



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2022/09.20.00.17-TDI

**USO DE IMAGENS CENTIMÉTRICAS E ALGORITMOS
DE APRENDIZADO DE MÁQUINA NO SUPORTE AO
MANEJO DE POMARES DE LARANJA: DETECÇÃO E
DELINEAMENTO DE PLANTAS, IDENTIFICAÇÃO DE
LINHAS, FALHAS DE PLANTIO E DE PLANTAS COM
GREENING**

Felipe Rafael de Sá Menezes Lucena

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Hermann Johann
Heinrich Kux, e Fábio Marcelo
Breunig, aprovada em 10 de agosto
de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47LEFTP>>

INPE
São José dos Campos
2022

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2022/09.20.00.17-TDI

**USO DE IMAGENS CENTIMÉTRICAS E ALGORITMOS
DE APRENDIZADO DE MÁQUINA NO SUPORTE AO
MANEJO DE POMARES DE LARANJA: DETECÇÃO E
DELINEAMENTO DE PLANTAS, IDENTIFICAÇÃO DE
LINHAS, FALHAS DE PLANTIO E DE PLANTAS COM
GREENING**

Felipe Rafael de Sá Menezes Lucena

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Hermann Johann
Heinrich Kux, e Fábio Marcelo
Breunig, aprovada em 10 de agosto
de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47LEFTP>>

INPE
São José dos Campos
2022

Dados Internacionais de Catalogação na Publicação (CIP)

Lucena, Felipe Rafael de Sá Menezes.

L963u Uso de imagens centimétricas e algoritmos de aprendizado de máquina no suporte ao manejo de pomares de laranja: detecção e delineamento de plantas, identificação de linhas, falhas de plantio e de plantas com greening / Felipe Rafael de Sá Menezes Lucena. – São José dos Campos : INPE, 2022.
xxiv + 109 p. ; (sid.inpe.br/mtc-m21d/2022/09.20.00.17-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2022.

Orientadores : Drs. Hermann Johann Heinrich Kux, e Fábio Marcelo Breunig.

1. Citricultura. 2. Agricultura de precisão. 3. Detecção de copas. 4. Identificação de linhas de plantio. 5. Identificação de falhas de plantio. I.Título.

CDU 528.8:634.3



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Secretaria de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE FELIPE RAFAEL DE SÁ MENEZES LUCENA
BANCA Nº 210/2022, REG 115358/2020

No dia 10 de agosto de 2022, às 09h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

Novo Título: “USO DE IMAGENS CENTIMÉTRICAS E ALGORITMOS DE APRENDIZADO DE MÁQUINA NO SUPORTE AO MANEJO DE POMARES DE LARANJA: DETECÇÃO E DELINEAMENTO DE PLANTAS, IDENTIFICAÇÃO DE LINHAS, FALHAS DE PLANTIO E DE PLANTAS COM GREENING.”

Membros da banca:

Dr. Thales Sehn Körting – Presidente – INPE
Dr. Hermann Johann Heinrich Kux – Orientador – INPE
Dra. Ieda Del'Arco Sanches – Membro Interno – INPE
Dr. Fábio Marcelo Breunig – Orientador – UFSM
Dr. Renato Beozzo Bassanezi – Membro Externo – Fundecitrus



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 12/08/2022, às 11:06 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ieda Del Arco Sanches, Pesquisadora**, em 12/08/2022, às 11:24 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Marcelo Breunig (E), Usuário Externo**, em 12/08/2022, às 14:08 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **RENATO BEOZZO BASSANEZI (E), Usuário Externo**, em 12/08/2022, às 14:24 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Hermann Johann Heinrich Kux, Pesquisador**, em 16/08/2022, às 09:51 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **10303567** e o código CRC **CFC06D82**.

Referência: Processo nº 01340.006031/2022-08

SEI nº 10303567

*Dedico a meus pais, Airton e Rivania,
a meus irmãos, Thalison e Júlia,
a minha sobrinha, Alice,
e a vovó Socorro.
Com amor.*

AGRADECIMENTOS

Agradeço aos meus orientadores Dr. Hermann Kux e Dr. Fábio Breunig por todo ensinamento repassado, pela confiança e pelos incentivos frequentes. Agradeço principalmente pelas interações, sejam elas acadêmicas ou pessoais, e pela amizade.

Agradeço ao Programa de Pós-Graduação do Instituto Nacional de Pesquisas Espaciais (INPE) e a todos os professores dos cursos de sensoriamento remoto e computação aplicada com quem tive oportunidade de aprender e me inspirar. Pelo financiamento desta pesquisa, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Agradeço à Dra. Ieda Sanches pelo apoio e suporte que foram indispensáveis para realização desta pesquisa. Agradeço em especial ao Dr. Bernardo Cândido pela parceria, ajuda e estrutura fornecida durante o mestrado. Muito obrigado por tornarem esta pesquisa possível!

Agradeço à solícita equipe da Fundecitrus pelo suporte que foi determinante para a execução do estudo. Sobretudo ao Dr. Renato Bassanezi, agradeço pela cooperação e paciência. Agradeço também ao Samuel Silva pela colaboração e parceria durante os trabalhos de campo.

Agradeço aos meus orientadores da graduação Adriana Marques e Dr. Pedro Medeiros pelos ensinamentos, pelas importantes discussões e pelo incentivo durante a minha formação. Agradeço também ao Dr. Geraldo Landovsky pela amizade, pelo apoio e por sempre acreditar no meu potencial. Aos três, agradeço por me mostrarem grandes exemplos de profissionais e pessoas, com quem aprendi não só sobre a técnica, mas também sobre valores humanos.

Um agradecimento especial à Maria das Dores, minha segunda mãe de São José dos Campos. Seu companheirismo e cuidado foram cruciais para meu bem-estar durante o mestrado. Obrigado pelas risadas, conversas, pelos ensinamentos e por todo suporte.

Obrigado aos meus amigos de Fortaleza por me apoiarem e pela paciência para lidar com o amigo distante. Vocês sempre estiveram presentes!

Obrigado também aos meus amigos de São José dos Campos, com quem tive muitos momentos de alegria e interações importantíssimas. Aos do mestrado, agradeço pelo companheirismo, pelo cuidado e pela amizade. Meu muito obrigado por estarem comigo durante toda esta desafiadora e prazerosa caminhada. Aos de fora do ambiente acadêmico, agradeço pela parceria, pelo apoio e pelos momentos que passamos juntos. Vocês também fazem parte desta conquista!

De maneira singular e muito especial, agradeço à minha família pelo apoio incondicional. Principalmente aos meus pais Airton e Rivania, responsáveis por pavimentar o caminho que me fez chegar até aqui e aos meus irmãos Thalison e Júlia por sempre acreditarem em mim. Agradeço também aos meus primos, primas, tios, tias e avós pelo carinho e incentivo de sempre.

RESUMO

O cultivo de laranjas é uma das principais atividades da citricultura mundial e, nacionalmente, corresponde à maior produção de frutos do país. Contudo, apesar da potência produtiva do país, o desenvolvimento de técnicas adequadas de manejo ainda é demandado, pois estas são importantes aliadas para a gestão e condução dos desafios da agricultura em termos de produtividade, segurança alimentar, impacto ambiental e sustentabilidade. Neste sentido, este trabalho explorou o uso de imagens captadas por Veículo Aéreo Não Tripulado para extração de dados e informações a respeito da cultura visando o desenvolvimento de ferramentas de auxílio ao manejo agrícola. Os objetivos principais do estudo foram divididos em três principais frentes de atuação: detecção e delineamento de copas de árvores; identificação de linhas e falhas de plantio; e diagnóstico da situação fitossanitária da cultura em relação à contaminação pela doença do *greening*. Na análise de detecção e delineamento, foi utilizado o modelo de *deep learning* baseado em rede neural convolucional (*Mask R-CNN*) para comparação do desempenho da atividade entre imagens RGB com e sem a adição de uma quarta banda com o dado de altitude das copas. Além disso, nesta primeira etapa da pesquisa, foram discutidos e sugeridos métodos para operacionalização da atividade. Na segunda etapa, foi discutida proposição de um modelo baseado em análise espacial de padrões lineares para identificação não supervisionada de linhas e falhas de plantio a partir de dados de posição das copas. Por fim, os dados levantados nas duas primeiras etapas foram utilizados para avaliação da capacidade de diagnóstico preciso da doença do *greening* em uma área cuja inspeção visual foi realizada. A metodologia de diagnóstico proposta fez uso de atributos espectrais extraídos dos segmentos das copas aplicados ao classificador *Random Forest*. Os resultados encontrados na primeira etapa sugerem que o uso do dado de altitude das copas aumenta a capacidade de detecção do modelo, mas o delineamento pode ser impactado pela qualidade do dado de entrada. Na segunda etapa, a metodologia proposta se mostrou viável para identificação automatizada de linhas e falhas de plantio em talhões com até 20% de falhas. Além disso, a presença de plantas fora do alinhamento padrão do talhão não foi suficiente para inviabilizar os resultados encontrados. Por último, na terceira etapa, os resultados obtidos indicam o potencial do método em identificar a ocorrência da doença a partir da segmentação realizada e dos atributos espectrais adotados, mas sugerem novas abordagens no sentido de identificar uma solução operacional para o problema. Por fim, os processos adotados nesta pesquisa contribuem para o desenvolvimento de métodos práticos de auxílio à tomada de decisões dos produtores e prestadores de serviços.

Palavras-chave: Citricultura. Agricultura de precisão. Detecção de copas. Identificação de linhas de plantio. Identificação de falhas de plantio. *Greening*. Mask R-CNN.

USE OF CENTIMETER IMAGES AND MACHINE LEARNING ALGORITHMS TO SUPPORT ORANGE ORCHARD MANAGEMENT: DETECTION AND DELINEATION OF TREES, IDENTIFICATION OF PLANTING ROWS, PLANTING GAPS AND TREES WITH GREENING

ABSTRACT

The orange cultivation is one of the main activities of citriculture worldwide and corresponds to the largest production of fruit nationally. However, despite the potential production, the development of management techniques is still required, because they are important tools for conduction of agriculture challenges in terms of productivity, food safety, environmental impact and sustainability. In this context, this work explored the use of images captured by Unmanned Aerial Vehicle (UAV) to extract useful data about the crop, aiming the development of tools to help agricultural management. The main objectives of study were organized in three main areas: detection and delineation of tree crowns; identification of planting rows and planting gaps; and diagnosis of the crop health status in terms of greening disease. In the detection and delineation analysis, deep learning model based on convolutional neural network (Mask R-CNN) was used to compare the performance between RGB images with and without addition of a channel with the canopy altitude data. Furthermore, in this first stage of our research, methods for operationalizing the activity were discussed. In the second stage, we proposed and discussed a model based on spatial analysis of linear patterns for unsupervised identification of planting lines and planting gaps from crown position. Finally, the data collected in the first two stages were used to evaluate the ability to accurately diagnose the greening disease. The proposed diagnostic methodology used spectral attributes extracted from canopy areas and applied to the Random Forest classifier. The results found in the first stage suggest that the use of canopy altitude data increases the detection capability, but the delineation may be impacted by the quality of the input data. In the second stage, the proposed methodology proved feasible for automated identification of planting rows and planting gaps in plots with up to 20% gap rate. Furthermore, the presence of plants outside the alignment of the field was not enough to invalidate the results. Finally, in the third stage, the results indicated the potential of the method to identify the occurrence of the disease based on the segmentation performed and the spectral attributes chosen, but suggest new approaches in order to identify an operational solution to the problem. Finally, the processes adopted in this research contribute to the development of practical methods to assist the decision making process of the farmers and service providers.

Keywords: Citriculture. Precision agriculture. Canopy detection. Identification of planting rows. Identification of planting gaps. Greening. Mask R-CNN.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Principais dificuldades encontradas pelos produtores no cultivo de laranja entre as safras de 2017 e 2019.....	8
Figura 2.2 - Percentual de árvores contaminadas pelo <i>greening</i> no cinturão citrícola.....	10
Figura 3.1 - Mapa de localização das áreas de estudo e detalhes ampliados dos talhões adotados.....	19
Figura 3.2 - <i>Canopy Height Model</i> (CHM) derivado do processo de fotogrametria aplicado às imagens VANT.....	21
Figura 3.3 - Estrutura da <i>Mask R-CNN</i>	22
Figura 3.4 - <i>Framework</i> do processo adotado para delimitação das copas.....	24
Figura 3.5 - Exemplos do processo de geração das amostras com os resultados preliminar e final.....	25
Figura 3.6 - Sequência dos processos adotados no processamento dos <i>patches</i>	27
Figura 3.7 - Evolução das métricas de validação durante o treinamento da <i>Mask R-CNN</i>	29
Figura 3.8 - <i>Framework</i> adotado no processo de identificação de copas e mosaicagem.....	31
Figura 3.9 - Esquema ilustrativo das métricas de validação do delineamento das copas de laranjeiras.....	33
Figura 3.10 - Exemplos de resultados do processo de mosaicagem não supervisionada.....	35
Figura 3.11 - Exemplos do resultado do processo de detecção e delineamento das copas.....	36
Figura 3.12 - Métricas de detecção das copas de larnajeiras a partir de diferentes limiares de filtragem.....	37

Figura 3.13 - Exemplos da diferença de delineamento das copas entre os dois modelos.....	38
Figura 3.14 - Histograma dos valores de IoU para os dois modelos (RGB e RGBC).....	39
Figura 3.15 - Resultados da regressão linear para a área das copas.	40
Figura 3.16 - Resultados da regressão linear para o diâmetro das copas.....	41
Figura 4.1 - Fluxograma de processos adotados na metodologia proposta para detecção de linhas e falhas de plantio.....	53
Figura 4.2 - Esquema ilustrativo do processo de geração dos segmentos-semente.....	55
Figura 4.3 - Ilustração da área de busca e exemplos dos resultados parciais do processo iterativo.....	58
Figura 4.4 - Linhas de plantio com falhas e seus respectivos histogramas de comprimento dos segmentos unitários..	59
Figura 4.5 - Esquema ilustrativo do processo de identificação de falhas de plantio.....	60
Figura 4.6 - Talhões adotados como área de estudo do experimento.	62
Figura 4.7 - Resultados do processo de identificação de linhas e falhas de plantio em frações dos 4 talhões.....	67
Figura 4.8 - Métricas de validação dos traçados das linhas para os cenários sem falsos positivos.....	68
Figura 4.9 - Métricas de validação dos traçados das linhas para os cenários com falsos positivos.....	68
Figura 4.10 - Métricas da análise de regressão para os cenários sem falsos positivos.....	70
Figura 4.11 - Métricas da análise de regressão para os cenários com falsos positivos.....	71

Figura 4.12 - Tempo de execução da metodologia proposta para identificação de linhas e falhas de plantio.....	77
Figura 4.13 - Exemplos dos casos de inconsistência na metodologia proposta para identificação de linhas e falhas de plantio.	81
Figura 5.1 - Exemplos da redução do traçado das copas para 70% de área.....	86
Figura 5.2 - Distribuição de valores normalizados dos 20 atributos mais importantes durante o processo de classificação....	94
Figura 5.3 - Diferença dos atributos entre plantas infectadas e sadias.	95
Figura 6.1 - Design proposto para o sistema de auxílio ao manejo agrícola de talhões comerciais de laranja.....	101

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 - Características dos voos de imageamento de cada talhão estudado.....	20
Tabela 3.2 - Características e quantidade de amostras usadas nos dois modelos (RGB e RGBC).....	27
Tabela 3.3 - Resultados do processo de detecção de copas.....	34
Tabela 3.4 - Métricas de validação do processo de delineamento.....	38
Tabela 3.5 - Valores médios de IoU das copas corretamente identificadas.....	39
Tabela 3.6 - Características e resultados das pesquisas de detecção de árvores similares a este estudo.....	43
Tabela 4.1 - Parâmetros adotados no estudo de caso.....	66
Tabela 4.2 - Resultados da identificação de falhas de plantio sem a presença dos falsos positivos.....	73
Tabela 4.3 - Resultados da identificação de falhas de plantio com a presença dos falsos positivos.....	75
Tabela 4.4 - Resultados da filtragem de falsos positivos após o processo de identificação de linhas e falhas de plantio...	76
Tabela 5.1 - Características dos voos de obtenção das imagens.....	85
Tabela 5.2 - Atributos espectrais adotados no processo de classificação.....	87
Tabela 5.3 - Resultados da inspeção visual completa nas diferentes variedades de laranja.....	90
Tabela 5.4 - Matrizes de confusão geradas pela classificação das amostras nos diferentes cenários.....	92
Tabela 5.5 - Métricas da classificação dos diferentes cenários.....	93

LISTA DE SIGLAS E ABREVIATURAS

CHM	<i>Canopy Height Model</i>
CNN	<i>Convolutional Neural Networks</i>
FN	Falso Negativo
FP	Falso Positivo
<i>LiDAR</i>	<i>Light Detection And Ranging</i>
LM	Local Maxima
MCWS	<i>Marker-Controlled Watershed Segmentation</i>
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
MVS	<i>Multi-View Stereo</i>
NMS	<i>Non-Maximum Supression</i>
PCR	<i>Polymerase Chain Reaction</i>
SfM	<i>Structure from Motion</i>
TP	True Positives
VANT	Veículo Aéreo Não Tripulado
VRA	<i>Variable Rate Applications</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Objetivo.....	4
1.2 Objetivos específicos.....	4
1.3 Estrutura do trabalho.....	4
2 REFERENCIAL TEÓRICO.....	6
2.1 Citricultura no Brasil.....	6
2.2 Doença do <i>greening</i>	9
2.3 Uso de sensoriamento remoto no monitoramento agrícola.....	12
3 USO COMBINADO DE IMAGENS RGB E MDE DE VANT PARA DETECÇÃO E DELINEAMENTO DE COPAS DE LARANJEIRAS COM A MASK R-CNN: UMA ABORDAGEM DE ROTULAGEM E FRAMEWORK UNIFICADO.....	14
3.1 Materiais e métodos.....	19
3.1.1 Área de estudo.....	19
3.1.2 Aquisição das imagens e pré-processamento.....	20
3.1.3 Arquitetura Mask R-CNN.....	21
3.1.4 Base de dados das copas de laranjeiras.....	23
3.1.5 Treinamento dos modelos.....	25
3.1.6 Mosaicagem do resultado de identificação e delimitação das copas.....	29
3.1.7 Métricas de validação.....	31
3.1.7.1 Detecção.....	32

3.1.7.2 Delineamento.....	33
3.2 Resultados.....	34
3.2.1 Detecção das copas de laranjeiras e mosaicagem do resultado dos <i>patches</i>	34
3.2.2 Delineamento das copas de laranjeiras.....	37
3.3 Discussão.....	41
3.3.1 Detecção das copas de laranjeiras.....	41
3.3.2 Delineamento das copas de laranjeiras.....	45
3.3.3 Mosaicagem dos resultados de detecção e delineamento das copas limitados pelos <i>patches</i>	46
3.4 Conclusão.....	48
4 ANÁLISE ESPACIAL BASEADA EM PADRÕES LINEARES PARA DETECÇÃO NÃO SUPERVISIONADA DE LINHAS E FALHAS DE PLANTIO APLICADA EM CULTURAS DE LARANJA.....	50
4.1 Introdução.....	50
4.2 Metodologia.....	52
4.2.1 Fase inicial.....	53
4.2.2 Fase recursiva.....	56
4.2.3 Fase de detecção de falhas de plantio.....	58
4.3 Estudo de caso.....	61
4.3.1 Implementação do estudo de caso.....	61
4.3.2 Base de dados.....	61
4.3.3 Falhas de plantio.....	63
4.3.4 Falsos positivos.....	63
4.3.5 Validação.....	64

4.3.5.1 Traçado da linha.....	64
4.3.5.2 Pontos agrupados.....	65
4.3.5.3 Falhas e falsos positivos.....	65
4.4 Resultados.....	66
4.4.1 Parâmetros adotados.....	66
4.4.2 Traçado das linhas.....	67
4.4.3 Pontos (árvores) agrupados em linhas de plantio.....	69
4.4.4 Falhas de plantio.....	71
4.4.5 Falsos positivos.....	76
4.4.6 Desempenho computacional.....	76
4.5 Discussão.....	77
4.6 Conclusão.....	82
5 USO DE MODELOS DE APRENDIZADO DE MÁQUINAS E IMAGENS DE VANT PARA DETECÇÃO DA DOENÇA DO GREENING EM LAVOURA DE LARANJA.....	83
5.1 Introdução.....	83
5.2 Metodologia.....	85
5.2.1 Área de estudo.....	85
5.2.2 Imageamento, pré-processamento e segmentação.....	85
5.2.3 Extração de atributos.....	87
5.2.4 Classificação.....	88
5.2.5 Verdade de campo.....	88
5.2.6 Validação.....	89
5.3 Resultados.....	89
5.3.1 Inspeção visual.....	89

5.3.2 Classificação.....	90
5.4 Discussão.....	95
5.5 Conclusão.....	98
6 CONSIDERAÇÕES FINAIS.....	99
REFERÊNCIAS BIBLIOGRÁFICAS.....	102

1 INTRODUÇÃO

O cultivo de laranjas é uma das principais atividades da citricultura mundial e, nacionalmente, corresponde à maior produção de frutos do país. Ainda, o Brasil é o maior produtor da fruta no cenário internacional e ocupa a segunda posição – atrás da China – no cultivo de citros em geral (FAO, 2019). Sendo assim, a atividade impacta diretamente na dinâmica socioeconômica nacional, tendo sido responsável, em 2009, pela criação de 230 mil novos empregos diretos e indiretos (NEVES et al., 2010). Apenas no estado de São Paulo, foram geradas 48 mil vagas de trabalho em 2019, o que corresponde a 26% das vagas abertas no estado (SÃO PAULO, 2020).

Apesar da potência produtiva do país, técnicas adequadas de manejo ainda são demandadas, pois são importantes aliadas para a gestão e condução dos desafios da agricultura em termos de produtividade, segurança alimentar, impacto ambiental e sustentabilidade (GEBBERS; ADAMCHUK, 2010). Devido à heterogeneidade e complexidade do ambiente agrícola, é necessário o seu entendimento a partir do monitoramento, da mensuração e da análise contínua da sua dinâmica e dos seus aspectos físicos (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

Trabalhos de campo voltados para o levantamento de dados de fenotipagem, detecção de invasoras, identificação de falhas de plantio e da situação fitossanitária das culturas demandam tempo e esforço, além de recursos financeiro e humano (LUVISI; AMPATZIDIS; DE BELLIS, 2016). Os dados de fenotipagem como área e formato das copas das árvores, por exemplo, demandam uma abordagem que trata cada planta individualmente e a sua obtenção em campo torna o monitoramento local e regional uma atividade onerosa.

A identificação individual e o delineamento das copas são atividades importantes para extração de parâmetros que auxiliam na tomada de decisões (KRAUSE et al., 2019), sobretudo porque podem ser relacionados diretamente

com a produção e subsidiam cálculos de estimativa de safra (FUNDECITRUS, MARKESTRAT, FEA-RP/USP, FCAV/UNESP, 2021).

No contexto de produtividade, uma atividade frequentemente realizada em campo é a identificação de falhas de plantio para a adequada reposição de mudas (RODRIGUES, 2020). Entretanto, uma vez que o talhão apresente estágio fenológico avançado, o diagnóstico de falhas se torna trabalhoso pela necessidade de caminhamento em todo o talhão.

Além dos dados relacionados com a fenotipagem e a distribuição de plantas e falhas na área plantada, cujo benefício envolve a obtenção de informações inventariadas da cultura – como contagem de plantas, densidade de plantio, área média das copas, espaçamento real entre plantas, entre outros – outro levantamento importante para o manejo da citricultura é o acesso à condição fitopatológica do plantio, principalmente em talhões comerciais da cultura.

O cinturão citrícola, por exemplo, é a região do país com a maior produção de laranja e é responsável por quase 80% da produção da fruta (FUNDECITRUS, 2020a). Entretanto, a região vem sendo prejudicada por fatores que afetam a sustentabilidade econômica da produção, como o aparecimento e a disseminação de problemas fitossanitários, sendo o principal deles o *greening* (detalhes na Seção 2.2).

As formas de levantamento de dados que auxiliam no manejo e na detecção de doenças mais utilizadas atualmente apresentam uma série de desvantagens relacionadas ao tempo de resposta, custos elevados, necessidade de mão de obra especializada e precisão insuficiente do diagnóstico (FUTCH; WEINGARTEN; IREY, 2009; BELASQUE JUNIOR et al., 2010; DENG et al., 2020). Diante deste cenário, o sensoriamento remoto surge como uma alternativa viável para auxílio no manejo e para detecção de doenças em lavouras agrícolas (OSCO et al., 2020; JUNG et al., 2021).

Dados e ferramentas de sensoriamento remoto vêm sendo amplamente utilizados na gestão agrícola, inclusive para análises em nível de planta cujo

dado de interesse é levantado para cada planta do campo. Em particular, os Veículos Aéreos não Tripulados (VANTs) são as plataformas de sensoriamento remoto mais utilizadas para essa atividade uma vez que fornecem imagens com resolução espacial centimétrica, permitem imageamento sob demanda, possibilitam o processamento e aquisição da informação em tempo hábil e possuem custo-benefício positivo quando comparados a imageamento aéreo tripulado ou orbital equivalentes (HUNT; DAUGHTRY, 2018).

Com o uso de imagens de sensoriamento remoto, diversas técnicas de processamento digital podem ser aplicadas. Dentre elas, as técnicas de *machine learning* e *deep learning* ganharam muita importância com o desenvolvimento da computação. Estudos indicam que a detecção de doenças em plantas com uso de imagens de sensoriamento remoto, aéreo ou terrestre, e de abordagens de aprendizado de máquina atinge os melhores resultados e são extremamente viáveis para a atividade (LAN et al., 2020; OSCO et al., 2021).

De modo geral, uma variedade de abordagens envolvendo levantamento de dados de plantio e de detecção de doenças com uso de VANTs vêm sendo estudadas ao longo dos últimos anos (HUNT; DAUGHTRY, 2018) e os resultados indicam o grande potencial aliado à viabilidade de implementação de sistemas de monitoramento a partir do sensoriamento remoto. Por outro lado, o inventário anual de árvores (FUNDECITRUS, 2020b) e o monitoramento do *greening* nos estados de São Paulo e Minas Gerais ainda são fortemente dependentes da inspeção visual e individualizada das árvores (FUNDECITRUS, 2020c), o que demanda muitos recursos para execução da atividade.

Diante disso, é necessário o desenvolvimento de abordagens que aumentem a viabilidade de obtenção de dados de culturas agrícolas a partir de imagens de sensoriamento remoto. Além disso, é necessária a investigação da capacidade de detecção e monitoramento do *greening* em plantações de laranja, de modo que sejam explorados procedimentos diagnósticos mais eficientes do que os

utilizados atualmente e sejam reduzidos os custos da produção, aumentando a sustentabilidade econômica da atividade.

1.1 Objetivo

O objetivo geral do presente estudo é explorar o uso de imagens obtidas por VANT para obtenção de dados de plantio e suporte no manejo de talhões comerciais de laranja.

1.2 Objetivos específicos

Avaliar a capacidade de detecção e delimitação individual de copas de laranjeiras a partir do uso de produtos obtidos pelo imageamento;

Analisar a viabilidade de identificação não-supervisionada de linhas e falhas de plantio das árvores identificadas e delimitadas;

Investigar a possibilidade de diagnóstico da condição fitossanitária das árvores estudadas quanto à infecção pelo *greening*.

1.3 Estrutura do trabalho

Esta dissertação de mestrado foi escrita em seis capítulos, a saber:

Capítulo 1 – Introdução: apresenta uma breve introdução sobre as características de plantio de laranja no país, bem como expõe as possibilidades e a atual situação do manejo agrícola em escala de plantio. Além disto, apresenta a relevância desta pesquisa e elenca o objetivo geral e os principais objetivos específicos do estudo.

Capítulo 2 – Referencial teórico: Discute o referencial teórico a respeito da citricultura no Brasil e os desafios encontrados pelos produtores, faz um levantamento dos principais problemas que assolam o plantio comercial da cultura, discute as características do *greening* e situa o uso do sensoriamento remoto na âmbito do monitoramento agrícola.

Capítulo 3 – Detecção e delineamento de copas: levanta a importância, a necessidade e as aplicações da detecção de plantas via imagens de VANT, bem como descreve a metodologia proposta e os resultados obtidos, fazendo uma discussão com foco no aumento da viabilidade e precisão da atividade.

Capítulo 4 – Identificação de linhas e falhas de plantio: discute a necessidade e importância da identificação não supervisionada de linhas e falhas de plantio por meio de imagens aéreas. O capítulo traz ainda a discussão e os resultados obtidos a partir da aplicação da metodologia sugerida em um estudo de caso.

Capítulo 5 – Diagnóstico da doença do *greening*: descreve a metodologia adotada no processo de identificação remota de árvores infectadas e discute as potencialidades e limitações encontradas. Além disso, são elencadas as principais sugestões para trabalhos futuros visando o avanço científico no âmbito da detecção da doença.

Capítulo 6 – Considerações finais: sintetiza as principais contribuições e possibilidades de uso prático dos processos metodológicos sugeridos por este estudo.

É importante notar que a sequência dos capítulos desta dissertação não necessariamente segue a aplicação dos processos sugeridos na mesma área de estudo. As análises realizadas focaram principalmente na validação dos métodos propostos e, por isso, foi necessária em alguns casos a adoção de dados de entrada com diferentes características.

2 REFERENCIAL TEÓRICO

Os tópicos citados nesta seção compreendem os assuntos que envolvem o plantio de laranja, os problemas associados ao cultivo e uso o sensoriamento remoto no monitoramento agrícola. A exposição e discussão dos conceitos e técnicas de processamento de imagens e dos estudos relacionados aos temas abordados durante esta dissertação será realizada nos respectivos capítulos em que serão demandados.

2.1 Citricultura no Brasil

A citricultura compreende o cultivo de laranja, lima, limão, tangerina e toraja e é uma das principais atividades agrícolas do Brasil. Além da produção para abastecimento do mercado interno, o setor apresenta significativa importância para a economia nacional e foi responsável, em 2010, pela exportação de 26% da produção mundial de laranja e por 56% de todo suco de laranja consumido mundialmente (NEVES et al., 2010). Atualmente, apesar da variação na produção, o país é um dos maiores produtores de citros e mantém sua posição de destaque no cenário internacional (FAO, 2019).

O cultivo dos citros foi iniciado ainda no período da colonização devido à disponibilidade de condições favoráveis para o plantio e se expandiu por todo território nacional. Desde a década de 1960, com a exportação do suco de laranja, a produção comercial de citros se intensificou no país e, ao longo dos anos, o Brasil tornou-se o principal produtor de laranjas do mundo (BOTEON, M.; NEVES, 2005; FAO, 2019).

Desde então, a laranja é a fruta mais cultivada dentre os citros, representando 87,3% da produção em 2019, e é ainda a fruta mais cultivada no país, com mais de 17 milhões de toneladas produzidas. Considerando todos os produtos agrícolas, seja de lavouras temporárias ou permanentes, a laranja ocupa a quinta posição na produção nacional, precedida pela Cana-de-açúcar, Soja, pelo Milho e pela Mandioca (IBGE, 2019).

Apesar de estar presente em todos os estados brasileiros, a maior parte do cultivo de citros, sobretudo da laranja, está concentrada espacial e potencialmente no estado de São Paulo, que é responsável por 63,97% da área colhida e por 77,64% da produção total da fruta no país (IBGE, 2019).

Além de São Paulo, o triângulo/sudoeste mineiro também é um potencial produtor citrícola e a região formada pelos 374 principais municípios dos dois Estados corresponde ao chamado cinturão citrícola, região de maior produção do setor no País. (FUNDECITRUS, 2020a).

Os esforços dos agentes envolvidos no cultivo de citros e as condições ambientais e socioeconômicas favoráveis subsidiam o destaque do cinturão e do Brasil no plantio desse setor (FRANCO, 2016). Entretanto, apesar da grande produção, a região vem sofrendo redução da sua capacidade produtiva nos últimos anos (FUNDECITRUS, 2020b), o que demanda atenção na gestão agrícola de modo a garantir a sustentabilidade da citricultura.

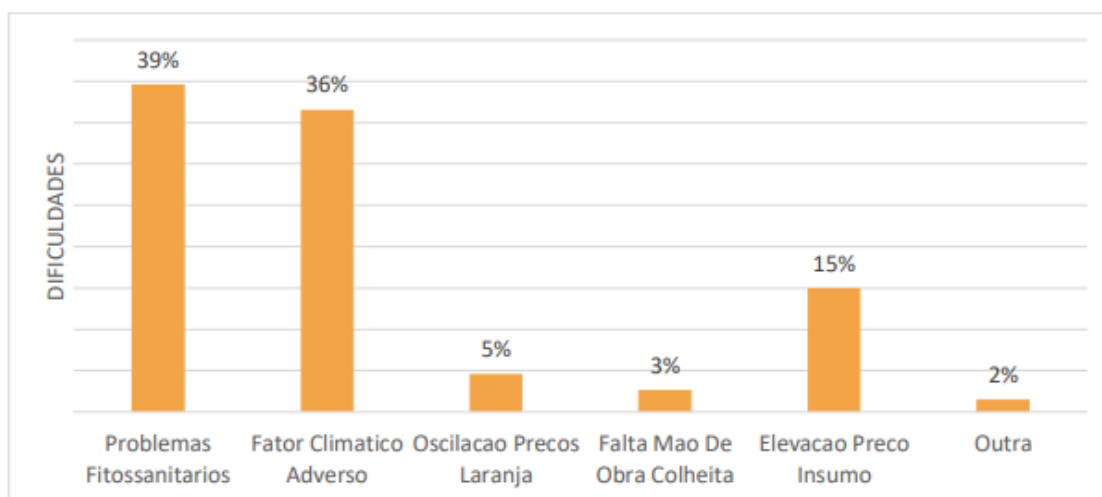
No levantamento realizado por Erpen et al. (2018), a análise do cultivo de laranja entre os anos de 2001 e 2015 detectou redução de 9,2% da produção no cinturão citrícola. Considerando as estimativas para a safra de 2020-2021, a redução projetada é de 12,5% em relação à média dos últimos dez anos e de 25,6% à safra anterior (FUNDECITRUS, 2020a), indicando a constância na queda da produção durante os últimos 20 anos.

Ainda segundo Erpen et al. (2018), a área de cultivo da laranja foi a variável mais impactada na região do cinturão entre 2001 e 2015, com redução de 29%, sendo a maior parte dessas terras transformadas em cultivo de cana-de-açúcar. Nos últimos anos, a área destinada ao plantio de laranja segue em declínio e teve redução de 1,44% na estimativa de 2021 em relação a 2019 – de 401,47 ha para 395,67 ha (FUNDECITRUS, 2020b).

Uma das maiores razões para a redução observada é o aumento nos custos de produção da cultura, que tem como principais componentes os gastos com mão de obra e com o controle fitossanitário (PAGLIUCA, 2012; ERPEN et al.,

2018). Um estudo amostral envolvendo 272 propriedades produtoras de laranja do cinturão citrícola demonstrou (2.1) que, segundo os agricultores, a principal dificuldade para produzir laranjas nas safras de 2017 a 2019 consiste nos problemas fitossanitários que assolam a lavoura (GUERREIRO NETO, 2019).

Figura 2.1 - Principais dificuldades encontradas pelos produtores no cultivo de laranja entre as safras de 2017 e 2019.



Fonte: Guerreiro Neto (2019).

De acordo com Rossi (2017), a incidência de pragas e doenças no plantio de laranjas é um problema substancialmente sério enfrentado pelos produtores e tem como principais impactos a necessidade de contratação de mão de obra especializada, o uso de produtos químicos para controle das doenças e a execução de erradicações obrigatórias¹, o que justifica o aumento nos custos da produção.

Diante do exposto, é notório o destaque do cinturão citrícola e do país na produção de citros, sobretudo da laranja. Por outro lado, este setor agrícola enfrenta uma redução crônica na sua capacidade produtiva, principalmente relacionada à perda de área cultivada gerada por fatores que afetam a sustentabilidade econômica da produção, como o controle fitossanitário.

¹ As erradicações obrigatórias são aplicadas através das diretrizes da Instrução Normativa nº 53 de 16/10/2008 / MAPA - Ministério da Agricultura, Pecuária e Abastecimento (D.O.U. 17/10/2008)

Dentre as principais doenças relacionadas à perda de produção de laranjas, é possível destacar, por critérios de nocividade e porcentagem de incidência, o *greening*, o CVC e o cancro cítrico (FUNDECITRUS, 2019). O *greening* é considerado pela literatura e pelos produtores como a principal doença de citros da atualidade e tem demandado muito recurso financeiro e humano no combate aos impactos causados (BELASQUE JUNIOR et al., 2009).

2.2 Doença do *greening*

O *greening* ou *Huanglongbing* (HLB, do chinês “doença do ramo amarelo”) é uma doença causada, no Estado de São Paulo, pelas bactérias *Candidatus Liberibacter asiaticus* e *Ca. L. americanus* e a sua transmissão está associada ao psílídeo dos citros *Diaphorina citri* Kuwayama (*D. citri*) (CAPOOR et al., 1967; TEIXEIRA et al., 2005; BELASQUE JUNIOR et al., 2009).

O impacto causado nas plantas infectadas abrange tanto a estrutura das folhas, ramos e frutos quanto a produtividade da laranjeira. É possível observar a presença da doença a partir dos sintomas como amarelamento das folhas dos ramos infectados, acúmulo de amido no tecido foliar, má formação e permanência da coloração verde nos frutos maduros. Entretanto, Lin et al. (2010) destacam que os sintomas observados podem ser, ainda, confundidos com outros problemas bióticos e abióticos relacionados à saúde do vegetal.

Além dos sintomas visuais, o *greening* pode afetar diretamente a produtividade da planta. Segundo Fundecitrus (2020c), à medida que a severidade dos sintomas aumenta, a produção diminui, uma vez que reduz o crescimento e aumenta a queda prematura dos frutos. O impacto na produção pode provocar uma redução de até 100%, tornando o vegetal totalmente improdutivo.


O grande desafio provocado pela doença consiste na condição de ainda não haver uma abordagem curativa para as plantas infectadas. Desta forma, o manejo da doença deve ser focado em procedimentos preventivos que visam evitar novas contaminações, que são executados através da eliminação de

plantas sintomáticas e da aplicação de defensivos agrícolas para controle do vetor (BOVÉ, 2006; BELASQUE JUNIOR et al., 2010).

Após sua identificação, o *greening* rapidamente se disseminou por todas as regiões citrícolas do estado e do Brasil, tendo sido constatada em 2005 em Minas Gerais e em 2007 no Paraná (BELASQUE JUNIOR et al., 2009). A disseminação da doença no cinturão citrícola ocorreu de forma acelerada, de modo que em 2004 apenas 3,4% dos talhões comerciais apresentavam alguma contaminação e oito anos depois, em 2012, atingiu a maioria (64%) das unidades produtoras (ROSSI, 2017).

A partir de 2011, não foram encontrados dados a respeito da contaminação em relação aos talhões, contudo, o monitoramento anual de doenças estima a quantidade de plantas infectadas e na 2.2 é possível observar os dados a respeito da quantidade de árvores contaminadas no cinturão citrícola entre os anos de 2008 e 2020.

Figura 2.2 - Percentual de árvores contaminadas pelo *greening* no cinturão citrícola.



Fonte: Fundecitrus (2020c).

Segundo Bassanezi et al. (2020), o aumento significativo do número de árvores contaminadas a partir de 2010 foi provocado principalmente pela descrença

dos produtores em relação à prática de erradicação das plantas sintomáticas como uma forma de controle, causada pelo aumento dos casos nos anos anteriores e pelo afrouxamento na aplicação da lei que determina a erradicação.

O dado exposto na 2.2 considera o cinturão citrícola em sua totalidade, entretanto, considerando-se os setores de forma individualizada, dada a heterogeneidade da disseminação do *greening*, algumas regiões apresentam até 60,46% das árvores contaminadas, como em Brotas e 53,18% em Limeira (FUNDECITRUS, 2020c).

A detecção do *greening* pode ser realizada por meio de inspeção visual ou por métodos analíticos. Os testes analíticos mais comuns utilizados para diagnóstico e confirmação da doença são microscopia eletrônica, sondas de DNA, ensaios enzimático e imunoenzimático, Reação em Cadeia da Polimerase (PCR, do inglês polymerase chain reaction) e PCR quantitativo (qPCR) (YAMAMOTO et al., 2006). Desses, o PCR e o qPCR são os testes laboratoriais mais utilizados e que apresentam maior sensibilidade de detecção (HANSEN et al., 2008; BELASQUE JUNIOR et al., 2009).

Por outro lado, Deng et al. (2020) afirmam que análises laboratoriais apresentam condições que podem inviabilizar a detecção em tempo hábil, como nível de complexidade relativamente alto, longo período necessário para o resultado e demanda de mão de obra qualificada, o que implica aumento dos custos necessários para a análise.

Com o método da inspeção visual, os responsáveis pela detecção visam identificar as plantas infectadas através da observação dos sintomas visíveis, sendo negligenciadas aquelas árvores que, apesar de infectadas, se mantêm assintomáticas. Diferentemente dos testes laboratoriais, este é um método simples e não requer o uso de equipamentos (HALL et al., 2010), entretanto, é prejudicado pela subjetividade de detecção e requer experiência e conhecimento específico dos operadores, o que implica a variação da acurácia do diagnóstico (DENG et al., 2020).

Segundo Belasque Junior et al. (2010), a partir do caminhamento a pé, uma equipe de detecção é capaz de identificar, em média, apenas 47,6% das plantas com algum sintoma, o que pode ser ainda mais impreciso ao se considerar as plantas visivelmente assintomáticas. De acordo com Futch, Weingarten e Irey (2009), alterando-se a altura de observação com uso de plataformas, o intervalo de acurácia desse método pode variar entre 47% e 59%.

Diante disso, é possível afirmar que o desenvolvimento de técnicas de detecção do *greening* que visem praticidade, maior confiabilidade e menor tempo de resposta é uma demanda urgente da citricultura. Nesse contexto, o uso do sensoriamento remoto no monitoramento agrícola vem sendo amplamente estudado nas últimas três décadas (WEISS; JACOB; DUVEILLER, 2020) e tem significativo potencial para detecção de doenças em lavouras.

As características de incidência e sintomas do *greening* na agricultura favorecem o uso do sensoriamento remoto uma vez que corresponde a um problema de natureza espacial ao se considerar o talhão agrícola e que provoca alterações na reflectância espectral das árvores (amarelamento das folhas e ramos, por exemplo), que podem ser identificadas pelos sensores.

2.3 Uso de sensoriamento remoto no monitoramento agrícola

O uso de satélites de observação da terra e de aeronaves tripuladas para monitoramento da agricultura tem sido pesquisado por mais de 60 anos (COLWELL, 1956; JACKSON, 1984; PINTER et al., 2003) e, segundo Herbei et al. (2016), têm sido motivado principalmente pelo interesse de trazer mais eficiência para a atividade.

Os estudos envolvendo essas plataformas fazem uso de imagens de média a alta resolução espacial e são responsáveis por levantamentos relacionados principalmente à análise de uso do solo. Por isso, os dados de sensoriamento remoto apresentam grande importância para agências governamentais no gerenciamento da agricultura (ALLEN, 1990; DORAISWAMY et al., 2003).

Por outro lado, com o uso de imagens satélite as aplicações de escala local, envolvendo análise dos talhões e das unidades produtivas, não têm sido exploradas na sua totalidade devido a fatores como resolução espacial grosseira, tempo de revisita inadequado, presença de nuvens nas imagens e morosidade na entrega das informações para os usuários, além do custo de aquisição (JACKSON, 1984; PINTER et al., 2003; MULLA 2013).

Os VANTs consistem, no âmbito do sensoriamento remoto, em uma plataforma do nível aéreo que apresenta características de obtenção de imagens ideais para a gestão da agricultura na escala da propriedade produtora. Dentre elas é possível destacar a resolução espacial refinada, cobertura de aquisição de acordo com a necessidade do produtor e características da cultura, rápido acesso aos dados gerados e custos acessíveis (MULLA, 2013; JUNG et al., 2021). Sendo assim, os VANTs se apresentam como uma boa alternativa para a identificação e o monitoramento agrícola, sendo um importante aliado na detecção das áreas de manejo para o controle com adição de insumos a taxas variadas (VRA, do inglês *Variable Rate Applications*) (KRISHNA, 2017), prática muito aplicada no contexto da agricultura de precisão.

Os estudos envolvendo o mapeamento de áreas agrícolas com uso de VANTs abordam diferentes objetivos, que vão desde identificação e contagem de plantas, extração de parâmetros fenológicos, acesso à condição nutricional da cultura, identificação de linhas e falhas de plantio, entre outros. Informações a respeito desses estudos e a importância dos levantamentos para o manejo agrícola são discutidas nos próximos capítulos.

3 USO COMBINADO DE IMAGENS RGB E MDE DE VANT PARA DETECÇÃO E DELINEAMENTO DE COPAS DE LARANJEIRAS COM A MASK R-CNN: UMA ABORDAGEM DE ROTULAGEM E FRAMEWORK UNIFICADO

A identificação individual das copas de árvore em campos agrícolas cultivados com espécies lenhosas, como a citricultura, é de extrema importância para contagem de plantas, avaliação do crescimento vegetal e estimativa de produção. Entretanto, a detecção e o mapeamento de árvores são atividades onerosas e que consomem muito tempo e esforço quando realizadas por técnicas tradicionais de campo (LEIVA et al., 2017; MOHAN et al., 2017). Diante disso, abordagens práticas de identificação e mapeamento eficientes são necessários para melhoria do processo agrícola.

No contexto do sensoriamento remoto, diversas plataformas são utilizadas para imageamento da superfície terrestre e suas aplicações dependem do objeto de estudo analisado. Os Veículos Aéreos não Tripulados (VANTs), são um tipo de plataforma atuante no nível aéreo de aquisição de imagens capaz de, com uso de sensores espectrais, realizar o imageamento de talhões agrícolas com características adequadas para a detecção de doenças agrícolas.

Fan et al. (2018) avaliaram a capacidade de detecção automática de plantas de tabaco com foco no manejo agrícola a partir de imagens RGB adquiridas por VANTs. Wu et al. (2019) utilizaram imagens RGB de VANT para identificação de plantas individuais de arroz em talhões agrícolas visando a estimativa da produção. Dadrasjavan et al. (2019) utilizaram imagens de VANT multiespectrais e atributos espectrais derivados (i.e. índices de vegetação) para identificação do *greening* em plantio de laranja por meio da identificação e individualização das regiões de copas antes do processo de classificação.

Os dispositivos imageadores geralmente utilizados em VANTs são as câmeras digitais RGB, os sensores multi e hiperespectrais e, menos comumente, os sensores termais e *light detection and ranging* (LiDAR) (HUNT; DAUGHTRY, 2018). O uso de câmeras RGB em VANTs é consideravelmente mais acessível

que os demais e, por meio de técnicas de fotogrametria e algoritmos como *Structure from Motion* (SfM) e *Multi-View Stereo* (MVS), permite a aquisição de dados além das cenas imageadas, como nuvens de pontos tridimensionais densas, modelos digitais de elevação (MDE) e mosaicos de imagens ortorretificados (PÁDUA et al., 2017).

A integração das imagens com esses dados tridimensionais torna o monitoramento da vegetação mais robusto não apenas pela capacidade de identificação individual de plantas, mas também pela possibilidade de estimação dos parâmetros de morfologia da copa como altura, diâmetro, perímetro e volume (MARQUES et al., 2019; DI GENNARO; MATESE, 2020; HAO et al., 2021).

As técnicas de detecção de copas a partir de imagens de sensoriamento remoto aplicam diferentes conceitos e a adequabilidade depende do tipo de copa estudada e das características das áreas avaliadas. Os métodos mais clássicos são Máximo Local (LM, do inglês *local maxima*), segmentação de bacia hidrográfica controlada por marcadores (MCWS, do inglês *marker-controlled watershed segmentation*), correspondência a modelos, crescimento de regiões e detecção de bordas (YU et al., 2022). Contudo, a grande limitação da aplicação desses métodos se dá pela exigência de configuração manual de parâmetros específicos para cada tipo de alvo de interesse ou imagem durante a identificação (CHADWICK et al., 2020; DONG et al., 2020), o que demanda conhecimento específico do analista e diminui a viabilidade do desenvolvimento de *frameworks* automatizados do processo.

Além dos métodos clássicos, os modelos de *deep learning* vêm sendo amplamente utilizados nos últimos anos devido a sua capacidade de lidar com diversos problemas da visão computacional (MA et al., 2019), sobretudo por meio das arquiteturas de redes neurais convolucionais (CNN, do inglês *convolutional neural networks*). Um dos avanços realizados no campo das CNNs foi o desenvolvimento de *Region-based CNNs* (R-CNN) (GIRSHICK et al., 2014), que são arquiteturas capazes de realizar a segmentação de instâncias de imagens, isto é, a identificação individual dos objetos

pertencentes a uma mesma classe semântica (i.e. diferenciação de copas de árvore individuais dentro da classe vegetação).

Um dos avanços das R-CNNs corresponde à arquitetura *Mask R-CNN* (HE et al., 2017), que é capaz de realizar a identificação e delimitar contorno do objeto de interesse em nível de pixel. A *Mask R-CNN* vem sendo amplamente utilizada no campo do sensoriamento remoto da vegetação e os resultados obtidos indicam seu grande potencial na detecção e delineamento de alvos. Yu et al. (2022) compararam a performance de modelos clássicos com a *Mask R-CNN* para identificação de pinheiro chinês e concluíram que a *Mask R-CNN* apresenta desempenho superior, atingindo *F1-score* de até 95%. Machefer et al. (2020) investigaram a parametrização do modelo para uso de amostras de treinamento com diferentes níveis de refinamento e atingiram *F1-score* de 90% e 97% para os plantios de batata e alface, respectivamente.

Mesmo com aplicação de *deep learning* – com uso de *region-based* ou outros modelos de CNN – a atividade de detecção de copas de árvores ainda demanda novas investigações, como uso de um único modelo para áreas com características espaciais heterogêneas e em culturas com alta densidade de plantio, onde a contiguidade e sobreposição entre duas copas vizinhas acontece naturalmente e torna a identificação individual uma tarefa difícil (AMPATZIDIS; PARTEL, 2019; OSCO et al., 2021).

Por outro lado, estudos de segmentação de instância aplicada a cenas naturais demonstraram que o desempenho dos modelos são superiores quando combinadas as informações de profundidade da cena às imagens RGB (SHAO; TIAN; BOHG, 2018). Diante disso, a informação estrutural/morfológica proveniente dos dados baseados em fotogrametria, atrelada às imagens das copas, pode ser um fator de relevância na identificação de cada uma das copas agrupadas.

Apesar desta possibilidade, não são muitos os estudos que avaliaram o uso de informação tridimensional proveniente de imageamento RGB como *proxy* de individualização de copas de árvores contíguas. Marques et al. (2019)

avaliaram a capacidade de identificação individual de copas de castanheiras a partir de produtos derivados do MDE baseado em SfM. O processo sugerido pelos autores se baseia principalmente no uso de filtros morfológicos, uma vez que as copas de castanheiras, apesar de se tocarem, mantêm claramente seu traçado circular visto pela visada a nadir. Hao et al. (2021) analisaram combinações de diferentes RGB e atributos baseados em SfM para identificação de copas e cálculo de altura de pinheiro chinês, mas, de modo similar, as copas não contemplam um alto nível de densidade.

Por outro lado, algumas culturas apresentam características distintas das espécies mencionadas e as copas se localizam extremamente adensadas, como laranja e uva. Di gennaro e Matese (2020), por exemplo, desenvolveram uma ferramenta baseada em nuvem densa de pontos e produtos derivados de MDE para levantamento da biomassa de viticultura. Os autores, contudo, não focaram na identificação individual das plantas para o cálculo da biomassa, mas na identificação de falhas pela diminuição da densidade das copas.

Além disso, um grande desafio do uso de *deep learning* corresponde à necessidade de quantidade e variedade significativas de amostras para treinamento da rede, o que demanda muito esforço aplicado ao trabalho manual de rotulagem. Alguns trabalhos baseiam-se, entre outras, nesta condição para simplificar a forma de detecção de árvores e adotam a identificação por retângulo envolvente, sem a delimitação do contorno de cada copa (AMPATZIDIS; PARTEL, 2019; AITELKADI et al., 2021) ou até mesmo a representação pontual, sem a delimitação bidimensional da planta (MATTOS et al., 2018; OSCO et al., 2020, 2021; RODRIGUES, 2020).

Em contrapartida, a identificação das árvores por máscara delimitadora da copa oferece uma gama de possibilidades de análise devido à discriminação da região do dossel em relação ao entorno (i.e. solo e sombra), possibilitando a aplicação de abordagens visando a extração de informações morfológicas, como mencionado, mas sobretudo, que utilizam a resposta espectral proveniente exclusivamente do dossel da planta, como na identificação de fitopatologias (GARZA et al., 2020).

Outro desafio do uso de algoritmos baseados em *deep learning* corresponde à adequabilidade das imagens à arquitetura dos modelos, pois estes geralmente são construídos para imagens naturais de tamanhos menores que as imagens orbitais ou de VANTs. Sendo assim, o uso de imagens de sensoriamento remoto nestes modelos requer a subdivisão da imagem original em vários *patches* (recortes) quadrados que demandam pós-tratamento do resultado para eliminação do efeito "mosaico" (FAN et al., 2018; YU et al., 2022), o que também dificulta o desenvolvimento de *frameworks* automatizados de detecção.

No melhor do nosso conhecimento, poucos estudos abordaram alguma metodologia de agregação do resultado final em uma única cena. De Carvalho et al. (2021) propuseram uma abordagem para estudo com pivôs irrigados – que diferem de árvores em talhões agrícolas pois apresentam formatos extremamente regulares e nenhuma sobreposição – por meio de uma modificação do método *Non-Maximum Supression* (NMS). Braga et al. (2020) adotaram um método próprio para integração dos resultados de identificação de copas de árvores florestais. Sem muitos detalhes a respeito do procedimento, os autores sugerem a união de quaisquer duas copas que se sobrepõem e se localizam nos extremos dos *patches*, desconsiderando a possibilidade de sobreposição real entre as árvores.

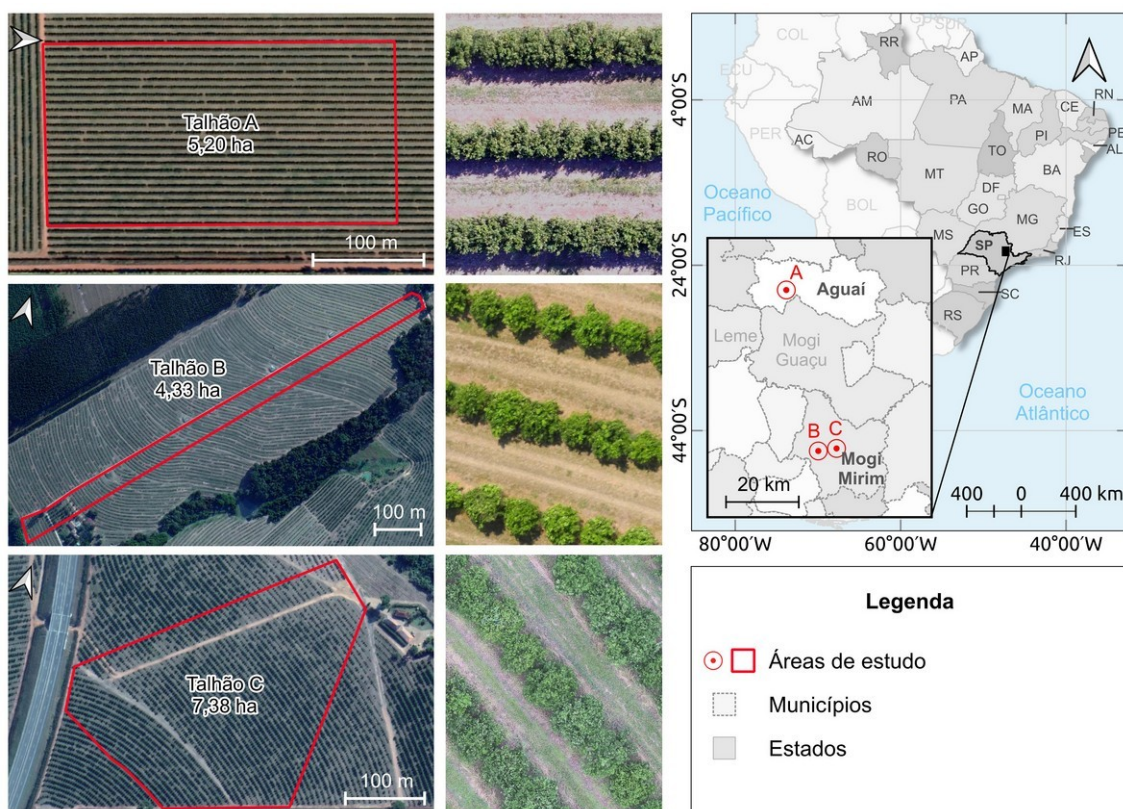
Portanto, o objetivo do trabalho é avaliar a performance da segmentação de instância em imagens de sensoriamento remoto com uso apenas de dados derivados de imageamento RGB e fotogrametria para detecção e delineamento de copas de árvores adensadas. A análise conduzida nesse estudo visa contribuir para a identificação e contagem de plantas de citros e delimitação de suas copas, bem como para aumento da viabilidade do processo de rotulagem em estudos envolvendo copas de árvores contíguas. Além disso, este estudo sugere um método de automatização do processo de segmentação de copas para grandes cenas a partir da mosaicagem não-supervisionada dos resultados.

3.1 Materiais e métodos

3.1.1 Área de estudo

A área de estudo (3.1) é composta por três frações de talhões localizados no estado de São Paulo, Brasil, nomeados de talhão A (47.1285°W , 22.0543°S), B (47.0491°W , 22.4555°S) e C (47.0003°W , 22.4508°S). Os talhões cobrem respectivamente 5,20, 4,33, 7,38 hectares, totalizando 16,9 ha de plantio de laranja das variedades Hamlin, Baianinha, Valência, Pêra e Natal. Ao todo, os segmentos de talhões adotados abrangem 9064 árvores e apresentam características espaciais distintas, como idade do plantio, altura e diâmetro das copas, espaçamento entre árvores e entre linhas, assim como diferentes coberturas do solo.

Figura 3.1 - Mapa de localização das áreas de estudo e detalhes ampliados dos talhões adotados.



Coordenadas geográficas em *Datum* WGS 84.

Fonte: Produção do autor.

3.1.2 Aquisição das imagens e pré-processamento

As imagens RGB foram adquiridas nos três talhões em diferentes datas e com equipamentos distintos. Os talhões A e C foram imageados com um VANT multi-rotor, o DJI Phantom 3 (DJI, Shenzhen, China) com uma câmera RGB – PowerShot S100 (lente 5.2 mm; sensor CMOS de 12.1 Megapixel; resolução de 4000 × 3000px). O talhão B foi imageado com um VANT de asa fixa, o senseFly's eBee (senseFly SA, Lausana, Suíça) integrado com a câmera sensefly Duet T, que possui um sensor RGB – Sensefly S.O.D.A. (lente 35 mm; resolução de 5472 x 3648px) – e um sensor termal que não foi considerado no estudo deste capítulo. Na 3.1 são sumarizadas as informações relacionadas à aquisição das imagens, incluindo equipamento e configuração de voo.

Tabela 3.1 - Características dos voos de imageamento de cada talhão estudado.

Talhão	Data	VANT	Altura do voo (m)	GSD (cm)	Sobreposição (%) (frontal/lateral)
A	05/dez/ 2019	DJI Phantom 3	50	2,2	80/70
B	27/set/ 2021	SenseFly's eBee	76	7,1	80/75
C	20/jan/ 2020	DJI Phantom 3	50	2,5	80/80


Fonte: Produção do autor.

O software Pix4Dmapper Pro (Pix4D SA, Lausana, Suíça) foi utilizado para o processamento fotogramétrico das imagens adquiridas pelo VANT, utilizando-se sequencialmente as técnicas de alinhamento, otimização do alinhamento, construção da malha densa de pontos, classificação dos pontos de solo, elaboração do Modelo de Digital de Superfície (MDS) e de Terreno (MDT) e ortomosaicos.

Além dos produtos gerados pelo software, foi computado ainda o Modelo de Altura de Dossel (CHM, do inglês *Canopy Height Model*) de cada talhão. O CHM é resultado da subtração do MDS pelo MDT, gerando um modelo de

elevação que considera apenas as alturas acima do solo e elimina a declividade de terreno. Na 3.2 é possível perceber que a partir da imagem RGB com a visada a nadir é difícil a diferenciação entre as copas mesmo pela interpretação visual, entretanto, as informações de altura dos dosséis sugerem a separação a partir da formação do ponto de sela entre as copas.

Figura 3.2 - *Canopy Height Model* (CHM) derivado do processo de fotogrametria aplicado às imagens VANT.




(A) Linha de perfil traçada sobre copas de árvores adensadas; (B) Visualização tridimensional do CHM sobreposto pelo ortomosaico; (C) Plot da linha de perfil explicitando a altura das copas.

Fonte: Produção do autor.

3.1.3 Arquitetura Mask R-CNN

A detecção e delimitação das copas de árvores foi realizada por meio da *Mask R-CNN* (HE et al., 2017), um dos principais *frameworks* utilizados atualmente para segmentação de instância em imagens de sensoriamento remoto (LI et al., 2020). A *Mask R-CNN* opera em dois módulos, sendo um para detecção de regiões cuja presença do objeto é detectada e discriminada, e outro para segmentação em nível de pixel dos limites do objeto. A estrutura da *Mask R-CNN* (3.3) é definida a partir do incremento desse segundo módulo à estrutura da *Faster R-CNN* (REN et al., 2017), rede capaz de realizar a detecção de objetos sem definição dos seus limites. O funcionamento do modelo é explicado a seguir.



Fonte: Produção do autor.

A imagem de entrada é inserida na rede extratora de atributos (*backbone*), que executa um conjunto de operações convolucionais e de *pooling* e é responsável pela extração de atributos visuais em diferentes escalas. Neste estudo foi utilizada a arquitetura ResNet101. Os mapas de atributos gerados pela primeira rede são usados como entrada para rede de regiões propostas (RPN, do inglês *Region Proposal Network*), que computa as prováveis regiões que contêm os objetos desejados a partir de padrões extraídos dos atributos.

Para cada região com alta probabilidade de ocorrência de um objeto, são computados múltiplos retângulos delimitadores (ou RoI, do inglês *Regions of Interest*), a depender dos parâmetros de escala e proporção definidos para o modelo. Neste estudo foram utilizados as escalas 4, 8, 16, 32, 64 (pixels) e proporções 0.5, 1, 2, resultando em 15 retângulos para cada região encontrada. Esses parâmetros foram definidos de acordo com a observação da abrangência e proporção das copas nas imagens de diferentes resoluções espaciais. Além disso, foi mantido o mesmo intervalo de escala – apesar de valores ligeiramente distintos – encontrado por (MACHEFER et al., 2020).

Devido aos diferentes tamanhos e proporções adotados para os Rols, o algoritmo realiza uma operação de homogeneização dos seus tamanhos, por meio de uma camada de convolução denominada *RoI-align*. Os Rols contendo o mesmo tamanho e escala são usados com entrada em três diferentes processos: (1) classificador *softmax* precedido por uma rede densamente conectada (FNC, do inglês *Fully Connected Network*) que indica a classe e a respectiva probabilidade de cada objeto identificado, (2) a regressão de polígono delimitador precedido por uma FCN para delimitação do retângulo final do objeto e (3) correspondente ao incremento da *Faster R-CNN* pela *Mask*

R-CNN, a delimitação da máscara do objeto, em nível de pixel, através de camadas de convolução (HE et al., 2017).

O algoritmo *Mask R-CNN* foi obtido e adaptado da implementação presente em Waleed (2017). A adaptação realizada inclui a possibilidade de uso de imagens com mais de 3 bandas e do uso de imagens em formato TIFF, preservando a informação geoespacial, o que subsidiou a geolocalização das máscaras inferidas. A implementação realizada utiliza rotulagens do tipo COCO em formato JSON para representação da verdade de campo demandada durante a fase de treinamento.

3.1.4 Base de dados das copas de laranjeiras

Para criação da base de dados com o delineamento de cada árvore presente nas áreas de estudos, foi adotada uma metodologia visando a diminuição do tempo e esforço demandado pela atividade manual a partir de técnicas processamento de imagens.

Esta metodologia fornece uma possibilidade de simplificação do processo e pode ser utilizada em futuros trabalhos que se propõem a criar um conjunto de dados de identificação de dosséis de vegetação arbórea não apenas com a localização pontual ou limite quadriculado dos alvos, mas com máscaras que contornam os seus limites. A partir da máscara, podem ser derivados a informação pontual e o retângulo envolvente a partir da extração do centroide e do *bounding box*, respectivamente.

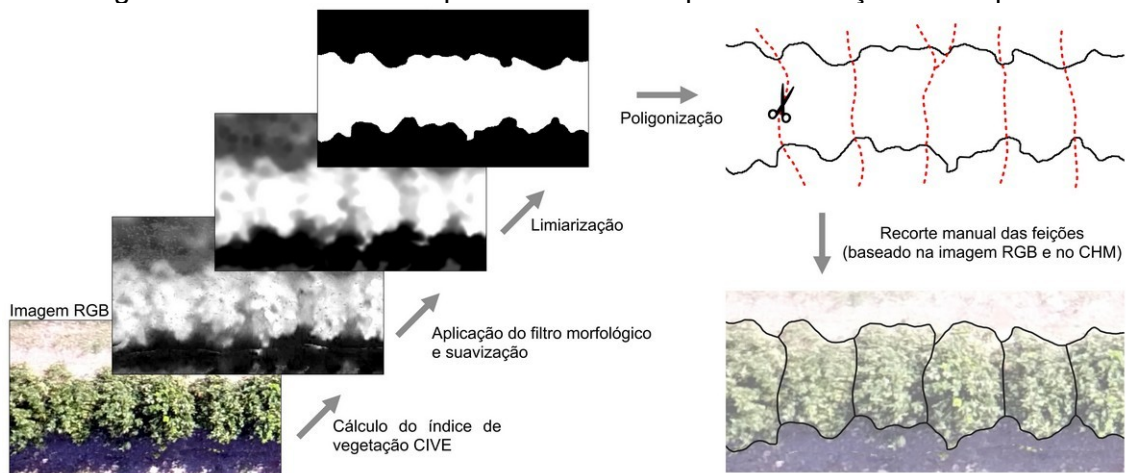
A metodologia proposta para delineamento das copas (3.4) foi realizada a partir da seguinte sequência:

- 1) Extração do *Colour Index of Vegetation Extraction* (CIVE), cuja equação é dada por (KATAOKA et al., 2003):

$$\text{CIVE} = (0.441 * \text{red}) - (0.811 * \text{green}) + (0.385 * \text{blue}) + 18.78745 \quad (3.1)$$

- 2) Aplicação da operação morfológica *opening* com dois diferentes tamanhos de janela (3 e 5 pixels) e suavização na imagem CIVE.
- 3) Limiarização da imagem gerada no passo anterior a partir de um limiar específico para cada imagem.
- 4) Conversão da imagem limiarizada de *raster* para vetor (poligonização) e seleção da área representada pelo conjunto de copas.
- 5) Individualização das copas, por meio do recorte manual, do polígono que representa o conjunto de copas.

Figura 3.4 - *Framework* do processo adotado para delimitação das copas.



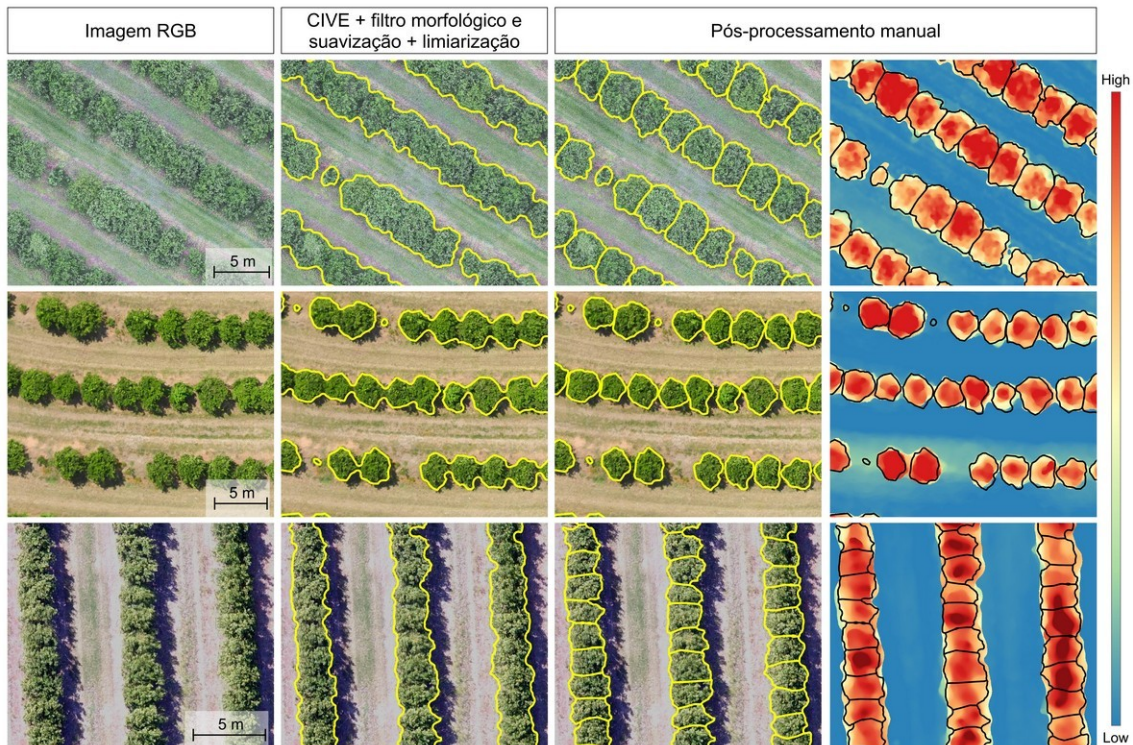
Fonte: Produção do autor.

Com isso, o trabalho manual do passo 5 foi necessário apenas para determinar a linha de separabilidade (ou interseção, quando houve) entre duas copas nas regiões em que havia algum nível de contato entre elas, sendo desnecessária a identificação e delimitação manual dos limites da copa que confrontam com o solo ou com as sombras.

Na região de contato entre duas árvores muito adensadas, a identificação visual da linha que as separa é uma tarefa difícil e enviesada se realizada apenas a partir da imagem RGB. Por isso, para identificação visual dos limites entre as copas foi utilizado, além da imagem RGB, o CHM, que forneceu a informação de morfologia dos dosséis, necessária principalmente nas áreas em

que não foi possível a individualização das árvores a partir dos aspectos de cor e textura provenientes da imagem RGB (3.5).

Figura 3.5 - Exemplos do processo de geração das amostras com os resultados preliminar e final.



Fonte: Produção do autor.

Além disso, para aumento da viabilidade da delimitação manual das copas, foi desenvolvido um algoritmo para conversão dos dados geográficos em rotulagem do tipo Coco, formato utilizado na *Mask R-CNN*. Assim, todas as etapas mencionadas nesse subtópico foram realizadas dentro do ambiente de Sistema de Informações Geográficas (SIG) – QGIS versão 3.16 – e posteriormente, de forma automatizada, as máscaras representadas pelas feições vetoriais foram convertidas diretamente em rótulos interpretáveis pelo modelo, referenciados e geolocalizados nas suas respectivas imagens.

3.1.5 Treinamento dos modelos

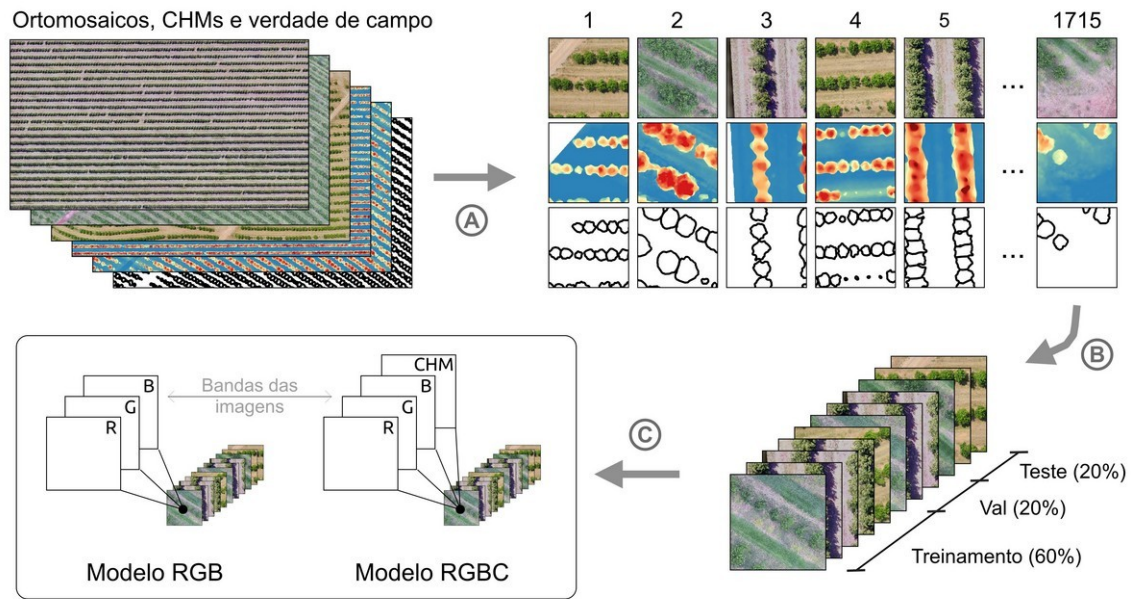
As imagens preprocessadas foram recortadas em *patches* quadrados para serem utilizadas nos modelos de segmentação. Os *patches* apresentam sobreposição horizontal e vertical e tamanho proporcional à resolução espacial

das respectivas imagens. Além das imagens, o dado vetorial contendo a verdade de campo com a delimitação das copas também foi recortado seguindo-se a mesma grade de corte, desse modo, cada amostra utilizada para treinamento ou inferência da detecção corresponde a um *patch*.

Foram definidos dois modelos de segmentação: o primeiro (modelo RGB) utilizando as imagens RGB com as três bandas originais do ortomosaico e o segundo (modelo RGBC), utilizando imagens com 4 bandas, sendo elas *Red*, *Green*, *Blue* e CHM. Para homogenização da resolução radiométrica entre as bandas das imagens do modelo RGBC, o CHM foi convertido para 8 bits por uma transformação linear, assim, todas as bandas dos *patches* utilizados em cada um dos modelos apresentam intervalo de valores dos pixels entre 0 e 255.

A análise realizada considerou as três áreas indistintamente, uma vez que o foco do trabalho foi avaliar e comparar a capacidade de detecção das copas entre imagens RGB e RGBC, considerando-se a complexidade espacial e a variabilidade das características de plantio, como variedade da laranja, idade do pomar, presença de cobertura vegetal ou solo exposto entre linhas de plantio e diferentes alturas de copas e densidades de plantio. Por isso, o treinamento, a validação do treinamento e a inferência foram realizados considerando-se os três talhões de forma unificada (3.6).

Figura 3.6 - Sequência dos processos adotados no processamento dos *patches*.



(A) Recorte dos *patches* das imagens RGB, CHMs e do dado com a verdade de campo; (B) Divisão do conjunto total de amostras em treinamento, validação do treinamento e teste; (C) Composição das amostras com as respectivas bandas usadas em cada modelo.

Fonte: Produção do autor.

Ao todo, 1715 *patches* foram utilizados em cada um dos dois modelos, sendo 1031 (60%) usados para treinamento, 342 (20%) para validação do treinamento e 342 (20%) para teste. As características adotadas em cada conjunto de *patches* são exibidas na 3.2. Para todos os *patches* dos três talhões adotados, a quantidade máxima de instâncias (copas ou frações) por amostras foi 30.

Tabela 3.2 - Características e quantidade de amostras usadas nos dois modelos (RGB e RGBC).

Talhão	Dimensões (x por x)		Sobreposição (px)	GSD (cm)	Área (m ²)	Número de <i>patches</i>			
	px	m				Trein.	Val.	Teste	Total
A	512	11,3	100	2,2	128,7	399	133	133	665
B	256	18,2	60	7,1	330	196	64	64	324
C	512	12,8	100	2,5	163,8	436	145	145	726
Total						1031	342	342	1715

Fonte: Produção do autor.

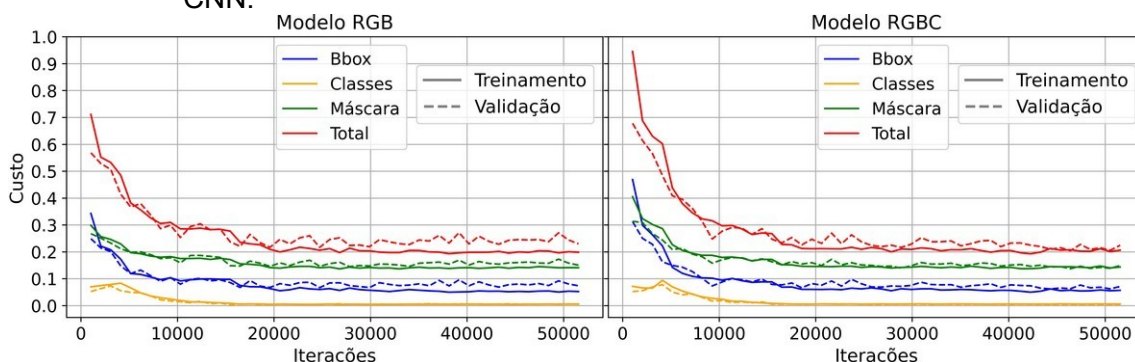
Os dois modelos foram treinados de forma similar, com taxa de aprendizado inicial de 0.001 e *momentum* de 0.9. O *epoch* corresponde a um ciclo de uso de todas as amostras de treinamento, que é formado por iterações que, por sua vez, pode ter ou não a mesma quantidade das amostras. Foram adotados 50 *epochs*, cada um com 1031 iterações e, para incremento no processo de aprendizado, foi adotada uma redução em 10 vezes da taxa de treinamento entre os *epochs* 15 e 27 (0.0001), 27 e 39 (0.00001) e 39 e 50 (0.000001).

Os modelos não foram iniciados aleatoriamente durante o processo de treinamento. As duas redes foram carregadas com parâmetros de pré-treinamento com o COCO *dataset*. Contudo, os parâmetros carregados correspondem ao pré-treinamento em imagens RGB e pelo fato de o modelo RGBC ser executado com imagens de 4 bandas, os pesos exclusivamente da primeira camada para esse modelo não foram herdados do pré-treinamento, e sim, iniciados aleatoriamente.

Além disso, incremento de dados (*data augmentation*) foi aleatoriamente aplicado nas imagens de treinamento antes da sua entrada nos modelos e as alterações aplicadas em cada uma das amostras correspondem a uma ou duas das seguintes transformações: (1) espelhamento horizontal, (2) espelhamento vertical, (3) rotação de 90°, 180° ou 270°, e (4) mudança no valor de brilho dos pixels no intervalo entre 50% e 150%.

A avaliação do treinamento e validação da *Mask R-CNN* é realizada por meio de um conjunto de métricas e cada uma avalia uma particularidade da atividade de detecção. As métricas utilizadas nesse estudo foram (1) *class loss* – que indica quão próximo o modelo está da classe correta, podendo ser copa ou plano de fundo, (2) *bounding box loss* – diferença entre os parâmetros dos bounding boxes (altura e largura) da referência e a inferência, (3) *mask loss* – diferença em nível de pixel entre a máscara de referência e a inferência, e (4) *total loss* – soma de todas as demais métricas. Após a fase de treinamento, as métricas foram computadas e a evolução da aprendizagem dos dois modelos é exposta na 3.7.

Figura 3.7 - Evolução das métricas de validação durante o treinamento da *Mask R-CNN*.



Fonte: Produção do autor.

3.1.6 Mosaicagem do resultado de identificação e delineamento das copas

Com a aplicação do modelo descrito para inferência, foram obtidas as possíveis delimitações das árvores nas imagens originais fracionadas pelos *patches*, entretanto, a sobreposição entre os *patches* significa que alguma árvore pôde ocorrer de forma redundante. As redundâncias podem ser uma parte de uma árvore que se localiza no extremo de um *patch* ou uma copa inteiramente duplicada.

Assim, a redundância é identificada pela sobreposição de duas ou mais máscaras relacionadas à mesma árvore. Para evitar que essa redundância degrade a precisão da detecção, foi desenvolvida uma metodologia de agregação (mosaicagem) do resultado a partir da relação topológica entre as máscaras candidatas inferidas.

A faixa de sobreposição entre os *patches* foi definida de tal forma que pelo menos um dos *patches* gerados contemple totalmente as copas de árvore presentes na região de intersecção. Desse modo, a atividade necessária para o refinamento do resultado foi identificar quais são as máscaras redundantes e apagá-las, não sendo necessária a união de duas ou mais máscaras para gerar um polígono final. As máscaras candidatas que não apresentam nenhuma sobreposição com as demais foram mantidas inalteradas.

É interessante notar que nos talhões com alta densidade de plantas a sobreposição entre elas pode ocorrer de forma natural e, assumindo essa possibilidade, não é possível simplesmente excluir os segmentos de árvore que se sobrepõem. Durante a realização da análise, foi observado que a adoção deste procedimento implica exclusão de máscaras não redundantes e redução da precisão de detecção por omissão.

Assim, o algoritmo não supervisionado proposto para essa atividade consiste nos seguintes passos:

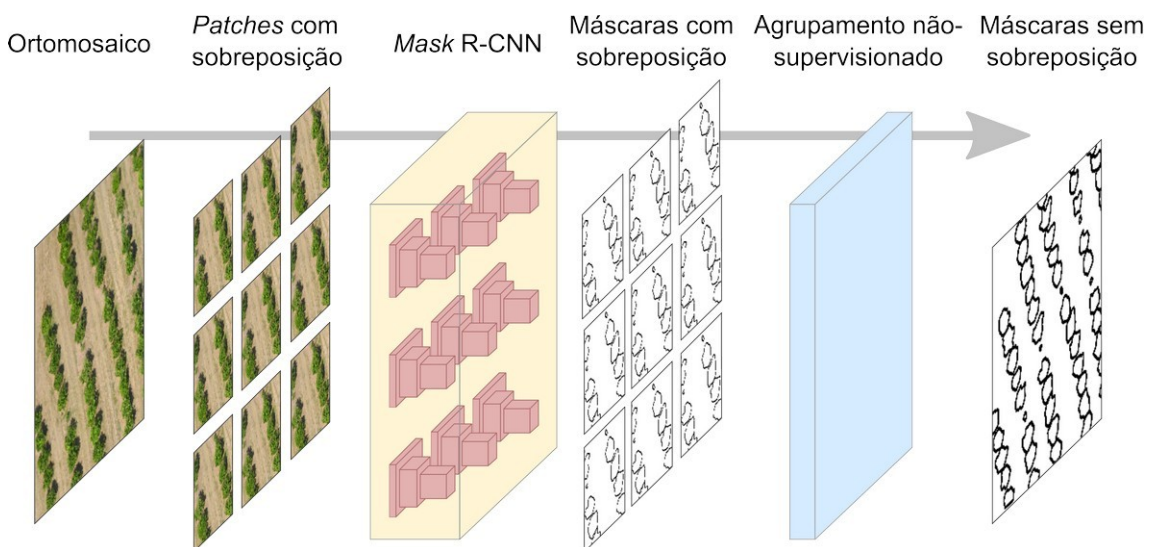
- 1) Para cada máscara candidatada, cômputo das intersecções existentes entre ela e as demais;
- 2) Avaliação do relacionamento espacial entre as intersecções e as máscaras e exclusão da máscara caso alguma dessas condições sejam observadas:
 - 2.1) Existência de pelo menos uma intersecção com área correspondente a, no mínimo, 50% da área da máscara originária;
 - 2.2) Somatório de todas as áreas de intersecção da máscara correspondente a, no mínimo, 50% da sua área;
 - 2.3) Área da máscara é menor que $1/3$ da área de qualquer outra máscara com a qual ela apresenta intersecção.

As condições definidas para o refinamento foram selecionadas empiricamente a partir dos resultados brutos obtidos nos diferentes talhões. A sobreposição natural presente nas copas de árvores ocorre de modo sutil e não ultrapassa mais de 50% da copa de cada uma delas, seja pela sobreposição unilateral (condição 2.1), seja pela bilateral (condição 2.2). Além disso, essa sobreposição ocorre entre duas árvores de grande porte e com áreas similares, sendo improvável, devido ao espaçamento homogêneo adotado no plantio, a sobreposição entre uma copa de pequeno porte com uma de grande porte

(condição 2.3), assim, essa observação auxilia na remoção de detecções falsas, muitas vezes relacionadas a ervas daninhas do entorno da planta.

O desenvolvimento desse algoritmo permitiu a adoção de um *framework* unificado e automatizado que contemplou todos os procedimentos de segmentação dos dois modelos previamente treinados, os quais recebem como entrada os ortomosaicos e os CHMs provenientes do pré-processamento e têm como saída o dado vetorial correspondente à delimitação das copas em toda área definida para inferência, sem nenhuma referência à divisão dos *patches* adotados na Mask R-CNN (3.8). Após a inferência, as copas foram submetidas à validação do resultado a partir da comparação com o dado de verdade de campo extraído manualmente.

Figura 3.8 - Framework adotado no processo de identificação de copas e mosaicagem.



Fonte: Produção do autor.

3.1.7 Métricas de validação

Para validação do método proposto, duas abordagens de avaliação foram aplicadas em cada um dos modelos de segmentação. A primeira voltada para performance da detecção individual das árvores presentes na área de teste e a segunda focada em avaliar a precisão do delineamento de cada copa identificada. Como as métricas das duas abordagens apresentam nomes

similares, foi adotado um sufixo em cada uma delas para discriminação de cada caso: `_det` para detecção e `_del` para delimitação. Em ambos os casos, a validação considerou todo o conjunto de copas inferidas e de referência.

3.1.7.1 Detecção

Todas as árvores inferidas foram validadas por meio da relação espacial entre os seus limites e os limites da sua respectiva verdade de campo através da métrica *Intersection over Union* (IoU) (3.9), que corresponde à razão entre as áreas da intersecção e união do par correspondente (verdade de campo e inferência). Quanto mais conformes os traçados das duas máscaras comparadas, mais próximo de 1 é o valor do IoU. Uma amostra foi considerada correta (TP, do inglês *true positive*) quando $IoU > 0.5$ e, de modo a garantir a integridade da validação, cada referência foi usada uma única vez quando da comparação com as copas inferidas.

Assim, três possíveis resultados foram adotados: (1) TP, quando árvore foi corretamente identificada ($IoU > 0.5$); (2) falso negativo (FN), quando ocorreu um erro de omissão, ou seja, uma planta existente não foi identificada e (3) falso positivo (FP), quando uma máscara inferida não corresponde de fato a uma planta existente, gerando um erro de comissão. A partir desses resultados, as métricas precisão`_det` (Pdet), recall`_det` (Rdet), F1-score`_det` (Fdet) e acurácia global (OA, do inglês *overall accuracy*) foram computadas para cada um dos dois modelos usando-se as seguintes equações:

$$\text{Precisão_det (Pdet)} = \frac{TP}{TP + FP} * 100 \quad (3.2)$$

$$\text{Recall_det (Rdet)} = \frac{TP}{TP + FN} * 100 \quad (3.3)$$

$$\text{F1-score_det (Fdet)} = \frac{2 * Pdet * Rdet}{Pdet + Rdet} \quad (3.4)$$


$$\text{Acurácia global (OA)} = \frac{TP}{TP + FN + FP} * 100 \quad (3.5)$$

3.1.7.2 Delineamento

A validação do delineamento de objetos é uma atividade que apresenta diferentes métodos de execução e nesse trabalho foram adotadas mais de uma abordagem visando a comparação com a literatura existente. A validação contemplou a avaliação do próprio valor de IoU, bem como das métricas precisão_del (Pdel), recall_del (Rdel), f1-score_del (F1del), além da análise estatística dos valores de área das copas por meio de regressão linear.

As métricas Pdel e Rdel foram calculadas segundo um incremento da abordagem proposta por (BRAGA et al., 2020), a qual analisa a relação entre as áreas dos retângulos delimitadores (*bounding boxes*) dos segmentos inferido, de referência e de suas intersecções. A modificação proposta em relação ao trabalho mencionado é que foram consideradas as próprias máscaras delimitadoras ao invés dos *bounding boxes*. Pdel é obtida a pela razão entre a área da intersecção de cada par correspondente e a área da máscara inferida; Rdel é obtida pela razão entre área da intersecção e a máscara de referência; F1-score_del é obtido pela Equação 3.4 com as métricas Pdel e Rdel substituindo respectivamente Pdet e Rdet. A 3.9 exhibe cada métrica de modo gráfico para melhor entendimento.

Figura 3.9 - Esquema ilustrativo das métricas de validação do delineamento das copas de laranjeiras.



Fonte: Produção do autor.

A análise de regressão foi realizada para avaliação da relação da área e do perímetro entre as copas de referência e aquelas estimadas pelo método proposto. Para cada uma das análises, foram computadas o coeficiente de determinação (R^2), que indica quão relacionadas estão as duas variáveis

envolvidas, o *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE) e *Mean Absolute Percent Error* (MAPE). Quanto maior o R^2 , maior a correlação entre as variáveis e quanto menor os RMSE, MAE e MAPE, mais próximas elas se apresentam. As quatro métricas foram utilizadas para avaliação da análise.

3.2 Resultados

3.2.1 Detecção das copas de laranjeiras e mosaicagem do resultado dos patches

Os resultados dos dois modelos quanto à detecção das árvores são expostos na 3.3. A identificação e delimitação manual resultou em 2117 copas presentes na área de inferência que foram usadas como verdade de campo.

O modelo RGB identificou corretamente 2086 copas, incorretamente 190 e deixou de identificar 31 árvores presentes na área. O modelo RGBC obteve um desempenho superior nas três situações e identificou corretamente 2108 copas, incorretamente 56 e deixou de identificar 9 copas. Todas as métricas de avaliação da identificação do modelo RGBC foram superiores às do RGB e, desconsiderando-se a acurácia global, a maior diferença (4,98 %) entre os modelos se deu pela precisão_det – que avalia a influência dos FP – e a menor (0,4 %), pela recall_det – que avalia a influência dos FN.

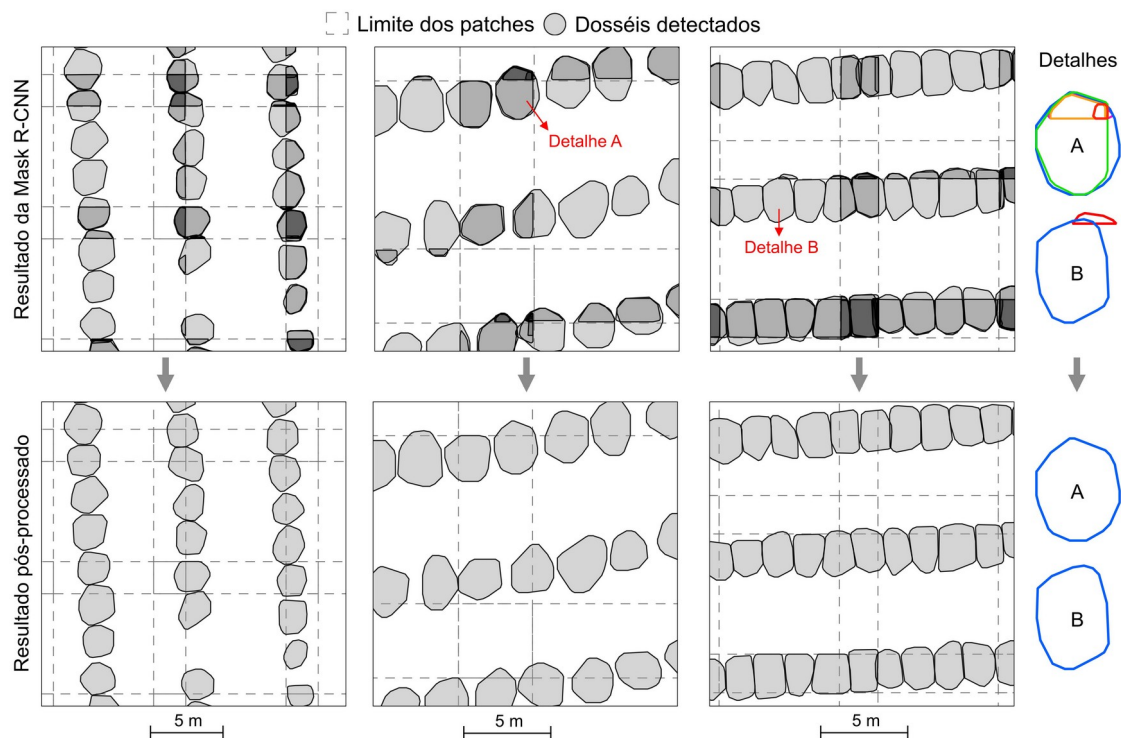
Tabela 3.3 - Resultados do processo de detecção de copas.

Métricas	Modelo RGB	Modelo RGBC
Detecções/Verdade de campo	2276/2117	2164/2117
TP	2086	2108
FP	190	56
FN	31	9
Acurácia global	90,42 %	97,01 %
Precisão_det	91,65 %	97,41 %
Recall_det	98,54 %	99,57 %
F1-Score_det	94,97 %	98,48 %

Fonte: Produção do autor.

Após a validação da identificação, constatou-se que nenhuma das ocorrências de FN foram provocadas pela aplicação da metodologia de agrupamento não supervisionado do resultado. As redundâncias originadas pelos *patches* de imagens sobrepostos foram corretamente identificadas e todas foram suprimidas, assim como todas inferências não redundantes foram mantidas inalteradas no resultado final. A 3.10 sumariza alguns exemplos da performance do processo de agrupamento.

Figura 3.10 - Exemplos de resultados do processo de mosaicagem não supervisionada.

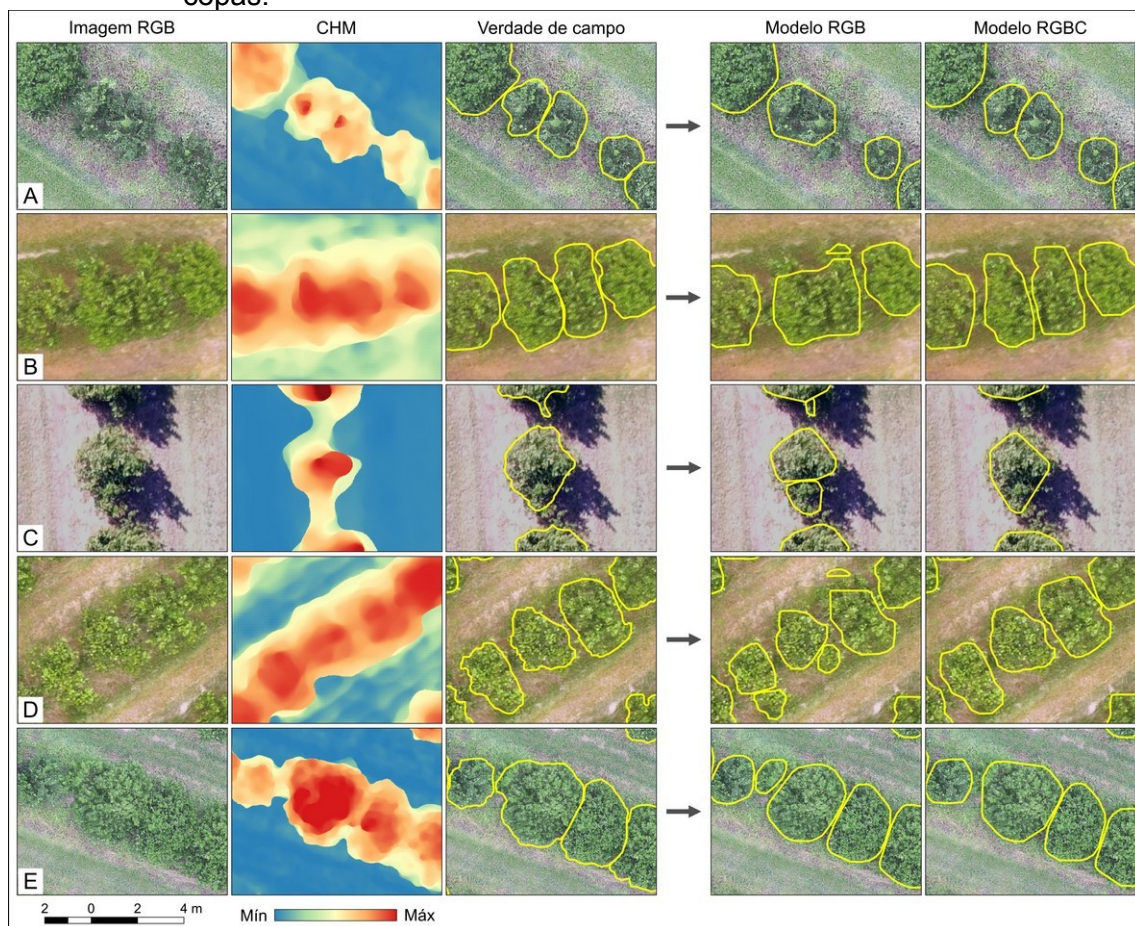


Fonte: Produção do autor.

As copas não identificadas (FN) pelo modelo RGB foram fruto, em alguns casos, da identificação equivocada de apenas uma copa quando existiram duas ou mais árvores adensadas (*under-segmentation*), enquanto o modelo RGBC foi capaz de realizar, com algumas exceções, a correta identificação das diferentes unidades de copas. Isto indica que, de modo geral, o modelo RGB não identificou corretamente a linha de separabilidade entre duas árvores de copas contíguas, o que não foi observado com a mesma frequência no modelo RGBC.

Quanto aos FP, a maior diferença entre os dois modelos se deu pela incorreta identificação de copas localizadas entre linhas de plantio devido à presença de cobertura vegetal. A informação de altura das copas inserida no modelo RGBC forneceu uma maior capacidade de identificação entre o que era de fato uma copa e que era cobertura vegetal do solo. Ainda, casos de identificações incorretas (FP) pelo modelo RGB também estão associados, em algum nível, à detecção incorreta de mais de uma copa para a mesma árvore quando da presença de sombras que supõem uma divisão do dossel (*over-segmentation*) (3.11).

Figura 3.11 - Exemplos do resultado do processo de detecção e delineamento das copas.



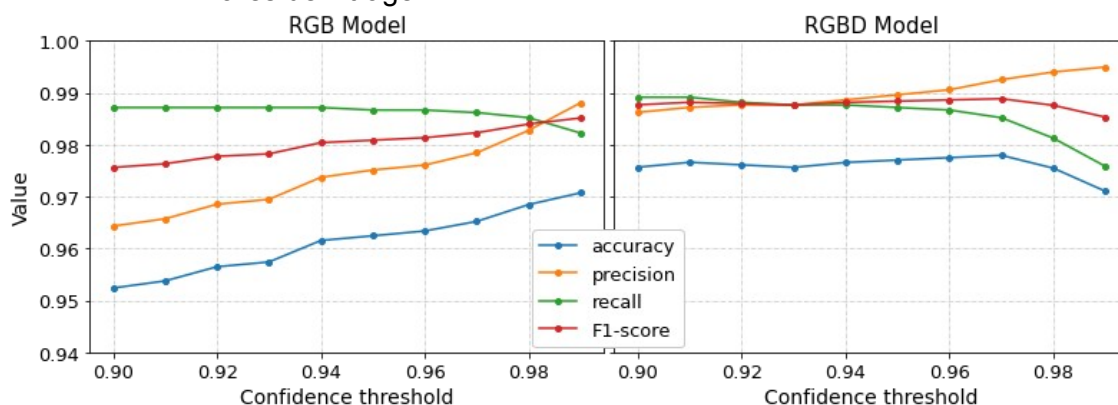
Fonte: Produção do autor.

Os resultados mostrados foram obtidos levando-se em consideração todos as máscaras inferidas em ambos os modelos. Levando-se em conta a pontuação de detecção (*confidence*) de cada árvore, as métricas foram recalculadas para

diferentes filtragens do conjunto de copas inferidas. Em cada filtragem, as copas foram selecionadas pelo limiar de *confidence* variando de 0,90 a 0,99, com passos de 0,01. Em cada cenário as copas adotadas apresentam a pontuação maior que o limiar. A 3.12 exhibe o comportamento das métricas baseado no limiar de filtragem.

O modelo RGB apresenta significativa variação quando adotados diferentes limiares de *confidence* e o modelo RGBC mantém suas métricas estáveis, sobretudo até o limiar 0,97, quando o desempenho apresenta leve queda. No modelo RGB, a filtragem pode acarretar ganho na precisão da identificação de copas, entretanto, de forma geral, o melhor desempenho deste modelo se equipara ao resultado do modelo RGBC sem adoção de filtragens.

Figura 3.12 - Métricas de detecção das copas de laranja a partir de diferentes limiares de filtragem.



Fonte: Produção do autor.

3.2.2 Delineamento das copas de laranjeiras

A avaliação do delineamento pelo cálculo de *precisão_del*, *recall_del* e *f1_del* foi realizada para as copas corretamente identificadas (*IoU* > 0,5) em cada modelo e os resultados são expostos na 3.4. Essas métricas são calculadas para cada árvore e, para avaliação da performance geral, foram computados a média e o desvio padrão de cada uma delas. O modelo RGB apresentou média de *precisão_del* de 93,5%, *recall_del* de 91,7% e F1 de 92,3% dentre um conjunto de 2086 copas. O modelo RGBC apresentou variação positiva em

relação à precisão_del, com 96,1%, e negativa quanto ao recall_del, de 87,8%, e ao F1, com 91,6%, em um total de 2108 copas.


Tabela 3.4 - Métricas de validação do processo de delineamento.

Métrica	Modelo RGB	Modelo RGBC
Precisão_del	0,935 ± 0,082	0,961 ± 0,051
Recall_del	0,917 ± 0,058	0,878 ± 0,067
F1-Score_del	0,923 ± 0,060	0,916 ± 0,046

De modo visual, é possível perceber que uma diferença significativa entre os dois resultados é a abrangência do traçado das máscaras inferidas (3.13). No modelo RGB, as máscaras das copas geralmente contemplaram toda a região visivelmente compreendida pelo dossel da árvore, enquanto no modelo RGBC houve um pequeno recuo dos seus limites. Isso é evidenciado pelo alto valor de precisão_del associado ao baixo de recall_del.

Uma possível justificativa para esse resultado é a diferença da natureza da informação trazida pelas bandas RGB e pelo CHM, pois enquanto a imagem RGB com altíssima resolução espacial é capaz representar as extremidades dos dosséis pela reflectância proveniente até das folhas mais extremas, a geração e a precisão do CHM é limitada pelo processo de *Structure from Motion* e da filtragem realizada no MDS para geração do MDT.

Figura 3.13 - Exemplos da diferença de delineamento das copas entre os dois modelos.



Fonte: Produção do autor.

A média do IoU foi calculada para todas as copas inferidas que apresentaram intersecção com alguma referência (IoU > 0) e apenas para aquelas com

valores maiores que 0,5 (TP), os resultados são expostos na 3.5. O modelo RGB apresentou valores médios de IoU superiores aos do modelo RGBC em todos os casos, com média de 0,862 considerando-se todas as copas e 0,867 apenas com as copas com IoU > 0,5. O modelo RGBC apresentou 0,847 e 0,848 para todos os valores e para aqueles maiores de 0,5, respectivamente.


Tabela 3.5 - Valores médios de IoU das copas corretamente identificadas.

Modelo	Todas	IoU > 0.5
RGB	0,862 ± 0,081	0,867 ± 0,061
RGBC	0,847 ± 0,070	0,848 ± 0,066

Fonte: Produção do autor.

Por outro lado, analisando-se os histogramas dos dois modelos (3.14), é possível observar que o modelo RGB apresentou valor máximo de IoU inferior ao do RGBC (0,969 e 0,997) e inferiu maior quantidade de copas que, apesar de conterem intersecção com a respectiva referência, apresentavam IoU inferior ao mínimo necessário para ser considerado um TP ($0 < \text{IoU} < 0,5$). Além disso, o modelo RGB resultou um total de 96,72% (2037) das copas com IoU maior que 0,7, enquanto o modelo RGBC atingiu 97,58 % (2060), indicando que, apesar de ambos os modelos apresentarem alta fidelidade em relação à verdade de campo, o RGBC teve desempenho ligeiramente superior na delimitação dos traçados mais concordantes com a referência (IoU > 0,7).

Figura 3.14 - Histograma dos valores de IoU para os dois modelos (RGB e RGBC).




Fonte: Produção do autor.

Para determinar a relação da área e do perímetro de cada máscara resultante com a respectiva referência, foi realizada uma análise de regressão linear e os resultados são expostos nas Figuras 3.15 e 3.16. De acordo com a 3.15, é

possível perceber que ambos os modelos atingiram resultados com expressiva correlação entre as áreas dos pares correspondentes (predita e referência), tendo o modelo RGB resultados ligeiramente melhores que o RGBC. O coeficiente de determinação (R^2) do modelo RGB foi de 0,973, enquanto o do RGBC foi de 0,967. Além disso, as métricas relacionadas aos resíduos do modelo RGB também foram levemente melhores, com $RMSE = 0,439 \text{ m}^2$, $MAE = 0,320 \text{ m}^2$ e $MAPE = 6,90 \%$ enquanto o RGBC obteve $RMSE = 0,492 \text{ m}^2$, $MAE = 0,357 \text{ m}^2$ e $MAPE = 7,98 \%$.


Figura 3.15 - Resultados da regressão linear para a área das copas.



Fonte: Produção do autor.

Em relação ao perímetro (3.16), a correlação entre os pares de máscara correspondentes também foram elevadas, com $R^2 = 0,972$ para o modelo RGB e $R^2 = 0,969$ para o modelo RGBC. A pequena diferença entre as métricas também se deu em relação aos resíduos, com os resultados do modelo RGB ligeiramente melhores. Foram obtidos $RMSE = 0,353 \text{ m}$, $MAE = 0,261 \text{ m}$ e $MAPE = 3,46\%$ para o modelo RGB e $RMSE = 0,382 \text{ m}$, $MAE = 0,291 \text{ m}$ e $MAPE = 3,85\%$ para o modelo RGBC.

Figura 3.16 - Resultados da regressão linear para o diâmetro das copas.



Fonte: Produção do autor.

3.3 Discussão

3.3.1 Detecção das copas de laranjeiras

O uso da *Mask R-CNN* para detecção e delimitação de alvos por imagens de sensoriamento remoto é um assunto em crescente discussão nos últimos anos, seja para detecção em ambiente construído (WU et al., 2021), em ambiente natural (CHADWICK et al., 2020; ULLO et al., 2021), ou para ambiente agrícola (MACHEFER et al., 2020; YU et al., 2022). Ainda que o terreno agrícola apresente características mais uniformes que o natural, a avaliação desse estudo abordou um ambiente agrícola complexo, com laranjeiras de diferentes idades e variedades de plantio, espaçamento e cobertura entre as linhas de plantio e, sobretudo, com diferentes densidades de plantio, um dos principais limitadores na detecção precisa de copas de árvores (AMPATZIDIS; PARTEL, 2019; OSCO et al., 2020).

Neste estudo foi proposta uma abordagem de uso combinado de imagens RGB com o CHM para incremento de performance da atividade de detecção e delineamento de copas e foram obtidos resultados com alta acurácia. Para as mesmas condições, o uso do CHM aumentou significativamente a acurácia de detecção em comparação com o uso apenas das bandas RGB (acurácia global de 90,4% para 97,0% e f1-score de 95,0% para 98,5%).

Outros estudos também avaliaram o uso do CHM na detecção de alvos com modelos de deep learning. Yu et al. (2022) avaliaram a melhor combinação de bandas para detecção de copas de pinheiro chinês com uso da Mask R-CNN treinada com verdade de campo manualmente delimitada. Os autores avaliaram 9 combinações de bandas e concluíram que o melhor desempenho é obtido com a combinação RGB com $F1 = 94,7\%$, entretanto, não foi avaliada a combinação RGB + CHM, sendo o CHM avaliado individualmente. Pleşoiianu et al. (2020) avaliaram o uso de 150 combinações de atributos provenientes das imagens RGB e do MDE para identificação de copas de árvores em ambientes variados. A combinação de melhor resultado incluía dados obtidos pelas bandas RGB (*grayscale*) e MDE (*slope, hillshade, CHM*), com F1-score de 92,5%. Comparando os resultados obtidos nesta pesquisa com os estudos anteriores abordando o uso de imagens RGB e dados baseados em MDE, destaca-se o desempenho do modelo RGBC proposto para detecção de copas de árvores em terrenos agrícolas de características heterogêneas.

Em relação à detecção de copas utilizando materiais e método ligeiramente diferentes dos adotados nesta pesquisa, alguns estudos representam o estado da arte quanto a detecção/contagem de plantas de diferentes espécies em talhões agrícolas e apresentam resultados similares aos obtidos. A 3.6 mostra uma síntese das características e os resultados dessas pesquisas, contemplando o método de detecção utilizado, as características espectrais demandadas (bandas), a espécie de árvore, o tipo de saída do resultado, se os resultados são limitados por *patches* ou distribuídos em toda a imagem e as métricas de avaliação de detecção/contagem.

Tabela 3.6 - Características e resultados das pesquisas de detecção de árvores similares a este estudo.

Estudo	Algoritmo	Bandas usadas	Espécie vegetal	Tipo do resultado	Abrangência do resultado	Precisão	Recall	F1
Yu et al. (2022)	MCWS	CHM	Pinheiro	Máscara	Imagem	0,770	0,972	0,859
Oscó et al. (2021)	CNN	RGB	Milho	Ponto	<i>Patch</i>	0,856	0,905	0,876
Yu et al. (2022)	Máximo local	CHM	Pinheiro	Ponto	Imagem	0,793	0,985	0,879
Oscó et al. (2021)	CNN	RGB	Laranja	Ponto	<i>Patch</i>	0,922	0,905	0,911
Yu et al. (2022)	<i>Mask R-CNN</i>	RGB	Pinheiro	Máscara	<i>Patch</i>	0,957	0,937	0,947
Este estudo (Abordagem existente)	<i>Mask R-CNN</i>	RGB	Laranja	Máscara	Imagem	0,917	0,985	0,950
Oscó et al. (2020)	CNN	Multiespectral	Laranja	Ponto	<i>Patch</i>	0,950	0,960	0,950
Ampatzidis e Partel (2019)	CNN (antes do pós-processamento)	Multiespectral	Laranja	<i>Bbox</i>	Imagem	0,987	0,981	0,984
Este estudo (Abordagem proposta)	<i>Mask R-CNN</i>	RGB + CHM	Laranja	Máscara	Imagem	0,974	0,996	0,985
Dong et al. (2020)	Máximo local + MCWS	RGB + CHM	Maçã	Máscara	Imagem	0,997	0,983	0,990
			Pear	Máscara	Imagem	0,995	0,990	0,993

Fonte: Produção do autor.

Dos estudos listados na 3.6, alguns deles abordam um modelo baseado em CNN para detecção de copas de laranjeiras e obtém resultados de F1-score acima de 90%, no entanto, os autores discutem a influência da densidade de plantio nos resultados obtidos. Em Ampatzidis e Partel (2019), os autores explicitam a necessidade de um espaçamento bem definido entre as copas vizinhas, por isso, as características dos talhões estudados são diferentes desse estudo e apresentam limitações quanto a sua aplicação.

Por outro lado, Osco et al. (2021) utilizam imagens de talhões com características de densidade de plantas similares às do talhão 3 adotado no presente estudo, e, com método de detecção por localização pontual das copas, atingiu resultado de F1-score de 91,1%. Os resultados obtidos sugerem, portanto, que a informação de altitude das copas, que pode ser adquirida através das imagens RGB e técnicas de SfM, tem potencial para auxiliar no processo de identificação de copas espacialmente adensadas.

Assim, quatro características do presente estudo se destacam frente aos estudos anteriores com resultados similares: (1) a técnica proposta é baseada em sistemas de sensoriamento remoto VANT de baixo custo, uma vez que utiliza apenas imagens RGB e CHM que são derivadas de sensores menos onerosos quando comparados aos sensores multiespectrais, (2) os talhões estudados apresentam significativa variabilidade nas características espaciais e espectrais, sendo viável a identificação inclusive de árvores adensadas devido à informação de altitude e estrutura das copas fornecida pelo CHM, (3) o resultado obtido abrange toda a área da imagem estudada, sem a necessidade de análise fracionada ou de pós-processamento manual e (4) o resultado da identificação não se dá apenas com a localização pontual ou com o retângulo envolvente, e sim, com a máscara delimitadora dos limites das copas, subsidiando análises com outras abordagens além da contagem de plantas.

Como pode ser observado, as vantagens citadas no parágrafo anterior não se aplicam ao estudo de Dong et al. (2020), que apresenta resultados ligeiramente superiores aos obtidos neste estudo. Entretanto, a metodologia aplicada pelos autores demanda uma seleção de limiares de detecção exclusivos para cada

análise, e, adotando-se talhões com características espaciais e espectrais distintas (como as utilizadas neste trabalho), faz-se necessário o conhecimento prévio do analista ou uma abordagem de tentativa e erro para definição dos parâmetros de cada um deles. Essa condição diminui a viabilidade da análise e dificulta o desenvolvimento de *frameworks* automatizados de detecção. Por outro lado, o uso da *Mask R-CNN* previamente treinada, demonstrou potencial para detecção em talhões heterogêneos com resultados muito próximos.

3.3.2 Delineamento das copas de laranjeiras

O delineamento de copas de árvores proposto nesse estudo apresenta algum grau de dependência com a correta detecção individual delas, pois problemas como *over-segmentation* e *under-segmentation* já são fatores de inconsistência do delineamento individual. O modelo RGBC apresentou melhor performance ao identificar corretamente maior quantidade de copas individuais, entretanto, os resultados das métricas de delineamento e da correlação da área e do perímetro entre as copas inferidas e de referência mostraram que, no geral, a delimitação realizada pelo modelo RGBC foi inferior à do RGB. A diferença entre os traçados se deu quase de maneira unânime pela redução e suavização dos limites das copas e alguns pontos podem ser elencados para justificativa desse resultado.

Inicialmente, durante o processo de geração da nuvem de pontos que origina o MDE por meio da técnica de SfM-MVS, a complexidade da estrutura da vegetação é naturalmente um desafio (CARRIVICK; SMITH; QUINCEY, 2016), uma vez que o traçado irregular da borda das copas provoca uma suavização no CHM, reduzindo sua abrangência em relação a área plana ocupada pela planta (JAYATHUNGA; OWARI; TSUYUKI, 2018). Em segundo lugar, é importante notar que todas as imagens foram adquiridas sem a utilização de pontos de controle, o que influencia diretamente na qualidade geométrica das imagens do VANT para geração do MDE e conseqüentemente do CHM e do ortomosaico.

Em terceiro lugar, as imagens foram adquiridas a partir de um plano de voo que contemplou unicamente a visada a nadir e a sobreposição longitudinal e lateral das imagens. É possível que o processo de reconstituição do CHM seja mais preciso caso seja adotado um plano de voo com diferentes visadas e linhas de imageamento cruzadas, aumentando a sobreposição entre as cenas.

De todo modo, ainda que seja possível a melhoria do processo de geração do CHM, o modelo RGBC apresentou resultados promissores no delineamento das copas e pode ser equiparado aos resultados de estudos anteriores. Dong et al. (2020), a partir de técnicas de local máximo e MCWS usadas para segmentar copas de árvores em regiões agrícolas, obtiveram os melhores resultados para o plantio de maçã com $R^2 = 0,87$, RMSE = 0,72 e MAE = 0,57 para a correlação entre a área das copas estimadas e de referência e $R^2 = 0,81$, RMSE = 0,48, MAE = 0,39 para o perímetro.

Braga et al. (2020), para detecção de copas adensadas em ambiente de floresta com uso da Mask R-CNN, obtiveram $R^2 = 0,93$ na análise de correlação das áreas das copas inferidas com as de referência. Wu et al. (2020) usaram um modelo baseado em CNN para delimitação individual de árvores em plantio de maçã. Os resultados do coeficiente de correlação entre a área e perímetro dos resultados obtidos com a referência foram $R^2 = 0,80$ e $R^2 = 0,79$ para área e perímetro, respectivamente.

Frente a esses estudos, os resultados obtidos com o método proposto se mostram extremamente viáveis para aumento da viabilidade e da precisão da delimitação de copas de árvores no ambiente agrícola, o que facilita a aplicação de estudos envolvendo as características fenológicas de cada planta do talhão. É necessário, entretanto, que sejam realizados novas análises com uso de dados de campo, como levantamento da área e do perímetro das copas.

3.3.3 Mosaicagem dos resultados de detecção e delineamento das copas limitados pelos *patches*

Para a detecção e delimitação de copas de árvores foi utilizada uma CNN (Mask R-CNN) que recebe como entrada *patches* de imagens com áreas significativamente menores (limite de 256x256 ou 512x512 pixels) do que um talhão completo. Essa abordagem é comum em estudos que envolvem detecção de objetos ou segmentação de instância em imagens de sensoriamento (AMPATZIDIS; PARTEL, 2019; DONG et al., 2020; MACHEFER et al., 2020; OSCO et al., 2020, 2021; YU et al., 2022), pois são representações que apresentam dimensões variáveis e geralmente superiores às imagens convencionais.

Entretanto, diferentemente das pesquisas mencionadas, no presente estudo foi proposto um algoritmo de mosaicagem automatizada dos resultados que apresentou significativa performance e que dispensa a necessidade de pós-processamento manual dos resultados obtidos em cada fração de imagem.

São poucos os estudos que abordam algum processamento similar para aplicação em segmentação de instância. Braga et al. (2020) propôs uma abordagem similar para detecção de copas em florestas adensadas por meio da união de quaisquer duas árvores presentes nos limites dos *patches* que apresentam intersecção – do tipo polígono – entre si.

De Carvalho et al. (2021) propuseram um método de mosaicagem por janela móvel aplicada na região análoga a de sobreposição dos *patches* desse estudo. A partir de uma modificação do algoritmo *Non-Maximal Supression*, os autores realizam a exclusão dos objetos redundantes com uma metodologia similar a condição 2.3 do algoritmo proposto, mas considerando apenas os *bounding box* das máscaras.

As técnicas mencionadas, contudo, não apresentam robustez suficiente para contemplar a possibilidade de intersecção real em duas copas vizinhas e, sobretudo, a filtragem de falsos positivos de grandes proporções que se sobrepõem a mais de uma copa real (filtrados pela condição 2.2 da abordagem proposta), o que aumentaria os erros de omissão e comissão, respectivamente, caso fossem aplicadas para a mesma finalidade deste estudo.

Diante disso, o método proposto tem um grande potencial para permitir a análise focada em detecção e delimitação de copas em talhões com alta densidade de plantio – nos quais a sobreposição entre copas é natural – a partir de imagens de grandes áreas aplicadas à arquitetura *Mask R-CNN*.

3.4 Conclusão

Nesse estudo, nós avaliamos o uso de imagens captadas por VANTs para identificação e delineamento de copas de árvores das laranjeiras situadas em diferentes densidades espaciais com uso de *deep learning*. A arquitetura do modelo adotado, a *Mask R-CNN*, corresponde ao estado da arte no processo de segmentação de instância e as imagens utilizadas contemplam exclusivamente os sensores de câmeras digitais RGB.

Além disso, foi adotada uma metodologia de elaboração da verdade de campo que aumentou a viabilidade da análise realizada e foi desenvolvido um algoritmo não supervisionado que contribui com automatização da segmentação de instância em imagens de sensoriamento remoto.

Diante disso, as principais contribuições da abordagem proposta corresponde a (1) diminuição do esforço demandado pelo processo de elaboração da verdade de campo e das amostras de treinamento; (2) obtenção de um modelo capaz de identificar e delimitar copas de árvores adensadas em imagens de diferentes características com resultados acurados (Detecção: acurácia global e F1-score de 97,01% e 98,48%, respectivamente; e Delineamento: IoU > 0,5 médio de 0,848 e F1-score médio de 91,6%); e (3) desenvolvimento da metodologia que encapsula todos os procedimentos adotados, diminuindo a necessidade de operação manual.

A análise realizada não contemplou todas as possibilidades envolvendo a melhoria do processo de segmentação de instância com uso de dados baseados em SfM e futuros trabalhos devem ser realizados no sentido de explorar outras culturas agrícolas e florestais nas quais as copas também

apresentem alta densidade espacial, além de diferentes características de imageamento.

4 ANÁLISE ESPACIAL BASEADA EM PADRÕES LINEARES PARA DETECÇÃO NÃO SUPERVISIONADA DE LINHAS E FALHAS DE PLANTIO APLICADA EM CULTURAS DE LARANJA

4.1 Introdução

O plantio de laranja vem sendo amplamente beneficiado pelos recentes estudos envolvendo o levantamento de dados de plantio com foco no auxílio do manejo agrícola. Dentre os diversos métodos e processamentos adotados, a identificação de plantas e falhas de plantio é uma atividade que auxilia significativamente no processo de monitoramento da lavoura e subsidia a tomada de decisões dos produtores. Particularmente, a identificação de linhas de plantio beneficia diretamente as atividades de obtenção de densidade de plantio, estimativa de produção, definição de trajeto dos veículos agrícolas autônomos e manutenção de tarefas realizadas em locais específicos do talhão (CUE LA ROSA et al., 2020).

Além disso, a reconstituição de linhas plantadas possibilita a identificação de falhas de plantio, auxilia no processo de identificação de ervas daninhas e plantas fora do alinhamento previsto, subsidia a extração de métricas de plantio – espaçamento, distanciamento entre plantas, entre outros – e possibilita definição de um sistema de rotulagem das árvores para trabalhos de campo (i.e. sistema de coordenadas definido pela linha de plantio e a sequência da árvore na linha).

Diversos estudos investigaram a capacidade de obtenção de linhas de plantio, e seus dados derivados, a partir de imagens de sensoriamento remoto e diferenciados processos metodológicos. Os métodos tradicionais de processamento de imagens mais utilizados para esse fim são operações morfológicas (OLIVEIRA et al., 2018) e Transformada de Hough (HT, do inglês *Hough Transform*) (SOARES; ABDALA; ESCARPINATI, 2018) e segmentação com uso de clusterização (RAMESH K N et al., 2016).

Além dos métodos tradicionais, técnicas de *machine learning* e *deep learning* também são amplamente utilizadas e, segundo a literatura, atingem resultados mais acurados que as técnicas tradicionais devido à capacidade de trabalhar com situações complexas, como linhas de plantio com traçados irregulares e com a presença de falhas (GONÇALVES et al., 2021).

Osco et al. (2021) propuseram um método de identificação simultânea de plantas e linhas de plantio e talhões comerciais de laranja e milho com uso de uma Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*). Os autores basearam-se na ocorrência de padrões como textura, cor e formato para identificação de copas e distanciamento entre as árvores para reconstituição das linhas de plantio. Contudo, a metodologia considera uma relação simplificada de proximidade entre os alvos e apresenta limitações em quando da presença de falhas de plantio e padrões de linhas distintas daquelas usadas no treinamento do modelo.

Frente a esse desafio, Cue la rosa et al. (2020) desenvolveram um método de correção da segmentação de imagens em linhas de plantio com uso de pós-processamento também baseado em rede neural em associação com padrões geométricos das linhas. Os resultados exibidos porém, explicitam a limitação da metodologia quando ocorrem falhas consecutivas, sobretudo em regiões de curvatura abrupta das linhas de plantio. Além disso, os autores não consideraram talhões onde a presença de alvos fora do alinhamento dificulta a reconstituição devido a descaracterização da linearidade do plantio.

Para solução deste problema, Gonçalves et al. (2021) propuseram uma arquitetura de CNN baseada em grafos aplicada em imagens de VANT. Os autores atingiram resultados satisfatórios de identificação de linhas com diferentes padrões espaciais, como direções variadas, curvaturas e presença de falhas de plantio. Contudo, uma limitação da aplicação de redes neurais em imagens de sensoriamento remoto é a necessidade de particionamento da imagem em recortes pequenos, o que demanda pós-processamento manual para identificação de toda a extensão das linhas de plantio.

Diante deste cenário, ainda há uma lacuna no processo de reconstituição automatizada de linhas de plantio a partir de imagens de sensoriamento. Paralelamente, são encontrados na literatura diversos estudos que visam a correta identificação da localização individual das plantas em talhões comerciais com objetivos discutidos no Capítulo 3. Sendo assim, o objetivo deste trabalho é propor um método não supervisionado de detecção de linhas de plantio, e conseqüentemente falhas, baseado nos dados de posicionamento de árvores em talhões agrícolas.

A metodologia, exposta a seguir, baseia-se no padrão espacial adotado no plantio comercial de laranjas, cuja distribuição se dá em linhas espaçadas homogêneas. Além disso, o foco do algoritmo sugerido é desempenhar a atividade proposta em talhões com distintos padrões espaciais, com variadas taxas de falha de plantio e com presença de alvos fora do alinhamento planejado.

4.2 Metodologia

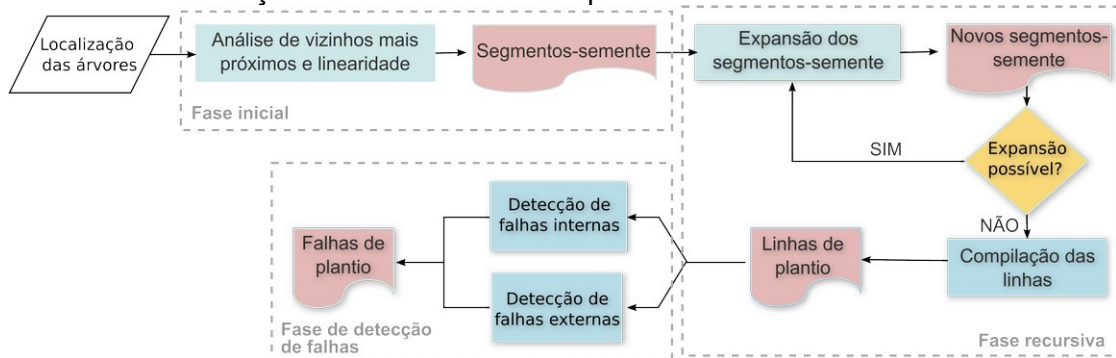
O processamento adotado neste trabalho tem como entrada a localização pontual de cada árvore presente em talhões agrícolas e gera dois produtos principais: o agrupamento das árvores em linhas de plantio (ou identificação de linhas de plantio) e a identificação e localização das falhas presentes no talhão.

A análise é baseada nos padrões geométricos que definem a configuração espacial de plantações comerciais, como linearidade entre plantas, homogeneidade de espaçamento entre árvores da mesma linha, maior proximidade entre duas árvores pertencentes à mesma linha do que duas árvores de linhas distintas, inexistência de cruzamentos entre linhas, inexistência de curvas abruptas no alinhamento das árvores, entre outros.

O conjunto de processos desenvolvido, sumarizado na 4.1, possui três módulos, sendo (I) fase inicial, responsável pela identificação e agrupamento dos pontos (árvores) nas parcelas mais lineares de cada linha, (II) fase

recursiva, no qual acontece a finalização do agrupamento dos pontos em linhas e (III) fase de detecção de falhas, onde ocorre a identificação das falhas.

Figura 4.1 - Fluxograma de processos adotados na metodologia proposta para detecção de linhas e falhas de plantio.



A cor azul representa os processos e em cor-de-rosa estão os subprodutos e produtos gerados.

Fonte: Produção do autor.

4.2.1 Fase inicial

O primeiro módulo da metodologia é voltado para a identificação inicial das linhas por meio de análise de vizinhos mais próximos e da avaliação de linearidade entre os pontos. Inicialmente, são computados os dois vizinhos mais próximos de cada ponto do conjunto de dados, que em seguida serão submetidos à análise de linearidade. A disposição do conjunto formado por cada ponto e seus dois vizinhos mais próximos formam uma angulação α dada por:

$$\alpha_{i,m} = \angle C_{viz1} C_{i,m} C_{viz2} \quad (4.1)$$

Sendo C usado para representar a unidade de árvore, i a linha de plantio a qual pertence a árvore, m o seu número na linha de plantio e viz1 e viz2 a primeira e segunda árvore mais próxima daquela está sendo avaliada ($C_{i,m}$), respectivamente.

Considerando-se uma linha de plantio hipotética perfeitamente retilínea, o ângulo formado por quaisquer três árvores vizinhas é de 180 graus, entretanto, em se tratando de uma linha de plantio real formada por plantas identificadas a

partir da imagem, a linearidade do plantio sofre influência direta (I) da própria sementeira, (II) da direção preferencial de crescimento da copa e, sobretudo, (III) da qualidade do processo de identificação. Por este motivo, os pontos com a localização de cada árvore tendem a apresentar pequenos desvios individuais em relação à reta ou curva que une os dois extremos da linha de plantio. Sendo assim, a condição inicial do processo de agrupamento dos pontos (árvores) em linhas de plantio é dada pela equação:

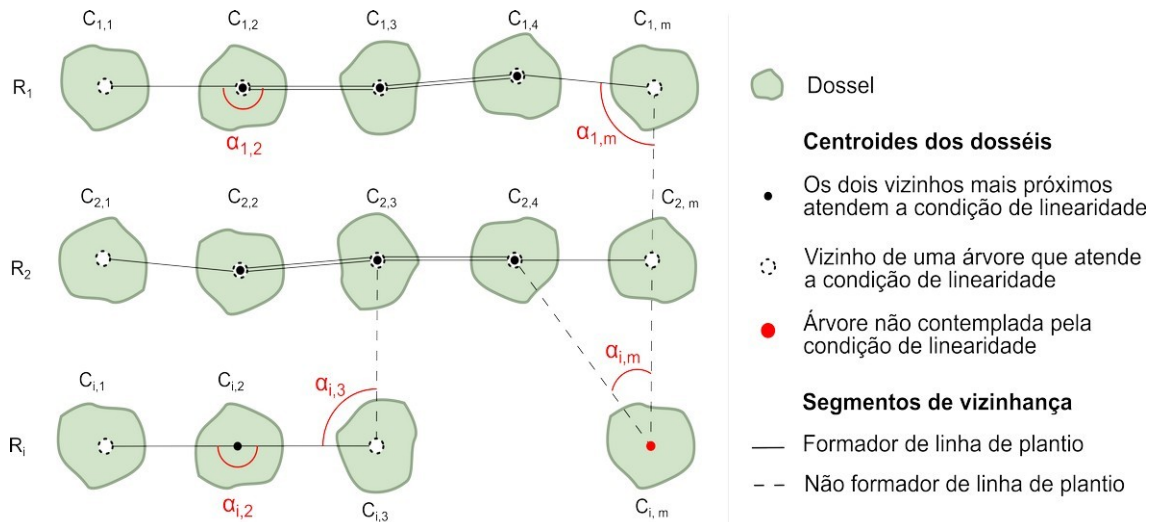
$$|\alpha_{i,m} - 180^\circ| \leq r \quad (4.2)$$

Sendo r o limiar de aceitação em graus do ângulo entre um ponto e seus dois vizinhos para que os três sejam considerados de uma mesma linha. A análise de linearidade avalia, portanto, se as 3 árvores de cada conjunto pertencem a mesma linha e, caso positivo, as agrupam em trios que apresentam pontos em comum. A redundância de pontos nos trios acontece pela avaliação individual de cada ponto e seus vizinhos ainda que ele já tenha sido usado como vizinho de outro ponto. A partir da redundância de pontos entre os trios é possível agrupá-los em grupos maiores representados pelo conjunto de triplas que apresentam um elo entre seus pontos em comum.

De forma visual, a análise da linearidade e agrupamento dos pontos podem ser notados observando-se uma linha de plantio e traçando-se dois segmentos de reta (grafos) que ligam respectivamente cada ponto a seus 2 vizinhos quando o trio atende à condição de linearidade. Em seguida, é possível visualizar o traçado formado por grafos sobrepostos que representam a redundância entre os trios.

Isto ocorre devido ao fato de que um ponto avaliado que obedece à condição certamente é vizinho do próximo ponto a ser avaliado que também obedecerá, com exceção dos pontos nos extremos da linha, dos pontos próximos a falhas de plantio e dos pontos com desvio espacial atípico em relação a linha de plantio. A 4.2 mostra um esquema que explicita a formação inicial da linha a partir dos grafos sobrepostos que representam os agrupamentos iniciais formados, chamados de segmentos-semente.

Figura 4.2 - Esquema ilustrativo do processo de geração dos segmentos-semente.



Na Figura, o traçado duplo foi utilizado para auxílio na visualização e corresponde à sobreposição dos grafos causada pela redundância de pontos nos trios.

Fonte: Produção do autor.

O limiar de aceitação do ângulo formado por três árvores vizinhas e pertencentes à mesma linha de plantio é definido não apenas para contemplar a variação posicional de cada árvore comentada anteriormente, mas para operar em talhões que apresentam plantio em nível, nos quais as linhas de plantio apresentam traçados curvilíneos. Nesses casos, ainda que as linhas apresentem curvas de pequeno raio, a angulação formada por três plantas vizinhas não necessariamente inviabiliza a aplicação da condição, ou seja, a curva na linha de plantio é formada pelo acúmulo de pequenas angulações em árvores consecutivas que, dentro de um limiar r , podem obedecer a esta condição. A partir de análises prévias, o valor de r foi definido em 15 graus.

A avaliação da linearidade entre plantas vizinhas é responsável pela identificação quase completa das linhas que compõem o talhão, porém, as linhas não são definidas completamente neste primeiro passo nos casos de plantações que apresentam falhas de plantio ou que o deslocamento espacial atípico de algumas plantas inviabiliza a adequação à condição de linearidade. Sendo assim, dá-se início ao segundo passo que corresponde a um processo recursivo de expansão das linhas.

4.2.2 Fase recursiva

Depois de iniciado o processo de identificação das linhas no primeiro passo, ainda que elas não tenham sido completamente traçadas devido à presença de falhas ou de desvios atípicos, foram definidos segmentos-semente de cada uma. A segunda etapa é responsável, portanto, pela expansão dos segmentos iniciais ocasionando a união de dois ou mais que pertencem a mesma linha de plantio bem como a agregação dos pontos que foram negligenciados no primeiro agrupamento.

Para isso, a segunda etapa se baseia na condição geométrica das linhas de plantio que apresenta características particulares como permanência da linearidade entre as árvores mesmo com a existência de falhas de plantio; inexistência de bifurcações ou confluências nos traçados das linhas e impossibilidade de cruzamento entre linhas de plantio. Sendo assim, esta etapa é representada pela exploração espacial, a partir dos extremos de cada segmento-semente, em busca de pontos candidatos a pertencerem à mesma linha.

A busca acontece segundo duas regras que contemplam as condições mencionadas acima: (I) a árvore candidata a pertencer à mesma linha de plantio do segmento que está se expandindo deve obrigatoriamente ser um extremo de outro segmento ou está isolada até então e (II) a árvore candidata deve estar no interior da área de busca (4.3) que é definida para cada um dos extremos a serem expandidos. A área de busca é delimitada pela região a frente dos extremos de cada segmento inicial na qual uma árvore ali posicionada apresenta linearidade aceitável em relação à última e à penúltima árvore do extremo a se expandir.

Sendo assim, a área de busca é definida por uma função que relaciona a razão entre a distância da árvore candidata até a extremidade do segmento e a distância (d) entre as duas últimas árvores do segmento, com o intervalo da angulação permitida entre essas três árvores para que sejam consideradas da mesma linha. Sendo assim, sejam C_{extr} a árvore do extremo do segmento, C_{penult}

a penúltima árvore do segmento e C_{alvo} uma árvore candidata a pertencer a mesma linha de plantio, tem-se que:

$$\alpha_{extr} = \angle C_{penult} C_{extr} C_{alvo} \quad (4.3)$$

$$\overline{C_{penult} C_{extr}} = d ; \overline{C_{extr} C_{alvo}} = p \quad (4.4)$$

$$x = \frac{p}{d} \quad (4.5)$$

$$\alpha_{min} = f(x) = 180 - \frac{1}{a * x^b}, \quad (0 < b < 1) \quad (4.6)$$

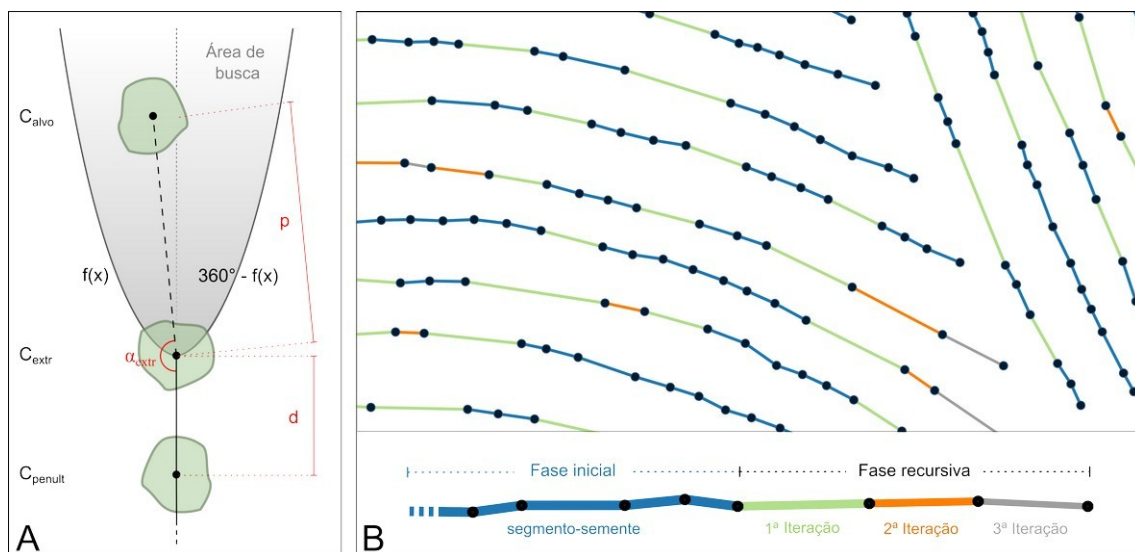
$$\alpha_{max} = 360 - \alpha_{min} \quad (4.7)$$

Desta forma, a medida em que a distância da árvore candidata até o extremo buscador aumenta, a amplitude da angulação permitida para α_{extr} é reduzido e se aproxima de 180 graus, formando uma área de busca em formato de sino a partir dos extremos de cada linha inicial. Portanto, dados d e p, caso $\alpha_{max} > \alpha_{extr} > \alpha_{min}$, a árvore candidata pertence à mesma linha de plantio.

Assim, todos os segmentos-semente são usados para esta expansão e cada um dos seus dois extremos são considerados. Uma vez que seja encontrado um ponto que atenda às condições citadas, este é incorporado ao segmento/agrupamento, expandindo-o, e novas buscas são realizadas de modo iterativo. O processo iterativo é realizado até que todos os pontos sejam contemplados ou até quando não seja mais possível expandir os segmentos formados devido às restrições definidas.

A 4.3 mostra o esquema ilustrativo que representa os limites da área de busca e um exemplo do processo iterativo de expansão dos segmentos-semente em uma porção de talhão simulado com alta taxa de falhas.

Figura 4.3 - Ilustração da área de busca e exemplos dos resultados parciais do processo iterativo.



(A) Croqui de representação da área de busca definida pela função $f(x)$ e (B) Resultados gerados na fase inicial e em cada iteração da fase recursiva numa área de talhão com falhas e com diferentes direções de linha de plantio.

Fonte: Produção do autor.

A área de busca pode abranger mais de um ponto candidato e os critérios utilizados para selecionar apenas um seguem uma ordem de prioridade que corresponde respectivamente ao menor valor da razão p/d e ao menor ângulo α_{extr} . Além disso, os pontos candidatos que geram cruzamento entre linhas de plantio são desconsiderados.

Ao final desta etapa o conjunto de segmentos formado indica o traçado das linhas de plantio e os seus respectivos pontos. A partir deste resultado, os pontos são mapeados e usados como insumos para a próxima etapa que corresponde a identificação de falhas que ocorrem em cada linha identificada.

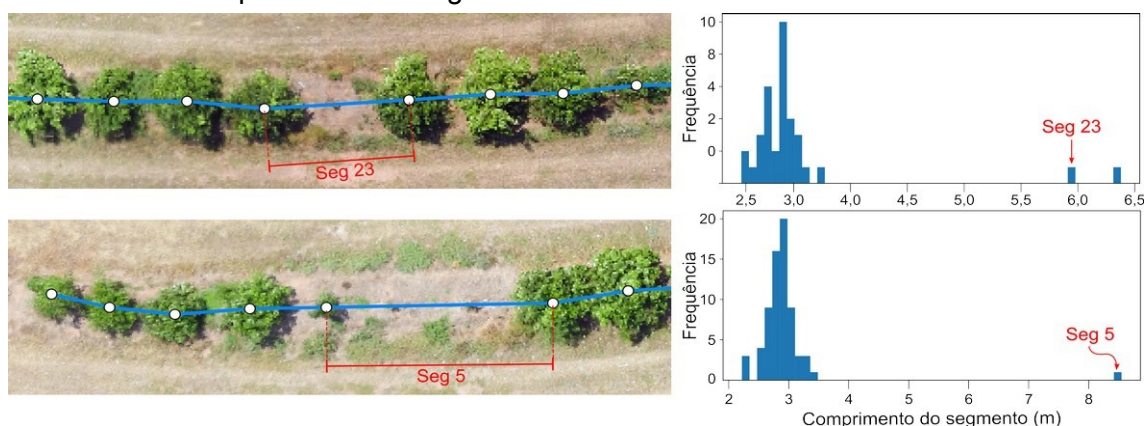
4.2.3 Fase de detecção de falhas de plantio

As linhas geradas ao final da etapa anterior são formadas pelo conjunto de vértices que correspondem ao centroide de cada árvore que a compõe, ou seja, o comprimento de cada segmento unitário formado por duas árvores consecutivas corresponde ao distanciamento entre elas. Isto é particularmente

interessante uma vez que a distribuição de frequência dos comprimentos dos segmentos unitários que compõem cada linha apresenta um comportamento gaussiano, já que o espaçamento entre plantas adotado em talhões comerciais é homogêneo para a linha de plantio.

Nas situações em que há falhas ao longo da linha identificada, a distribuição de frequência apresenta *outliers*, que representam os segmentos unitários localizados nas regiões onde existe pelo menos uma falha de plantio. A 4.4 exibe dois exemplos de linhas de plantio com falhas e o histograma de comprimentos dos seus respectivos segmentos unitários. O levantamento das falhas acontece de maneira individualizada para cada uma das linhas a partir da identificação dos espaçamentos extremos de cada uma delas.

Figura 4.4 - Linhas de plantio com falhas e seus respectivos histogramas de comprimento dos segmentos unitários.



À esquerda, a representação visual do espaçamento e à direita, o histograma de frequência dos comprimentos dos segmentos unitários de cada linha.

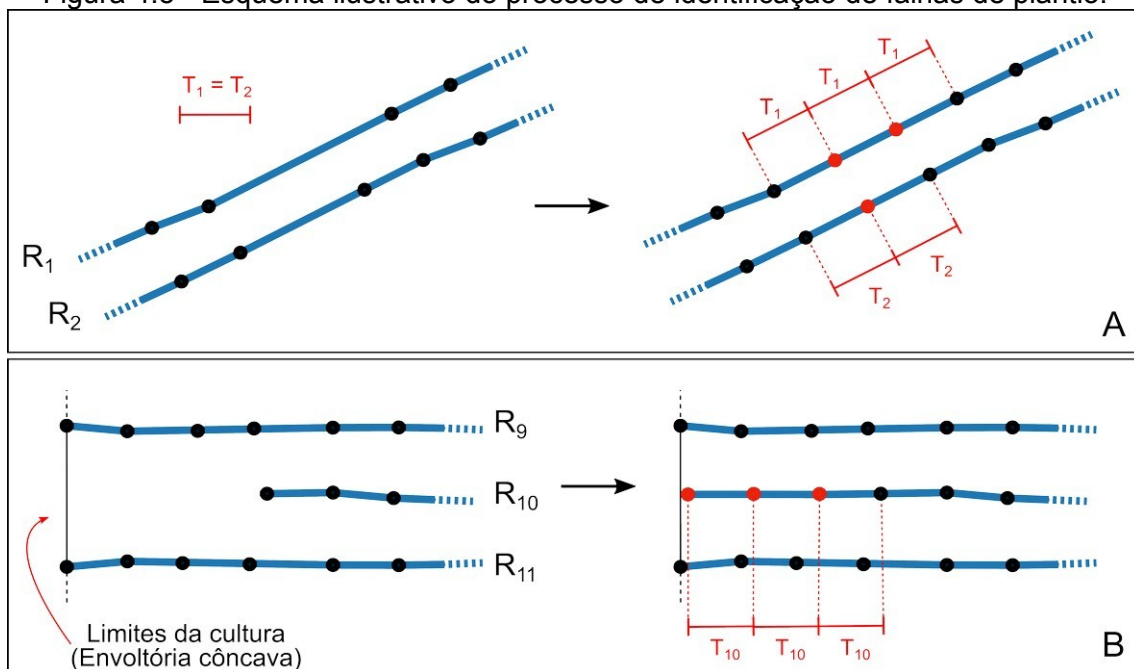
Fonte: Produção do autor.

Para identificação dos *outliers*, inicialmente é definido o valor padrão para o espaçamento entre plantas de cada linha, que de maneira empírica, a partir das análises realizadas, foi definido como o valor do 3° quantil ou tercil (T). A partir da definição do espaçamento padrão entre linhas é definido o limiar que seleciona os espaçamentos extremos. Assim, o segmento unitário (seg) é considerado extremo, e sobre o qual incide uma ou mais falhas, se:

$$\dim(\text{seg}_{t,i}) \geq 1,5 * T_i \quad (4.8)$$

Sendo $\text{seg}_{t,i}$ o t -ésimo segmento da linha i . Uma vez selecionados os segmentos extremos, os seus respectivos comprimentos são divididos pelo espaçamento padrão da linha (T) para definição das posições de cada falha de plantio ao longo de sua extensão. Desta forma, acontece um particionamento de cada segmento extremo nos locais correspondentes às falhas, gerando novos pontos distanciados pelo espaçamento padrão da linha (4.5). Em seguida, os novos pontos referentes às falhas são inseridos no conjunto de pontos de entrada com a devida identificação da sua linha e mapeados como falhas.

Figura 4.5 - Esquema ilustrativo do processo de identificação de falhas de plantio.



(A) Falhas internas; (B) falhas externas; Os pontos pretos representam as posições das árvores contidas no conjunto de dados de entrada e os vermelhos, às falhas identificadas pela metodologia proposta.

Fonte: Produção do autor.

Desta forma, são encontradas as falhas de plantio que se localizam entre duas plantas já identificadas previamente – falhas internas, mas não é possível inferir as falhas que acontecem nos extremos das linhas – falhas externas. Por este motivo, após a primeira identificação das falhas, é realizada uma nova

análise para determinação dessas possíveis falhas remanescentes. A análise é realizada a partir do cômputo da envoltória côncava dos pontos (MOREIRA; SANTOS, 2007), que representa um método não supervisionado de definição dos limites do talhão estudado.

Em seguida, a distância entre os extremos de cada linha até o limite do talhão (envoltória côncava) é avaliada e caso ela seja maior que T , são inseridos novos pontos, distanciados pelo espaçamento padrão, na mesma direção do extremo da linha até que a distância calculada seja menor que T . Esse processo é realizado seguindo a restrição do cruzamento entre linhas. Do mesmo modo do passo anterior, os novos pontos são inseridos no conjunto de pontos com a identificação da linha e mapeados como falha de plantio.

4.3 Estudo de caso

4.3.1 Implementação do estudo de caso

Um estudo de caso foi elaborado para validação da metodologia desenvolvida. A implementação dos processos foi realizada na linguagem de programação Python e foi naturalmente focada em desempenho, contudo, não esgotou todas as possibilidades de melhoria. O computador utilizado para implementação e avaliação do estudo de caso apresenta memória RAM de 16gb, processador Intel core i7 e placa gráfica Nvidia Geforce GTX 1050.

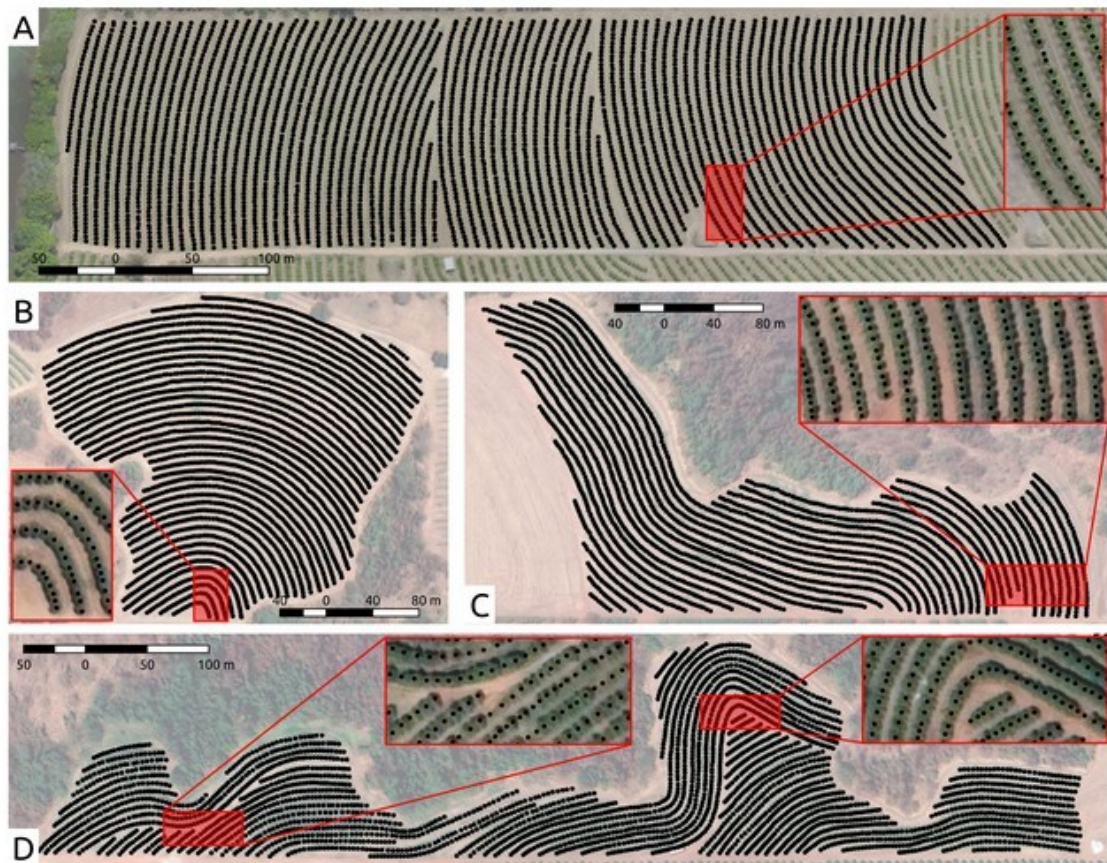
4.3.2 Base de dados

O método proposto por este estudo é realizado a partir de um conjunto de pontos que representam as posições de árvores em talhões comerciais de citros. O conjunto de pontos utilizado foi extraído manualmente em ambiente SIG a partir de *basemaps* de imagens em quatro áreas de plantio de laranja (A, B, C e D) que apresentam diferentes características. Nas áreas selecionadas são encontradas linhas de plantio que variam de quase lineares a curvilíneas com diferentes raios de curvatura; linhas com diferentes quantidades de

árvores e extensões; linhas com extremos não alinhados e diferentes padrões de direção.

O levantamento das posições de cada árvore se deu pela identificação por especialista das copas individuais e todas as linhas de plantio foram extraídas completamente, isto é, nos locais onde havia falhas de plantio, a posição de cada falha foi estimada a partir do padrão de espaçamento da linha. Foram levantadas 4.379 árvores no talhão A, 3.484 no B, 2.972 no C e 3.317 no talhão D. A 4.6 mostra uma visão geral da disposição das árvores e das linhas em cada talhão adotado.

Figura 4.6 - Talhões adotados como área de estudo do experimento.



Os pontos pretos correspondem a posição aproximada do centro das copas identificadas.

Fonte: Produção do autor.

4.3.3 Falhas de plantio

Para simulação das falhas de plantio, uma parcela das árvores/pontos de cada talhão foi suprimida e as demais submetidas à análise. Os pontos suprimidos foram selecionados aleatoriamente para simular uma situação em que as falhas do plantio não apresentam nenhum viés (ex. região do solo degradada) e que corresponde à forma de detecção que demanda mais esforço quando realizada manualmente. Os talhões foram analisados em cinco cenários distintos, dos quais quatro são representados pela redução do número de pontos para 80, 85, 90 e 95%, que correspondem às taxas de falhas simuladas e o último cenário considera o talhão sem redução (100%) ou sem falhas. Os pontos considerados como falhas foram selecionados de maneira independente para cada taxa simulada, isto é, a falha que acontece no cenário de 95% pode ou não ocorrer nos demais cenários.

4.3.4 Falsos positivos

O conjunto de pontos levantados manualmente corresponde às posições de cada árvore nos talhões levantadas manualmente, entretanto, a metodologia sugerida pretende atender principalmente aos processos de identificação automatizada de plantas em talhões comerciais. Uma característica comum aos diversos métodos de detecção é a presença de inconsistências relacionadas aos falsos positivos, os quais aumentam o nível de complexidade da identificação de linhas de plantio.

Para simular a presença de falsos positivos, foram inseridos 5% da quantidade total de pontos de cada talhão em posições aleatórias e, para evitar que fossem inseridos novos pontos entre dois pertencentes à mesma linha de plantio, foi considerada a distância mínima de 1,5 metro de qualquer linha presente no talhão. Assim, todos os cenários foram considerados apenas com os pontos corretos (TP, do inglês *True Positive*) – 80tp, 85tp, 90tp, 95tp e 100tp – e com os TP e falsos positivos (FP) - 80fp, 85fp, 90fp, 95fp e 100fp.

4.3.5 Validação

A validação foi realizada a partir de duas abordagens que avaliaram o comprimento e a quantidade de pontos (árvores e falhas) pertencentes em cada linha do resultado. Ambas as abordagens foram baseadas no método proposto por (HEIPKE et al., 1997), que corresponde ao tipo de validação baseada em feições vetoriais e relaciona a feição inferida com a de referência. O processo de pareamento entre o dado extraído e de referência foi realizado a partir de um *buffer* de largura fixa ao redor de cada referência para seleção da linha extraída correspondente, isto é, o resultado que apresenta intersecção com o *buffer* é o par da linha de referência que o gerou.

Entretanto, o processo de reconstituição de uma determinada linha de plantio não gera necessariamente apenas uma linha como resultado. Do contrário, é possível que as árvores pertencentes à mesma linha sejam agrupadas em duas ou mais linhas, o que corresponde a uma inconsistência no resultado. Diante disso, nos casos em que mais de uma linha extraída intersecciona um *buffer* de referência, apenas aquela com maior intersecção é considerada no processo de pareamento e as demais são desconsideradas.

4.3.5.1 Traçado da linha

A acurácia de detecção voltada para o traçado da linha foi avaliada utilizando as métricas completude (C_p), exatidão (C_r) e qualidade (Q). No cômputo das métricas são utilizados tanto o *buffer* ao redor da referência quanto ao redor das linhas inferidas correspondentes, sendo C_p a proporção da linha de referência que está dentro do *buffer* das linhas inferidas, C_r a proporção das linhas inferidas dentro do *buffer* das referências e Q a métrica geral que leva em consideração os valores de C_p e C_r . As três métricas são dadas por (HEIPKE et al., 1997):

$$C_p = \frac{\text{comprimento da referência pareada}}{\text{comprimento da referência}} = \frac{TP}{TP + FN} \quad (4.9)$$

$$C_r = \frac{\text{comprimento da extração pareada}}{\text{comprimento da extração}} = \frac{TP}{TP + FP} \quad (4.10)$$

$$Q = \frac{\text{comprimento da extração pareada}}{\text{comp. da extração} + \text{comp. da referência não pareada}} = \frac{TP}{TP + FP + FN} \quad (4.11)$$

4.3.5.2 Pontos agrupados

Em seguida, cada linha inferida e contemplada pelo processo de pareamento foi comparada a sua respectiva referência a partir da análise de regressão. A análise foi realizada para avaliação da relação da quantidade de árvores agrupadas entre as linhas de referência e aquelas estimadas pelo método proposto. É importante notar que a contagem de plantas nas linhas inferidas não contemplou os falsos positivos simulados, caso algum tenha sido erroneamente atribuído a uma linha. Para cada uma das análises, foram computadas o coeficiente de determinação (R^2), que indica quão relacionadas estão as duas variáveis envolvidas, o Root Mean Squared Error (RMSE), Mean Absolute Error (MAE). Quanto maior o R^2 , maior a correlação entre as variáveis e quanto menor os RMSE, MAE, mais próximas elas se apresentam.

4.3.5.3 Falhas e falsos positivos

As falhas foram avaliadas para todo talhão independentemente da linha de planto a qual cada uma pertence. Para validação, foram usadas as métricas precisão, *recall* e *F1-score* definidas pelas equações 3.2, 3.3 e 3.4, respectivamente. Neste caso, os TPs correspondem aos pontos de falhas detectados que estão situados até 1,5 metro de distância (raio médio das copas estudadas) de alguma referência, os FPs são as falhas inferidas sem a sua referência correspondente e os FNs são as falhas de referência sem a falha detectada correspondente.

Os falsos positivos simulados nos dados de entrada foram avaliados quanto a filtragem realizada a partir da identificação de linhas, ou seja, para cada talhão

foi avaliada a quantidade de falsos positivos que foram corretamente desconsiderados e, portanto, correspondem a parcela filtrada pela metodologia. Assim, a porcentagem de filtragem foi avaliada para cada cenário.

4.4 Resultados

4.4.1 Parâmetros adotados


A 4.7 exibe os recortes das áreas de estudo com alguns resultados encontrados a partir da aplicação da metodologia proposta. Os parâmetros utilizados durante a execução e avaliação do estudo de caso são expostos na 4.1.

Tabela 4.1 - Parâmetros adotados no estudo de caso.

Parâmetro	Descrição	Valor
r	Limiar de aceitação da linearidade	15
a	Parâmetro da área de busca	0,4
b	Parâmetro da área de busca	45

Fonte: Produção do autor.

Figura 4.7 - Resultados do processo de identificação de linhas e falhas de plantio em frações dos 4 talhões.



Os pontos pretos correspondem ao posicionamento das árvores de entrada; os vermelhos, às falhas de plantio corretamente identificadas; os amarelos, aos falsos positivos corretamente ignorados pelo processo de identificação de linhas; e as linhas azuis representam o traçado das linhas de plantio identificadas.

Fonte: Produção do autor.


4.4.2 Traçado das linhas

Quanto ao comprimento das linhas identificadas, de modo geral, foi possível observar relação entre a quantidade de falhas de plantio e os resultados encontrados, isto é, quanto mais incompletas estão as linhas devido às falhas presentes no talhão, menor é o desempenho da metodologia proposta na reconstituição completa das linhas. Além disso, os resultados foram superiores nos cenários sem os falsos positivos, os quais funcionam como ruído para o problema proposto.

Nos casos apenas com os TP, o desempenho do método proposto foi similar entre os talhões A, B e C, apresentando pequenas variações entre 99,7% e

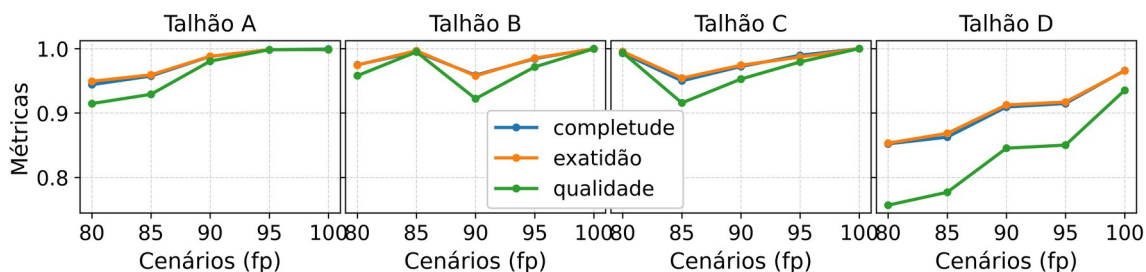
100% para as métricas completude, exatidão e qualidade nas diferentes taxas de falhas simuladas. O talhão D apresentou resultados inferiores aos demais e com maiores variações em relação às diferentes taxas de falhas, sobretudo entre os cenários 80tp e 100tp, onde variou a qualidade de 92,9% para 100%. Contudo, a partir do cenário de 85tp, todas as três métricas foram superiores a 98,5%, atingindo 100% no cenário 100tp (Figuras 4.8 e 4.9).

Figura 4.8 - Métricas de validação dos traçados das linhas para os cenários sem falsos positivos.



Fonte: Produção do autor.

Figura 4.9 - Métricas de validação dos traçados das linhas para os cenários com falsos positivos.



Fonte: Produção do autor.

Quando considerados os falsos positivos (TP + FP), os resultados obtidos foram ligeiramente inferiores e apresentaram maior variação entre os cenários de falhas, entretanto, a relação direta entre a porcentagem de falhas e o resultado foi reduzida, ou seja, cenários com menores porcentagem de falhas nem sempre apresentaram resultados inferiores.

O comportamento das métricas para os talhões A, B e C apresentou alguma semelhança em relação aos casos com FP. De modo geral, o cenário 100fp dos três talhões foi completamente reconstituído (100% para todas as métricas)

e apenas os cenários 80fp e 85fp do talhão A, 90fp do B e 85fp do C apresentaram qualidade menor que 95%.

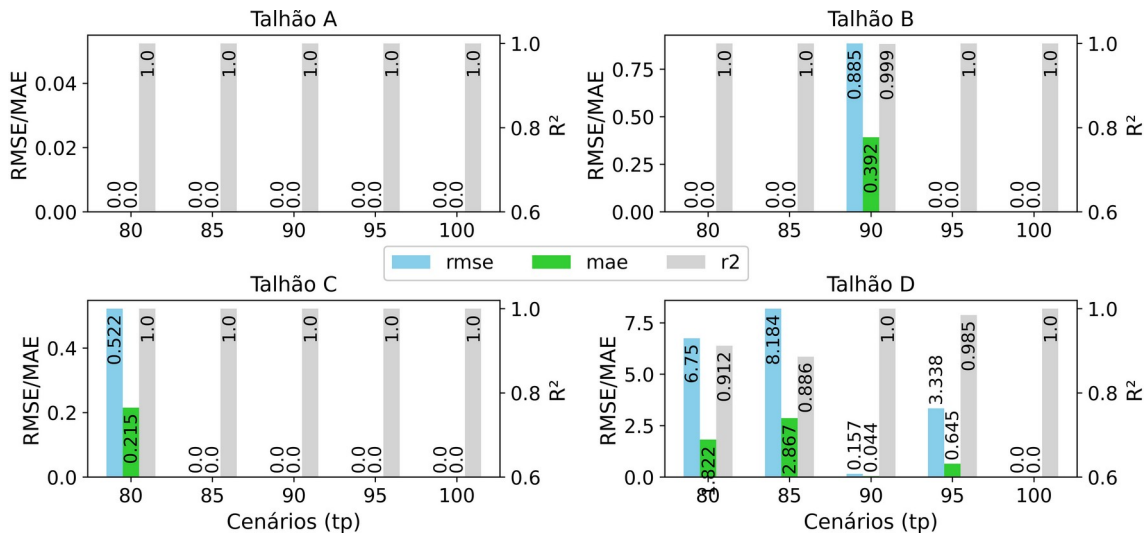
No talhão D, a qualidade do resultado foi mais diretamente relacionada com a taxa de falhas e a amplitude das três métricas foi a maior entre as quatro áreas. Sendo assim, no cenário 80fp, foi obtido o pior resultado de qualidade com 75% e no 100fp o melhor, com 93,5%.

4.4.3 Pontos (árvores) agrupados em linhas de plantio

A segunda abordagem da validação atuou na relação entre a quantidade de plantas que pertencem a cada linha identificada pelo método proposto e as da verdade de campo. Para cada cenário, foram realizadas análises de regressão linear e avaliadas as métricas correspondentes com os pares identificados no processo de pareamento da referência com a inferência.

Quanto à quantidade de árvores agrupadas por linha de plantio sem considerar os falsos positivos (4.10), os talhões A, B e C apresentaram resultados muito similares entre os diferentes cenários de falhas, com máximo desempenho para quase todos ($R^2 = 1$; RMSE = MAE = 0), exceto pelo cenário 90tp do talhão B ($R^2 = 0,999$; RMSE = 0,89; MAE = 0,39) e o 80tp do talhão C ($R^2 = 1$; RMSE = 0,52; MAE = 0,22). O máximo desempenho significa que a identificação de linhas pelo método proposto resultou em linhas idênticas às da verdade de campo, tendo a mesma posição do traçado e mesma quantidade de árvores, sem exceção.

Figura 4.10 - Métricas da análise de regressão para os cenários sem falsos positivos.

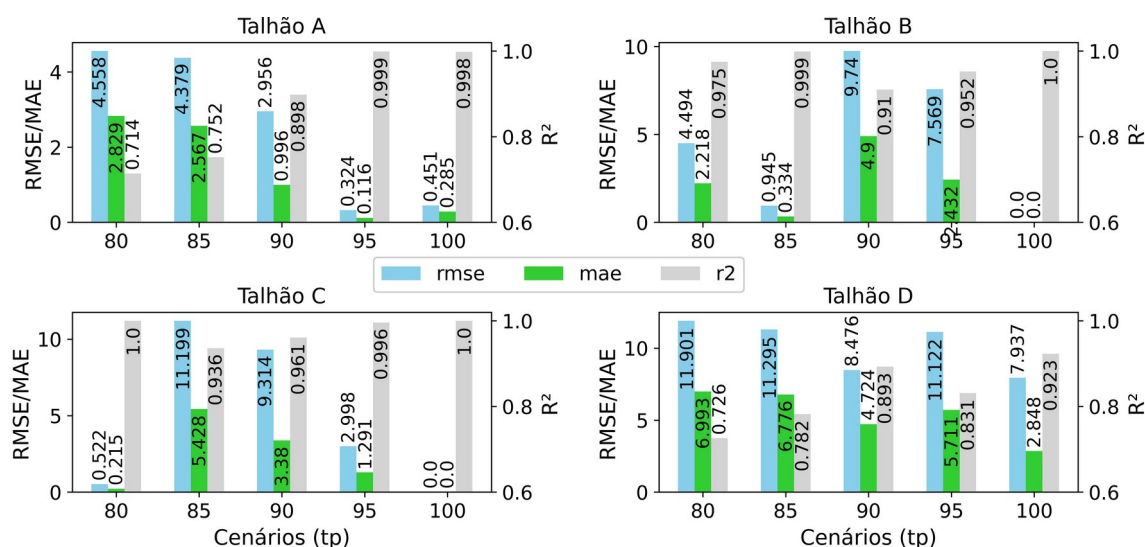


Fonte: Produção do autor.

No talhão D, foi observado maior influência dos cenários de falhas no resultado e genericamente foram obtidos maiores erros e menores valores para o R^2 , sobretudo nos cenários 80tp e 85tp. No primeiro, foram obtidos $R^2 = 0,91$, $RMSE = 6,75$ e $MAE = 0,82$ e no segundo, $R^2 = 0,89$, $RMSE = 8,18$ e $MAE = 2,87$. Por outro lado, nos demais cenários (90tp, 95tp, 100tp), o resultado foi tão bom quanto os outros talhões, obtendo R^2 entre 0,99 e 1, $RMSE$ entre 0 e 3,34 e MAE inferior a 0,65.

Quando considerados os FP (4.11), os talhões sofreram impactos na qualidade do resultado em diferentes medidas. O talhão A obteve valores de R^2 reduzidos para menores que 90% nos cenários 80fp, 85fp e 90fp, enquanto nos cenários 95fp e 100fp foi mantido o R^2 maior que 99,8%, $RMSE < 0,5$ e $MAE < 0,29$. No talhão A, foi possível observar relação entre a taxa de falhas e a qualidade do resultado da regressão, ou seja, quanto mais falhas, maiores são os erros $RMSE$ e MAE e menor o R^2 .

Figura 4.11 - Métricas da análise de regressão para os cenários com falsos positivos.



Fonte: Produção do autor.

Por outro lado, os talhões B e C não apresentaram relação clara entre as falhas e o resultado, e mesmo com a presença dos FPs, os resultados se mantiveram elevados, como nos cenários 100fp e 80fp do talhão C e o cenário 100fp do talhão B com $R^2 = 1$ e erros quase nulos. Os demais cenários dos dois talhões ficaram com R^2 mínimo de 0,94 (C – 85fp), RMSE menores que 11,2 e MAE menores que 5,5.

O talhão D evidenciou o pior resultado tanto entre as quatro áreas quanto entre os cenários de falhas e uma pequena relação entre as falhas e os resultados da regressão pôde ser observada. O cenário 80fp conteve o pior valor de R^2 (0,73) e os maiores erros (RMSE = 11,9 e MAE = 6,99) para o talhão, e o cenário 100fp exibiu o melhor resultado ($R^2 = 0,92$; RMSE = 7,94 e MAE = 2,85).

4.4.4 Falhas de plantio

Na validação das falhas identificadas, só foram considerados os cenários 80, 85, 90, e 95, uma vez que o cenário 100 corresponde à inexistência de falhas. Os resultados obtidos quando não foram considerados os falsos positivos podem ser vistos na 4.2 e quando foram considerados na 4.3. Para os

diferentes casos, a quantidade de falhas a serem identificadas variou de 149 a 887.

Tabela 4.2 - Resultados da identificação de falhas de plantio sem a presença dos falsos positivos.

Talhão	Taxa de falhas	Número de detecções	TP	FP	FN	Verdade de campo	Precisão (%)	Recall (%)	F1-score (%)
A	80	866	855	11	32	887	98,73	96,39	97,55
	85	660	653	7	16	669	98,94	97,61	98,27
	90	443	440	3	10	450	99,32	97,78	98,54
	95	224	224	0	8	232	100,00	96,55	98,25
B	80	686	686	2	24	695	99,71	96,62	98,14
	85	528	531	2	11	521	99,62	97,97	98,79
	90	354	355	1	7	349	99,72	98,07	98,89
	95	181	181	0	4	173	100,00	97,84	98,91
C	80	597	591	9	17	594	98,50	97,20	97,85
	85	448	446	3	12	445	99,33	97,38	98,35
	90	299	296	3	11	297	99,00	96,42	97,69
	95	156	154	2	4	149	98,72	97,47	98,09
D	80	672	645	29	33	664	95,70	95,13	95,41
	85	498	481	20	25	498	96,01	95,06	95,53
	90	348	335	14	11	332	95,99	96,82	96,40
	95	170	162	8	8	166	95,29	95,29	95,29

Fonte: Produção do autor.

Apenas com os TPs, os resultados para as três métricas ficaram todos acima de 95% e em dois cenários (A-95tp e B-95tp) foi obtida a precisão de 100%. O melhor resultado entre os talhões foi do B que atingiu valores de F1-score entre 98,14 e 98,91%. Os talhões A e C apresentaram resultados similares na detecção de falhas e atingiram F1-score entre 97,55 e 98,54%.

O talhão D atingiu o pior resultado, mas se manteve com f1-score acima de 95% em todos os cenários. Os cenários tiveram uma relação diretamente proporcional com os valores de precisão e *recall*, onde quanto menor a quantidade de falhas, maior o valor das métricas avaliadas.

Nos cenários com FP, os cenários atingiram resultados levemente inferiores e a faixa de valores de F1-score foi reduzida para 91,94 a 98,64%. Nenhum cenário atingiu 100% em alguma métrica e o valor máximo de precisão foi de 99,45% (B-95fp) e de *recall*, 97,97% (B-85fp). O talhão B novamente performou melhor entre os talhões e a relação entre taxa de falha e a qualidade do resultado para as métricas precisão e *recall* também foi verificada nesses cenários, com exceção da precisão do C-95fp.

Tabela 4.3 - Resultados da identificação de falhas de plantio com a presença dos falsos positivos.

Talhão	Taxa de falhas	Número de detecções	TP	FP	FN	Verdade de campo	Precisão (%)	Recall (%)	F1-score (%)
A	80	854	829	25	58	887	97,07	93,46	95,23
	85	651	637	14	32	669	97,85	95,22	96,52
	90	448	439	9	11	450	97,99	97,56	97,77
	95	233	226	7	6	232	97,00	97,41	97,20
B	80	698	681	19	27	695	97,29	96,19	96,73
	85	529	531	3	11	521	99,44	97,97	98,70
	90	360	353	9	9	349	97,51	97,51	97,51
	95	182	181	1	4	173	99,45	97,84	98,64
C	80	597	591	9	17	594	98,50	97,20	97,85
	85	441	438	5	19	445	98,87	95,84	97,33
	90	302	295	7	13	297	97,68	95,78	96,72
	95	165	151	14	6	149	91,52	96,18	93,79
D	80	686	629	58	48	664	91,56	92,91	92,23
	85	493	462	35	46	498	92,96	90,94	91,94
	90	350	323	28	20	332	92,02	94,17	93,08
	95	177	160	17	10	166	90,40	94,12	92,22

Fonte: Produção do autor.

4.4.5 Falsos positivos

Nos quatro talhões, a filtragem dos FP aconteceu de forma significativa, com remoção superior a 90% do total de FP para cenário com pior resultado (D – 80fp) e atingindo até 100% de remoção. A 4.4 exhibe o resultado da filtragem nos diferentes cenários e talhões.

O talhão A teve mais de 94% de remoção dos falsos positivos em todos os cenários e chegou a 98,63% no cenário 100fp. O talhão B teve os melhores desempenhos na filtragem dos FP com taxas que variaram de 98,85% no cenário 80fp a 100% nos cenários 85fp e 100fp. O talhão C também possuiu cenários com 100% de filtragem, como o 80fp e 100fp. O 85fp apresentou o menor resultado do talhão com 97,99%. Já no talhão D, a remoção variou entre 90,96% para 98,19% entre os diferentes cenários.

Tabela 4.4 - Resultados da filtragem de falsos positivos após o processo de identificação de linhas e falhas de plantio.

Cenário	Talhão A		Talhão B		Talhão C		Talhão D	
	FP filtrados	%	FP filtrados	%	FP filtrados	%	FP filtrados	%
80	206/219	94,06	172/174	98,85	149/149	100,00	151/166	90,96
85	207/219	94,52	174/174	100,00	146/149	97,99	156/166	93,98
90	214/219	97,72	173/174	99,43	148/149	99,33	157/166	94,58
95	215/219	98,17	173/174	99,43	147/149	98,67	160/166	96,39
100	216/219	98,63	174/174	100	149/149	100	163/166	98,19

Fonte: Produção do autor.


4.4.6 Desempenho computacional

A avaliação do desempenho da aplicação da metodologia proposta levou em consideração todo os processos envolvidos no *framework* de trabalho, adotando o início como a entrada do conjunto de pontos e a saída como a geração dos dados de linhas e falhas de plantio. Os tempos de execução atingiram valores entre 141 a 677 segundos entre todos os talhões e cenários.

Além disso, o tempo de execução não foi diretamente dependente dos cenários de falhas adotados.

Os resultados obtidos (4.12) mostram que, no geral, o desempenho dos cenários que não apresentavam os falsos positivos foi melhor do que os que apresentavam. Esse resultado é justificado pela quantidade reduzida de pontos (-5%) e principalmente pela complexidade de análise provocada pelos pontos que não estão alinhado com os demais, o que demanda mais esforço e tempo do algoritmo na tomada de decisões. Além, disso o cenário com maior variação no padrão das linhas (D) apresentou os piores resultados quando comparados com os demais talhões. O talhão C apresentou os melhores resultados com tempos que variaram abaixo de 200 s (3"20').

Figura 4.12 - Tempo de execução da metodologia proposta para identificação de linhas e falhas de plantio.



Fonte: Produção do autor.

Ainda, é possível notar que o comportamento dos tempos de execução para os talhões A, B e C é similar ao longo dos cenários, entretanto, com valores absolutos diferentes. Isso pode ser justificado pelas diferentes quantidade de linhas e de pontos por linhas presentes nos três talhões, e que demonstrou estar mais relacionado com o desempenho do que a taxa de falhas.

4.5 Discussão

Neste estudo, nós investigamos a performance de um método não supervisionado baseado em análise espacial focada em padrões lineares para extrair linhas de plantio e identificar falhas de plantio a partir do posicionamento de árvores extraído de imagens de sensoriamento remoto. Para isso, nós demonstramos a aplicação da abordagem em quatro pomares de laranja com

diferentes padrões de linhas de plantio em 10 cenários diferentes. Os cenários avaliados contemplaram diferentes porcentagens de falhas de plantio bem como a presença ou não de ruídos ou pontos que não representavam plantas de interesse (falsos positivos). O método proposto foi capaz de realizar o agrupamento de árvores em linhas de plantio e identificar falhas com alta acurácia. Estudos anteriores usaram diferentes técnicas para identificação de linhas de plantio a partir de árvores previamente identificadas.

Gonçalves et al. (2021) avaliaram o uso de rede neural convolucional baseada em grafos para detecção de linhas de plantio em talhão de milho e atingiram f1-score de 91,5%. Osco et al. (2021) analisaram a performance de uma arquitetura de rede neural para identificação de plantas e linhas de plantio simultaneamente. A metodologia proposta pelos autores usa a localização de cada planta identificada como insumo do processo de extração de linhas e por isso foi usada como comparação. Os autores avaliaram diferentes parâmetros e atingiram o melhor valor F1-score de 96,3% para plantio de milho e 96,4% para plantio de laranja.

Bah, Hafiane e Canals (2020) propuseram o uso de uma rede neural convolucional aliada a transformação de Hough a partir da segmentação previamente realizada e atingiram F1-score médio de 90,39% para beterraba e 82,50% para plantação de milho. Os resultados encontrados nesta pesquisa atingiram a métrica qualidade entre de 75 e 100%, ficando a maioria dos cenários acima de 95%.

Além da elevada a acurácia, o método proposto se destaca diante dos métodos baseados em *deep learning* porque consistem na análise espacial não supervisionada e, por isso, não demanda esforço na produção de amostras de treinamento. Além disso, modelos que utilizam redes neurais convolucionais adotam *patches* de imagens como entrada e desempenha a atividade limitando-se à extensão de cada *patch* (AMPATZIDIS; PARTEL, 2019; CUE LA ROSA et al., 2020; OSCO et al., 2021). No método proposto, a identificação acontece em toda a extensão da área de estudo sem a necessidade de pós-processamento dos resultados.

Outra vantagem da metodologia proposta é a robustez da performance quando aplicada em talhões com falhas de plantio, o que naturalmente dificulta a identificação das linhas devido a descaracterização dos seus traçados. Os cenários foram testados com até 20% de falhas e as acurácias de detecção dos talhões A, B e C (áreas com disposição das linhas mais comumente encontradas) foram todas acima de 90%, considerando-se os FP ou não.

Além disso, o método proposto foi capaz de identificar e geolocalizar com alta acurácia as falhas de plantio em diferentes cenários. A atividade foi testada para talhões com até 20% de falhas e os resultados indicaram a robustez da metodologia (91,94% de F1-score para o pior resultado). Ampatzidis e Partel (2019) propuseram uma metodologia similar a deste estudo para identificação de falhas a partir da localização das árvores e da identificação das linhas de plantio. Os autores testaram em um pomar de laranja com linhas retilíneas e regulares com 2,2% de falhas, 0,01% de falsos positivos e atingiram F1-score de 97,3%. O cenário similar adotado neste estudo é o 95tp do talhão A, com 5% de falha, cujo F1-score atingiu 98,25%.

A presença de falsos positivos é uma realidade em atividades de detecção de alvos em imagens. A metodologia proposta neste estudo pretende atuar como filtragem de falsos positivos que se localizam fora dos padrões lineares de um talhão comercial e que podem representar desde ervas daninhas a ruído do modelo utilizados na identificação. A filtragem ocorre porque esta metodologia é capaz de ignorar os alvos fora do alinhamento padrão e ao final do processo, os pontos não agrupados em nenhuma das linhas identificadas podem ser eliminados ou usados como objeto de estudo, dependendo da abordagem. Bah, Hafine e Canals (2020) e Adhikari, Yang e Kim (2019), por exemplo, abordaram a detecção de linhas de plantio por diferentes métodos como subsídio para identificação de ervas daninhas em culturas agrícolas.


Os testes realizados neste trabalho demonstraram que a qualidade do resultado obtido com o algoritmo proposto depende da complexidade da distribuição das árvores, da quantidade de pontos falsos positivos (ruído) presente no talhão e da taxa de falhas que ele apresenta. A complexidade da

distribuição das plantas é uma condição do plantio adotado e quanto mais variedade no direcionamento das linhas e irregularidade no paralelismo entre elas (como no talhão D), menor é o resultado obtido. Por outro lado, os resultados nos talhões A, B e C indicaram que fatores como presença e variação de curvatura nas linhas, irregularidade nos tamanhos de cada linha e extremos de linhas não alinhados não interferem de maneira significativa no resultado.

Além da disposição das árvores, as falhas de plantio e os falsos positivos também são fatores determinantes para a acurácia do resultado porque afetam diretamente os padrões abordados na metodologia: proximidade e linearidade de plantas da mesma linha de plantio. As falhas provocam distanciamento entre as plantas que afeta a homogeneidade do espaçamento e interferem na condição de proximidade e os falsos positivos afetam a linearidade dos pontos de entrada.

Os resultados mostraram que apesar da ocorrência dos fatores limitantes, a metodologia apresentou alta acurácia quando lidou de forma independente com cada um deles. Contudo, o pior cenário se deu quando os dois fatores ocorreram de forma simultânea, ou seja, na região onde ocorreu falhas sequenciais ocorreu também a presença de falso positivo. Esta configuração é possível devido ao carácter aleatório da disposição espacial das falhas de plantio e dos falsos positivos (situação similar à realidade) que pode favorecer ou não a reconstituição das linhas. A 4.13 mostra situações onde a combinação dos ruídos foi desvantajosa.

Figura 4.13 - Exemplos dos casos de inconsistência na metodologia proposta para identificação de linhas e falhas de plantio.



Os pontos pretos correspondem ao posicionamento das árvores de entrada; os amarelos, aos falsos positivos; e as linhas azuis representam o traçado das linhas de plantio identificadas.

Fonte: Produção do autor.

Além da acurácia de identificação das linhas e falhas de plantio, nós realizamos a avaliação desempenho do tempo de execução da metodologia proposta. A avaliação contemplou talhões com números de pontos que não variam significativamente e, por isso, foi focada no diagnóstico dos parâmetros que influenciam no tempo de execução. Foi demonstrado que os cenários de falhas podem ter alguma relação com custo de tempo, mas as características como a presença de falsos positivos fora do alinhamento e a quantidade de linhas e de árvores por linha estão mais relacionadas com o desempenho.

O tempo de execução ainda pode ser melhorado, uma vez que a implementação realizada buscou eficiência, mas não esgotou todas as possibilidades de melhoria e é possível que a implementação via Linguagem de Consulta Estruturada (SQL, do inglês *Structured Query Language*) operando em um banco de dados possa otimizar significativamente o desempenho de execução.

4.6 Conclusão

Neste estudo, nós sugerimos uma metodologia para identificação não supervisionada de linhas e falhas de plantio a partir de dados espacializados de posicionamento de árvores de laranja em talhões comerciais. A metodologia é baseada sobretudo em análise de padrões lineares e proximidade entre os alvos.

A validação do método foi realizada em um estudo de caso envolvendo quatro áreas com diferentes distribuição e complexidade do plantio, a partir de diferentes cenários de falhas e considerando a ocorrência de ruídos. Os resultados mostraram e justificaram a adoção da análise proposta em estudos que buscam extrair dados de plantio com foco na tomada de decisões.

Sendo assim, a metodologia apresentada neste trabalho se demonstrou capaz e viável para atuar com dados de posicionamento de plantas para extração de informações importantes para o manejo agrícola. O *framework* adotado pode se configurar como um módulo de pós-processamento de algoritmos de detecção de alvos agrícolas para identificação das linhas e falhas e de levantamento dados derivados, como métricas de espaçamento médio entre linhas e entre plantas. De todo modo, trabalhos futuros deverão ser conduzidos para avaliação da metodologia aplicada a diferentes culturas agrícolas.

5 USO DE MODELOS DE APRENDIZADO DE MÁQUINAS E IMAGENS DE VANT PARA DETECÇÃO DA DOENÇA DO *GREENING* EM LAVOURA DE LARANJA

5.1 Introdução

O *greening* é considerado a doença mais importante para a citricultura mundial dado o desafio para o manejo e atenuação dos seus impactos (BOVÉ, 2006). De acordo com Rodrigues et al. (2020), a identificação prévia da doença nas lavouras de laranjas é de extrema importância, uma vez que favorece a redução do potencial de disseminação e diminui os prejuízos financeiros da produção.

Como já foi comentado nesta dissertação (Seção 2.2), a principal forma de detecção da doença, o diagnóstico a partir da inspeção visual, demanda grandes esforços e não apresenta nível de confiabilidade suficiente para o controle adequado a nível local e regional. Diante disso, o uso do sensoriamento remoto pode ser um importante aliado no contexto da identificação rápida aplicada em escala espacial de talhões ou fazendas.

Diversos estudos foram realizados a partir de imagens RGB, multiespectral e termal com foco no aumento da viabilidade de detecção da doença. Garza et al. (2020) analisaram a capacidade do atributo espectral derivado de índice de vegetação RGB extraído da região das copas de árvores em diagnosticar a doença. A limitação do estudo, contudo, se dá pela necessidade de delimitação manual das copas a partir da interpretação visual das imagens, o que inviabiliza a implementação de plataformas operacionais que auxiliam de modo prático o monitoramento agrícola.

Por outro lado, Garcia-Ruiz et al. (2013) investigaram o uso de imagens multiespectrais obtidas por duas plataformas aéreas a partir de extração de atributos espectrais, segmentação das copas por limiarização e classificação via análise de discriminante linear e quadrática. A necessidade de segmentação manual não foi observada, porém, a desvantagem deste método

é, entre outras, a necessidade de definição de um limiar de segmentação independente para cada imagens usada, sobretudo se estas apresentam diferentes características espaciais e espectrais.

Como visto, as principais técnicas utilizadas ultimamente no âmbito da detecção da doença via sensoriamento remoto fazem uso da identificação inicial da região compreendida pela vegetação (segmentação) para posterior análise da resposta espectral e classificação das regiões (copas ou pixel) em saudias ou infectadas pela doença (GARCIA-RUIZ et al., 2013; DADRASJAVAN et al., 2019; GARZA et al., 2020; LAN et al., 2020).

Os métodos de segmentação da região de vegetação são realizados por delineamento manual, extração de polígono de interesse circular e limiarização por índice de vegetação. Por causa dessa condição, além da demanda de esforços voltados para a correta segmentação das copas, os estudos envolvendo esses procedimentos são conduzidos com uma quantidade limitada de amostras (menos de 50).

Além disso, a classificação final é altamente dependente da precisão da segmentação inicial, uma vez que a delimitação imprecisa considera parcela de alvos sem interesse – como sombras externas às áreas das copas e solo – influencia diretamente no cômputo dos atributos espectrais extraídos dos segmentos ou dos pixels. Diante disso, esforços devem ser realizados para aumento da precisão da segmentação que subsidia classificação ao passo que também seja reduzida a necessidade de trabalho manual.

Diante disso, o objetivo desse estudo é avaliar a capacidade de diagnóstico da doença de *greening* em talhões comerciais de laranja a partir de imagens obtidas por VANT. O diferencial da metodologia adotada no presente estudo é o uso de delimitador preciso das copas das árvores, a partir do modelo de segmentação de instância implementado no 3, e possibilidade de análise com variadas amostras, subsidiada pela metodologia desenvolvida no Capítulo 4.

5.2 Metodologia

5.2.1 Área de estudo

Este estudo foi conduzido em um talhão comercial de laranjas situado no Município de Mogi Mirim – SP. A área apresenta cerca de 15ha e é composta pelo plantio de aproximadamente 6200 árvores das variedades Baianinha, Valência, Pêra e Natal cujo plantio se deu em 2015. O talhão foi selecionado de acordo com a anuência do proprietário em participar do estudo.

5.2.2 Imageamento, pré-processamento e segmentação

As imagens utilizadas na análise foram adquiridas usando o VANT de asa fixa SenseFly's eBee (senseFly SA, Lausana, Suíça) em 27 de setembro de 2021 com três sensores divididos em dois voos. O primeiro voo foi realizado com a câmera DuetT que apresenta dois sensores que operam simultaneamente e atuam respectivamente na região espectral do infravermelho termal – FLIR (lente de 35 mm; resolução de 640 x 512px) – e do RGB – senseFly S.O.D.A. (lente de 35 mm; resolução de 5472 x 3648px). O segundo voo foi realizado com o sensor multiespectral – Parrot Sequoia+ (1.2 MP, resolução de 1280 x 960px) – operante nas bandas espectrais do verde (550 nm ± 40 nm), vermelho (660 nm ± 40 nm), borda do vermelho (735 nm ± 10 nm) e infravermelho próximo (790nm ± 40nm). As demais características dos voos são expostas na 5.1.

Tabela 5.1 - Características dos voos de obtenção das imagens.

Voo	Sensor	Região espectral	Altura (m)	GSD (cm)	Sobreposição (%) (frontal/lateral)
1	senseFly S.O.D.A	RGB	75	2	80/75
2	Parrot Sequoia+	Multiespectral	65	6	80/60
1	FLIR	Termal	75	10	75/65

Fonte: Produção do autor.

O software Pix4Dmapper Pro (Pix4D SA, Lausana, Suíça) foi utilizado para o processamento fotogramétrico das imagens adquiridas pelo VANT utilizando-se os mesmos processos adotados no Capítulo 3, exceto pela correção radiométrica aplicada às imagens multiespectrais a partir dos dados de irradiância captados pelo sensor auxiliar (*sunshine*).

Após a obtenção dos ortomosaicos, foi realizada a segmentação de instância de objeto com uso do modelo RGBC e dos processos definidos no Capítulo 3, cujo produto corresponde à identificação e delimitação das copas de laranjeiras. Em seguida, os segmentos foram manualmente avaliados e refinados para remoção dos falsos positivos e obtenção das copas não identificadas (falsos negativos) de modo a corrigir todos os erros de comissão e omissão e, por isso, não foi realizada validação do resultado da segmentação.

Além disso, todos os segmentos foram reduzidos proporcionalmente à área com a aplicação de *buffer* negativo para eliminação das bordas das copas. A diminuição das copas foi embasada no fato de que a contaminação inicial das árvores se dá principalmente pela região do topo do dossel (BOVÉ, 2006), e as análises indicaram que a redução para 70% da área de cada segmento (5.1) resultou no melhor desempenho da identificação da doença.

Figura 5.1 - Exemplos da redução do traçado das copas para 70% de área.



Fonte: Produção do autor.

5.2.3 Extração de atributos

Após o pré-processamento das imagens e da segmentação e manipulação das copas, os ortomosaicos foram utilizados como insumos para extração dos atributos espectrais adotados no processo de classificação. Os atributos correspondem aos dados de temperatura obtido do sensor termal, de reflectância espectral das bandas de atuação do sensor multiespectral, dos produtos da análise de principais componentes da imagem multiespectral e dos índices de vegetação. Os atributos, os dados que os geraram e a descrição de cada um são expostos na 5.2.

Tabela 5.2 - Atributos espectrais adotados no processo de classificação.

Dado originário	Atributo	Descrição	
Imagem termal	Temperatura (°C)	Banda individual da imagem	
	Reflectância – <i>Green</i>	Banda individual da imagem	
	Reflectância – <i>Red</i>		
	Reflectância – <i>Red edge</i>		
Reflectância – <i>NIR</i>			
Imagem multiespectral	Principal componente 1	Produto da Análise de Principais Componentes	
	Principal componente 2		
	Principal componente 3		
	Principal componente 4		
	<i>Normalized Difference Vegetation Index (NDVI)</i>	$\frac{N - R}{N + R}$	
	<i>Normalized Difference Red-edge Index (NDRE)</i>	$\frac{N - Re}{N + Re}$	
	<i>Triangular Vegetation Index (TVI)</i>	$0,5 \times (120 (N - G) - 200 (R - G))$	
	<i>Structure Insensitive Pigment Index (SIPI)</i>	$\frac{N - B}{N - R}$	
	<i>Leaf Chlorophyll Index (LCI)</i>	$\frac{N - Re}{N + R}$	
	Imagem RGB	<i>Visible Atmospherically Resistant Index (VARI)</i>	$\frac{G - R}{G + R - B}$

Fonte: Produção do autor.

Em seguida, os segmentos reduzidos foram amostrados com 8 métricas de cada atributo espectral para definição dos atributos finais que caracterizaram cada árvore presente no talhão. As medidas adotadas foram soma, amplitude, média, mediana, máximo, mínimo, variância e desvio padrão. Ao final, a combinação dos 15 atributos espectrais com as 8 medidas adotadas totalizou em 120 atributos finais que foram utilizados na classificação. A partir de agora os atributos finais serão chamados apenas de atributos.

5.2.4 Classificação

O conjunto de dados dos segmentos com seus respectivos atributos foi utilizado para aplicação do classificador *random forest*. O *random forest* é um algoritmo de classificação supervisionada baseado em árvores de decisão (BREIMAN, 1999). Para definição dos seus parâmetros ou treinamento, o classificador define as regras de cada árvore a partir de subconjuntos aleatórios das amostras de treinamento. A ideia principal do algoritmo é realizar a inferência de acordo com o voto da maioria das árvores de decisão definidas, a classe atribuída a uma amostra é aquela que recebeu mais votos entre as árvores treinadas (BREIMAN, 1999).

A classificação foi realizada em 5 subconjuntos de amostras, sendo um para cada variedade de laranja e o último para o talhão inteiro. Para cada cenário, os dosséis foram divididos em 80% para treinamento e 20% para teste e validação. O resultado da classificação foi obtido pela média de 100 iterações realizadas com diferentes conjuntos de amostras de treinamento e teste selecionadas aleatoriamente.

5.2.5 Verdade de campo

A verdade de campo foi obtida a partir de inspeção visual realizada duas vezes por uma equipe especializada. As árvores foram classificadas em saudáveis ou infectadas segundo a presença ou não dos sintomas visuais da doença. A primeira inspeção foi realizada em setembro de 2021 e todas as árvores foram

analisadas. Além disso, foram amostradas 100 árvores para realização do teste PCR tendo em vista a confirmação do diagnóstico visual por amostragem.

A segunda inspeção se deu dois meses depois da primeira, em novembro de 2021, e foram avaliadas apenas 100 árvores selecionadas dentre aquelas caracterizadas comumente como falsos positivos nas iterações de classificação para análise da pertinência do resultado. Para diminuir o viés do resultado, os especialistas pelo diagnóstico visual não foram informados a respeito da condição fitossanitária das árvores reinspecionadas, levantada na primeira inspeção.

5.2.6 Validação

O processo de classificação foi avaliado quanto a pertinência do resultado em relação à verdade de campo. As amostras inferidas foram classificadas em verdadeiro positivo (TP), verdadeiro negativo (TN), falso positivo (FP) e falso negativo (FN). Para visualização dos resultados foram computadas matrizes de confusão de cada cenário e extraídas as métricas de validação precisão, *recall* e F1-score dadas pelas equações 3.2, 3.3 e 3.4, respectivamente.

5.3 Resultados

5.3.1 Inspeção visual

A inspeção visual realizada em todas as árvores demonstrou que a incidência da doença na área de estudo acontece de forma diferenciada entre as variedades (5.3), contudo, em todas foi constatado maior quantidade de plantas infectadas em comparação com as sadias. A Natal apresentou a maior porcentagem de incidência (85,2%), seguida pela Baianinha (81,26%) e Valência (77,15%). A variedade Pêra apresentou a menor taxa de incidência (63,87%), e considerando-se o talhão completo, foram identificadas 4762 plantas infectadas do total de 6197 (76,84% de incidência).

A validação da inspeção visual foi realizada por amostragem a partir do teste analítico PCR realizado com material recolhido de 100 árvores. A partir dos

testes, foi identificado que a situação fitossanitária de todas as amostras estavam em conformidade com a inspeção visual.

Tabela 5.3 - Resultados da inspeção visual completa nas diferentes variedades de laranja.

Variedade	Número de árvores	Árvores infectadas	Incidência (%)
Baianinha	2076	1687	81,26
Pera	1597	1020	63,87
Valência	1186	915	77,15
Natal	1338	1140	85,20
Todas	6197	4762	76,84

Fonte: Produção do autor.

5.3.2 Classificação

A classificação dos dosséis identificados na área de estudo utilizou os atributos de cada copa para a classificação baseada em regiões. As matrizes de confusão de cada cenário são mostradas na 5.4 e subsidiaram o cálculo das métricas de validação, expostas na 5.5. Em todos os cenários, foi observado o desbalanceamento entre a quantidade de amostras sadias e infectadas. Este desbalanceamento foi proveniente da própria taxa de incidência da doença na área de estudo e a intensidade do desequilíbrio se deu devido à seleção aleatória de amostras de teste, que pode ter amenizado ou intensificado a diferença da quantidade de amostras entre as duas classes.

De modo geral, todos os cenários apresentaram distribuição semelhante das proporções dos acertos (positivos e negativos) e dos erros (falsos positivos e falsos negativos). Mais da metade das árvores avaliadas foram corretamente classificadas como infectadas, sendo a menor proporção correspondente a variedade Pêra (51,38%) e a maior da Natal (84,35%).

Ainda, todos os resultados indicaram maior tendência do modelo em classificar erroneamente plantas sadias como infectadas (falsos positivos) em comparação com a classificação de plantas infectadas como sadias (falsos

negativos). A classificação das amostras da variedade Baianinha resultou, na média, em 16,48% de falsos positivos e 1,87% de falsos negativos; a Pêra, cuja proporção entre amostras das duas classes é a mais equilibrada, apresentou 14,18% de FP e 12,28% de FN; na variedade Valência, 16,81% de FP e 5,26% de FN; para a Natal, 14,19% e 0,96%, respectivamente. Quando avaliadas todas as árvores, foi obtido 17,72% de FP e 3,48% de FN.

Tabela 5.4 - Matrizes de confusão geradas pela classificação das amostras nos diferentes cenários.

Legenda

		Classificador	
		Neg	Pos
Referência	Neg	Verdadeiro Negativo (%) Média ± Desvio p.	Falso Positivo (%) Média ± Desvio p.
	Pos	Falso Negativo (%) Média ± Desvio p.	Verdadeiro Positivo (%) Média ± Desvio p.

Mín  Máx

Baianinha

		Classificador	
		Neg	Pos
Referência	Neg	2,36 ± 0,72	16,48 ± 1,89
	Pos	1,87 ± 0,68	79,29 ± 1,98

Pera

		Classificador	
		Neg	Pos
Referência	Neg	22,17 ± 1,89	14,18 ± 1,98
	Pos	12,28 ± 1,77	51,38 ± 2,48

Valência

		Classificador	
		Neg	Pos
Referência	Neg	6,05 ± 1,35	16,81 ± 2,52
	Pos	5,26 ± 1,65	71,88 ± 2,48

Natal

		Classificador	
		Neg	Pos
Referência	Neg	0,49 ± 0,4	14,19 ± 2,25
	Pos	0,96 ± 0,71	84,35 ± 2,21

Todas

		Classificador	
		Neg	Pos
Referência	Neg	5,51 ± 0,51	17,72 ± 1,15
	Pos	3,48 ± 0,62	73,29 ± 1,18

Fonte: Produção do autor.

Dentre as três métricas adotadas para avaliação da classificação, a precisão foi a menor em todos os cenários, uma vez que os falsos positivos foram os erros majoritários. As amostras da variedade Pêra foram as mais afetadas quanto à precisão e obteve, em média, 78,4%. A maior precisão foi obtida na variedade Natal, com 85,6%.

Tabela 5.5 - Métricas da classificação dos diferentes cenários.


Variedade	Precisão	Recall	F1-score
Baianinha	82,8 ± 0,02	97,69 ± 0,01	89,62 ± 0,01
Pera	78,4 ± 0,03	80,71 ± 0,03	79,49 ± 0,02
Valência	81,07 ± 0,03	93,19 ± 0,02	86,67 ± 0,02
Natal	85,6 ± 0,02	98,87 ± 0,01	91,74 ± 0,01
Todas	80,54 ± 0,01	95,47 ± 0,01	87,36 ± 0,01

Fonte: Produção do autor.

Os resultados da classificação atingiram F1-score entre 79,49% (Pêra) e 91,74% (Natal) com o levantamento da primeira inspeção usado para treinamento e validação do modelo. Quando analisado – apenas para validação – o resultado da segunda inspeção realizada nas 100 árvores comumente consideradas falsos positivos dentre as iterações da classificação, foi constatado que aproximadamente 30% dos falsos positivos representavam escape da primeira inspeção visual, isto é, apesar de estarem infectadas, foram diagnosticadas visualmente como sadias. Contudo, foram corretamente identificadas pelo modelo de classificação.

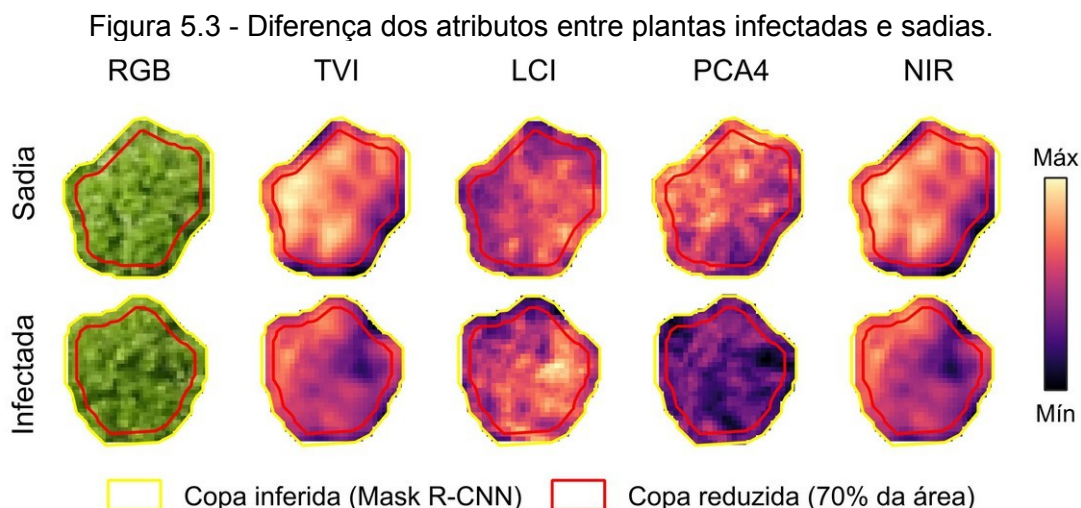
Após o processo iterativo adotado, os atributos foram avaliados quanto a sua influência na classificação das amostras. Os 20 atributos mais importantes e a distribuição dos valores das amostras são mostrados na 5.2.

Figura 5.2 - Distribuição de valores normalizados dos 20 atributos mais importantes durante o processo de classificação.



Fonte: Produção do autor.

Foi observado que os índices de vegetação TVI (valor máximo) e LCI (amplitude) foram os que mais exerceram influência no resultado, ocupando respectivamente a primeira e a segunda posição. Os atributos gerados pelas principais componentes da imagem multiespectral ocuparam 10 posições (50%) dentre as mais importantes. Quanto as bandas individuais, o NIR foi o mais observado. Em relação às medidas usadas para composição dos atributos, as mais comuns foram a amplitude e o valor máximo. A 5.3 exhibe o comparativo visual dos principais atributos usados no processo de classificação entre amostras infectadas e sadias.



Fonte: Produção do autor.

5.4 Discussão

A abordagem realizada neste estudo buscou diferenciar, a partir da delimitação individual de copas de laranjeiras e de atributos espectrais derivados de imagens VANT, as árvores sadias daquelas infectadas pelo *greening*. A metodologia adotada contemplou o levantamento de verdade de campo por meio da inspeção visual e testes analíticos (PCR). A partir do método executado, foi possível identificar as plantas infectadas com resultados significativos, cujo *F1-score* variou entre 79,44% e 91,74%. Alguns estudos similares relataram resultados próximos aos obtidos nesta pesquisa.

Dadrasjavan et al. (2019) realizaram a identificação a partir de dois passos principais: inicialmente foram identificados os pixels referentes à vegetação e a partir de então foi realizada a classificação – em nível de píxel – das regiões infectadas e sadias usando o algoritmo *Support Vector Machine* (SVM) e 16 atributos espectrais. Os autores atingiram 81,75% de acurácia global e, assim como no presente estudo, os falsos negativos (4,88%) foram inferiores aos falsos positivos (13,37%).

Garcia-ruiz et al. (2013) avaliaram a capacidade de discriminação entre plantas sadias e infectadas com a doença do *greening* a partir de imagens hiperespectrais obtidas por VANT e por aerolevanteamento e atingiram os

melhores resultados com uso do classificador SVM. A partir do levantamento da área das copas por delimitação manual, os autores extraíram atributos espectrais envolvendo a média das bandas individuais e de índices de vegetação de cada árvore. A máxima acurácia da metodologia adotada, cuja necessidade de manipulação manual é maior que a sugerida no presente estudo, foi de 85% com 11% de falsos negativos.

Ainda, um estudo envolvendo modelos de *deep learning* e imagens multiespectrais indica que a possibilidade de identificação da doença pode atingir até 98% de acurácia quando adotado um processo de extração da área da copa e atributos espectrais similar ao sugerido neste estudo (LAN et al., 2020). De todo modo, os resultados obtidos no presente estudo indicam a viabilidade de aplicação da metodologia para identificação da doença uma vez se assemelham aos resultados encontrados na literatura. Contudo, alguns pontos abordados demandam atenção.

É importante notar, inicialmente, que os dados de campo levantados pela primeira inspeção visual foram comparados com os testes PCR por amostragem ($n = 100$) e os resultados indicaram que 100% do diagnóstico visual estava em conformidade com o resultado do teste. Porém, isso sugere a existência de viés na coleta das amostras que foram testadas, uma vez que, segundo a literatura, a inspeção visual apresenta limitações na identificação da doença e é capaz de atingir no máximo 59% de acurácia (FUTCH; WEINGARTEN; IREY, 2009). Diante disso, não é válido afirmar que o levantamento visual indicou com fidedignidade a condição fitopatologias das árvores estudadas.

Além disso, a taxa de incidência da doença entre as variedades e no talhão inteiro provocaram um desbalanceamento das amostras sadias e infectadas e pode ter influenciado no processo de treinamento. Uma vez que as amostras utilizadas durante a construção das árvores de decisão estejam desbalanceadas, há uma tendência do algoritmo em prever mais amostras com a classe majoritária, o que gera naturalmente mais falsos positivos. Por outro lado, a reinspeção indicou que aproximadamente 30% dos falsos

positivos realmente representaram escapes da primeira inspeção e foram corretamente classificados pelo modelo.

Além disso, ainda que o processo de treinamento possa ter sofrido influência do desbalanceamento das amostras, é importante notar que a parcela dos falsos negativos foi a menor em todos os cenários (entre 0,96 e 12,28%) e este corresponde ao resultado menos desejado de um modelo de identificação da doença, já que o diagnóstico visual positivo representa de fato uma planta infectada e esta deve ser corretamente identificada.

Com isso, é possível observar que os resultados do classificador final são altamente dependentes do método de amostragem, e para apresentar uma solução global, é necessária a realização de mais testes com diferentes situações. É interessante notar, por exemplo, que o levantamento da verdade de campo contemplou apenas a classificação dual das árvores em sadia ou infectada, porém, tendo em vista os atributos sugeridos, é recomendado avaliar a capacidade de classificação quando adotados diferentes níveis de severidade da doença.

Essa abordagem se faz necessária uma vez que os dosséis infectados que apresentam baixa incidência dos sintomas tendem a apresentar valores de atributos – sobretudo os que usam medidas de tendência central (média e mediana) – mais próximos de uma árvore sadia do que de uma com grande manifestação dos sintomas e, portanto, devem ser diferenciados no processo de classificação.

Outra sugestão para novas abordagens é realizar a classificação de modo estratificado em relação a área das copas para avaliar o comportamento das métricas em árvores com diferentes idades e estágios fenológicos, o que pode contribuir para diminuição dos erros e aumento da viabilidade de detecção remota.

Além disso, é sugerida a aplicação de técnicas de processamento de imagens para redução das incertezas associadas aos imageamentos futuros. Um

exemplo é a ocorrência de sombras na região das copas que é responsável pela alteração dos atributos dos segmentos, sobretudo dos índices de vegetação (RANSON; DAUGHTRY, 1987). Portanto, é recomendada a identificação e filtragem dos pixels de sombra para obtenção de atributos mais representativos.

Por fim, é possível ainda a diminuição da dimensionalidade do problema proposto por meio da seleção de atributos adotados na classificação. Esse processo é responsável pela redução dos atributos espectrais para um conjunto menor capaz de diferenciar com a mesma acurácia as amostras infectadas das sadias. Com isso, é possível aumentar a viabilidade de aplicação pois a quantidade de sensores necessários possivelmente será menor.

De todo modo, mesmo sem a definição de uma solução global, a abordagem proposta nessa pesquisa apresenta, de antemão, a capacidade de contribuir para maior viabilidade do processo de inspeção visual uma vez que é possível, a partir do diagnóstico visual de uma parcela do talhão, extrapolar a identificação para toda a área com f1-score mínimo de 79,5%.

5.5 Conclusão

A capacidade de diagnóstico de detecção da doença do *greening* em plantio de laranjas a partir de imagens obtidas por VANT foi avaliada neste estudo e os resultados indicaram o potencial do método proposto para auxílio no manejo da doença. Apesar das limitações encontradas, a metodologia adotada foi capaz de identificar com acurácia satisfatória a condição patológica do talhão estudado, sobretudo as plantas sabidamente infectadas e sadias.

Os resultados sugeriram ainda o potencial do método em identificar corretamente as plantas infectadas que foram negligenciadas no processo de identificação visual. De todo modo, novos estudos devem ser realizados de modo a investigar as sugestões levantadas neste estudo em busca de uma solução operacional para o problema.

6 CONSIDERAÇÕES FINAIS

Nesta pesquisa, nós buscamos investigar as possibilidades de uso de imagens de VANT para aquisição de dados e informações do plantio de laranja a nível de talhão para auxílio no manejo agrícola e na tomada de decisões. Os resultados encontrados justificam a aplicação das metodologias propostas na geração de dados úteis e com nível de precisão significativos.

A investigação a respeito da capacidade de detecção e delineamento de plantas via modelo de *deep learning* (*Mask R-CNN*) indicou que o uso da informação proveniente de modelos digitais de elevação, sobretudo, dos CHMs é indicado quando avaliados talhões com alta densidade de plantio. Esse dado auxilia na diminuição de falsos positivos e viabiliza a discriminação precisa entre duas copas contíguas.

Ainda no contexto da segmentação das imagens em copas de árvores, nós propomos também duas metodologias auxiliares que aumentaram a viabilidade do estudo. Para geração dos rótulos das amostras de treinamento e da verdade de campo, foi adotado um processo envolvendo processamento digital de imagens, cujo objetivo foi operacionalizar o trabalho manual. Além disso, foi proposto um método de mosaicagem não supervisionada aplicada aos resultados intermediários do modelo de segmentação, a partir do qual é viável a implementação *framework* unificado para realização da atividade.

Uma vez realizada a atividade de identificação e delineamento de plantas, um sistema de monitoramento aplicado ao plantio é capaz de fornecer diversas informações para produtores e prestadores de serviço, como quantidade e densidade de árvores no talhão, distribuição da área e do perímetro das copas e o posicionamento preciso de cada planta da cultura.

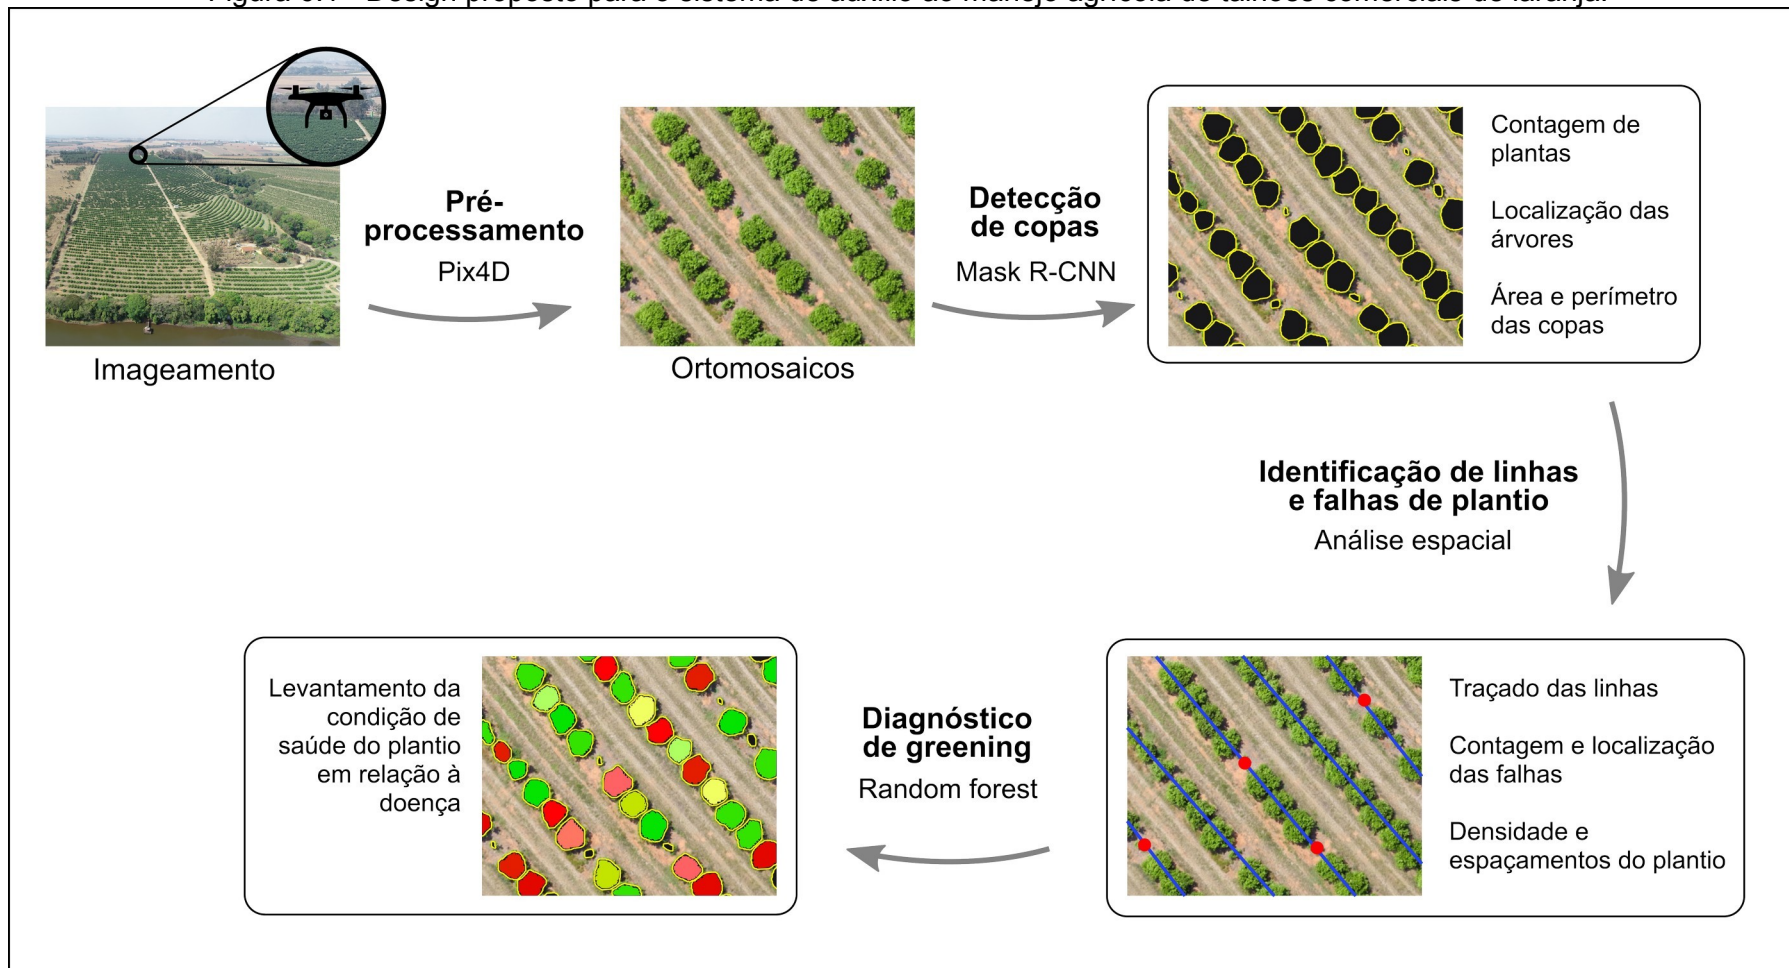
A partir do posicionamento das plantas, nós avaliamos a viabilidade de implementação de um algoritmo não supervisionado para identificação de linhas e falhas de plantio baseado em análise espacial de padrões lineares. Os resultados indicaram que o método é capaz de fornecer bons resultados

mesmo em situações de ruidosas, como a presença de muitas falhas de plantio (até 20%) e de plantas daninhas fora do alinhamento padrão projetado para o talhão. Esse processamento disponibiliza, por sua vez, informações a respeito do traçado real das linhas de plantio, estatísticas do relacionamento entre as plantas e as linhas, espaçamento real das plantas e linhas e, sobretudo, da contagem e do posicionamento das falhas de plantio.

Por fim, nós avaliamos a possibilidade de diagnóstico do *greening* a partir de atributos extraídos de imagens multiespectral e termal nos segmentos de copas identificados e rotulados nas etapas anteriores. Os resultados exibiram as potencialidades e desafios do método proposto e indicaram novas formas de abordagem para trabalhos futuros com vistas na implementação de uma solução global.

Como pode ser visto, os objetivos do trabalho se relacionam de modo sequencial, no qual o resultado do primeiro processamento é utilizado como insumo do processamento seguinte. Esse design (6.1) sugere a possibilidade de implementação de um sistema unificado de monitoramento agrícola a partir de imagens de VANT. Uma vez em operação, o usuário é capaz de extrair, sem a necessidade de domínio avançado, informações que podem ser de muita valia para auxílio no manejo agrícola local e regional.

Figura 6.1 - Design proposto para o sistema de auxílio ao manejo agrícola de talhões comerciais de laranja.



Fonte: Produção do autor.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADHIKARI, S. P.; YANG, H.; KIM, H. Learning semantic graphics using convolutional encoder–decoder network for autonomous weeding in paddy. **Frontiers in Plant Science**, v. 10, p. 1–12, 2019.
- AITELKADI, K.; OUTMGHOUST, H.; LAARAB, S.; MOUMAYIZ, K.; SEBARI, I. Detection and counting of fruit trees from RGB UAV images by convolutional neural networks approach. **Advances in Science, Technology and Engineering Systems Journal**, v. 6, n. 2, p. 887–893, 2021.
- AMPATZIDIS, Y.; PARTEL, V. UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. **Remote Sensing**, v. 11, n. 4, 2019.
- BAH, M. D.; HAFIANE, A.; CANALS, R. CRowNet: deep network for crop row detection in UAV images. **IEEE Access**, v. 8, p. 5189–5200, 2020.
- BASSANEZI, R. B.; LOPES, S. A.; DE MIRANDA, M. P.; WULFF, N. A.; VOLPE, H. X. L.; AYRES, A. J. Overview of citrus huanglongbing spread and management strategies in Brazil. **Tropical Plant Pathology**, v. 45, n. 3, p. 251–264, 2020.
- BELASQUE JUNIOR, J.; BERGAMIN FILHO, A.; BASSANEZI, R. B.; BARBOSA, J. C.; FERNANDES, N. G.; YAMAMOTO, P. T.; LOPES, S. A.; MACHADO, M. A.; LEITE JUNIOR, P.; AYRES, A. J.; MASSARI, C. A. Base científica para a erradicação de plantas sintomáticas e assintomáticas de huanglongbing (HLB, greening) visando o controle efetivo da doença. **Tropical Plant Pathology**, v. 34, n. 3, p. 137–145, 2009.
- BELASQUE JUNIOR, J. B.; YAMAMOTO, P. T.; MIRANDA, M. P.; BASSANEZI, R. B.; AYRES, A. J.; BOVÉ, J. M. Controle do huanglongbing no estado de São Paulo, Brasil. **Citrus Research & Technology**, v. 31, n. 1, p. 53–64, 2010.
- BOVÉ, J. M. Huanglongbing: a destructive, newly-emerging, century-old disease of citrus. **Journal of Plant Pathology**, v. 88, n. 1, p. 7–37, 2006.
- BRAGA, J. R. G.; PERIPATO, V.; DALAGNOL, R.; FERREIRA, M. P.; TARABALKA, Y.; ARAGÃO, L. E. O. C.; DE CAMPOS VELHO, H. F.; SHIGUEMORI, E. H.; WAGNER, F. H. Tree crown delineation algorithm based on a convolutional neural network. **Remote Sensing**, v. 12, n. 8, p. 1–27, 2020.

- BREIMAN, L. **Random forests**: random features, technical report 567. Berkeley: University of California, 1999.
- CARRIVICK, J. L.; SMITH, A. M. W.; QUINCEY, D. J. **Structure from motion in the Geosciences**. [S.l.]: Wiley, 2016. 210 p. ISBN(9781118895849).
- CHADWICK, A. J.; GOODBODY, T. R. H.; COOPS, N. C.; HERVIEUX, A.; BATER, C. W.; MARTENS, L. A.; WHITE, B.; RÖESER, D. Automatic delineation and height measurement of regenerating conifer crowns under leaf-off conditions using uav imagery. **Remote Sensing**, v. 12, n. 24, p. 1–26, 2020.
- CUE LA ROSA, L. E.; OLIVEIRA, D. A. B.; ZORTEA, M.; HOLTZ GEMIGNANI, B.; QUEIROZ FEITOSA, R. Learning geometric features for improving the automatic detection of citrus plantation rows in UAV images. **IEEE Geoscience and Remote Sensing Letters**, v. 19, p. 1–5, 2020.
- DADRASJAVAN, F.; SAMADZADEGAN, F.; SEYED POURAZAR, S. H.; FAZELI, H. UAV-based multispectral imagery for fast Citrus Greening detection. **Journal of Plant Diseases and Protection**, 2019.
- DE CARVALHO, O. L. F.; DE CARVALHO, O. A.; ALBUQUERQUE, A. O.; BEM, P. P.; SILVA, C. R.; FERREIRA, P. H. G.; DE MOURA, R. D. S.; GOMES, R. A. T.; GUIMARÃES, R. F.; BORGES, D. L. Instance segmentation for large, multi-channel remote sensing imagery using mask-RCNN and a mosaicking approach. **Remote Sensing**, v. 13, n. 1, p. 1–24, 2021.
- DENG, X.; ZHU, Z.; YANG, J.; ZHENG, Z.; HUANG, Z.; YIN, X.; WEI, S.; LAN, Y. Detection of citrus huanglongbing based on multi-input neural network model of UAV hyperspectral remote sensing. **Remote Sensing**, v. 12, n. 17, p. 1–20, 2020.
- DI GENNARO, S. F.; MATESE, A. Evaluation of novel precision viticulture tool for canopy biomass estimation and missing plant detection based on 2.5D and 3D approaches using RGB images acquired by UAV platform. **Plant Methods**, v. 16, n. 1, p. 1–12, 2020.
- DONG, X.; ZHANG, Z.; YU, R.; TIAN, Q.; ZHU, X. Extraction of information about individual trees from high-spatial-resolution uav-acquired images of an orchard. **Remote Sensing**, v. 12, n. 1, p. 1–21, 2020.
- ERPEN, L.; MUNIZ, F. R.; MORAES, T. S.; TAVANO, E. C. R. Análise do cultivo da laranja no Estado de São Paulo de 2001 a 2015. **Revista IPecege**, v. 4, n. 1, p. 33–43, 2018.
- FAN, Z.; LU, J.; GONG, M.; XIE, H.; GOODMAN, E. D. Automatic tobacco plant detection in UAV images via deep neural networks. **IEEE Journal of Selected**

Topics in Applied Earth Observations and Remote Sensing, v. 11, n. 3, p. 876–887, 2018.

FOOD AND AGRICULTURE ORGANIZATION (FAO). **Crops**. Disponível em: <<http://www.fao.org/faostat/en/#data/QC>>. Acesso em: 10 mar. 2021.

FRANCO, A. S. M. O Suco de laranja brasileiro no mercado global. **Análise Conjuntural**. 2016. Disponível em: <http://www.ipardes.gov.br/biblioteca/docs/bol_38_6_c.pdf>.

FUNDO DE DEFESA DA CITRICULTURA (FUNDECITRUS). **Inventário de árvores do cinturão citrícola de São Paulo e Triângulo/Sudoeste Mineiro: retrato dos pomares em março de 2021**. Araraquara, SP: Fundecitrus, 2021.

FUNDO DE DEFESA DA CITRICULTURA (FUNDECITRUS). **Estimativa da safra de laranja 2020/21 São Paulo e Triângulo/Sudoeste Mineiro**. 2020a. Disponível em: <http://marefateadyan.nashriyat.ir/node/150>.

FUNDO DE DEFESA DA CITRICULTURA (FUNDECITRUS). **Inventário de árvores do cinturão citrícola de São Paulo e Triângulo/Sudoeste Mineiro: retrato dos pomares em março de 2020**. Araraquara: Fundecitrus, 2020b.

FUNDO DE DEFESA DA CITRICULTURA (FUNDECITRUS). **Levantamento da incidência das doenças dos citros: Greening, CVC e cancro cítrico no Cinturão Citrícola de São Paulo e Triângulo/Sudoeste Mineiro 2019**. Araraquara, SP: Fundecitrus, 2020c.

FUTCH, S.; WEINGARTEN, S.; IREY, M. Determining HLB infection levels using multiple survey methods in florida citrus. **Proceedings of the Florida State Horticultural Society**, v. 122, p. 152–157, 2009.

GARCIA-RUIZ, F.; SANKARAN, S.; MAJA, J. M.; LEE, W. S.; RASMUSSEN, J.; EHSANI, R. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106–115, 2013.

GARZA, B. N.; ANCONA, V.; ENCISO, J.; PEROTTO-BALDIVIESO, H. L.; KUNTA, M.; SIMPSON, C. Quantifying citrus tree health using true color UAV images. **Remote Sensing**, v. 12, n. 1, p. 1–13, 2020.

GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science**, v. 327, n. 5967, p. 828–831, 2010.

GONÇALVES, D. N.; DE ARRUDA, M. S.; PISTORI, H.; FERNANDES, V. J. M.; RAMOS, A. P. M.; FURUYA, D. E. G.; OSCO, L. P.; HE, H.; LI, J.; MARCATO JUNIOR, J.; GONÇALVES, W. N. A Deep learning approach based on graphs to detect plantation lines. **Arxiv**, , 2021.

GUERREIRO NETO, G. **Perfil e tendências da cultura da laranja dentro do cinturão citrícola (São Paulo e triângulo/sudoeste mineiro) para o citricultor**. 2019. Dissertação (Mestrado em Administração) - Universidade Estadual Paulista, Jaboticabal, 2019.

HALL, D. G.; SHATTERS, R. G.; CARPENTER, J. E.; SHAPIRO, J. P. Research toward an artificial diet for adult Asian citrus psyllid. **Annals of the Entomological Society of America**, v. 103, n. 4, p. 611–617, 2010.

HAO, Z.; LIN, L.; POST, C. J.; MIKHAILOVA, E. A.; LI, M.; CHEN, Y.; YU, K.; LIU, J. Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R-CNN). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 178, p. 112–123, 2021.

HE, K.; GKIOXARI, G.; DOLLAR, P.; GIRSHICK, R. Mask R-CNN. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2017. **Proceedings...** IEEE, 2017. p. 2961–2969.

HERBEI, M. V.; POPESCU, C. A.; BERTICI, R.; SMULEAC, A.; POPESCU, G. Processing and use of satellite images in order to extract useful information in precision agriculture. **Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Agriculture**, v. 73, n. 2, p. 238, 2016.

HUNT, E. R.; DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing**, v. 39, n. 15–16, p. 5345–5376, 2018.

JAYATHUNGA, S.; OWARI, T.; TSUYUKI, S. Evaluating the performance of photogrammetric products using fixed-wing UAV imagery over a mixed conifer-broadleaf forest: comparison with airborne laser scanning. **Remote Sensing**, v. 10, n. 2, 2018.

JUNG, J.; MAEDA, M.; CHANG, A.; BHANDARI, M.; ASHAPURE, A.; LANDIVAR-BOWLES, J. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. **Current Opinion in Biotechnology**, v. 70, p. 15–22, 2021.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: a survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018.

KATAOKA, T.; KANEKO, T.; OKAMOTO, H.; HATA, S. Crop growth estimation system using machine vision. **IEEE/ASME International Conference on Advanced Intelligent Mechatronics, AIM**, v. 2, p. 1079–1083, 2003.

- KRAUSE, S.; SANDERS, T. G. M.; MUND, J. P.; GREVE, K. UAV-based photogrammetric tree height measurement for intensive forest monitoring. **Remote Sensing**, v. 11, n. 7, p. 1–18, 2019.
- LAN, Y.; HUANG, Z.; DENG, X.; ZHU, Z.; HUANG, H.; ZHENG, Z.; LIAN, B.; ZENG, G.; TONG, Z. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. **Computers and Electronics in Agriculture**, v. 171, 2020.
- LEIVA, J. N.; ROBBINS, J.; SARASWAT, D.; SHE, Y.; EHSANI, R. Evaluating remotely sensed plant count accuracy with differing unmanned aircraft system altitudes, physical canopy separations, and ground covers. **Journal of Applied Remote Sensing**, v. 11, n. 3, e036003, 2017.
- LIN, H.; CHEN, C.; DODDAPANENI, H.; DUAN, Y.; CIVEROLO, E. L.; BAI, X.; ZHAO, X. A new diagnostic system for ultra-sensitive and specific detection and quantification of *Candidatus Liberibacter asiaticus*, the bacterium associated with citrus Huanglongbing. **Journal of Microbiological Methods**, v. 81, n. 1, p. 17–25, 2010.
- LUVISI, A.; AMPATZIDIS, Y. G.; DE BELLIS, L. Plant pathology and information technology: opportunity for management of disease outbreak and applications in regulation frameworks. **Sustainability (Switzerland)**, v. 8, n. 8, 2016.
- MA, L.; LIU, Y.; ZHANG, X.; YE, Y.; YIN, G.; JOHNSON, B. A. Deep learning in remote sensing applications: a meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, p. 166–177, 2019.
- MACHEFER, M.; LEMARCHAND, F.; BONNEFOND, V.; HITCHINS, A.; SIDIROPOULOS, P. Mask R-CNN refitting strategy for plant counting and sizing in uav imagery. **Remote Sensing**, v. 12, n. 18, p. 1–23, 2020.
- MARQUES, P.; PÁDUA, L.; ADÃO, T.; HRUŠKA, J.; PERES, E.; SOUSA, A.; SOUSA, J. J. UAV-based automatic detection and monitoring of chestnut trees. **Remote Sensing**, v. 11, n. 7, p. 1–32, 2019.
- MATTOS, A. B.; ZORTEA, M.; MACEDO, M. M. G.; RUGA, B. C.; GEMIGNANI, B. H. Automatic citrus tree detection from UAV images based on convolutional neural networks intravascular optical coherence tomography image analysis view project. In: CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 31., 2018. **Proceedings...** 2018.
- MOHAN, M.; SILVA, C. A.; KLAUBERG, C.; JAT, P.; CATTS, G.; CARDIL, A.; HUDAK, A. T.; DIA, M. Individual tree detection from unmanned aerial vehicle

(UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, v. 8, n. 9, p. 1–17, 2017.

MOREIRA, A.; SANTOS, M. Y. Concave hull: a K-Nearest neighbours approach for the computation of the region occupied by a set of points. In: INTERNATIONAL CONFERENCE ON COMPUTER GRAPHICS THEORY AND APPLICATIONS, 2., 2007. **Proceedings...** 2007. p. 61-68.

NEVES, F.; TROMBIN, V. G.; MILAN, P.; FONSECA LOPES, F.; CRESSONI, F. K. R. **O retrato da citricultura brasileira**. [S.l.]: Markestrat, 2010.

OLIVEIRA, H. C.; GUIZILINI, V. C.; NUNES, I. P.; SOUZA, J. R. Failure detection in row crops from UAV images using morphological operators. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 7, p. 991–995, 2018.

OSCO, L. P.; DE ARRUDA, M. S.; MARCATO JUNIOR, J.; DA SILVA, N. B.; RAMOS, A. P. M.; MORYIA, É. A. S.; IMAI, N. N.; PEREIRA, D. R.; CRESTE, J. E.; MATSUBARA, E. T.; LI, J.; GONÇALVES, W. N. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 160, p. 97–106, 2020.

OSCO, L. P.; DOS SANTOS DE ARRUDA, M.; GONÇALVES, D. N.; DIAS, A.; BATISTOTI, J.; DE SOUZA, M.; GOMES, F. D. G.; RAMOS, A. P. M.; DE CASTRO JORGE, L. A.; LIESENBERG, V.; LI, J.; MA, L.; MARCATO, J.; GONÇALVES, W. N. A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 174, p. 1–17, 2021.

PÁDUA, L.; VANKO, J.; HRUŠKA, J.; ADÃO, T.; SOUSA, J. J.; PERES, E.; MORAIS, R. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2349–2391, 2017.

PLEȘOIANU, A. I.; STUPARIU, M. S.; ȘANDRIC, I.; PĂTRU-STUPARIU, I.; DRĂGUȚ, L. Individual tree-crown detection and species classification in very high-resolution remote sensing imagery using a deep learning ensemble model. **Remote Sensing**, v. 12, n. 15, 2020.

RAMESH, K. N.; CHANDRIKA, N.; OMKAR, N. S.; MEENAVATHI, M. B.; REKHA, V. Detection of rows in agricultural crop images acquired by remote sensing from a UAV. **International Journal of Image, Graphics and Signal Processing**, v. 8, n. 11, p. 25–31, 2016.

RANSON, K. J.; DAUGHTRY, C. S. T. Scene shadow effects on multispectral response. **IEEE Transactions on Geoscience and Remote Sensing**, v. 25, n. 4, p. 502–509, 1987.

RODRIGUES, R. **Detection of sugarcane crop rows from UAV images using semantic segmentation and radon transform**. 2020. 101p. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Uberlândia, Uberlândia, 2020.

ROSSI, F. R. **Determinantes da adoção de irrigação por citricultores da região centro-norte do Estado de São Paulo**. 2017. 254 p. Tese (Doutorado em Gestão de Sistemas Agroindustriais) – Universidade Federal de São Carlos, São Carlos, 2017.

SÃO PAULO. GOVERNO DO ESTADO. **Citricultura gera mais de 48 mil vagas de empregos no Estado em 2019**. Disponível em: <<https://www.saopaulo.sp.gov.br/spnoticias/citricultura-gera-mais-de-48-mil-vagas-de-empregos-no-estado-em-2019/>>. Acesso em: 15 mar. 2020.

SHAO, L.; TIAN, Y.; BOHG, J. ClusterNet: 3D instance segmentation in RGB-D images. **Arxiv**, 2018.

SOARES, G. A.; ABDALA, D. D.; ESCARPINATI, M. C. Plantation rows identification by means of image tiling and hough transform. In: INTERNATIONAL JOINT CONFERENCE ON COMPUTER VISION, IMAGING AND COMPUTER GRAPHICS THEORY AND APPLICATIONS, 13., 2018. **Proceedings...** Visigrapp, 2018. p. 453–459.

ULLO, S.; MOHAN, A.; SEBASTIANELLI, A.; AHAMED, S.; KUMAR, B.; DWIVEDI, R.; SINHA, G. A new mask R-CNN-based method for improved landslide detection. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 3799–3810, 2021.

WALEED, A. **Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow**. Disponível em: <https://github.com/matterport/Mask_RCNN>. Acesso em: 19 jun. 2020.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, v. 236, p. 111402, 2020.

WU, J.; YANG, G.; YANG, X.; XU, B.; HAN, L.; ZHU, Y. Automatic counting of in situ rice seedlings from UAV images based on a deep fully convolutional neural network. **Remote Sensing**, v. 11, n. 6, 2019.

WU, Q.; FENG, D.; CAO, C.; ZENG, X.; FENG, Z.; WU, J.; HUANG, Z.
Improved mask r-cnn for aircraft detection in remote sensing images. **Sensors**, v. 21, n. 8, 2021.

YU, K.; HAO, Z.; POST, C. J.; MIKHAILOVA, E. A.; LIN, L.; ZHAO, G.; TIAN, S.; LIU, J. Comparison of classical methods and mask R-CNN for automatic tree detection and mapping using UAV imagery. **Remote Sensing**, v. 14, n. 2, 2022.