avaliação, as bases de dados foram criadas no formato de tabela contendo os valores dos parâmetros agronômicos coletados em campo e valores radiométricos extraídos das bandas espectrais e índices de vegetação para todos os sensores.

A partir das imagens multiespectrais corrigidas e os pontos levantados em campo com o receptor GNSS, shapefiles foram criados com polígonos vetorizados para a extração dos valores radiométricos, na região de cada planta avaliada nas parcelas, utilizando a ferramenta ROI - *Region of Interest* do software *ENVI 5.1*. Os valores radiométricos de banda a banda foram extraídos de forma automática e calculados pelo próprio software, sendo considerados os valores médios dos pixels abrangidos nos polígonos vetorizados para cada parcela.

Este conjunto de dados foi utilizado para gerar o modelo de predição. Ao todo foi realizado o treinamento de quatro algoritmos de classificação disponíveis no software *WEKA 3.9.4: Linear Regression; Random Forest; Multilayer Perceptron; SMOreg*.

Os algoritmos de Linear Regression são baseados em uma técnica estatística para investigar e modelar a relação entre variáveis (MONTGOMERY; PECK; Vining, 2012). A

análise de regressão linear avalia a relação entre a variável dependente Y e variáveis independentes X. Esta relação é representada por um modelo matemático, por meio de uma equação que associa estas variáveis (RODRIGUES, 2012). Para as modelagens com o algoritmo Linear Regression foram aplicadas as configurações de rede, proposta pelo próprio software: tamanho do lote (100 instâncias), método de seleção (M5).

Proposto por Breiman (2001), o algoritmo Random Forest, ou florestas aleatórias, permite a modelagem de dados com flexibilidade de interações em altas dimensões, construindo um grande número de árvores de regressão e calcular as médias de suas previsões. Seus processamentos utilizam kernels e métodos de vizinho mais próximo, pois fazem ponderações de previsões fundamentadas na média ponderada de observações próximas, porém, diferente de outros métodos, o Random Forest, se baseia em dados para determinar quais observações próximas receberão mais peso (WAGER; ATHEY, 2018). Para as modelagens com o algoritmo Random Forest foram aplicadas as configurações de rede, proposta pelo próprio software: tamanho do lote (100 instâncias), número de interações (100) e Bag Size Percent (100).

Em sua estrutura, as redes neurais do tipo Multilayer Perceptron, são formadas por uma camada de entrada, camada de saída e uma ou mais camadas ocultas, denominados de unidades setoriais ou neurônios, por onde o sinal de entrada percorre, camada por camada (HAYKIN, 2001). Redes neurais deste tipo utilizam um algoritmo baseado em regra de retropropagação de erro, conhecido como algoritmo de retropropagação de erro, ou error back-propagation (HAYKIN, 2001). Para as modelagens com o algoritmo Multilayer Perceptron foram aplicadas as configurações de rede, proposta pelo próprio software: taxa de aprendizagem (0.3); momentum (0.2); e épocas de treinamento (500).

O algoritmo SMOReg é uma implementação do algoritmo SMO proposto por Platt (1999) e melhorado por Shevade et al. (2000), que apresentaram um algoritmo iterativo, denominado de otimização mínima sequencial (SMO), associado ao Support Vector Machine, para solucionar problema de regressão. Diferente de outros modelos de aprendizagem, o Support Vector Machine se baseia na minimização de erros estruturais. Este algoritmo objetiva-se em criar, a partir de um conjunto de dados, um hiperplano de espaçamento equidistante dos dados mais próximos de cada classe para atingir uma margem máxima em cada lado do hiperplano, sendo considerado para cada hiperplano, apenas os dados de treinamento de cada classe que se enquadram na borda dessas margens. Os dados são denominados de vetores de suporte (SUÁREZ, 2013). Para as modelagens com o algoritmo SMOReg, foram aplicadas as configurações de rede, proposta pelo próprio software: tamanho

do lote (100 instâncias); Kernel (*Polykernel*).

O método de treinamento utilizado foi o *Supplied Test Set*. No total, 165 amostras foram analisadas e divididas aleatoriamente em conjuntos de entrada de treinamento, contendo 80% dos dados (132 amostras) e conjunto de dados de teste, contendo 20% dos dados (33 amostras), pelo método de aprendizagem supervisionado.

A modelagem dos dados foi realizada utilizando os conjuntos de dados de entrada das três avaliações em uma única análise. Desta forma, foi possível criar modelos multitemporais aplicados para cada parâmetro agronômico, em todos os períodos avaliados no experimento.

Vale ressaltar que, para todos os algoritmos de regressão, após vários testes, definiram-se como parâmetros de ajuste dos modelos, aqueles já definidos de forma padrão pelo próprio algoritmo *WEKA 3.9.4*. Esta opção justificou-se pelo fato que não houve ganhos significativos na acurácia dos modelos de predição com a experimentação de valores de ajustes diferentes dos já propostos pelo próprio algoritmo.

Para avaliar a relação entre os parâmetros agronômicos e os valores radiométricos, foram analisadas três estruturas de arquitetura para a construção do modelo de predição: apenas bandas espectrais originais; apenas índices de vegetação; e combinação entre bandas espectrais e índices de vegetação resultantes da análise de agrupamento.

2.10 Métrica de avaliação dos modelos

Para validar a qualidade e determinar o melhor modelo de predição, algumas métricas de avaliação foram aplicadas, tais como a Raiz do erro quadrático médio (RMSE - *root mean square error*).

O RSME e RMSE% são respectivamente definidos pelas equações 2 e 3:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - x_{med})^2}{n}} \quad (2)$$

$$RMSE\% = \sqrt{\frac{\sum_{i=1}^n (x_i - x_{med})^2}{n}} X \left(\frac{100Xn}{\sum_{i=1}^n x_{med}} \right) \quad (3)$$

onde, x_i e x_{med} representam respectivamente os valores estimados e medidos; e n o número de amostras.

Dos modelos treinados, foram selecionadas apenas as arquiteturas que apresentaram o melhor e pior desempenho, em função dos erros médios quadráticos (RMSE) e o RMSE

normalizado (RMSE%), considerando o erro da diferença entre as variáveis observadas e estimadas, para cada parâmetro agronômico avaliado na área experimental.

2.11 Mapas de caracterização das taxas de crescimento

Após definir o melhor modelo baseado nos algoritmos, conjuntos de dados de entrada e sensores, foram gerados imagens de interpolação com as estimativas dos parâmetros agronômicos, para cada época das etapas avaliativas, a fim de gerar uma grade regular de valores para o cálculo das taxas de crescimento das plantas. O método utilizado para gerar as imagens interpoladas, foi o inverso da distância (IDW), utilizando o software *ArcGis 10.5*.

Para calcular a taxa de crescimento das plantas, foi utilizada a equação da taxa de crescimento relativo (TCR), apresentando as taxas de crescimento mensal para cada parâmetro avaliado (Equação 4). Nesta etapa foram calculadas as taxas de crescimento entre a primeira (23/09/2019) e terceira (12/03/2020) avaliação, compreendendo um intervalo de seis meses.

$$TCR = \frac{\frac{N_f - N_i}{N_i}}{t} \quad (4)$$

onde, N_f = o valor final; N_i = valor inicial; e t = tempo.

3. RESULTADOS E DISCUSSÃO

3.1 Análise de agrupamento para seleção da combinação de dados de entrada.

A partir dos resultados exibidos no dendrograma, para cada agrupamento criado, foram selecionados aleatoriamente uma banda espectral ou índice de vegetação, para compor um dos conjuntos de dados de entrada para o modelo de predição.

Para as bandas espectrais e índices de vegetação do sensor da câmera MAPIR (Figura 5), foi criado um dendrograma particionado em quatro agrupamentos. Os agrupamentos foram compostos pelas seguintes observações: primeiro agrupamento (R/G/N); segundo agrupamento (SR); terceiro agrupamento (NDVI); e quarto agrupamento (CVI/GNDVI). Em cada agrupamento foram selecionadas, respectivamente, as seguintes observações: N, SR, NDVI e CVI.

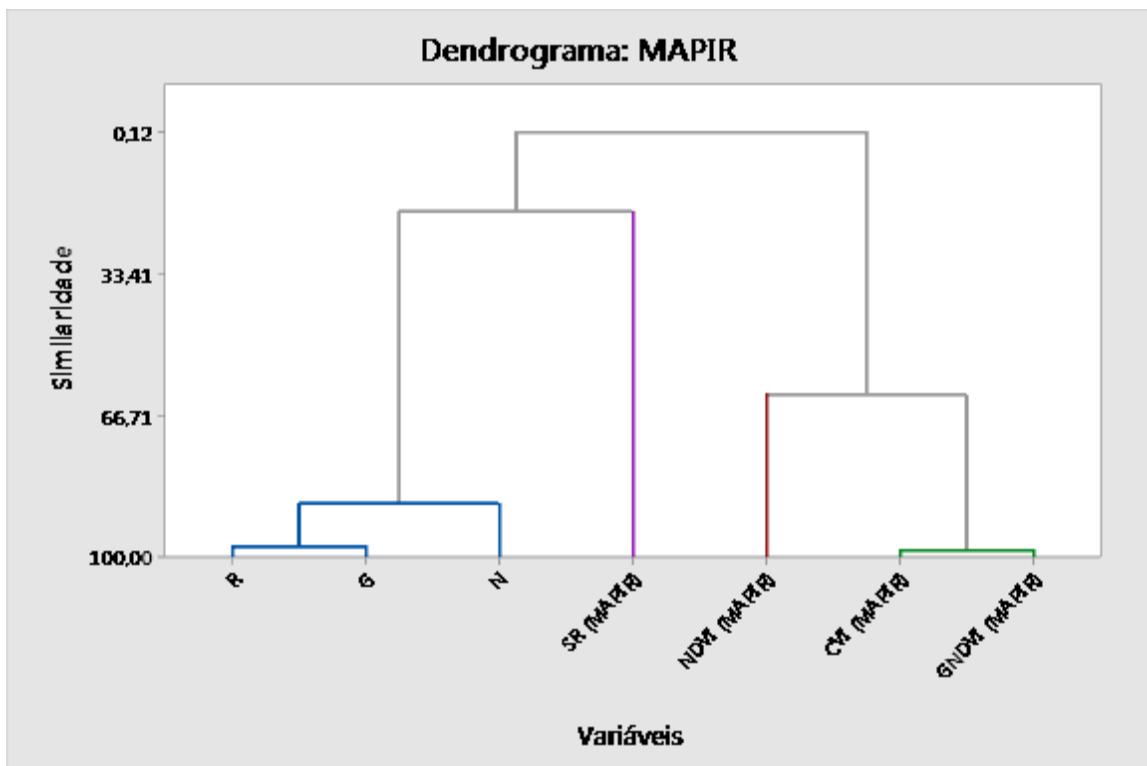


FIGURA 5 – Dendrograma de agrupamento das bandas espectrais e índices de vegetação para o sensor da câmera MAPIR. O dendrograma foi particionado em quatro agrupamentos e de forma aleatória foram escolhidas respectivamente de cada agrupamento as seguintes variáveis (NIR, SR, NDVI e CVI)

A Figura 6 apresenta o dendrograma resultante das análises das bandas espectrais e índices de vegetação do sensor do ARP, onde foi criado um dendrograma particionado em dois agrupamentos com as seguintes observações como variáveis preditoras: primeiro agrupamento (R/B/G); segundo agrupamento: (MPRI/VARI/TGI). Em cada agrupamento foram selecionadas respectivamente as seguintes observações: G e TGI.

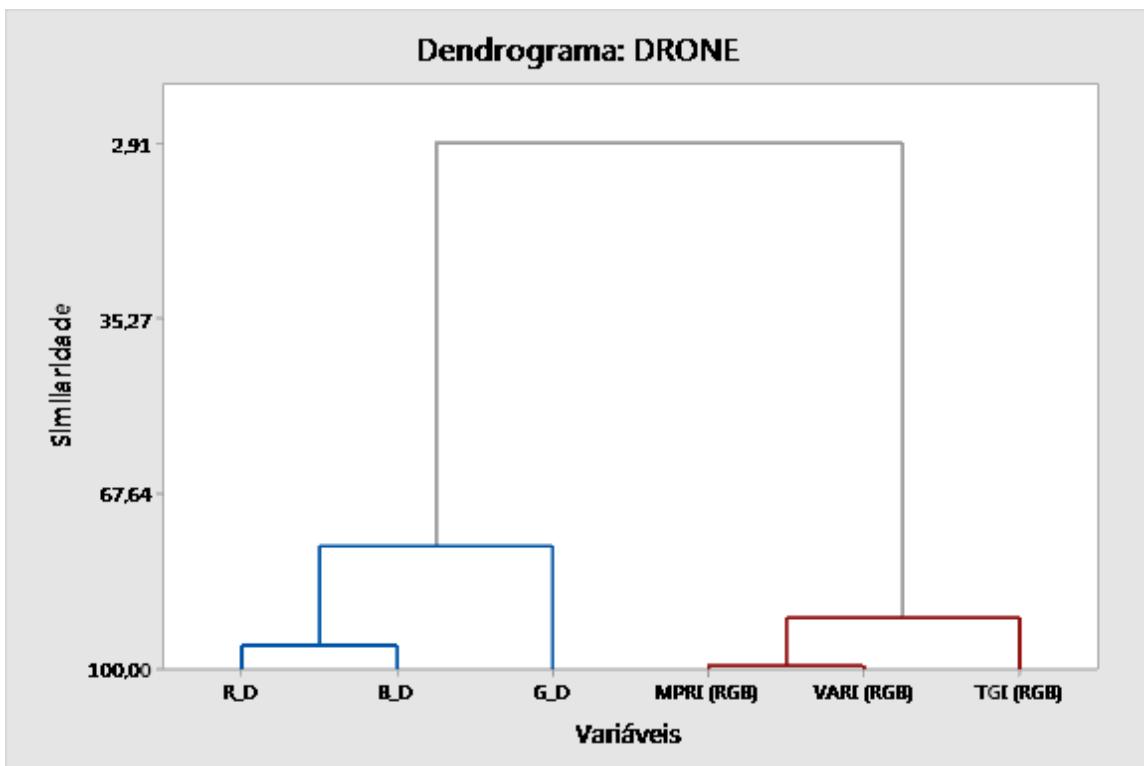


FIGURA 6 – Dendrograma de agrupamento das bandas espectrais e índices de vegetação para o sensor da câmera da ARP. O dendrograma foi particionado em dois agrupamentos e de forma aleatória foram escolhidas respectivamente de cada agrupamento as seguintes variáveis (G e TGI)

Na análise gerada para as bandas espectrais originais e índices de vegetação do satélite PLANET, conforme apresentado na Figura 7, observa-se que o dendrograma foi particionado em dois agrupamentos com as seguintes observações: primeiro agrupamento (B/G/R/SR/SIPI); segundo agrupamento (N/NDVI/ARVI/GNDVI/MPRI/VARI/TGI/CVI). Para cada agrupamento foram selecionadas respectivamente as seguintes observações: G e CVI.

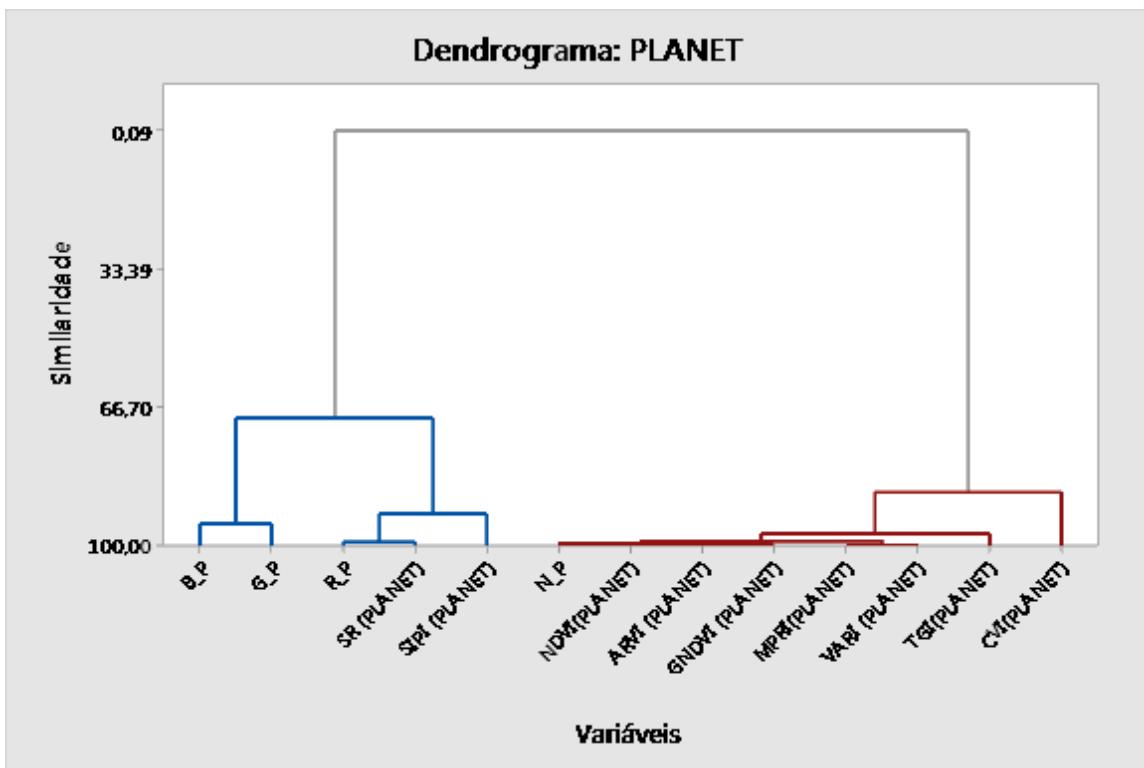


FIGURA 7 – Dendrograma de agrupamento das bandas espectrais e índices de vegetação para o sensor da câmera do satélite PLANET. O dendrograma foi particionado em dois agrupamentos e de forma aleatória foram escolhidas respectivamente de cada agrupamento as seguintes variáveis (G e CVI)

3.2 Definição dos melhores algoritmos para modelos de estimação

As Tabelas 2, 3, 4, 5, 6, 7, 8 e 9, apresentam os resultados das análises para definir os melhores algoritmos, conjuntos de dados e sensores, respectivamente para os seguintes parâmetros: índice de clorofila total; altura das plantas (m); comprimento de ramos (sul) (m); comprimento de ramos (norte) (m); número de ramos; número de nós (sul); número de nós (norte); e diâmetro de copa (m).

Para o parâmetro Índice de Clorofila Total (Tabela 2), o algoritmo Random Forest apresentou o melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos dos índices de vegetação das imagens da ARP, com os menores valores RMSE (4,7975) e RMSE% (9,0545).

No entanto, o algoritmo Random Forest apresentou o pior desempenho ao estimar os índices de clorofila total, utilizando como conjunto de dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento das imagens do satélite PLANET, com os maiores valores RMSE (6,1261) e RMSE% (11,5621).

TABELA 2 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa dos teores de clorofila para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

CLOROFILA TOTAL	MÉTRICA	MAPIR			ARP			PLANET		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	4,8566	4,9574	4,9574	5,1373	5,3161	5,0919	5,6580	5,3231	5,1853
	RMSE%	9,1661	9,3563	9,3563	9,6958	10,0333	9,6102	10,6786	10,0465	9,7864
Multilayer Perceptron	RMSE	5,0353	5,3551	5,1380	6,0262	5,4438	5,8068	5,4939	5,5143	5,4392
	RMSE%	9,5033	10,1069	9,6972	11,3735	10,2743	10,9594	10,3689	10,4074	10,2656
SMOreg	RMSE	4,8602	4,9820	4,8864	5,0421	5,0920	4,9559	5,7365	5,6554	5,2385
	RMSE%	9,1729	9,4027	9,2223	9,5162	9,6103	9,3535	10,8267	10,6737	9,8868
Random Forest	RMSE	5,3016	5,5198	4,9820	6,0722	4,7975	5,4918	5,9411	5,2788	6,1261
	RMSE%	10,0059	10,4178	9,4027	11,4603	9,0545	10,3649	11,2129	9,9629	11,5621

Chemura, Mutanga e Oindi (2017), utilizou dados espectrais do MSI Sentinel-2, com resoluções espaciais de 10 m e 20 m, ao estimar índices de clorofila na cultura cafeeira, utilizando o algoritmo Random Forest. Ao avaliar o modelo para todo o cafezal, com plantas em diferentes estádios fenológicos, utilizando bandas com resolução espacial de 10 m, o algoritmo apresentou RMSE (6,80). Ao aplicar o modelo apenas para plantas em estádio de amadurecimento dos frutos, foi observado o melhor desempenho do algoritmo, com redução do RMSE (5,90).

Shah et al. (2019), apresentaram resultados significativos na estimativa de índices de clorofila, ao utilizar o mesmo algoritmo, e com conjunto de dados de entrada, as medições de refletância hiperespectral adquiridas por espetrorradiômetro, em diferentes combinações de espectro e índices de vegetação. Ao analisar toda a faixa spectral de bandas individuais como conjunto de entrada, o algoritmo estimou satisfatoriamente os índices de clorofila em plantas de trigo, com RMSE (5,49). Ao utilizar apenas índices de vegetação, a precisão do modelo apresentou melhora, com valores RMSE variando entre 3,62 a 3,91, de acordo com as combinações de índices de vegetação selecionados.

Lee, Wang e Leblon (2020) avaliaram imagens multiespectrais adquiridas por ARP para prever o acúmulo de nitrogênio no dossel de plantas de milho. Os algoritmos Simple/Multiple Linear Regression, Random Forest, e Support Vector Regression (SVR) foram selecionados para a criação dos modelos, utilizando como dados de entrada as bandas espectrais individuais e combinações de índices de vegetação. O algoritmo Random Forest obteve o melhor desempenho, com valores RMSE (4,52).

Em outras pesquisas, os algoritmos SMOREG, Multilayer Perceptron e Linear Regression, foram utilizados na estimativa de índices de clorofila, a partir de dados adquiridos por plataformas de sensoriamento remoto. Ruiz Sánchez (2019), estimou índices de clorofila em culturas de capim Mombaça, utilizando o algoritmo SMOREG, a partir de dados hiperespectrais, com valor médio do RMSE (0,2280). As bandas espectrais do visível e red-edge foram as melhores bandas para a estimativa dos teores de clorofila.

Fiorio et al. (2015) verificaram a possibilidade de monitoramento de nitrogênio sazonal, utilizando sensores espectrais de dossel em canaviais com dispositivo FieldSpec 4, por meio de Regressões Lineares. Os dados da região espectral do verde (550 nm) e do infravermelho próximo (750 nm) foram usados para o cálculo do Índice NDVI, apresentando boa correlação com o conteúdo relativo de clorofila ($R^2 = 0,68$). A regressão linear múltipla apresentou resultado $R^2 = 0,69$ e erro padrão de 0,81.

Para o parâmetro altura das plantas (m) (Tabela 3), o algoritmo SMOREG, apresentou o

melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento das imagens do ARP, com os menores valores de RMSE (0,1128) e RMSE% (3,6929).

Para o parâmetro altura das plantas (m), o pior desempenho foi observado para o algoritmo Random Forest, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais das imagens da câmera MAPIR, com os maiores valores RMSE (0,1718) e RMSE% (5,6244).

TABELA 3 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa da altura das plantas para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

ALTURA DAS PLANTAS	MÉTRICA	MAPIR			ARP			PLANET		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	0,1379	0,1443	0,1394	0,1314	0,1223	0,1332	0,1331	0,1336	0,1340
	RMSE%	4,5146	4,7241	4,5637	4,3018	4,0039	4,3607	4,3574	4,3738	4,3869
Multilayer Perceptron	RMSE	0,1465	0,1448	0,1436	0,1538	0,1556	0,1513	0,1355	0,1460	0,1569
	RMSE%	4,7961	4,7405	4,7012	5,0351	5,0940	4,9533	4,4360	4,7798	5,1366
SMOreg	RMSE	0,1284	0,1303	0,1303	0,1203	0,1204	0,1128	0,1159	0,1219	0,1219
	RMSE%	4,2036	4,2658	4,2658	3,9384	3,9417	3,6929	3,7943	3,9908	3,9908
Random Forest	RMSE	0,1718	0,1370	0,1298	0,1185	0,1443	0,1261	0,1308	0,1508	0,1647
	RMSE%	5,6244	4,4851	4,2494	3,8795	4,7241	4,1283	4,2821	4,9369	5,3920

Para avaliar altura das plantas, Bunruang e Kaewplang (2021) testaram três algoritmos de aprendizagem de máquinas (Generalized Linear Model, Decision Tree e Support Vector Machine), usando valores de refletâncias de imagens RGB adquiridas em aerolevantamento com ARP e modelos digitais de terreno, em plantações de cana-de-açúcar. Os resultados apresentaram correlação entre as alturas medidas e estimadas, com melhor desempenho para o algoritmo Support Vector Machine, com valor de R^2 (0,82) e RMSE (0,19).

Prestes (2020) utilizou o mesmo algoritmo para prever a produtividade de trigo, avaliando as alturas das plantas como indicativo de rendimento, a partir de valores de refletância de imagens RGB e NIR adquiridas em aerolevantamento com ARP e modelos digitais de terreno. O algoritmo apresentou bom desempenho para a estimativa deste parâmetro, principalmente com a banda espectral NIR, que apresentou erro médio menor que as bandas espectrais do visível, com valor de R^2 (0,97).

Em outras pesquisas, os algoritmos Multilayer Perceptron e Linear Regression foram utilizados na estimativa da altura das plantas, a partir de dados adquiridos por plataformas de sensoriamento remoto.

Ndikumana et al. (2018) utilizaram três algoritmos (Multiple Linear Regression, Support Vector Regression e Random Forest), para validar a capacidades de imagens de radar multitemporais do Sentinel-1 na estimativa da altura de plantas arroz e biomassa seca. Para a altura das plantas o algoritmo Random Forest apresentou o melhor desempenho com coeficiente de correlação R^2 (0,92) e RMSE (16%).

Osco (2020), estimarem teor de nitrogênio e altura das plantas de milho, utilizando bandas espectrais e índices de vegetação gerados de imagens multiespectrais adquiridas por ARP e aprendizagem de máquina. O algoritmo Random Forest apresentou melhor desempenho, com RMSE (1,9) e o uso de índices de vegetação como conjunto de dados de entrada, contribuíram consideravelmente para o bom desempenho do modelo, em relação às bandas espectrais individuais.

Para os parâmetros comprimento de ramos (sul) (m) (Tabela 4), o algoritmo SMOreg, apresentou o melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento das imagens da ARP, com os menores valores RMSE (0,1329) e RMSE% (15,3025).

Para o parâmetro comprimento de ramos (sul) (m), o pior desempenho foi observado para o algoritmo Multilayer Perceptron, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais das imagens do ARP, apresentando os maiores valores RMSE (0,1691) e RMSE% (19,4707).

TABELA 4 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do comprimento de ramos (sul) para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

COMPRIMENTO DE RAMOS (SUL)	MÉTRICA	MAPIR			ARP			PLANET		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	0,1447	0,1430	0,1430	0,1353	0,1337	0,1340	0,1410	0,1404	0,1418
	RMSE%	16,6612	16,4655	16,4655	15,5789	15,3946	15,4292	16,2352	16,1661	16,3273
Multilayer Perceptron	RMSE	0,1568	0,1677	0,1679	0,1691	0,1654	0,1583	0,1598	0,1520	0,1661
	RMSE%	18,0544	19,3095	19,3325	19,4707	19,0447	18,2271	18,3999	17,5017	19,1253
SMOreg	RMSE	0,1408	0,1431	0,1439	0,1348	0,1348	0,1329	0,1411	0,1403	0,1432
	RMSE%	16,2121	16,4770	16,5691	15,5213	15,5213	15,3025	16,2467	16,1546	16,4885
Random Forest	RMSE	0,1661	0,1646	0,1607	0,1646	0,1367	0,1398	0,1535	0,1429	0,1580
	RMSE%	19,1253	18,9525	18,5035	18,9525	15,7401	16,0970	17,6745	16,4539	18,1926

Para os parâmetros comprimento de ramos (norte) (m) (Tabela 5), o algoritmo SMOreg, apresentou o melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento das imagens da ARP, com os menores valores de RMSE (0,1436) e RMSE% (16,8162).

Para o parâmetro comprimento de ramos (norte) (m), o pior desempenho foi observado para o algoritmo Random Forest, utilizando como conjunto de dados de entrada os valores radiométricos dos índices de vegetação das imagens da câmera MAPIR. Os resultados apresentam para este algoritmo os maiores valores RMSE (0,1825) e RMSE% (21,3715).

TABELA 5 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do comprimento de ramos (norte) para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

COMPRIMENTO DE RAMOS (NORTE)	MÉTRICA	MAPIR			ARP			PLANT		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	0,1561	0,1627	0,1546	0,1507	0,1523	0,1453	0,1516	0,1504	0,1498
	RMSE%	18,2800	19,0529	18,1043	17,6476	17,8350	17,0153	17,7530	17,6125	17,5422
Multilayer Perceptron	RMSE	0,1551	0,1539	0,1539	0,1470	0,1458	0,1477	0,1594	0,1582	0,1528
	RMSE%	18,1629	18,0224	18,0224	17,2143	17,0738	17,2963	18,6664	18,5259	17,8935
SMOreg	RMSE	0,1530	0,1536	0,1532	0,1516	0,1515	0,1436	0,1491	0,1450	0,1573
	RMSE%	17,9170	17,9872	17,9404	17,7530	17,7413	16,8162	17,4603	16,9801	18,4205
Random Forest	RMSE	0,1792	0,1825	0,1677	0,1616	0,1542	0,1523	0,1540	0,1645	0,1643
	RMSE%	20,9851	21,3715	19,6384	18,9241	18,0575	17,8350	18,0341	19,2637	19,2402

Para os parâmetros número de ramos (Tabela 6) e número de nós (sul) (Tabela 7), o algoritmo de Linear Regression, apresentou melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais e índices de vegetação selecionados por análise de agrupamento das imagens da ARP. Observaram-se respectivamente os menores valores de RMSE e RMSE%: (12,1711 e 16,4744; 5,0442 e 18,2725).

Para estes parâmetros, o algoritmo Random Forest apresentou o pior desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais e índices de vegetação selecionados por análise de agrupamento, das imagens do satélite PLANET, respectivamente com os menores valores de RMSE e RMSE%: (17,0949 e 23,1391; 7,0114 e 25,3986).

TABELA 6 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do número de ramos para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

NÚMERO DE RAMOS	MÉTRICA	MAPIR			ARP			PLANT		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	12,6672	12,4328	12,4328	12,7030	12,7974	12,1711	13,2677	12,6498	13,5959
	RMSE%	17,1459	16,8286	16,8286	17,1944	17,3222	16,4744	17,9587	17,1224	18,4030
Multilayer Perceptron	RMSE	13,1902	13,0240	13,2319	13,3447	13,6616	12,9758	12,8537	13,4042	13,3276
	RMSE%	17,8538	17,6289	17,9103	18,0630	18,4919	17,5636	17,3984	18,1435	18,0398
SMOreg	RMSE	12,4911	12,2850	12,1046	12,7445	12,6863	12,2239	12,6868	12,4639	13,0752
	RMSE%	16,9076	16,6286	16,3844	17,2506	17,1718	16,5459	17,1725	16,8707	17,6982
Random Forest	RMSE	15,1826	13,2792	14,6789	15,2404	13,4421	14,6098	13,6707	13,7901	17,0949
	RMSE%	20,5507	17,9743	19,8689	20,6289	18,1948	19,7754	18,5042	18,6658	23,1391

TABELA 7 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do número de nós (sul) para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

NÚMERO DE NÓS (SUL)	MÉTRICA	MAPIR			ARP			PLANET		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	5,5066	5,4188	5,4188	5,5664	5,5561	5,0442	5,7827	5,6713	6,1094
	RMSE%	19,9475	19,6295	19,6295	20,1641	20,1268	18,2725	20,9477	20,5441	22,1311
Multilayer Perceptron	RMSE	6,3083	5,5534	5,8177	5,7559	5,4792	5,1339	5,5142	5,4448	6,1065
	RMSE%	22,8516	20,1170	21,0745	20,8506	19,8483	18,5974	19,9750	19,7236	22,1206
SMOreg	RMSE	5,9004	5,9119	5,8174	5,5071	5,3703	5,1289	5,6402	5,4107	6,2885
	RMSE%	21,3740	21,4157	21,0734	19,9493	19,4538	18,5793	20,4315	19,6001	22,7799
Random Forest	RMSE	5,9888	6,7127	6,1882	6,0588	6,5763	6,8451	5,6800	5,6479	7,0114
	RMSE%	21,6943	24,3166	22,4166	21,9478	23,8225	24,7962	20,5756	20,4594	25,3986

Para o parâmetro número de nós (norte) (Tabela 8), o algoritmo Random Forest apresentou o melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais das imagens do satélite PLANET, com os menores valores de RMSE (7,5341) e RMSE% (26,2917).

O pior desempenho foi observado para o algoritmo Multilayer Perceptron, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais das imagens da câmera MAPIR, com os maiores valores RMSE (10,5508) e RMSE% (36,8191).

TABELA 8 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do número de nós (norte) para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

NÚMERO DE NÓS (NORTE)	MÉTRICA	MAPIR			ARP			PLANET		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	8,0848	8,1779	8,1779	8,3165	8,0148	8,0355	8,0714	8,0299	8,1999
	RMSE%	28,2135	28,5384	28,5384	29,0221	27,9692	28,0415	28,1668	28,0219	28,6152
Multilayer Perceptron	RMSE	10,5508	9,7021	9,7082	9,2025	9,0327	9,3524	10,1054	9,4925	9,2551
	RMSE%	36,8191	33,8574	33,8787	32,1140	31,5214	32,6371	35,2648	33,1260	32,2975
SMOreg	RMSE	7,8598	8,3006	7,9607	7,6931	7,9362	7,5937	8,1773	8,0295	7,9834
	RMSE%	27,4283	28,9666	27,7805	26,8466	27,6950	26,4997	28,5363	28,0205	27,8597
Random Forest	RMSE	9,4234	9,7318	8,9461	8,0566	8,5918	8,3851	7,5341	8,3370	9,1553
	RMSE%	32,8848	33,9611	31,2192	28,1151	29,9828	29,2615	26,2917	29,0936	31,9493

Para o parâmetro Diâmetro de Copa (m) (Tabela 9), o algoritmo SMOrég apresentou o melhor desempenho, utilizando como conjunto de dados de entrada os valores radiométricos das bandas espectrais das imagens multiespectrais do PLANET, com os menores valores de RMSE (0,1302) e RMSE% (7,7374).

O algoritmo Random Forest apresentou o pior desempenho, utilizado como conjunto de dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento, das imagens da ARP, com os maiores valores RMSE (0,1903) e RMSE% (11,3090).

TABELA 9 – Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) dos algoritmos na estimativa do diâmetro de copa para os sensores da MAPIR, ARP e PLANET e para os conjuntos de dados de entradas utilizando as bandas espectrais, índices de vegetação e bandas e índices selecionados por análise de agrupamentos

DIÂMETRO DE COPA	MÉTRICA	MAPIR			ARP			PLANT		
		BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.	BANDAS	INDICES	COMB.
Linear Regression	RMSE	0,1701	0,1861	0,1834	0,1506	0,1508	0,1578	0,1341	0,1375	0,1476
	RMSE%	10,1086	11,0594	10,8990	8,9498	8,9616	9,3776	7,9692	8,1713	8,7715
Multilayer Perceptron	RMSE	0,1496	0,1517	0,1482	0,1574	0,1543	0,1686	0,1613	0,1836	0,1555
	RMSE%	8,8903	9,0151	8,8071	9,3539	9,1696	10,0194	9,5856	10,9109	9,2410
SMOreg	RMSE	0,1784	0,1895	0,1898	0,1541	0,1456	0,1632	0,1302	0,1352	0,1393
	RMSE%	10,6018	11,2615	11,2793	9,1578	8,6526	9,6985	7,7374	8,0346	8,2782
Random Forest	RMSE	0,1857	0,1707	0,1625	0,1773	0,1762	0,1903	0,1382	0,1543	0,1547
	RMSE%	11,0357	10,1442	9,6569	10,5365	10,4711	11,3090	8,2129	9,1696	9,1934

Para o número de nós (sul), número de nós (norte), comprimento dos ramos (sul) (m), comprimento de ramos (norte) (m), número de ramos, e diâmetro de copa (m), não foram encontradas pesquisas relacionadas a estimativas destes parâmetros, no entanto, alguns estudos foram realizados utilizando os mesmos algoritmos de aprendizagem de máquinas e dados adquiridos por plataformas de sensoriamento para a estimativa de parâmetros relacionados à produtividade em diversas culturas, validando o potencial uso desta tecnologia.

Randđelović et al. (2020) utilizaram algoritmo Random Forest para estimar a densidade vegetal de plantas de soja, utilizando apenas índices de vegetação, gerados a partir de imagens RGB aéreas, adquiridas por ARP. Os resultados apresentaram validação do modelo significativa, com valor RMSE (7,47).

Zha, et al. (2020) utilizaram algoritmos de aprendizagem de máquina e métodos de Regressão Linear, para estimar a biomassa de plantas de arroz e níveis de N, utilizando índices de vegetação gerados a partir de imagens adquiridas por ARP. Os resultados indicaram que os métodos de aprendizagem de máquinas apresentaram melhor desempenho na estimativa dos índices de nutrição das plantas, quando comparados a métodos de Regressão Linear, com destaque para o algoritmo Random Forest, que apresentou menor RMSE (0,09).

Oliveira et al. (2019) utilizaram algoritmos baseados em redes neurais artificiais, para prever a maturação de vagens de amendoim, em áreas irrigadas e de sequeiro. Foram criadas duas redes neurais do tipo multicamadas, utilizando como dados de entrada sete índices de vegetação originais e outra com quatro índices de vegetação modificados, a partir de imagens de uma câmera multiespectrais com quatro bandas espectrais (R/G/N/RedEdge). As redes neurais apresentaram resultados significativos, apresentando melhor desempenho para os conjuntos de dados compostos por índices de vegetação modificados, com valores de RMSE de 0,069 e 0,088. Para os conjuntos de dados utilizando índices de vegetação originais, observaram-se valores RMSE de 0,090 e 0,094.

Zhou et al. (2020) utilizaram imagens multiespectrais adquiridas por ARP e aprendizagem de máquinas para prever a variabilidade no rendimento e teor de proteínas do trigo de inverno. Baseados na refletância espectral e altura das plantas, foram criados modelos, utilizando os algoritmos, SMOreg, Random Forest, Redes Neurais e Regressão Linear tradicional. O modelo de regressão linear, utilizando um índice de vegetação apresentou melhores resultados em prever o rendimento com R^2 de (0,62) e RMSE (972 kg ha^{-1}). Para prever o conteúdo de proteína das plantas, o modelo de Random Forest apresentou o melhor desempenho, por apresentar o menor RMSE (1,07%).

Para o parâmetro número de nós (norte) e diâmetro de copa, as imagens Planet apresentaram melhor desempenho. Esta ocorrência pode ser justificada devido as altas resolução espacial das imagens e variabilidade radiométrica das mesmas capturadas pela ARP, enquanto que nas imagens orbitais ocorre a generalização da informação, ou seja, é predominante a resposta das plantas no dossel.

O algoritmo SMOreg apresentou o melhor desempenho geral, ao estimar a maior parte dos parâmetros agronômicos avaliados, sendo eles: Altura das plantas (m), Comprimento de Ramos (sul) (m), Comprimento de Ramos (norte) (m) e diâmetro de copa (m).

A aplicação do algoritmo do tipo Support Vector Machine em modelagens utilizando imagem multiespectrais tem se mostrado eficiente mediante as características positivas em sua aplicação no sensoriamento remoto: capacidade de gerenciar pequenos conjuntos de dados de treinamento com eficácia; eficiente em lidar com espaços de alta dimensão; processo de decisão, utilizando apenas um subconjunto de dados de treinamento; métodos mais eficientes em termos de armazenado na memória; e aplicação de novos kernels em vez de limites lineares (SHEYKHMOUSA et al., 2020).

O algoritmo Random Forest apresentou bom desempenho ao estimar os parâmetros: Índice de clorofila total e número de nós (norte). Entre as vantagens do algoritmo Random Forest, quando comparado a outros classificadores, utilizando dados adquiridos por plataformas de sensoriamento remoto, destaca-se: capacidade de lidar com elevada variância temporal da reflectância da vegetação; alto dinamismo de processamento, por precisar de poucos parâmetros para as classificações; elevada acurácia de classificação, entre outros (SILVEIRA, 2018).

O algoritmo Linear Regression apresentou bom desempenho ao estimar os parâmetros: número de ramos e número de nós (sul). Na estimativa de parâmetros relacionada a áreas agrícolas, as regressões lineares têm sido constantemente aplicadas, evidenciando a sua potencial aplicação, utilizando dados de sensoriamento remoto (PAUL; SAHA; HEMBRAMA, 2020; LEE; WANG; LEBLON, 2020; XU et al., 2018).

Como conjunto de dados de entrada, as bandas espectrais e índices de vegetação selecionados por análise de agrupamento, apresentaram o melhor desempenho como variáveis preditoras para os parâmetros: altura das plantas (m), número de ramos, comprimento de ramo (norte) (m), comprimento de ramo (sul) (m), e número de nós (sul).

As bandas espectrais apresentaram melhor desempenho como variáveis preditoras para os parâmetros: número de nós (norte) e diâmetro de copa (m), enquanto os índices de vegetação apresentaram melhor desempenho como variáveis preditoras para o parâmetro:

índice de clorofila total. Neste sentido, as bandas espectrais e os índices de vegetação apresentam grande potencial para a estimativa de parâmetros agrícolas. Os índices de vegetação são indicativos das propriedades biofísicas dinâmicas relacionadas com a produtividade e o balanço de energia da vegetação, devido à correlação existente entre a radiação solar e os tecidos fotossintéticos ativos das plantas (FORMAGGIO; SANCHES, 2017). A disponibilidade de várias bandas espectrais permite explorar as características espectrais em conjunto com os modos operacionais dos sistemas sensores com mais eficiência, ou seja, quanto mais bandas espectrais disponíveis, maior a possibilidade de extrair informações sobre um objeto analisado (EPIPHANIO; FORMAGGIO, 1991).

As imagens do sensor da ARP apresentaram o melhor desempenho ao estimar os parâmetros: índice de clorofila; número de ramos; comprimento de ramos (norte) (m); comprimento de ramos (sul) (m); e número de nós (sul). As ARPs são apresentadas com uma ferramenta de auxílio em atividades relacionadas à agricultura, por fornecer gerenciamento de precisão inestimável com operações econômicas e flexíveis (MEIVEL; MAHESWARI, 2020). Isto pode ser observado nas diversas aplicações de ARP na agricultura, utilizando imagens multiespectrais geradas por seus sensores, que abrangem entre várias outras aplicações: estimativa de parâmetros agrícolas; identificação de ocorrência de pragas e doenças; identificação de falhas no plantio; e análises relacionadas ao uso do solo (STAVRAKOUDIS et al., 2019; OLIVEIRA et al., 2018; KAIVOSOJA et al., 2021; IVUSHKIN et al., 2019).

As imagens do sensor do satélite PLANET apresentaram o melhor desempenho ao estimar os parâmetros: número de nós (norte) e diâmetro de copa (m). As imagens obtidas por sensores orbitais, ao longo dos anos, têm sido amplamente aplicadas no monitoramento em áreas agrícolas, principalmente utilizando imagens multiespectrais de média resolução, disponibilizadas sem custos. Porém, alguns fatores são limitantes para o uso de sensores orbitais, destacando-se a baixa disponibilidade e acesso a satélites com imagens de alta resolução, bem como a flexibilidade temporal de aquisição de dados, que são importantes para aplicação agrícola (IVUSHKIN et al., 2018). Imagens de alta resolução são de alto custo de aquisição e comercializadas cobrindo apenas áreas maiores que 2.500 hectares (ALBUQUERQUE et al., 2017).

A Figura 8 apresenta os gráficos de dispersão da predição (eixo Y) e medidos (eixo X) das arquiteturas que apresentaram melhor desempenho para os parâmetro agronômico: clorofila (Figura 8-A), altura da planta (m) (Figura 8-B), número de ramos (Figura 8-C), comprimento de ramos (norte) (m) (Figura 8-D); comprimento de ramos (sul) (m) (Figura 8-

E); número de nós (norte) (Figura 8-F); número de nós (sul) (Figura 8-G); e diâmetro de copa (m) (Figura 8-H).

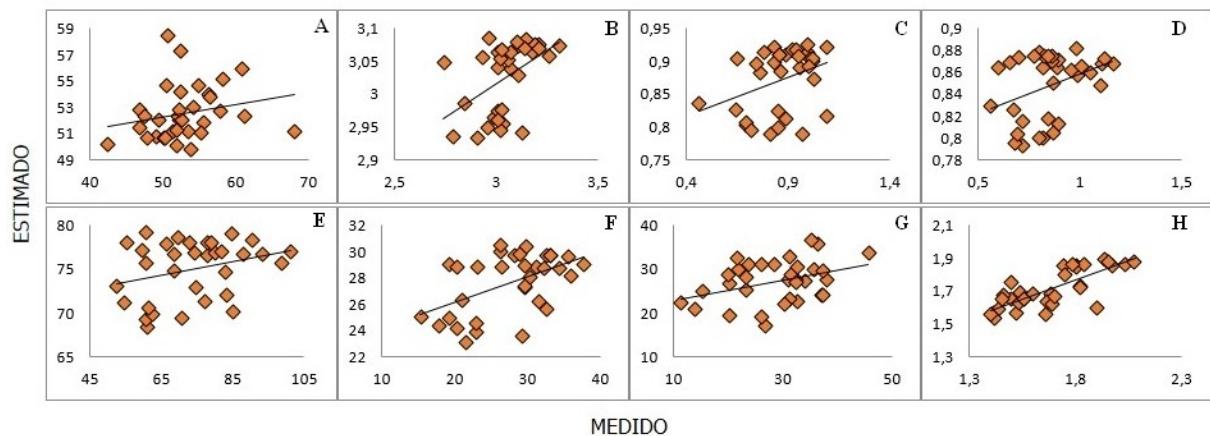


FIGURA 8 – Gráficos de dispersão de valores estimados (eixo Y) e medidos (eixo X) das arquiteturas que apresentaram melhor desempenho para os parâmetros agronômicos: (A) clorofila total; (B) altura das plantas (m); (C) número de ramos; (D) comprimento de ramos (norte) (m); (E) comprimento de ramos (sul) (m); (F) número de nós (norte); (G) número de nós (sul); e (H) diâmetro de copa (m)

3.3 Mapas de Caracterização dos parâmetros

As Figuras 9, 10, 11, 12, 13, 14, 15 e 16, apresentam os mapas de caracterização da taxa de crescimento entre a primeira avaliação (23/09/2019) e a terceira avaliação (12/03/2020), compreendendo um intervalo de 6 meses, respectivamente para os seguintes parâmetros: índice de clorofila total; altura das plantas (m); número de ramos; comprimento de ramos (sul) (m); comprimento de ramos (norte) (m); número de nós (sul); número de nós (norte); e diâmetro de copa (m).

A Figura 9 apresenta a taxa de crescimento (%) para o índice de clorofila total (%). É possível observar, a redução dos índices de clorofila total na área experimental, apresentando taxas de crescimento negativas em toda sua extensão, com valores entre 0% a 3% de crescimento/mês. Valores entre -3% a -4% de crescimento/mês também foram observadas pontualmente em todas as parcelas.

Taxas de crescimento positivas foram observadas em todas as parcelas, principalmente na face de exposição sul da área experimental, com valores entre 0% a 3% de crescimento/mês.

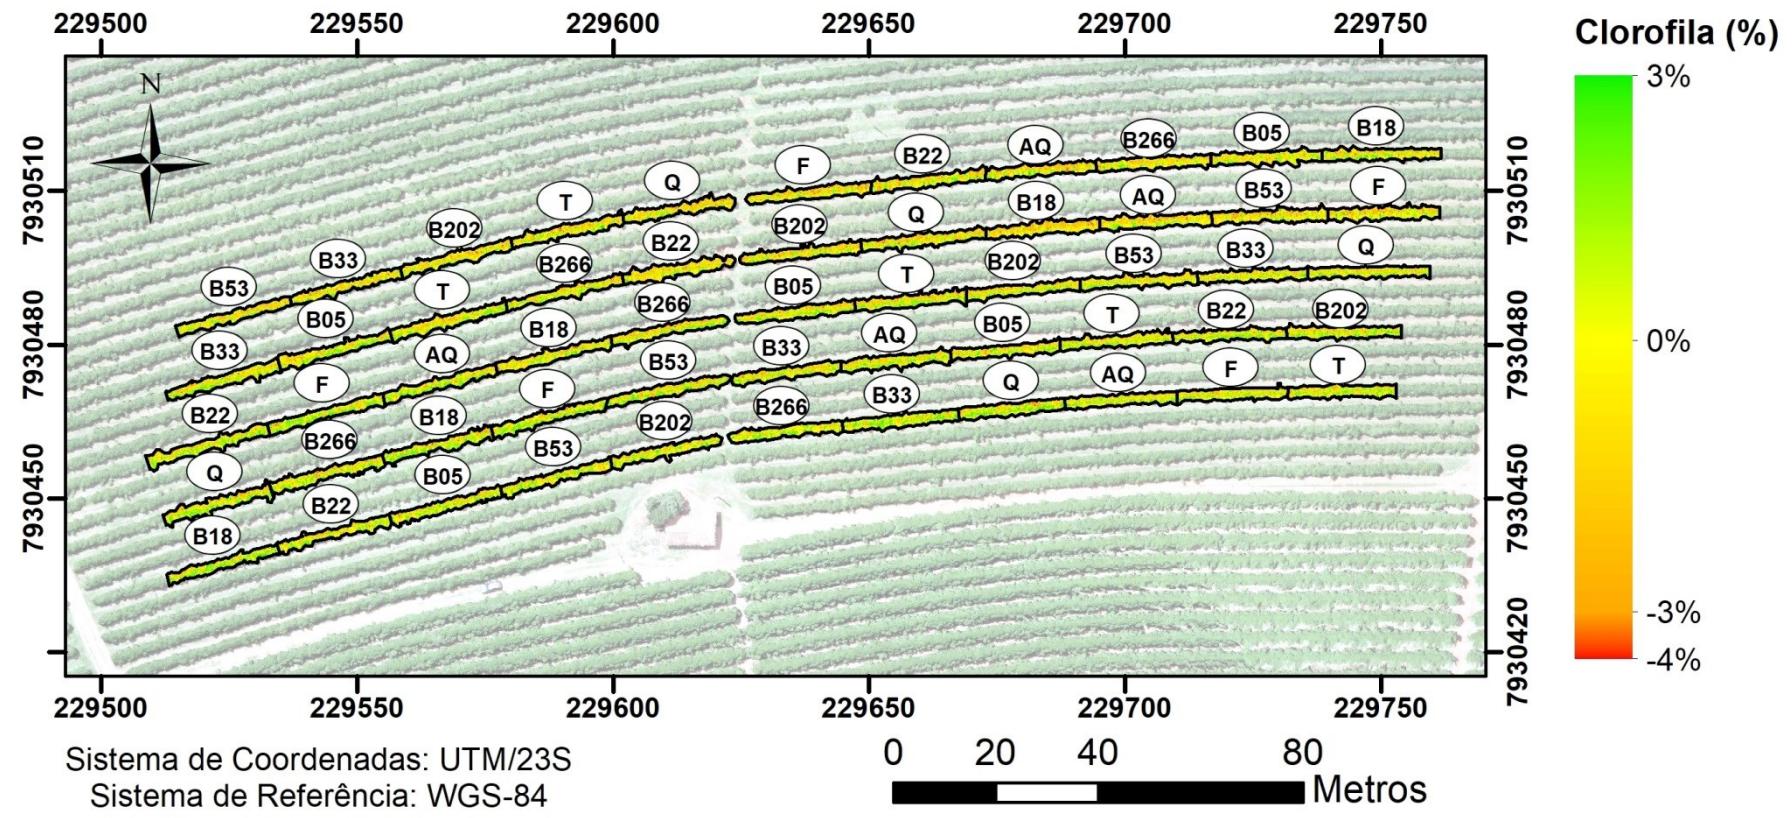


FIGURA 9 – Mapa de caracterização da taxa de crescimento para o parâmetro índice de clorofila total

Um fator que justifica este comportamento, levando em consideração o período das avaliações na área experimental, que ocorreram entre a segunda fase e início da quarta fase do ciclo fenológico do cafeeiro, compreendendo parte do período de florada no mês de setembro (primeira avaliação), chumbinho e expansão do fruto no mês de novembro (segunda avaliação), e granação dos frutos e início da maturação no mês de março (terceira avaliação).

A baixa disponibilidade de nitrogênio, em plantas que demandam maior quantidade desse nutriente, pode ser um fator limitante na produtividade em diversas culturas. A ausência de nitrogênio, importante para a síntese da clorofila e outros processos fotossintéticos, reduz a absorção de luz solar como fonte de energia e afeta funções essenciais como a absorção de nutrientes (REIS et al., 2006).

Somado a isso, nutrientes tais como o nitrogênio, que possuem ligação direta com os teores de clorofila nas plantas, constitui um papel essencial para a manutenção do vigor vegetativo das plantas, principalmente na fase reprodutiva. Jia et al. (2021), destacaram que o nitrogênio é um dos elementos mais importantes na clorofila e enzimas das plantas, e sua deficiência pode levar à diminuição de assimilação da fotossíntese e rendimento da cultura.

Durante a fase de expansão dos frutos do cafeeiro, ocorre o desvio de grandes quantidades de carboidratos, além do consumo de mais de 95% da absorção total de nitrogênio, causando sintomas de deficiência nas folhagens e restringindo o crescimento vegetativo (AMARAL et al., 2001). Na fase de granação dos frutos, ocorre o deslocamento de nutrientes como o nitrogênio, que se deslocam das folhas para os frutos e provoca maior deficiência foliar (MATIELLO et al., 2010).

A Figura 10 apresenta a taxa de crescimento (%) para a altura das plantas (m). É possível observar que o crescimento das plantas, apresentando em toda a extensão da área experimental taxa de crescimento positiva, com valores entre 0% e 1% de crescimento/mês. Valores entre 1% a 2% e 2% a 3%, também foram observados pontualmente em algumas parcelas, com destaque nos tratamentos B33 e B202 (*Bacillus subtilis*) e tratamento T (água) no segundo e quinto bloco, apresentando as maiores concentrações destes valores.

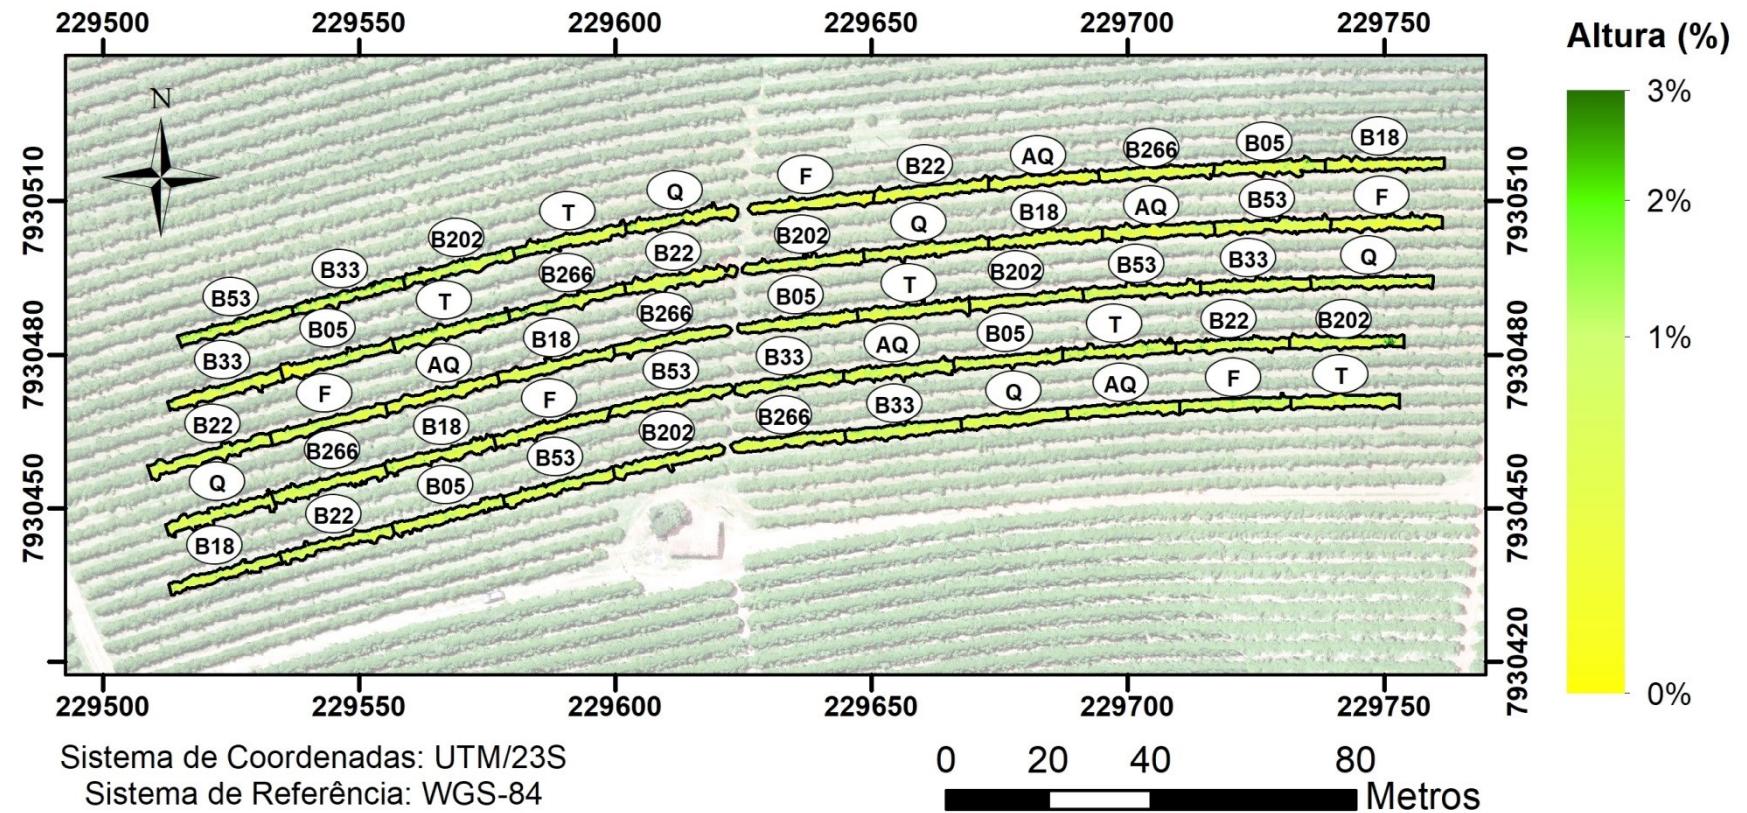


FIGURA 10 – Mapa de caracterização da taxa de crescimento para o parâmetro altura das plantas

A Figura 11 apresenta a taxa de crescimento (%) para o número de ramos. É possível observar o aumento do número de ramos, apresentando com maior concentração, em toda extensão da área experimental taxa de crescimento positiva, com valores entre 2% a 4% e 4% a 8% de crescimento/mês.

Taxas de crescimento negativas (%) também foram observadas em toda a extensão da área experimental, com valores entre 0% e -2% de crescimento/mês. Valores entre -2% a -4% foram observados pontualmente em algumas parcelas, com destaque para os tratamentos B33 (*Bacillus subtilis*) e B05 (*Bacillus methylotrophicus*) no quarto bloco, e tratamento B53 (*Bacillus safensis*) e B33 (*Bacillus subtilis*) no quinto bloco, com maior concentração destes valores.

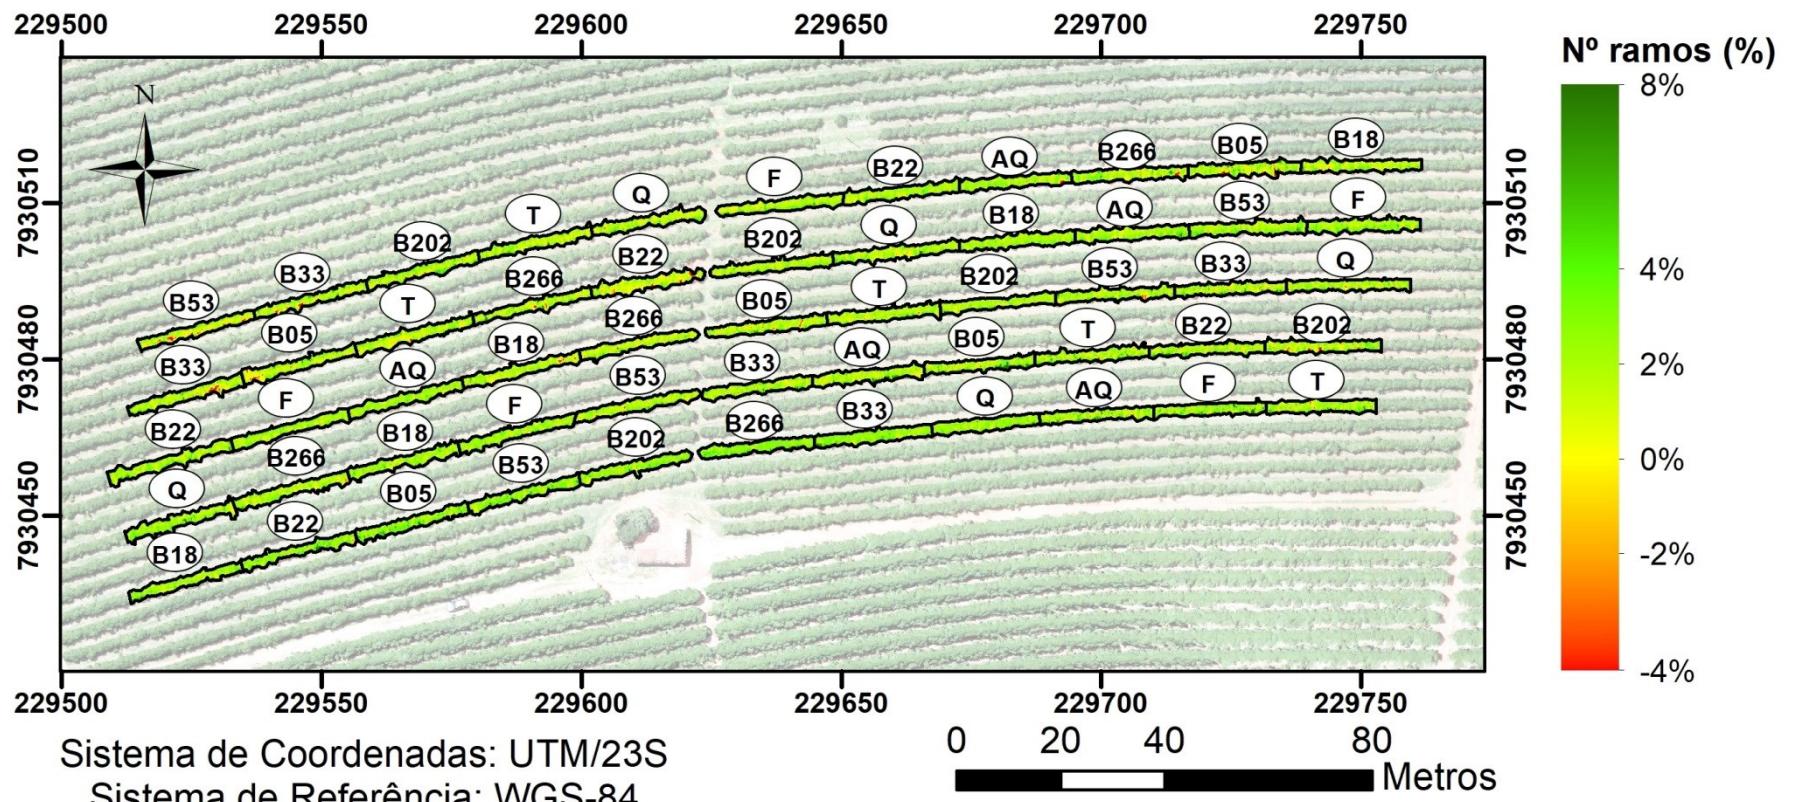


FIGURA 11 – Mapa de caracterização da taxa de crescimento para o parâmetro número de ramos

A Figura 12 apresenta a taxa de crescimento (%) para comprimento de ramos (sul) (m). É possível observar o crescimento dos ramos plagirotrópicos com face de exposição ao sul, apresentando em toda área experimental, com maior ocorrência, taxa de crescimento positiva, com valores entre 0% a 4% de crescimento/mês. Valores entre 4% a 8% e 4% a 8% de crescimento/mês foram observados pontualmente em algumas parcelas, com destaque para os tratamentos B202 (*Bacillus subtilis*) no segundo bloco e tratamentos B33 e B202 (*Bacillus subtilis*), T (água) e B05 (*Bacillus methylotrophicus*) no quinto bloco, com a maior concentração destes valores.

Taxa de crescimento negativa com valores entre 0% e -4% de crescimento/mês foram observadas pontualmente em todas as parcelas da área experimental, com destaque para os tratamentos B05 (*Bacillus methylotrophicus*) no terceiro bloco e quarto bloco, com maiores concentrações destes valores.

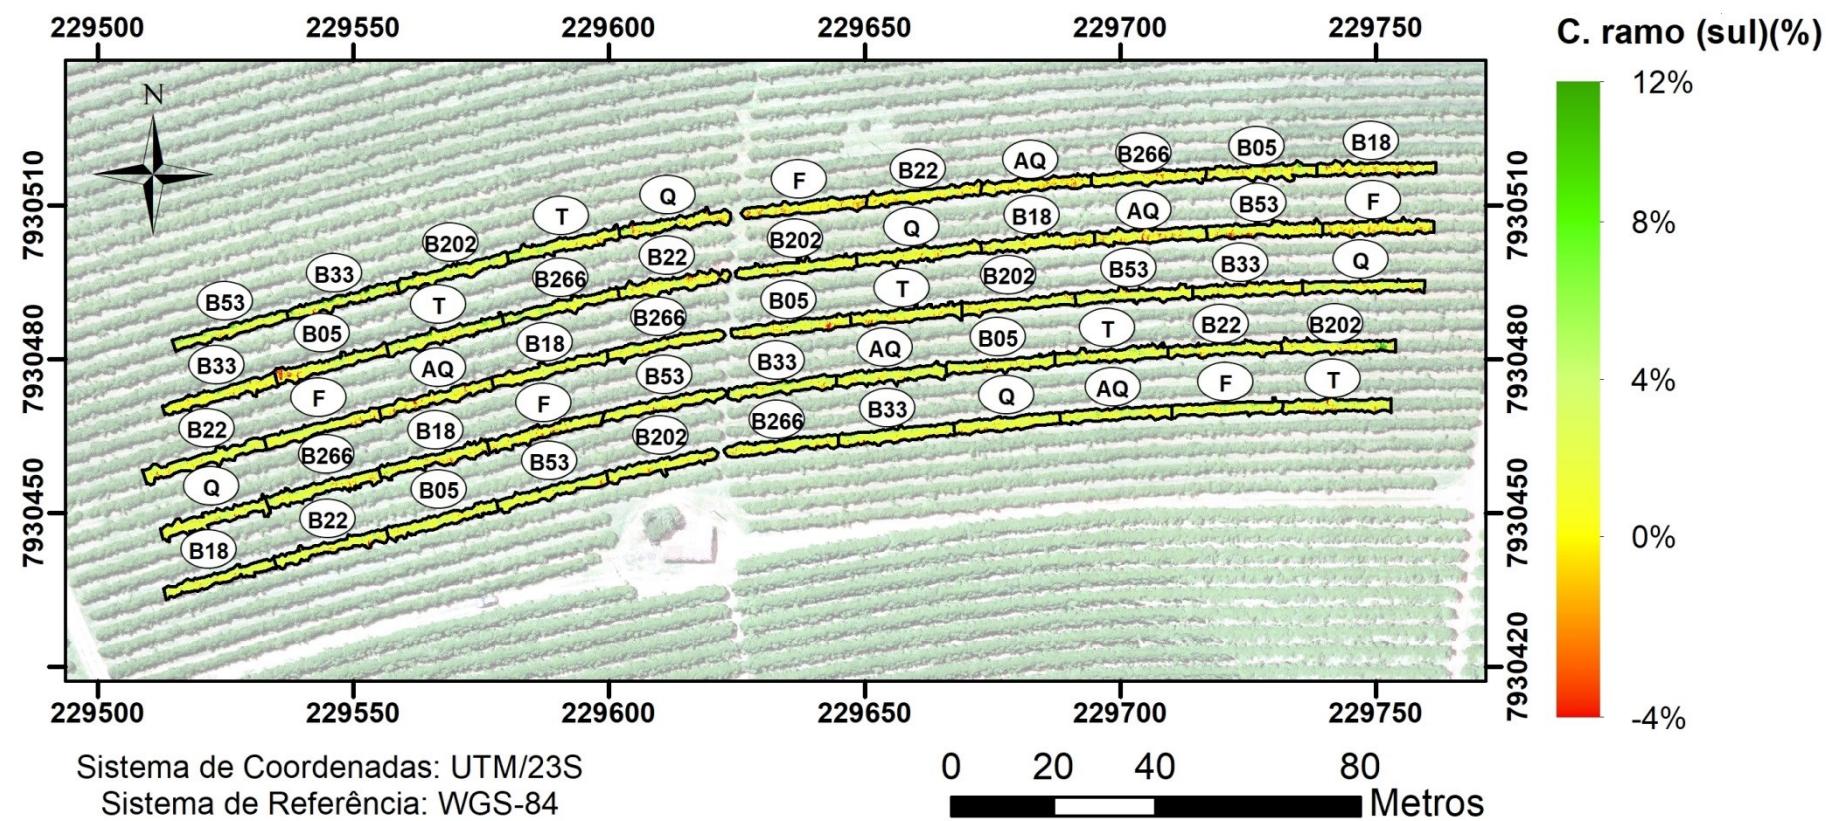


FIGURA 12 – Mapa de caracterização da taxa de crescimento para o parâmetro comprimento de ramos (sul)

A Figura 13 apresenta a taxa de crescimento (%) para comprimento de ramos (norte) (m). É possível observar o crescimento dos ramos plagiotrópicos com face de exposição ao norte, apresentando com maior ocorrência na área experimental, taxa de crescimento positiva, com valores entre 0% a 3% de crescimento/mês. Valores entre 3% a 6% foram observados discretamente em todas as parcelas da área experimental.

Taxa de crescimento negativo, também foram observadas pontualmente em algumas parcelas da área experimental, com valores entre 0% e -3% de crescimento/mês, com destaque para os tratamentos B33 (*Bacillus subtilis*) e B05 (*Bacillus methylotrophicus*) no terceiro e quinto bloco e tratamentos B53 (*Bacillus safensis*), B266 (*Bacillus amyloliquefaciens*) no quinto bloco, com a maior concentração destes valores.

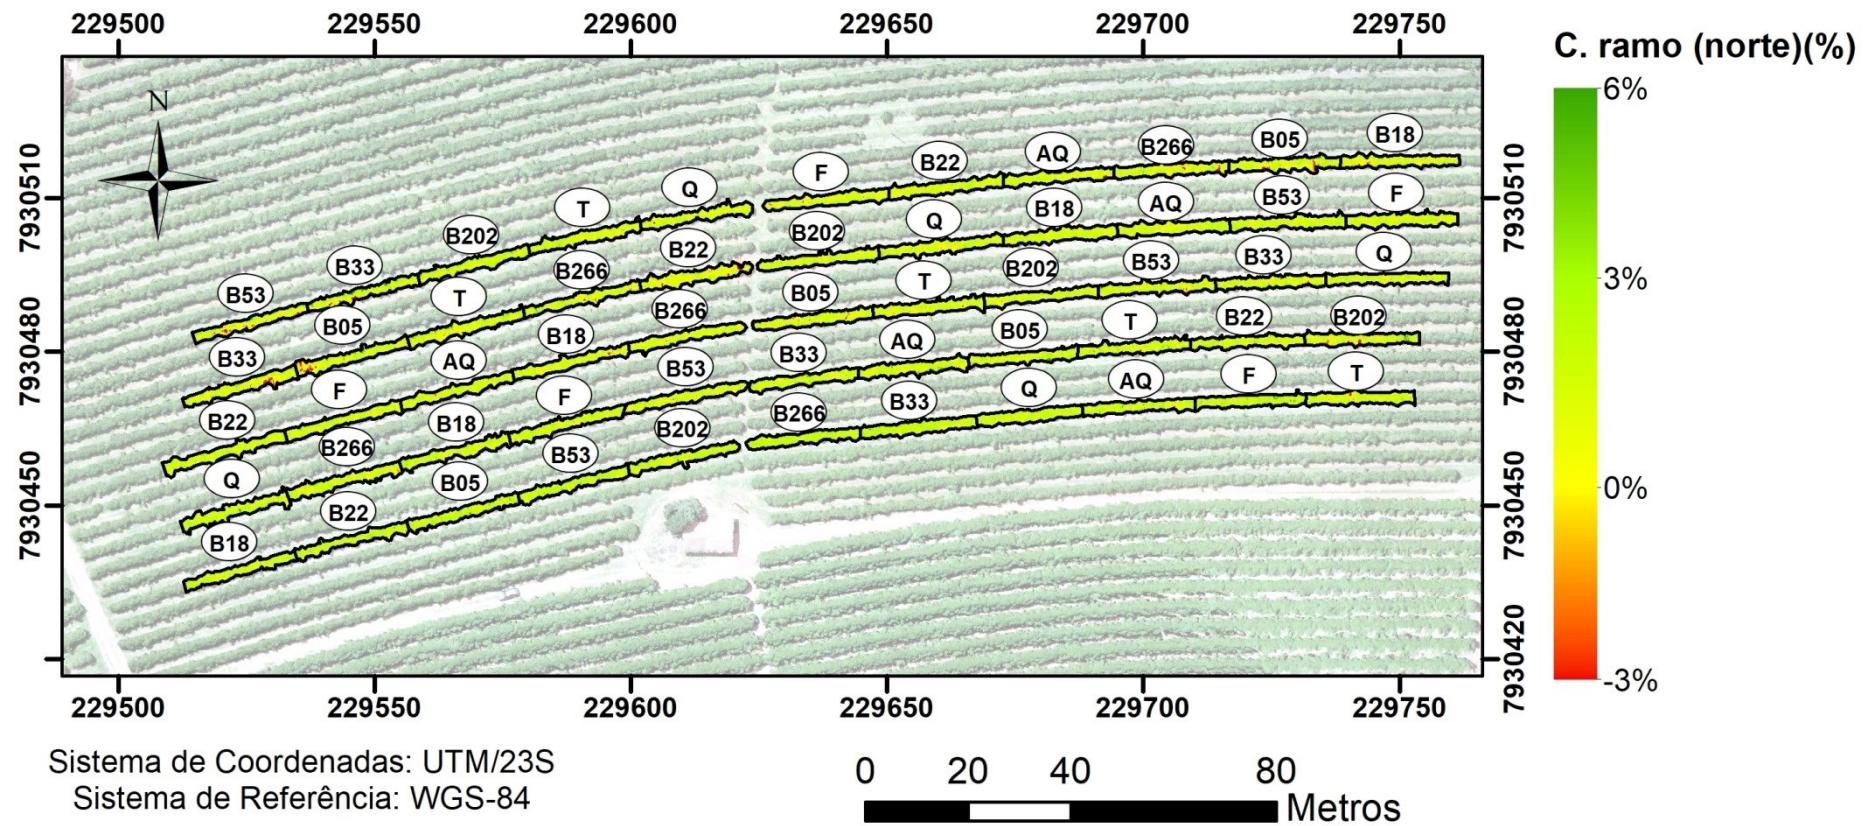


FIGURA 13 – Mapa de caracterização da taxa de crescimento para o parâmetro comprimento de ramos (norte)

A Figura 14 apresenta a taxa de crescimento (%) para o número de nós (sul). É possível observar o crescimento do número de nós com face de exposição ao sul, apresentando com maior ocorrência na área experimental, taxa de crescimento positiva com valores entre 0% a 5% e 5% a 10% de crescimento/mês. Valores entre 10% a 15% e 15% a 20%, foram observados pontualmente em todas as parcelas.

Taxas de crescimento negativas foram observadas pontualmente em -5% a -10% foram observadas pontualmente em algumas parcelas, com destaque para os tratamentos B33 (*Bacillus subtilis*) e B05 (*Bacillus methylotrophicus*) no quarto bloco e tratamento B53 (*Bacillus safensis*) no quinto bloco, com a maior concentração destes valores.

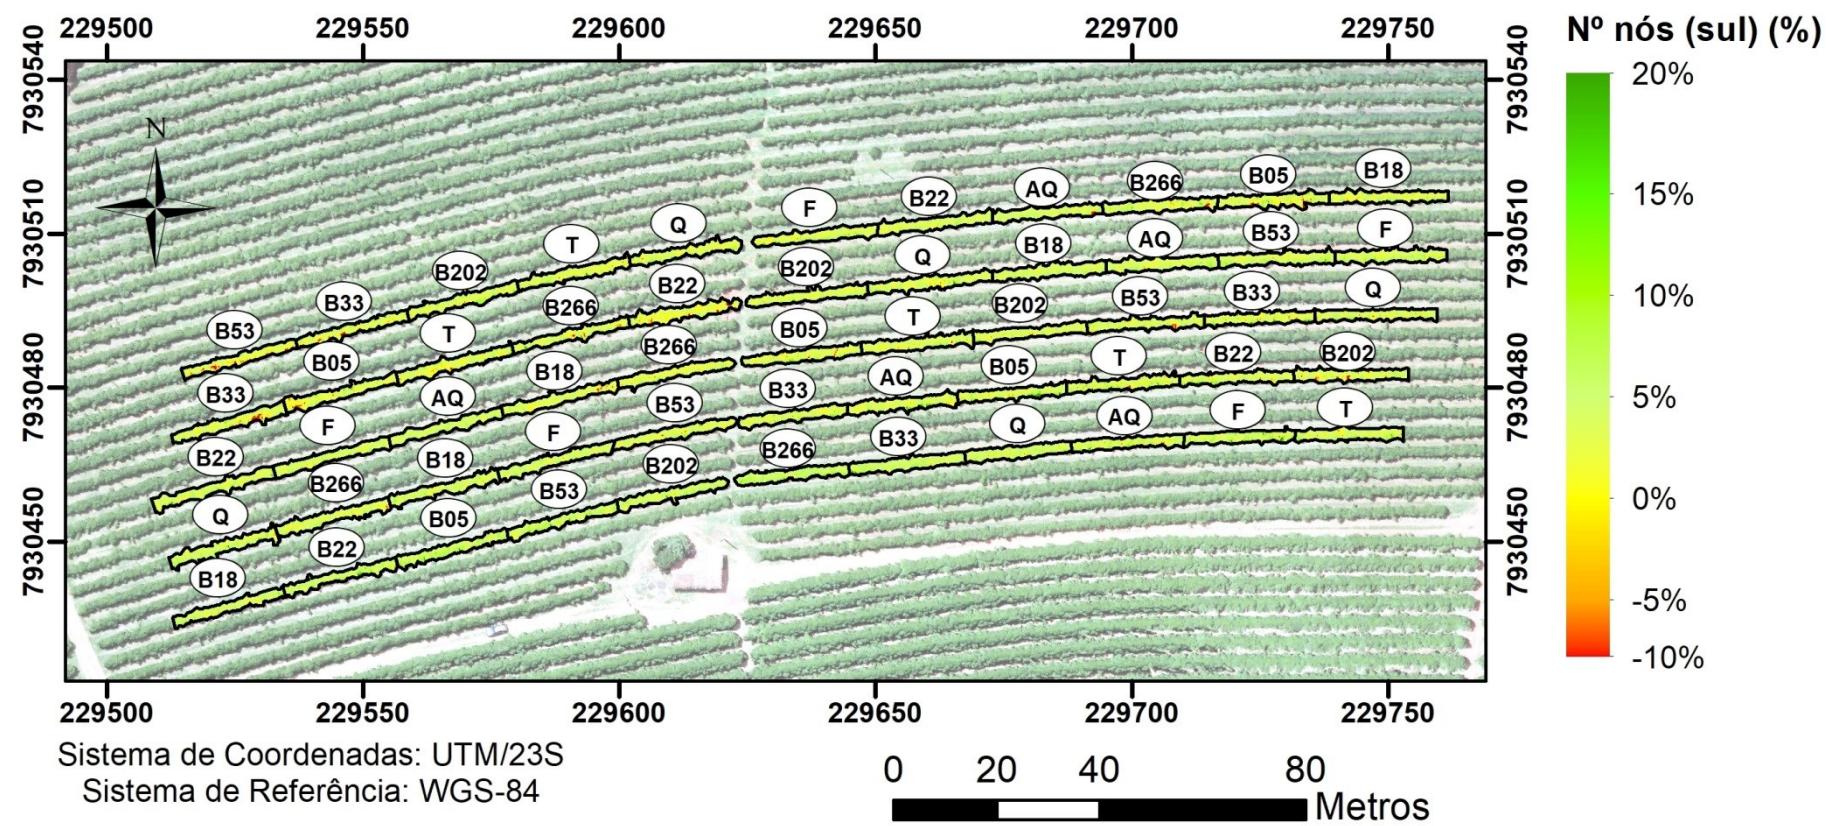


FIGURA 14 – Mapa de caracterização da taxa de crescimento para o parâmetro número de nós (sul)

A Figura 15 apresenta a taxa de crescimento (%) para o número de nós (norte). É possível observar o crescimento do número de nós com face de exposição ao norte, apresentando com maior ocorrência na área experimental, taxa de crescimento positiva com valores entre 0% a 5% e 5% a 10%. Valores entre 10% a 15% e 15% a 20%, foram observados com maior concentração em algumas parcelas, com destaque para os tratamentos B266 (*Bacillus amyloliquefaciens*) e B33 (*Bacillus subtilis*) no primeiro bloco, tratamentos F (Fluensulfone) e B33 (*Bacillus subtilis*) no segundo bloco, tratamentos AQ (Abamectina + *Bacillus subtilis* / *Bacillus licheniformis*) e B53 (*Bacillus safensis*) no terceiro bloco, e tratamento B266 (*Bacillus amyloliquefaciens*) e NF (Fluensulfone) no quarto bloco.

Taxas de crescimento negativa também foram observadas em algumas parcelas, com valores entre 0% a -5% de crescimento/mês, com destaque para os tratamentos B05 (*Bacillus methylotrophicus*) no segundo bloco, tratamentos B22 (*Bacillus thuringiensis*) e F (Fluensulfone) no terceiro bloco, tratamento B18 (*Bacillus subtilis*) no quarto bloco e tratamento B266 (*Bacillus amyloliquefaciens*) no quinto bloco, com maior concentração destes valores.

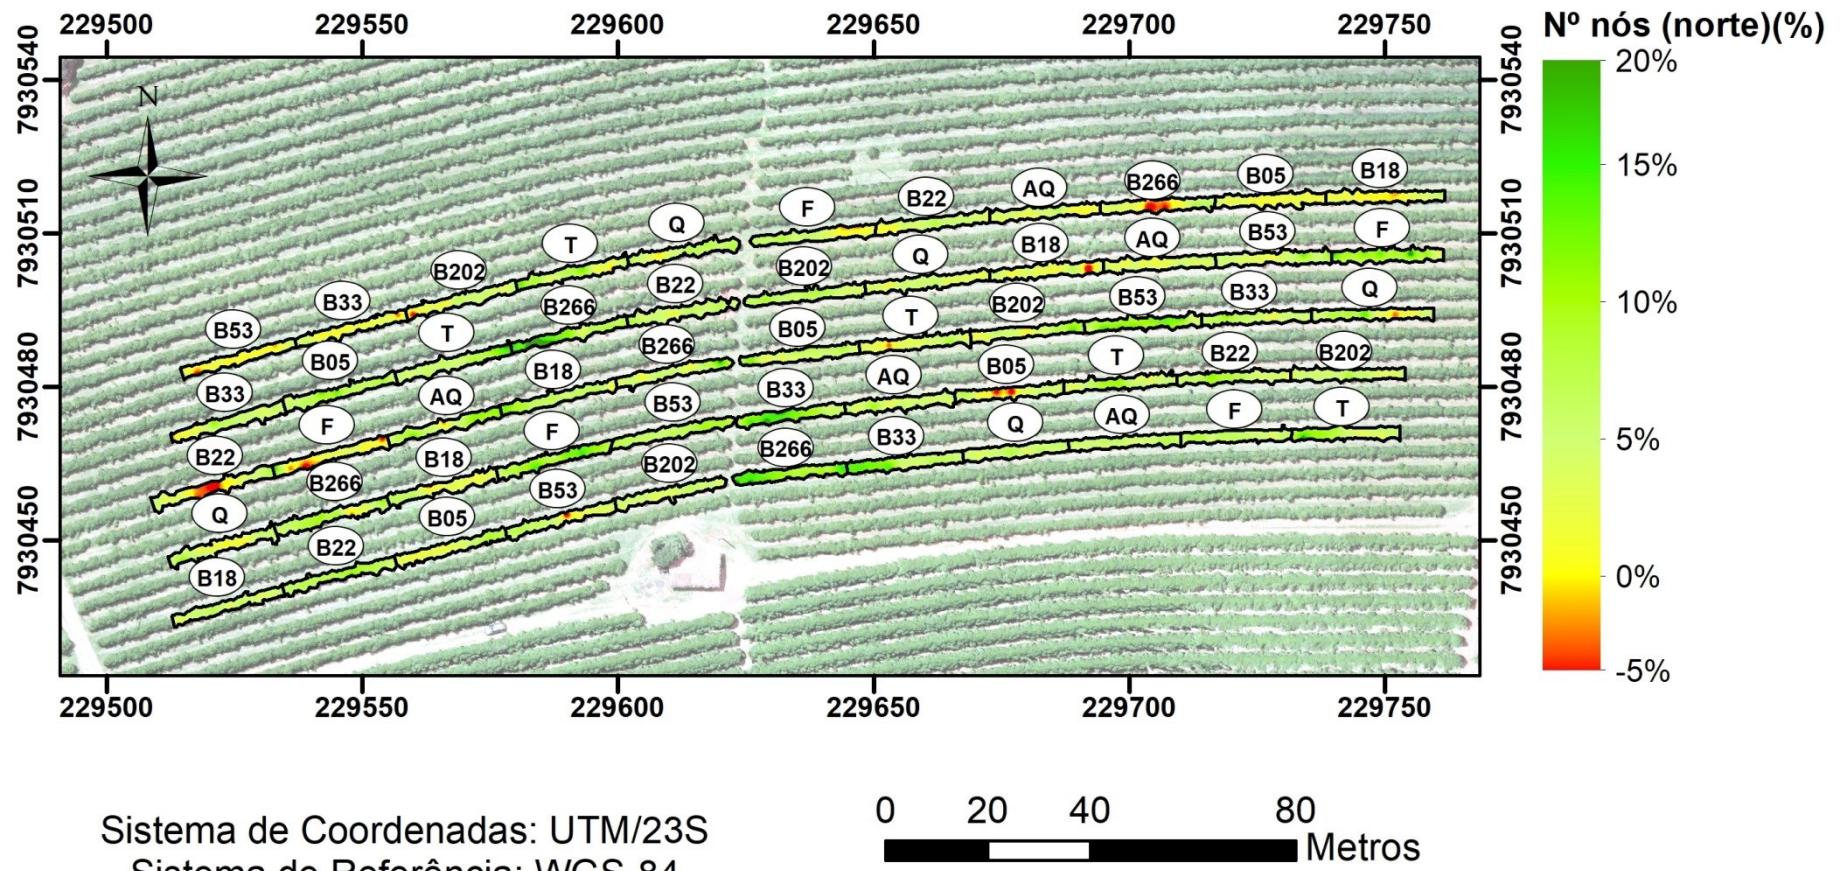


FIGURA 15 – Mapa de caracterização da taxa de crescimento para o parâmetro número de nós (norte)

A Figura 16 apresenta a taxa de crescimento (%) para o diâmetro de copa (m). É possível observar o crescimento dos diâmetros de copa, apresentando com maior ocorrência na região oeste da área experimental, taxas de crescimento positivas, com valores entre 2% a 4% e 4% a 5% de crescimento/mês. Valores entre 0% a 2% de crescimento/mês são observados com maior ocorrência na região leste da área experimental.

Taxas de crescimento negativa também foram observadas em apenas duas parcelas, nos tratamentos B22 e B222 no segundo bloco.

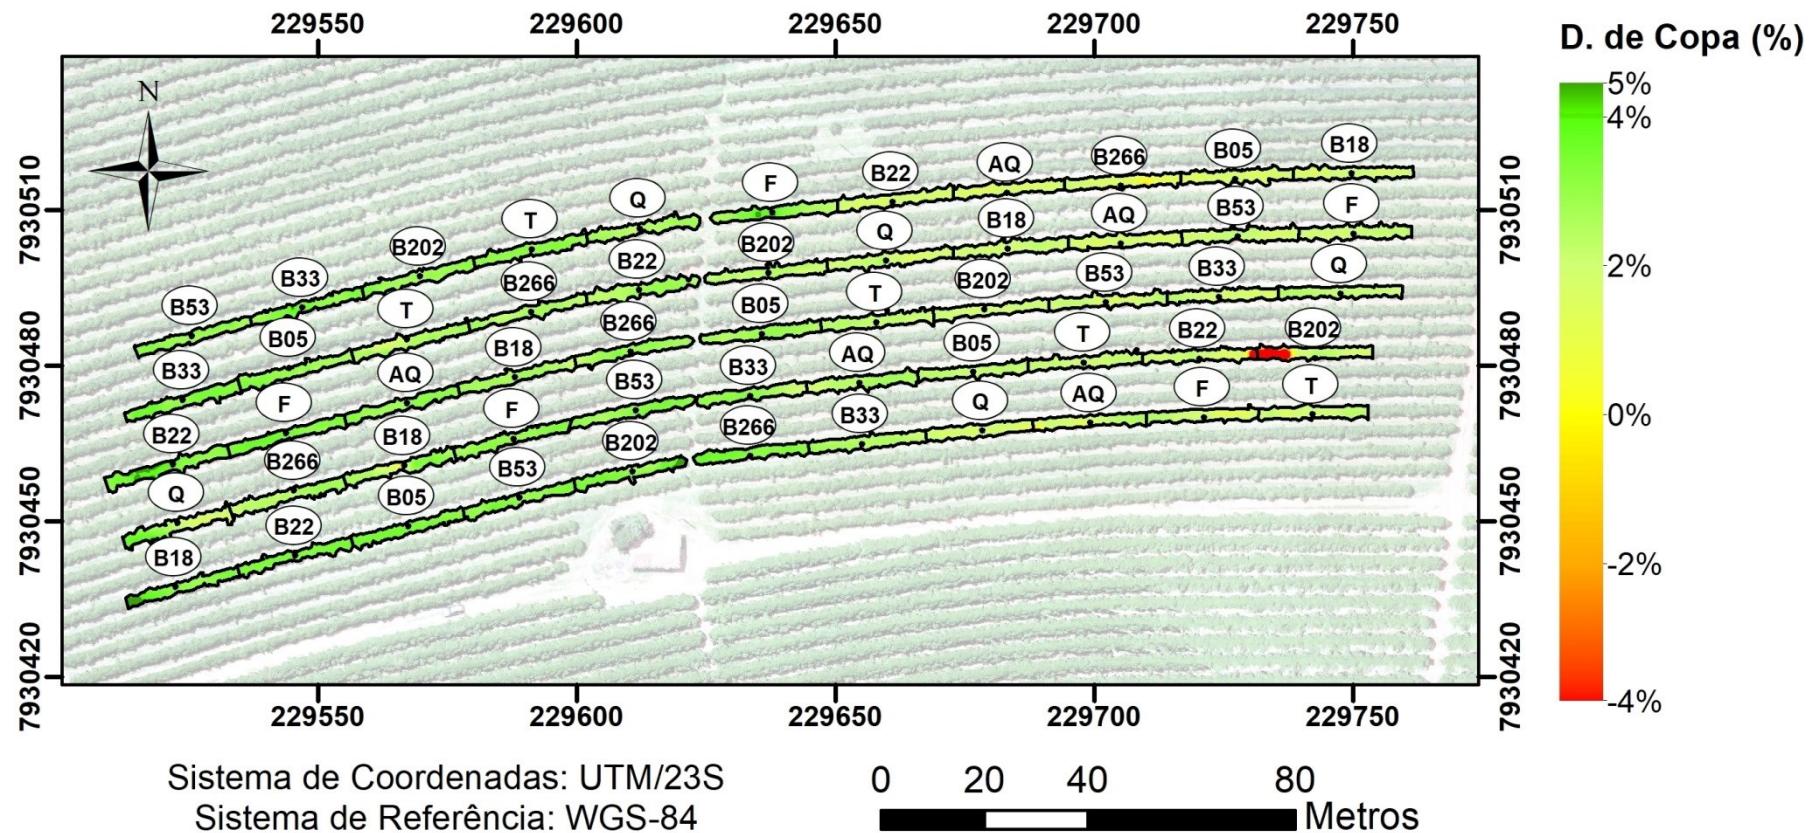


FIGURA 16 – Mapa de caracterização da taxa de crescimento para o parâmetro diâmetro de copa

Para os parâmetros altura da planta (m), número de ramos, comprimento de ramos (norte) (m), comprimento de ramos (sul) (m), número de nós (norte) (m), números de nós (sul) (m) e diâmetro de copa (m) foi possível observar significativo aumento do crescimento vegetativo durante o período do experimento em função dos tratamentos efetuados na área experimental, por serem promotores de crescimento vegetal.

O mapa de caracterização apresenta a distribuição populacional de nematoides final (posterior às aplicações dos tratamentos), para os gêneros *Meloidogyne* e *Pratylenchus*. (Figura 17). Os mapas foram gerados com base nos resultados das análises laboratoriais realizados na terceira avaliação (12/03/2020).

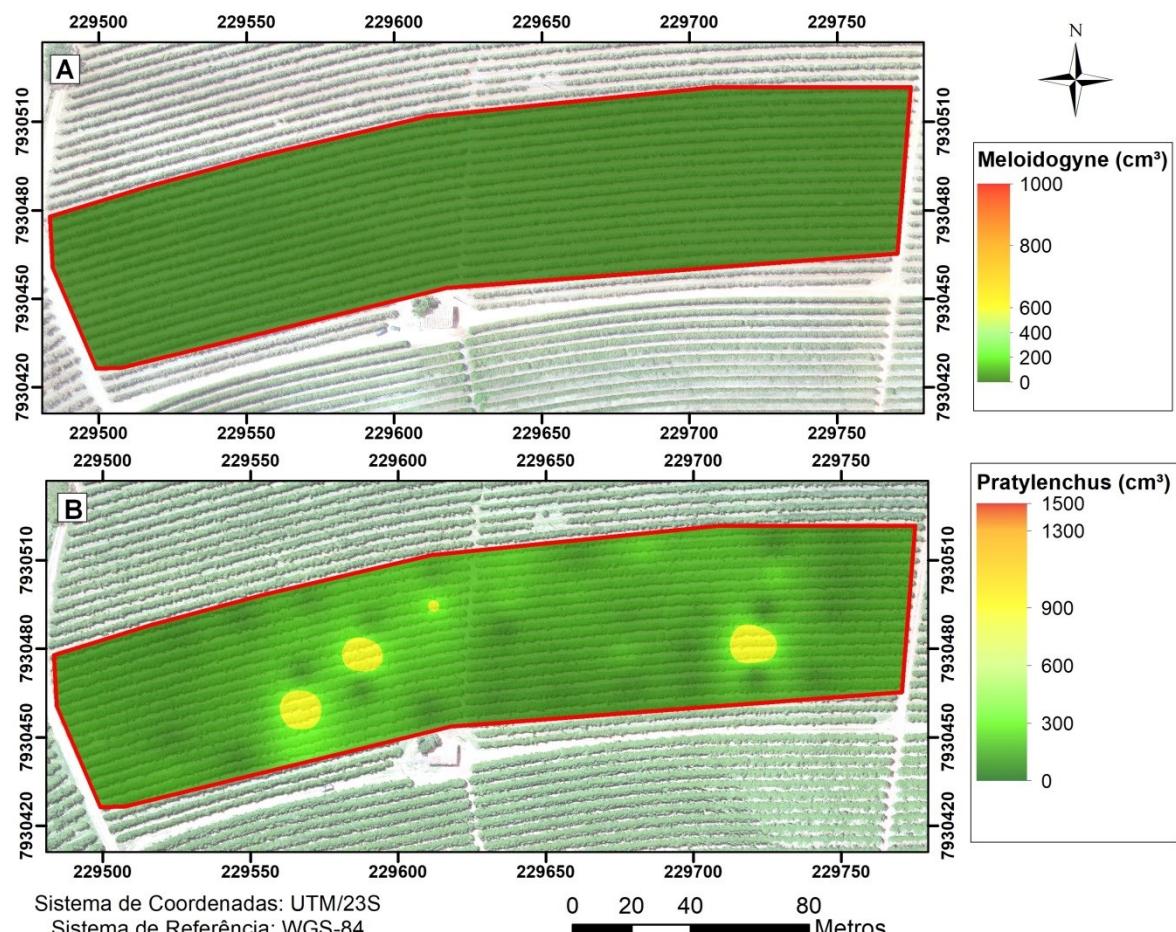


FIGURA 17 – Distribuição espacial populacional de nematoides na área experimental, anterior às aplicações dos tratamentos, para (A) *Meloidogyne* sp. (juvenis/150 cm^3) e (B) *Pratylenchus* sp. (indivíduos/150 cm^3) na terceira avaliação (12/03/2020)

Após a aplicação dos tratamentos, para o gênero *Meloidogyne* (Figura 17-A) é possível observar a redução da concentração de juvenis/150 cm^3 de solo de na região leste,

apresentando concentração populacional entre 0 a 200 juvenis/150 cm³ de solo em todo o talhão.

Para o gênero de *Pratylenchus*, após a aplicação dos tratamentos (Figura 17-B), é possível observar que o talhão apresentou aumento na concentração de indivíduos/cm³ de solo, com o crescimento de áreas com concentração entre 300 a 600 juvenis/150 cm³ de solo. Os dois pontos com concentrações críticas, observados na primeira avaliação para este gênero, na região leste do talhão, apresentaram redução da concentração de indivíduos/150 cm³ de solo, com um ponto, apresentando redução da concentração para 0 a 300 indivíduos/150 cm³ de solo e outro com redução da concentração para 900 a 1300 indivíduos/150 cm³ de solo. Na região oeste do talhão, nota-se o surgimento de três pontos, em que ocorreu o aumento da concentração para 900 a 1300 indivíduos/150 cm³ de solo.

As espécies do gênero *Meloidogyne* são consideradas parasitas sedentários e passam a maior parte do seu ciclo de vida em um mesmo local, alimentando-se das células das raízes do cafeeiro. Após o início do parasitismo, o metabolismo das plantas é alterado, provocando a formação de células grandes (ou células nutridoras) presentes nas galhas das raízes (REIS; CUNHA; CARVALHO, 2011).

As espécies do gênero *Pratylenchus* são classificadas como endoparasitas migradores. Nematoides desta espécie destroem as células vegetais das plantas durante os processos migratórios e de alimentação, provocando lesões nos tecidos do sistema radicular (SAKIYAMA et al., 2015).

Entre os outros sintomas decorrentes do parasitismo pelos nematoides destes gêneros, destaca-se: diminuição do crescimento das plantas parasitadas em reboleiras; desequilíbrios fisiológicos e carência de macro e/ou micronutrientes, alterações nas características agronômicas; e a queda progressiva de produtividade (FERRAZ; BROWN, 2016).

Alguns sintomas foram observados na área experimental, durante a primeira avaliação, anterior à aplicação de tratamentos químicos e biológicos contra nematoides, conforme apresentado na Figura 18.



FIGURA 18 – Sintomas reflexos observados nas plantas durante a primeira campanha avaliativa. (A) desfolhamento e queda das folhas; (B) seca dos ramos; e (C) presença de galhas nas raízes das plantas parasitadas por *Meloidogyne exigua*

Entre os sintomas observados, destaca-se a presença de desfolhamento e queda de folhas (Figura 18-A), seca dos ramos (Figura 18-B) e presença de galhas nas raízes das plantas parasitadas por nematoides do gênero *Meloidogyne exigua* (Figura 18-C).

Na terceira avaliação (Figura 19), após duas aplicações dos tratamentos para o manejo dos nematoides presentes na área é notável o crescimento vegetativo (Figura 19-A), emissão de ramos plagiotrópicos (Figura 19-B) e a expansão dos frutos (Figura 19-C).



FIGURA 19 – Aumento do vigor vegetativo das plantas durante a terceira campanha avaliativa. (A) crescimento vegetativo; (B) crescimento dos ramos plagiotrópicos; e (C) expansão dos frutos

Nesta perspectiva, medidas de manejo dos fitonematoídes são necessárias para a redução significativa dos níveis populacionais destes patógenos. O uso de fungos e bactérias está amplamente disponível para promover a redução dos níveis populacionais de fitonematoídes. As rizobactérias, como agente de controle biológico, atuam na promoção do crescimento vegetativo das plantas, antibiose, competição, indução de resistência sistêmica e na ação protetora contra agentes patogênicos, tais como os nematoides, entre outros (FERRAZ; BROWN, 2016).

Além disso, o uso de produtos químicos tem sido aplicado no manejo de fitonematoídes e imprime resultados significativos em áreas com incidente infestação por estes patógenos. Quando se espera uma resposta rápida para o controle populacional onde não se atingiu o nível de dado, o controle químico constitui uma prática eficaz, porém o uso de produtos com baixo poder residual se torna necessário para evitar riscos à saúde e danos ao meio ambiente, proporcionando maior qualidade do produto e sustentabilidade (MOREIRA et al., 2005).

4. CONCLUSÕES

O método aplicado mostrou-se apropriado para áreas de cultura cafeeira com alta variabilidade de tratamentos. Tanto as imagens orbitais, quanto as imagens adquiridas por aerolevantamento utilizando ARP mostraram-se potenciais ferramentas para estimar os parâmetros agronômicos em condições de alta variabilidade morfobiométrica. Os algoritmos de aprendizagem foram capazes de sustentar os modelos de estimativas de parâmetros agronômicos.

Devido à alta variabilidade observada na cultura cafeeira deste experimento, e a eficácia da metodologia, a partir deste estudo, sugere-se que as tais técnicas aqui abordadas, podem ser aplicadas com êxito a outras áreas, uma vez que esta pesquisa reflete condições ambientais e de manejo, as quais podem ocorrer em diversas outras áreas de plantio.

Os seguintes modelos de predição foram definidos para a estimativa dos parâmetros agronômicos:

- Teor de clorofila total: o algoritmo Random Forest, utilizando como dados de entrada os valores radiométricos dos índices de vegetação, das imagens da ARP.
- Altura das plantas, comprimento dos ramos (sul) e comprimento de ramos (norte): algoritmo SMOreg, utilizando como dados de entrada os valores radiométricos das bandas e índices de vegetação selecionados por análise de agrupamento, das imagens da ARP.
- Diâmetro de copa: algoritmo SMOreg, utilizando como dados de entrada, apenas os valores radiométricos das bandas espectrais originais, das imagens multiespectrais do PLANET.
- Número de Ramos e número de nós (sul): algoritmo Linear Regression, utilizando como dados de entrada os valores radiométricos das bandas espectrais e índices de vegetação selecionados por análise de agrupamento, das imagens da ARP.
- Número de gemas (2): algoritmo Random Forest, utilizando como dados de entrada apenas os valores radiométricos das bandas espectrais originais, das imagens do satélite PLANET.

Vale ressaltar que foi um estudo que gerou um vasto conhecimento, associado com outros já realizados, porém ressalta-se também que essa tessitura sugere uma abertura para a continuidade da pesquisa, com vistas a descobertas de grandes contribuições para o campo agrícola.

REFERÊNCIAS

- ABDULRIDHA, J.; EHSANI, R.; Abd-ELRAHMAN, A.; AMPATZIDIS, Y. A remote sensing technique for detecting laurel wilt disease in avocado in presence of other biotic and abiotic stresses. **Computers and Electronics in Agriculture**. Vol.156, Pages 549-557, 2019. DOI: <https://doi.org/10.1016/j.compag.2018.12.018> Disponível em: https://www.researchgate.net/publication/330061904_A_remote_sensing_technique_for_detecting_laurel_wilt_disease_in_avocado_in_presence_of_other_biotic_and_abiotic_stresses.
- ALBUQUERQUE, R. W.; COSTA, M. O.; FERREIRA, M. E.; JORGE, L. A de C.; SARRACINI, L.H.; ROSA, E. O. Uso do índice MPRI na avaliação de processos de Restauração Florestal (RF) utilizando sensor RGB a bordo de VANT quadricóptero. in:Anais do Simpósio Brasileiro de Sensoriamento Remoto, Campinas - SP 2020.
- ALVES, H. M. R.; VOLPATO, M. M. L.; VIEIRA, T. G. C.; MACIEL, D. A.; GONÇALVES, T. G.; DANTAS, M. F. Characterization and spectral monitoring of coffee lands in Brazil . The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**. Vol. XLI-B8, 2016. DOI: <https://doi.org/10.5194/isprsarchives-XLI-B8-801-2016> Disponível em: https://www.researchgate.net/publication/307529743_CHARACTERIZATION_AND_SPECTRAL_MONITORING_OF_COFFEE LANDS_IN_BRAZIL
- AMARAL, J. A.T.; da MATTA, F. M.; RENA, A. B. Effects of fruiting on the growth of Arabica coffee trees as related to carbohydrate and nitrogen status and to nitrate reductase activity. **Rev. Bras. Fisiol. Veg.** Vol. 13, n.1 pp.66-74. , 2001. DOI: <https://doi.org/10.1590/S0103-31312001000100008> Disponível em: <https://www.scielo.br/j/rbfv/a/8WDGq67NybNn4yZ97QFx9qb/?lang=en>
- ARANTES, B. H. T. et al. Spectral detection of nematodes in soybean at flowering growth stage using unmanned aerial vehicles. **Cienc. Rural**. Vol. 51, n.5, 2021. DOI: <https://doi.org/10.1590/0103-8478cr20200283> Disponível em: <https://www.scielo.br/j/cr/a/YWdtrPs5k49DG3yVmbHW7hj/?lang=en>
- ARPINI, B da. S., LIMA, I de. M., COSTA, N.S. Controle de meloidogyne exigua em cafeiro arábica com uso de bionematicida constituído por bacillus subtilis e b. licheniformis. In: XXII Encontro Latino-Americano De Iniciação Científica; XVIII Encontro Latino Americano de Pós Graduação; VIII Encontro Nacional De Iniciação À Docência; XII Encontro Latino-Americanano de Iniciação Científica Junior. São José dos Campos 2018.
- BOCCA, F. F.; RODRIGUES, L. H. A. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. **Computers and Electronics in Agriculture**. Vol. 128, Pages 67-76, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.08.015>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916306391>
- BREIMAN, L. Random Forests. Machine Learning. Springer Vol. 45, 5–32, 2001 DOI: <https://doi.org/10.1023/A:1010933404324> Disponível em:

<https://link.springer.com/article/10.1023/A:1010933404324>

BUNRUANG, P.; KAEWPLANG, S. Evaluation of Sugarcane Plant Height using UAV Remote Sensing. **Engineering Access**. Vol. 7 No. 2, 2021. DOI: <https://DOI.org/10.14456/mijet.2021.15> Disponível em: <https://ph02.tci-thaijo.org/index.php/mijet/article/view/243593>

CANATA, T.; WEI, M. C. F.; MALDANER, L. MOLIN, J. Sugarcane Yield Mapping Using High-Resolution Imagery Data and Machine Learning Technique. **Remote Sensing**. Vol. 13. 232, 2021. DOI: <https://DOI.org/10.3390/rs13020232> Disponível em: https://www.researchgate.net/publication/348415379_Sugarcane_Yield_Mapping_Using_High-Resolution_Imagery_Data_and_Machine_Learning_Technique

CHEMURA, A.; MUTANGA, O.; ODINDI, J. Empirical Modeling of Leaf Chlorophyll Content in Coffee (*Coffea Arabica*) Plantations With Sentinel-2 MSI Data: Effects of Spectral Settings, Spatial Resolution, and Crop Canopy Cover. **IEEE Journal of selected topics in applied earth observations and remote sensing**. Vol. 10, n. 12, 2017. DOI: <https://DOI.org/10.1109/JSTARS.2017.2750325>. Disponível em: <https://ieeexplore.ieee.org/document/8047262>

DIAO, C. Remote sensing phenological monitoring framework to characterize corn and soybean physiological growing stages. **Remote Sensing of Environment**. Vol. 248, 2020. DOI: <https://DOI.org/10.1016/j.rse.2020.111960> Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425720303308>

ELAZAB, A.; ORDÓÑEZ, R. A.; SAVIN, R.; SLAVER, G. A.; ARAUS, J. L. Detecting interactive effects of N fertilization and heat stress on maize productivity by remote sensing techniques. **European Journal of Agronomy**. Vol. L, 2016. DOI: <https://DOI.org/10.1016/j.eja.2015.11.010>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1161030115300575>

EPIPHANIO, J.; FORMAGGIO, A. Sensoriamento remoto de tres parametros agronomicos de trigo e de feijao. **Jour.**, 1991. Disponível em: https://www.researchgate.net/publication/47446211_Sensoriamento_remoto_de_tres_parametros_agronomicos_de_trigo_e_de_feijao

FERRAZ, L. C. C. B.; BROWN, D. J. F. Nematologia de Plantas: fundamentos e importância. Norma Editora 2016.

FERREIRA, G.; CAYFORD, E.L.; FENG, L.; SHAO, Y.; ISLA-CASARES, M. Use of satellite remote-sensing techniques to predict the variation of the nutritional composition of corn (*Zea mays L*) for silage. **Crea Journals**. Vol. 61, n. 1, 2016. Disponível em: <https://journals-crea.4science.it/index.php/maydica/article/view/1519>

FIORIO, P., MARTINS, J., SILVA BARROS, P. P., MOLIN, J., AMARAL, L. Dados espectrais de dossel de cana-de-açúcar para predição do teor relativo de clorofila . In: Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil 2015.

FORMAGGIO, A. R., SANCHES, I. D. Sensoriamento Remoto em agricultura. Oficina

de textos, São Paulo. 2017.

OLIVEIRA, M. F de.; SANTOS, A. F dos.; LACERDA, L.; SILVA, R, P de.; VELLIDIS, G. Estimativa da maturação de amendoim utilizando sensoriamento remoto e redes neurais artificiais . In:Anais do XVI Encontro Sobre a Cultura do Amendoim Vol. 3 , 2019. DOI: <https://DOI.org/10.17648/amenDOIm-2019-107243>. Disponível em: <https://proceedings.science/encontro-amendoim-2019/papers/estimativa-da-maturacao-de-AMENDOIM-utilizando-sensoriamento-remoto-e-redes-neurais-artificiais>

HAYKIN, S. Redes neurais, princípios e prática. 2. ed. Porto Alegre: Bookman 2001.

IVUSHKIN, K.; BARTHOLOMEUS, H.; BREGT, A. K.; PULATOV, A.; FRANCESCHINI,M. H.D.; KRAMER, H.; LOO, E. N. van.; ROMAN, V. J.; FINKERS,R. UAV based soil salinity assessment of cropland . **Geoderma** Vol. 338, Pages 502-512, 2018. DOI: <https://DOI.org/10.1016/j.geoderma.2018.09.046>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0016706118309509>

JIA, M.; COLOMBO, R.; ROSSINI, M.; CELESTI, M.; ZHU, J.; COGLIATI, S.; CHENG, T.; TIAN, Y.; ZHU, Y.; CAO, W.; YAO, X. Estimation of leaf nitrogen content and photosynthetic nitrogen use efficiency in wheat using sun-induced chlorophyll fluorescence at the leaf and canopy scales. **European Journal of Agronomy**, Vol. 122, 2021. DOI: <https://DOI.org/10.1016/j.eja.2020.126192> Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1161030120301994>

KAIVOSOJA, J.; HAUTSALO, J.; HEIKKINEN, J.; HILTUNEN, L.; RUUTTUNEN, P.; NÄSI, R.; NIEMELÄINEN,O.; LEMSALU, M.; HONKAVAARA,E.; SALONEN, J. Reference Measurements in Developing UAV Systems for Detecting Pests, Weeds, and Diseases . **Remote Sensing** Vol. 13, n. 7, 2021. DOI: <https://DOI.org/10.3390/rs13071238> Disponível em: <https://www.mdpi.com/2072-4292/13/7/1238>

LEE, H.; WANG, J.; LEBLON, B. Using Linear Regression, Random Forests, and Support Vector Machine with Unmanned Aerial Vehicle Multispectral Images to Predict Canopy Nitrogen Weight in Corn. **Remote Sensing** Vol. 12(13), 2071, 2020. DOI:<https://DOI.org/10.3390/rs12132071> Disponível em: <https://www.mdpi.com/2072-4292/12/13/2071>

MARTINS, G.D.; GALO, M.L.B.T.; VIEIRA, B.S. Detecting and mapping root-knot nematode infection in coffee crop using remote sensing measurements. . **IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.** Vol. 10 (12), 5395–5403, 2017. DOI: <http://dx.DOI.org/10.1109/JSTARS.2017.2737618> Disponível em: <https://repositorio.unesp.br/bitstream/handle/11449/163672/WOS000418871200007.pdf?sequence=1&isAllowed=y>

MARTINS, J. A.; FIORIO, P. R.; BARROS, P. P. da S.; DEMATTÊ, J. A. M.; MOLIN, J. P.; CANTARELLA, H.; NEALE, C. M. U. Potential use of hyperspectral data to monitor sugarcane nitrogen status. . **Acta Scientiarum. Agronomy**. Vol. 43(1), e47632, 2020. DOI: <https://DOI.org/10.4025/actasciagron.v43i1.47632>. Disponível em: <https://www.scielo.br/j/asagr/a/WnnDJMW4N5fbhnFXKfd8DsF/>

MATIELLO, J. B., SANTINATO, R., GARCIA, A. W. R., ALMEIDA, S. R., FERNANDES, D. R. Cultura de café no Brasil: Manual de recomendações. Rio de Janeiro - RJ e Varginha - MG: Fundação PROCAFÉ 2010.

MEIVEL, S.; MAHESWARI, S. Remote Sensing Analysis of Agricultural Drone. *J Indian Soc Remote Sens*. Vol. 49, 689–701 , 2021. DOI: <https://DOI.org/10.1007/s12524-020-01244-y> Disponível em: <https://link.springer.com/article/10.1007/s12524-020-01244-y>

MESQUITA, C. M. et al. Manual do café: distúrbios agronômicos, pragas e doenças do cafeeiro (*Coffea arábica* L.). . Belo Horizonte: EMATER-MG 2016.

MONTGOMERY, D. C., PECK, E. A., and VINING, G. G. Introduction to linear regression analysis. Wiley series in probability and statistics. 5th ed. Ed. Wiley 2012.

MOREIRA, W. A., MOREIRA, F. R. B., MAGALHÃES, E. E., MENEZES, C. F. de, PEREIRA, A. V. da S. Aplicação de abamectina como alternativa de controle químico do nematoide-das-galhas em melão. Boletim de Pesquisa e Desenvolvimento - Embrapa Semi-Árido 2005.

NDIKUMANA, E.; MINH, D.H.T.; NGUYEN, H.T.D.; BAGHDADI, D.C.; HOSSARD, L.; MOUSSAWI, I. Estimation of Rice Height and Biomass Using Multitemporal SAR Sentinel-1 for Camargue, Southern France. *Remote Sensing* Vol. 10(9), 1394, 2018. DOI: <https://DOI.org/10.3390/rs10091394> Disponível em: <https://www.mdpi.com/2072-4292/10/9/1394>

OLIVEIRA, H. C.; GUIZILINI, V. C.; NUNES, I. P.; SOUZA, J. R. Failure Detection in Row Crops From UAV Images Using Morphological Operators. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. Vol. 15, no. 7, pp. 991-995, 2018. DOI: <https://DOI.org/10.1109/LGRS.2018.2819944>. Disponível em: <https://ieeexplore.ieee.org/document/8335812>

ORLANDO, V. S. W. Imagens multiespectrais orbitais: ferramenta para discriminar manejos de fitonematoídes do cafeeiro. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) - Universidade Federal de Uberlândia 2020. DOI: <http://doi.org/10.14393/ufu.di.2020.845> Disponível em: <https://repositorio.ufu.br/handle/123456789/31129>

OSCO, L. P. Inferência do teor de nitrogênio foliar em laranjeira-valêncica com imagens multiespectrais de alta resolução espacial. Tese (Doutorado em Agronomia) - Universidade do Oeste Paulista - Presidente Prudente-SP 2019. Disponível em: <http://bdtd.unoeste.br:8080/jspui/handle/jspui/1286>

PARK, T.; GANGULY, S.; TØMMERVIK, H.; EUSKIRCHEN, E.; HØGDA, K.; KARLSEN, S.; BROVKIN, V.; NEMANI, R.; MYNENI, R. Changes in growing season duration and productivity of northern vegetation inferred from long-term remote sensing data . *Environmental Research Letters*. Vol. 10. n. 8, 2016. DOI: <https://DOI.org/10.1088/1748-9326/11/8/084001/meta> Disponível em: <https://iopscience.iop.org/article/10.1088/1748-9326/11/8/084001/meta>

PLATT, J. C. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. **Advances In Large Margin Classifiers**. Vol. 61-74, 1999. Disponível em:

https://www.researchgate.net/publication/2594015_Probabilistic_Outputs_for_Support_Vector_Machines_and_Comparisons_to-Regularized_Likelihood_Methods

PRESTES, C. D. P. Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada. .

Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa-SP 2020. Disponível em:

<http://tede2.uepg.br/jspui/handle/prefix/3276>

RANĐELOVIĆ, P.; ĐORĐEVIĆ, V.; MILIĆ, S.; BALEŠEVIĆ-TUBIĆ, S.; PETROVIĆ, K.; MILADINOVICIĆ, J.; ĐUKIĆ, V. Prediction of Soybean Plant Density Using a Machine Learning Model and Vegetation Indices Extracted from RGB Images Taken with a UAV. **Agronomy**. Vol. 10, 1108, 2020. DOI:

<https://DOI.org/10.3390/agronomy10081108>. Disponível em:

<https://www.mdpi.com/2073-4395/10/8/1108>

REIS, A. R dos, FURLANI JUNIOR, E.; BUZETTI, S. ANDREOTTI, M. Diagnóstico da exigência do cafeiro em nitrogênio pela utilização do medidor portátil de clorofila. . **Bragantia**. Vol. 65, n.1, 2006. DOI: <https://DOI.org/10.1590/S0006-87052006000100021> Disponível em: <https://www.redalyc.org/articulo.oa?id=90865121>

REIS, M.R. dos. Redistribuição de nutrientes em razão da fenologia da frutificação do café arábica Piracicaba. Dissertação de Mestrado (Fitotecnia) Escola Superior de Agricultura Luiz de Queiroz - USP 2019. DOI: <https://doi.org/10.11606/D.11.2019.tde-16092019-161210> Disponível em:

<https://www.teses.usp.br/teses/disponiveis/11/11136/tde-16092019-161210/pt-br.php>

REIS, R.R.; CUNHA, R.L da.; CARVALHO, G.R. Café arábica: da pós-colheita ao consumo. 2v. Lavras: U.R. EPAMIG SM 2011.

RODRIGUES, S.C.A. Modelo de Regressão Linear e suas Aplicações. Dissertação de Mestrado (Fitotecnia) Escola Superior de Agricultura Luiz de Queiroz - USP 2012. DOI: <https://doi.org/10.11606/D.11.2019.tde-16092019-161210> Disponível em:

https://www.researchgate.net/publication/263817587_Tutorial_sobre_Maquinas_de_Vectores_Soporte_SVM

SAKIYAMA, N., MARTINEZ, H., TOMAZ, M., BOREM, A. Café arábica: do plantio a colheita. Viçosa, MG: Ed. UFV 2015.

SALVADOR, P.; GÓMEZ, D.; SANZ, J.; CASANOVA, J.L. Estimation of Potato Yield Using Satellite Data at a Municipal Level: A Machine Learning Approach . **ISPRS Int. J. Geo-Inf.**. Vol. 9, 343. , 2020. DOI: <https://DOI.org/10.3390/ijgi9060343> Disponível em: <https://www.mdpi.com/2220-9964/9/6/343>

SANDRINI, F de. O. T.; LEAL, F. T.; COELHO, A. P.; LEMOS, L. B.; ROSALEN, D. L. Índices de vegetação na estimativa da produtividade do feijoeiro cultivado sob doses de nitrogênio . **Revista Brasileira de Ciências Agrárias**. Vol. 14, n.4, e7310. , 2019. DOI:

<https://DOI.org/10.5039/agraria.v14i4a7310>. Disponível em:
<https://www.agrolink.com.br/downloads/7310-19155-1-PB.pdf>

SHAH, S.H.; ANGEL, Y.; HOUORG, R.; ALI, S.; MCCABE, M.F. A Random Forest Machine Learning Approach for the Retrieval of Leaf Chlorophyll Content in Wheat. . **Remote Sensing**. Vol. 11, 920, 2019. DOI: <https://DOI.org/10.3390/rs11080920>
Disponível em: <https://www.mdpi.com/2072-4292/11/8/920>

SHARIFI, A. Yield prediction with machine learning algorithms and satellite images. **J Sci Food Agric**. Vol. 101: 891-896. , 2021. DOI: <https://DOI.org/10.1002/jsfa.10696>
Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.10696>

SHEVADE, S. K.; KEERTHI, S. S.; BHATTACHARYYA, C.; MURTHY, K. R. K. Improvements to the SMO Algorithm for SVM Regression. **IEEE Transactions On Neural Networks**, Vol. 11, n. 5, 2000. DOI:
<https://DOI.org/10.1.1.146.375&rep=rep1&type=pdf> Disponível em:
https://www.researchgate.net/publication/3302831_Improvements_to_SMO_algorithm_for_SVM_regression

SHEYKHOUSA, M.; MAHDIANPARI, M.; GHANBARI, H.; MOHAMMADIMANESH, F.; GHAMISI, P.; HOMAYOUNI, S. Support Vector Machine versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. Vol. 13, pp. 6308-6325, 2020. DOI:
<https://DOI.org/10.1109/JSTARS.2020.3026724>. Disponível em:
<https://ieeexplore.ieee.org/document/9206124>

SINGHAL, G.; BANSOD, B.; MATHEW, L.; GOSWAMI, J.; CHOUDHURY, B.U.; RAJU, P.L.N. Chlorophyll estimation using multi-spectral unmanned aerial system based on machine learning techniques . **Remote Sensing Applications: Society and Environment**. Vol. 15, 2019, 2019. DOI: <https://DOI.org/10.1016/j.rsase.2019.100235>.
Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S2352938519300989>

SOUSA, I. C. de et al. Genomic prediction of leaf rust resistance to Arabica coffee using machine learning algorithms. **Sci. agric.** Vol. 78, n.4, 2020. DOI:
<https://DOI.org/10.1590/1678-992x-2020-0021> Disponível em:
<https://www.scielo.br/j/sa/a/kpCQp5n8Pn6FRznXgnpDbxc/?lang=en>

STAVRAKOUDIS, D.; KATSANTONIS.D.; KADOGLIDOU, K; KALAITZIDIS, A.; GITAS, I. Z. Estimating Rice Agronomic Traits Using Drone-Collected Multispectral Imagery. **Remote Sensing**. Vol. 11(5):545, 2019.
DOI:<https://DOI.org/10.3390/rs11050545> Disponível em: <https://www.mdpi.com/2072-4292/11/5/545>

SUÁREZ, E. J. C. Tutorial sobre Máquinas de Vectores Soporte (SVM). Universidad Nacional de Educación a Distancia (UNED) 2016. Disponível em:
https://www.researchgate.net/publication/263817587_Tutorial_sobre_Maquinias_de_Vectores_Soporte_SVM

WAGER, S.; ATHEY, S. Estimation and Inference of Heterogeneous Treatment Effects using Random Forests. **Journal of the American Statistical Association**. Vol. 113, 2018, 2018. DOI: <https://DOI.org/10.1080/01621459.2017.1319839> Disponível em: https://www.tandfonline.com/doi/abs/10.1080/01621459.2017.1319839?journalCode=uas_a20

WANG, L.; ZHOU, X.; ZHU, X.; DONG, Z.; GUO, W. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data . The Crop Journal. Vol. 4, Issue 3, Pages 212-219, , 2016. DOI: <https://DOI.org/10.1016/j.cj.2016.01.008> Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214514116300162>

WOLANIN, A.; CAMPS-VALLS, G.; GÓMEZ-CHOVA, L.; MATEO-GARCIA, G.; TOL, C.; ZHANG, Y.; GUANTER, L. Estimating Crop Primary Productivity with Sentinel-2 and Landsat 8 using Machine Learning Methods Trained with Radiative Transfer Simulations. **Remote Sensing of Environment**. Vol. 225, Pages 441-457, 2019. DOI: <https://DOI.org/10.1016/j.rse.2019.03.002>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425719300938>

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active Optical Sensing of Spring Maize for In-Season Diagnosis of Nitrogen Status Based on Nitrogen Nutrition Index . **Remote Sensing** Vol. 8, 605, 2016. DOI: <https://DOI.org/10.3390/rs8070605> Disponível em: <https://www.mdpi.com/2072-4292/8/7/605>

XU, Y.; HO, H. C.; WONG, M. S.; DENG, C.; SHI, Y. CHAN, T.; KNUDBY, A. Evaluation of machine learning techniques with multiple remote sensing datasets in estimating monthly concentrations of ground-level. **Environmental Pollution**. Vol. 242, Part B, Pages 1417-1426, 2018. DOI: <https://DOI.org/10.1016/j.envpol.2018.08.029>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0269749118324229>

YE, H.; HUANG, W.; HUANG, S.; CUI, B.; DONG, Y.; GUO, A.; REN, Y.; JIN, Y. Recognition of Banana Fusarium Wilt Based on UAV Remote Sensing. **Remote Sensing** Vol. 12, 938, 2020. DOI: <https://DOI.org/10.3390/rs12060938> Disponível em: <https://www.mdpi.com/2072-4292/12/6/938>

YUAN, L.; BAO, Z.; ZHANG, H.; ZHANG, Y.; LIANG, X. Habitat monitoring to evaluate crop disease and pest distributions based on multi-source satellite remote sensing imagery. **International Journal for Light and Electron Optic**. Vol. 145, Pages 66-73, 2017. DOI: <https://DOI.org/10.1016/j.ijleo.2017.06.071>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0030402617307416>

ZERBATO, C. et al. Agronomic characteristics associated with the normalized difference vegetation index (NDVI) in the peanut crop. **Australian Journal of Crop Science**. Vol. 10, n. 5, p. 758–764, 2016. DOI: <https://DOI.org/10.21475/ajcs.2016.10.05.p7167> Disponível em: https://www.researchgate.net/publication/304575575_Agronomic_characteristics_associated_with_the_normalized_difference_vegetation_index_NDVI_in_the_peanut_crop

ZHA, H.; MIAO, Y.; WANG, T.; LI, Y.; ZHANG, J.; SUN, W.; FENG, Z.; KUSNIEREK, K. Improving Unmanned Aerial Vehicle Remote Sensing-Based Rice

Nitrogen Nutrition Index Prediction with Machine Learning. **Remote Sensing.** Vol. 12, 215, 2020. DOI: <https://DOI.org/10.3390/rs12020215> Disponível em: <https://www.mdpi.com/2072-4292/12/2/215>

ZHOU, C.; YE, H.; XU, Z.; HU, J.; SHI, X.; HUA, S.; YUE, J.; YANG, G. Estimating Maize-Leaf Coverage in Field Conditions by Applying a Machine Learning Algorithm to UAV Remote Sensing Images. **Appl. Sci.** Vol. 9, 2389, 2019. DOI: <https://DOI.org/10.3390/app9112389> Disponível em: <https://www.mdpi.com/2076-3417/9/11/2389>