

## DETECÇÃO SEMIAUTOMÁTICA DE ÁRVORES EM POMAR DE MANGUEIRA IRRIGADA A PARTIR DE IMAGENS OBTIDAS POR DRONE

CARLOS ANDRÉ DE SOUZA SÁ<sup>1</sup>; MAGNA SOELMA BESERRA DE MOURA<sup>1,2</sup>;  
JOSICLÊDA DOMICIANO GALVÍNCIO<sup>3</sup>; RODRIGO DE QUEIROGA MIRANDA<sup>3</sup>;  
MARCELO JOSÉ DA SILVA<sup>4</sup> E CLOVES VILAS BOAS DOS SANTOS<sup>3</sup>

<sup>1</sup> Programa de Pós Graduação em Engenharia Agrícola, Universidade Federal do Vale do São Francisco, Av. Antônio Carlos Magalhães, 510, Santo Antônio, CEP 48.903-210, Juazeiro, BA, Brasil, carlosandreaagronomia@outlook.com; magna.soelma@gmail.com.

<sup>2</sup> Embrapa Semiárido, BR 428, Km 152, s/n, Zona Rural, Petrolina, PE, Brasil, magna.moura@embrapa.br.

<sup>3</sup> Programa de Pós Graduação em Desenvolvimento e Meio Ambiente, Universidade Federal de Pernambuco, Av. Acadêmico Hélio Ramos, s/n, Cidade Universitária, 50.740-530, Recife, PE, Brasil, josicleda.galvencio@ufpe.br, rodrigo.qmiranda@gmail.com, clovesvilasboas@gmail.com.

<sup>4</sup> Programa de Pós Graduação em Engenharia Agrícola, Universidade Federal Rural de Pernambuco, Rua Dom Manuel de Medeiros, s/n, Dois Irmãos, CEP 52.171-900, Recife, PE, Brasil, marcelosilvaagr@gmail.com.

### 1 RESUMO

O monitoramento da população de plantas em áreas agrícolas é fundamental para acompanhar a produtividade, auxiliar no planejamento e na tomada de decisão. Assim, objetivou-se propor um protocolo para identificação remota de árvores de mangueiras no Submédio do Vale do São Francisco por meio de *softwares* e *plugins* gratuitos aplicados em imagens aéreas obtidas com drones. O estudo foi desenvolvido em três pomares de mangueira, empregando-se modelos digitais obtidos a partir de ortomosaicos gerados em três qualidades de processamento; avaliados no QGIS utilizando-se os *plugins* ‘Tree Density Calculator’ e ‘SAGA GIS’. Os resultados obtidos foram avaliados por meio dos índices de Precisão, Revocação e F1–Score. O índice de Precisão foi mais elevado para o processamento em qualidade baixa. O índice de Revocação apresentou maiores valores no processamento em qualidade média e elevada, indicando que quanto maior a qualidade do processamento, maior é a chance de acertar na contagem de árvores. Os maiores valores de F1–Score foram observados para o *Tree Density Calculator* com processamento na resolução baixa. Recomenda-se o uso de um protocolo para a identificação e contagem remota de árvores de mangueiras, de forma semiautomática por meio da utilização de imagens obtidas por VANTs e *softwares* de código livre e aberto.

**Palavras-chave:** Identificação de árvores, mangicultura, sensoriamento remoto, veículo aéreo não tripulado.

SÁ, C. A. S.; MOURA, M. S. B.; GALVÍNCIO, J. D.; MIRANDA, R. Q.; SILVA, M. J.;  
SANTOS, C. V. B.

SEMIAUTOMATIC DETECTION OF TREES IN IRRIGATED MANGO ORCHARD  
FROM DRONE IMAGES

## 2 ABSTRACT

The monitoring of plant populations in agricultural areas is essential to follow the productivity, assisting in planning and decision making. Thus, our objective was to propose a protocol for remote detection of mango trees in the *Low-Middle of the Sao Francisco River Valley*, by using free software and plugins applied on aerial drone images. The study was conducted in three mango orchards. We used digital models extracted from orthomosaics created under three level of quality; then they were evaluated on the package QGIS with the plugins ‘Tree Density Calculator’ and ‘SAGA GIS’. The results were evaluated with the indices Precision, Recall and F1–Score. The precision index was higher for low-quality processing; while the recall index showed higher values under medium and high quality, indicating that the higher the quality of the processing, the greater is the chance of acquiring an efficient tree counting. The highest F1–Score values were observed for the Tree Density Calculator plugin with low processing resolution. We recommend using this protocol for the remote identification and counting of mango trees, in a semiautomatic methodology by using aerial images obtained using drones and free software and plugins.

**Keywords:** Identification of trees, mango cultivation, remote sensing, unmanned aerial vehicle.

## 3 INTRODUÇÃO

O Brasil se destaca com elevada produção agrícola principalmente devido às propícias condições edafoclimáticas e aos investimentos públicos e privados em pesquisas, tecnologia e infraestrutura para maximizar a produção (PASSOS; FONTES; NASCIMENTO, 2020). Dentre as frutíferas mais exploradas economicamente no Brasil, a mangueira (*Mangifera indica* L.) se destaca, tornando o país o sétimo maior produtor mundial (FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS, 2019), superado apenas pela Índia, Indonésia, China, México, Paquistão e Malawi. Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE)/SIDRA, a produção total de manga no Brasil no ano de 2020 foi de 1.569.011 toneladas, com destaque para as cultivares Tommy Atkins, Keitt, Kent e Palmer, que são as principais responsáveis pelas exportações brasileiras. Nesse mesmo ano, a região Nordeste foi responsável pela maior parte da produção brasileira, obtendo em torno de 1.230.995 toneladas, com destaque para Pernambuco, maior estado produtor do

país, que contribuiu com a produção de 624.611 toneladas da fruta (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2021). Apesar das restrições hídricas e de solo (estrutura, textura e nutrientes) encontradas em parte do interior do nordeste (AMARAL, 2011), a região do Submédio do Vale do São Francisco, localizada na porção central do Semiárido brasileiro, tem apresentado os maiores índices de produtividade, exportando em torno de 87% da manga produzida no Brasil.

Com a expansão das áreas agrícolas, informações sobre o número exato de árvores frutíferas são fundamentais, tanto para estimar a taxa de sobrevivência das plantas quanto para acompanhar sua produtividade (LI et al., 2017; MASCHLER; ATZBERGER; IMMITZER, 2018), inclusive sendo útil para o cálculo de estoques de carbono (ZHANG, 2019). A detecção e a quantificação da vegetação têm diversos propósitos, incluindo a obtenção de informações sobre o estado de saúde das plantas (BARNES et al., 2017), avaliação da vegetação relacionada a parâmetros indiretos, a exemplo da porcentagem de

cobertura verde (HERNÁNDEZ-HERNÁNDEZ et al., 2016), dentre outros como estado nutricional e hídrico, que juntos auxiliam nas tomadas de decisão dentro da propriedade. Além disso, a geração de dados georreferenciados sobre os pomares são extremamente úteis para o desenvolvimento da agricultura 4.0.

Normalmente, o processo de contagem de plantas ocorre manualmente por trabalhadores rurais, apesar da eficácia quanto a identificação, esse método torna-se bastante ineficiente devido à alta demanda de horas-homens (ABIDIN et al., 2017). Por sua vez, o sensoriamento remoto torna-se uma importante alternativa para automatizar o processo de contagem de plantas a partir da aquisição de informações sem o contato direto com os alvos, com o uso de imagens com alta resolução espacial (LI et al., 2017). Neste sentido, buscando melhorar a qualidade no levantamento da área cultivada, o uso de veículos aéreos não tripulados (VANTs) torna-se uma importante alternativa pois fornece dados aéreos de sensoriamento remoto com altas resoluções temporais e espaciais, e a custos mais baixos para coberturas de áreas pequenas e médias quando comparados às plataformas aéreas tradicionais.

Por meio do uso dos VANTs é possível adquirir dados georreferenciados das culturas, a depender do tipo de sensor utilizado; além disso, pode-se explorar as diferentes partes do espectro eletromagnético utilizando o processamento digital das imagens (PÁDUA et al., 2020). Segundo esse mesmo autor, as imagens georreferenciadas podem ser utilizadas para calcular resultados ortorretificados por meio do processamento fotogramétrico, como mosaico de ortofotos, modelos digitais de elevação (DEM), índices espectrais, e diversos subprodutos do processamento digital.

O sucesso na identificação e quantificação do conjunto de árvores frutíferas depende da resolução espacial da

imagem; da dominância da árvore dentro do pomar quanto a sobreposição, união de copas, separação de galhos e geometria do alvo; topografia do terreno, e principalmente do tipo de sensor utilizado no processo de aquisição das imagens (OJEDA-MAGAÑA et al., 2020). Todos esses fatores podem atuar como facilitadores ou dificultar a contagem de árvores.

Automatizar o processo de análise de imagens digitais é bastante complexo, principalmente quando se trata da detecção de vegetação, tendo em vista seus parâmetros morfométricos, normalmente variáveis em condições naturais. Ojeda-Magaña et al. (2020), buscando detectar árvores de carvalho automaticamente, observaram que o tamanho, a forma e a cor da vegetação, assim como a borda da copa das árvores em contraste com imagens do solo e sua própria sombra são fatores que interferem diretamente na identificação correta das árvores. Os autores explicam que a detecção individual é prejudicada justamente pela dificuldade de delimitar a região de cada árvore, seja quando a sombra de uma árvore se projeta sobre si mesma ou quando se projeta no solo onde a copa das árvores e as sombras têm cores semelhantes ou mesmo quando a copa de uma árvore tem várias regiões.

De acordo com Arantes et al. (2020), para identificação da vegetação e validação dos resultados, não há uma única metodologia específica, e sim diversos estudos utilizando o sensoriamento remoto. Neste sentido, dispõe-se de diferentes técnicas e métodos para identificar árvores e seus elementos ou mesmo parâmetros métricos (diâmetro da copa, altura da planta, etc.), contudo a análise comparativa torna-se difícil devido a necessidade dos dados de referência e da métrica de avaliação (LI et al., 2016). Isso ocorre porque alguns métodos são baseados em classes espectrais, redes neurais de detecção, aprendizagem profunda e algoritmos para técnicas de análise de dados 'auto-organizados'. Em

contrapartida, os resultados da detecção das árvores também podem ser validados simplesmente comparando-os com resultados manuais, conforme Wagner et al. (2018) e Weinstein et al. (2019). No entanto, essas metodologias não são acessíveis para a maioria dos usuários, principalmente pela exigência de avançando conhecimento científico e uso de máquinas com maior capacidade de execução.

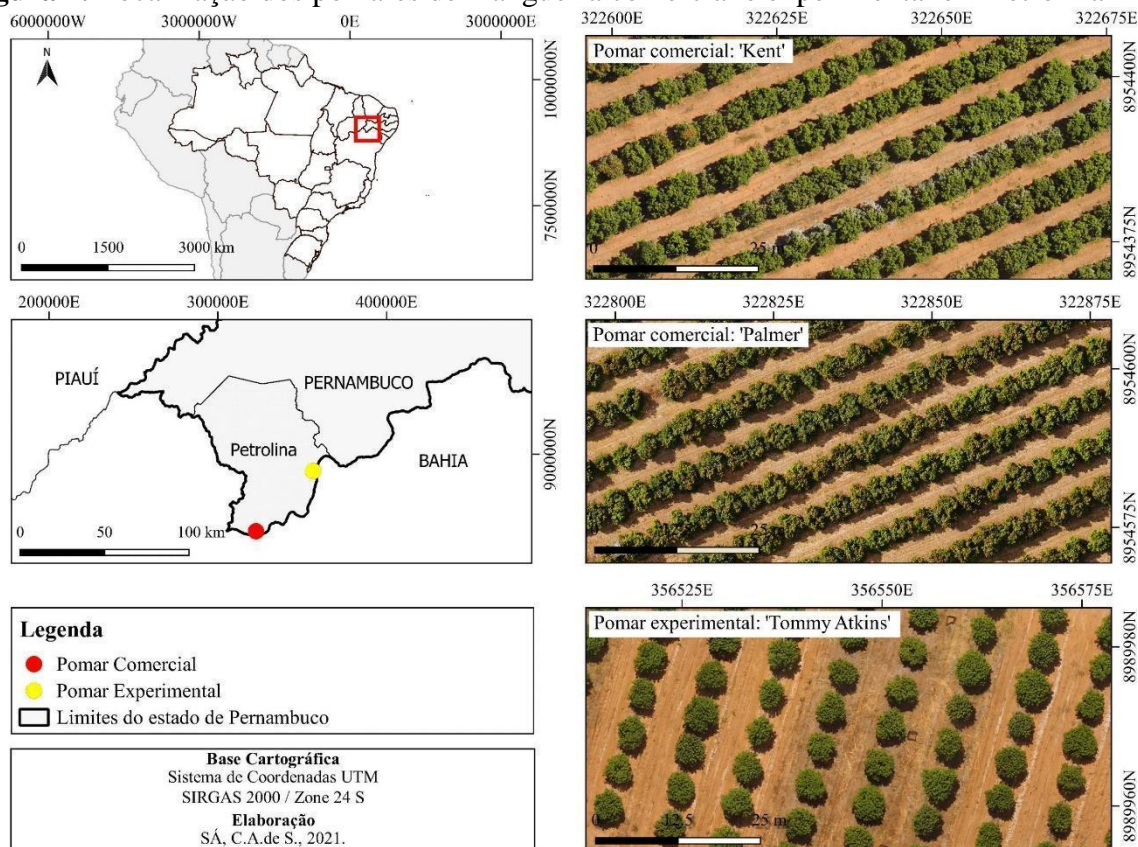
Com essas considerações, objetiva-se propor um protocolo para a identificação e contagem remota de árvores de mangueiras no Submédio do Vale São Francisco por meio de *software* e *plugin* gratuitos aplicados em imagens aéreas obtidas com

drones, e assim, fornecer informações para uma análise agrícola do pomar.

#### 4 MATERIAL E MÉTODOS

O estudo foi desenvolvido em três pomares de mangueira, sendo dois comerciais e um de pesquisa (Figura 1), localizados no município de Petrolina, Pernambuco, Submédio do Vale São Francisco. Segundo a classificação de Koppén, a região possui clima do tipo Bsw<sup>h</sup> (semiárido), com período chuvoso entre os meses de janeiro e abril (ÁLVARES et al., 2013).

**Figura 1.** Localização dos pomares de mangueira comercial e experimental em Petrolina-PE.



**Fonte:** Autores (2021).

Os três pomares utilizados para este estudo possuem cultivares de manga ‘Kent’ e ‘Palmer’ (pomares comerciais), e ‘Tommy Atkins’ (pomar experimental), cujas informações de plantio encontram-se na

Tabela 1. O solo das áreas comerciais foi classificado como arenoso (SANTOS et al., 2006), enquanto o solo experimental apresentou textura médio-argilosa (BRANDÃO et al., 2017).

**Tabela 1.** Informações dos pomares de mangueira.

Cultivar de mangueira	Área (ha)	Espaçamento (m)
Kent	3,54	4 x 7
Palmer	4,00	4 x 7
Tommy Atkins	0,86	5 x 8

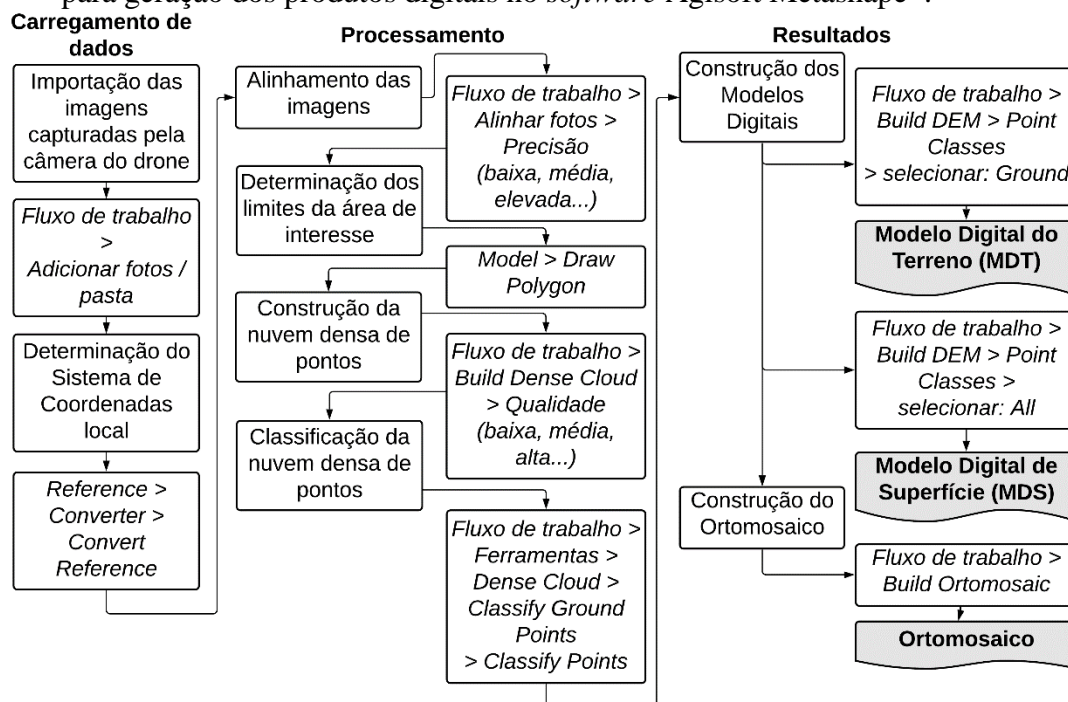
Fonte: Autores (2021).

Para a obtenção das imagens foram realizados voos utilizando o drone comercial DJI Phantom 3 Standard (DJI PHANTOM, 2021a) nos pomares da cultivar Kent e Tommy Atkins; e o drone DJI Phantom 4 Pro v2 (DJI PHANTOM, 2021b) para a área implantada com a cultivar Palmer, sendo o primeiro drone embarcado com sensor CMOS 1/2.3" de 12 Mp, FOV 94° 20 mm (formato equivalente de 35 mm) e abertura de f/2.8, e o segundo drone com sensor CMOS 1" de 20 Mp, FOV 84° 8,8 mm/24 mm (formato equivalente a 35 mm) e abertura de f/2.8-f/11. As aeronaves foram utilizadas de acordo com a disponibilidade nas épocas de realização dos voos. Ambas possuem registros segundo as normas brasileiras, assim como os planos de voo foram realizados obedecendo a legislação, com voos a 80 m de altura a fim de sobrevoar-se uma maior área por tempo de bateria, e a 50 m no pomar de 'Tommy Atkins' (área experimental). Foi adotada uma sobreposição lateral e frontal de 80% para garantir o fechamento do ortomosaico, e a câmera foi posicionada com ângulo de 90 graus em relação ao drone, ou seja, diretamente apontada ao solo e com configuração em modo manual de acordo com a iluminação da cena.

O processamento das imagens capturadas foi realizado com uso do *software* Agisoft Metashape Professional Edition 1.5.2<sup>®</sup> em sua versão trial, sendo gerados: modelo digital de superfície (MDS), modelo digital de terreno (MDT) e ortomosaico. A primeira etapa do processamento das imagens foi a geração dos produtos digitais (Figura 2), dos quais o ortomosaico, o MDS e o MDT são essenciais para a detecção de árvores neste estudo.

Contudo, a depender da variável analisada a qualidade do processamento pode interferir nos resultados. Segundo Hyslop et al. (2020) existem basicamente três tipos de modelos digitais que podem ser obtidos com o processamento das imagens obtidas por satélites ou VANTs: Modelo Digital de Elevação (MDE), que capta a elevação, assim como o dossel vegetal; Modelo Digital de Terreno (MDT), que capta a elevação com base no terreno, ignorando as elevações sobre o solo; e o Modelo Digital de Superfície (MDS), que capta todas as elevações sobre o solo (como edificações, ruas, árvores etc). O resultado desses produtos depende de vários fatores, desde antes do processamento, como resolução, sobreposição frontal e lateral das fotografias, luminosidade e altitude do VANT na coleta das imagens, assim como a escolha da qualidade de processamento das imagens dentro do *software*. Deste modo, foi realizado o processamento das imagens para cada pomar de mangueira, em três qualidades de processamento: baixa (B), média (M) e elevada (E). Por último, o próprio *software* emite um relatório com os detalhes dos produtos gerados. Nesse relatório constam informações sobre a câmera utilizada, os produtos gerados e a resolução desses, e é dado através do *Ground Sample Distance* (GSD). O GSD é a representação do pixel da imagem em unidades de terreno e está associado à qualidade final do processamento por meio do nível de detalhamento do levantamento aéreo. O valor dado pelo GSD é inversamente proporcional ao nível de detalhamento, ou seja, quanto maior o GSD, menor é o nível de detalhamento e vice-versa.

**Figura 2.** Etapas de processamento de imagens obtidas com VANT em pomar de mangueira para geração dos produtos digitais no *software* Agisoft Metashape®.



Fonte: Autores (2021).

Após a geração dos produtos (modelos digitais e ortomosaicos) de todas as áreas imageadas, os mesmos foram recortados para delimitar as áreas de interesse no pomar. Esse recorte é necessário para eliminar objetos que não sejam de interesse para o estudo e que geralmente se encontram ao redor da área de interesse, como construções, veículos, reservatórios, pessoas e outros pontos considerados como elevação, com a finalidade de que esses não interfiram na geração do MDS e MDT. A geração do Modelo Digital de Altura (MDH) ocorreu a partir da subtração do MDS pelo MDT, para o qual foi utilizado o QGIS®. Para isso, primeiramente foi criado um 'shape' (arquivo) com os limites da área a ser estudada e por meio da ferramenta 'Raster' foi realizado o recorte com base na 'camada de máscara' (arquivos com os limites da área), obtendo-se como produto os mesmos modelos digitais, porém agora recortados para a área de estudo. A geração do MDH foi realizada pela ferramenta 'Raster' utilizando-se a 'Calculadora

Raster', os arquivos MDS e MDT (recortados) e a equação:  $MDH = MDS - MDT$ . Posteriormente, procedeu-se ao recorte do ortomosaico, necessário para a contagem manual das árvores. Essa contagem foi essencial para validar os resultados, e também é uma exigência para o processo de contagem automatizada.

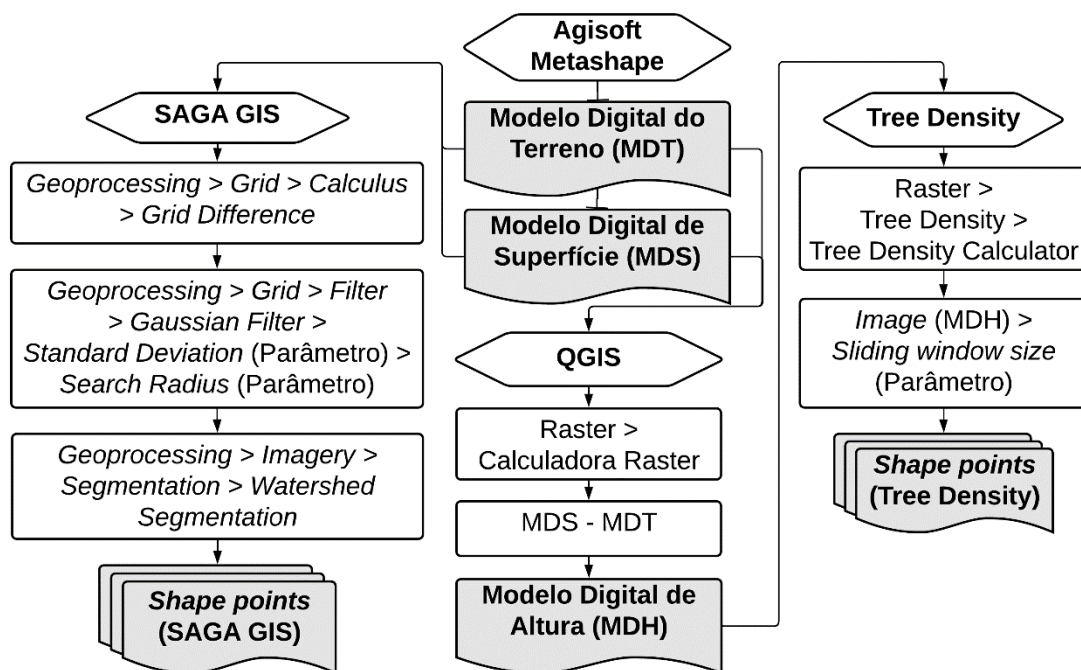
Para a realização deste estudo, foi utilizado o *software* QGIS versão 3.10.8-A Coruña®, e testados os *plugins* *Tree Density Calculator* versão 1.5.7 (CRABBÉ et al., 2020) e *SAGA System for Automated Geoscientific Analyses* versão 2.3.2 (CONRAD et al., 2015), todos livres. Como uma ferramenta gratuita e de fácil utilização, esses dois *plugins* foram avaliados quanto a sua capacidade de contagem de árvores de mangueira.

Após gerar, recortar e preparar os produtos digitais, foi realizado o processamento para identificação das árvores utilizando os *plugins* 'Tree Density' (a partir do MDH) e 'SAGA' (a partir do MDS e MDT), sendo gerados dois arquivos

com os pontos detectados, um para cada plugin, aqui denominados como ‘*shape points*’ (Figura 3). Em seguida, foi realizada a identificação e a contagem manual de cada árvore presente em todos os pomares com o propósito de comparar os resultados obtidos automaticamente com estes obtidos

manualmente. A partir do cálculo da população de plantas, levando-se em consideração o espaçamento da cultura, comparou-se o estande teórico e o real, além de ser realizada a verificação quanto a quantidade de árvores faltantes em cada pomar.

**Figura 3.** Etapas de processamento dos produtos digitais obtidos a partir de imagens de VANT para geração do *shape point* e a detecção de árvores de mangueira.



Fonte: Autores (2021).

O potencial de cada técnica proveniente da qualidade do processamento (baixa, média e alta), dos *plugins* (SAGA e *Tree Density*) e das cultivares (‘Kent’, ‘Palmer’ e ‘Tommy Atkins’) foi avaliado utilizando-se os índices de Precisão (Equação 1), Revocação (Equação 2) e F1-Score (Equação 3), nos quais árvores detectadas, pontos incorretos e árvores não detectadas correspondem aos números de verdadeiros positivos (VP), falsos positivos

(FP) e falsos negativos (FN), respectivamente, em uma tabela de contingência. As diferenças estatísticas entre os valores médios de *Ground Sample Distance* do ortomosaico e MDE entre as áreas de estudo e qualidades de processamento foram avaliadas usando a análise de variância (ANOVA) *One-way*. Todas as estatísticas foram realizadas usando o pacote R v3.5.3 (R CORE TEAM, 2020).

$$\text{Precisão} = \text{VP} / (\text{VP} + \text{FP}) \quad (01)$$

$$\text{Revocação} = \text{VP} / (\text{VP} + \text{FN}) \quad (02)$$

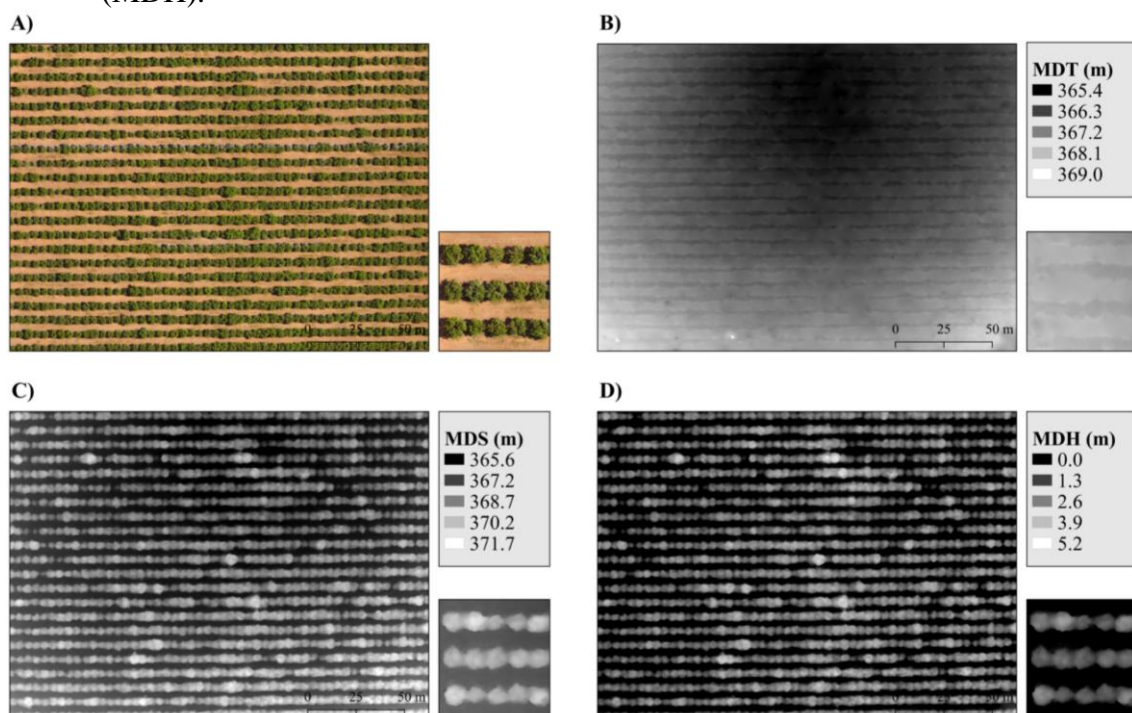
$$\text{F1-Score} = 2 * (\text{Precisão} * \text{Revocação}) / (\text{Precisão} + \text{Revocação}) \quad (03)$$

## 5 RESULTADOS E DISCUSSÃO

Os ortomosaicos e os modelos digitais resultantes do processamento das imagens capturadas nos pomares de mangueira das cultivares ‘Kent’, ‘Palmer’ e ‘Tommy Atkins’ são apresentados nas Figuras 4, 5 e 6, respectivamente. Pode-se observar que os ortomosaicos das Figuras 4A e 5A apresentam as árvores de forma muito similar, pois ambos os voos foram realizados a 80 m de altura, mesmo que tenham sido utilizadas aeronaves diferentes (Phantom 3 e Phantom 4, respectivamente). Por sua vez, na Figura 6A percebe-se que as plantas estão apresentadas em maior tamanho, exatamente em função da altura de voo realizado a 50 m. Essas características resultaram em diferenças estatísticas no tamanho do pixel entre os pomares, sendo que o maior GSD do ortomosaico foi

verificado no pomar da cultivar Kent, seguido pela ‘Tommy Atkins’ e ‘Palmer’ (Tabela 2), implicando em diferenças na resolução dos ortomosaicos. Por outro lado, não se observou diferença significativa ( $p < 0,05$ ) ao se realizar o processamento das imagens nas qualidades baixa, média e alta, independente do pomar analisado (Tabela 2). Na prática, considerando um mesmo equipamento (computador ou notebook), realizar todas as etapas do processamento (Figura 2) em diferentes qualidades implica em vários tempos de processamento, sendo que o tempo necessário para se chegar aos produtos finais na resolução baixa é menor do que na resolução média, e por sua vez, este é menor do que na resolução alta. Assim, trata-se uma etapa importante quando se necessita de agilidade na entrega de produtos digitais na contratação de serviços na propriedade agrícola.

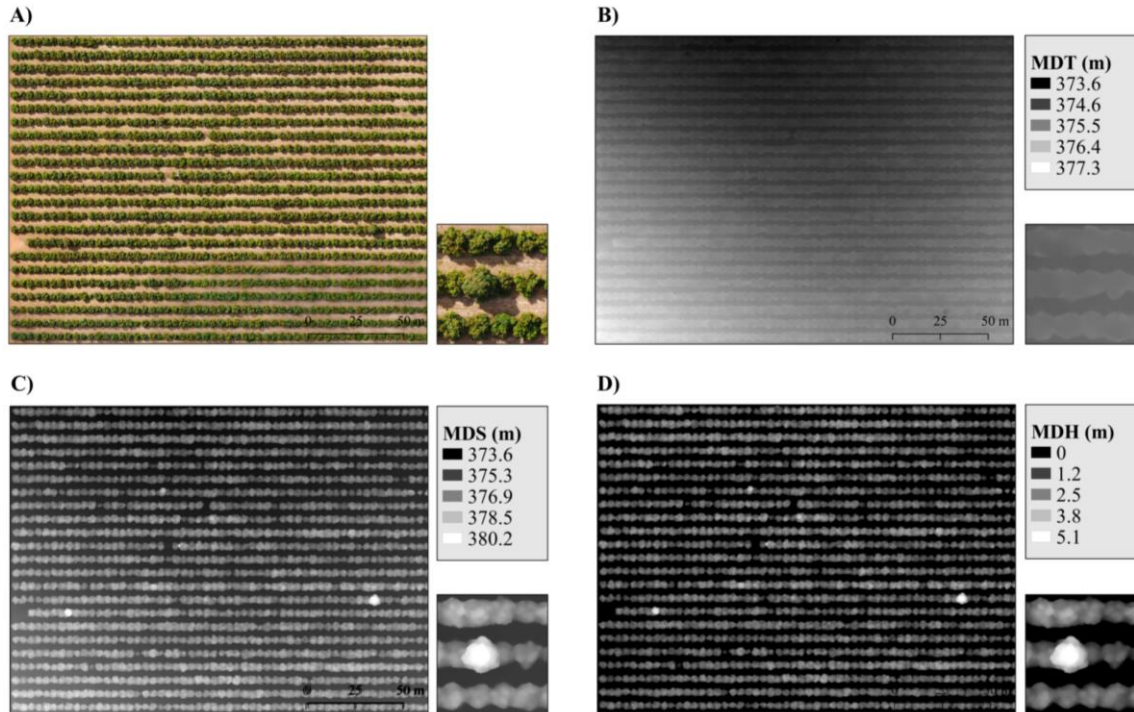
**Figura 4.** Produtos digitais obtidos a partir do processamento de imagens aéreas obtidas em VANT para o pomar de mangueira ‘Kent’: A) ortomosaico; B) modelo digital do terreno (MDT); C) modelo digital de superfície (MDS) e D) modelo digital de altura (MDH).



Fonte: Autores (2021).

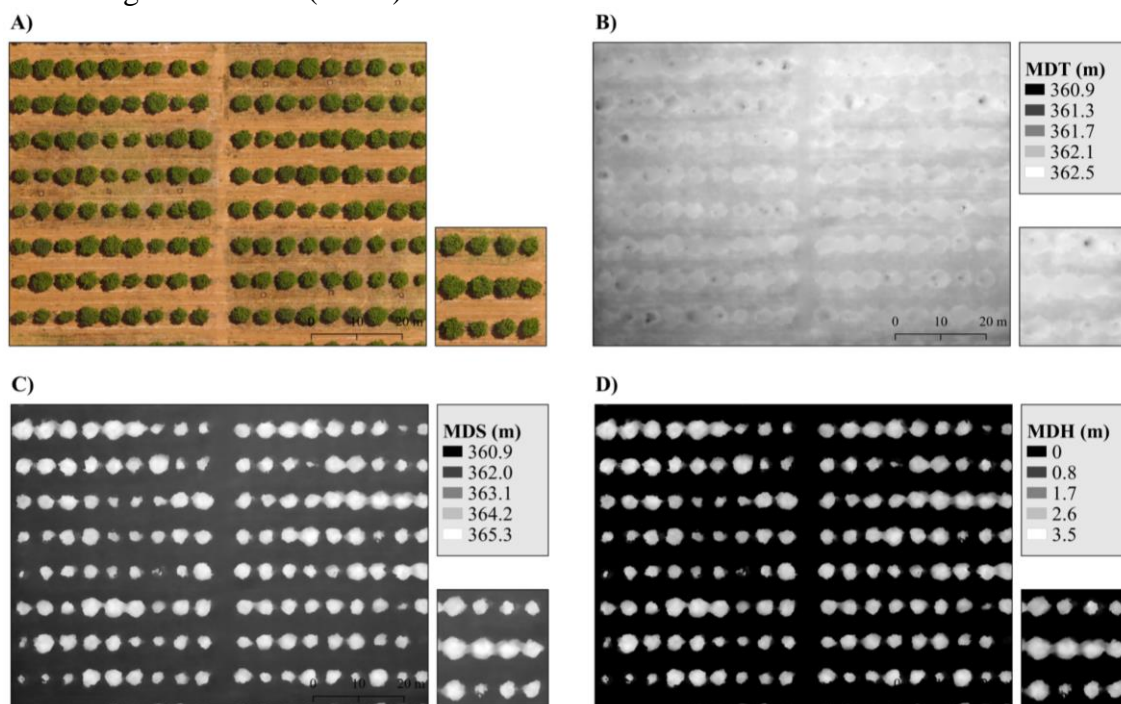


**Figura 5.** Produtos digitais obtidos a partir do processamento de imagens aéreas obtidas em VANT para o pomar de mangueira ‘Palmer’: A) ortomosaico; B) modelo digital do terreno (MDT); C) modelo digital de superfície - (MDS) e D) modelo digital de altura (MDH).



Fonte: Autores (2021).

**Figura 6.** Produtos digitais obtidos a partir do processamento de imagens aéreas obtidas em VANT para o pomar de mangueira ‘Tommy Atkins’: A) ortomosaico; B) modelo digital do terreno (MDT); C) modelo digital de superfície - (MDS) e D) modelo digital de altura (MDH).



Fonte: Autores (2021).

**Tabela 2.** Resolução do pixel do ortomosaico e do modelo digital de superfície (MDS) obtidos a partir do processamento em diferentes qualidades de imagens de VANT.

Cultivar implantada	Área (ha)	Qualidade do Processamento	GSD do Ortomosaico (cm/pixel)	GSD do MDS (cm/pixel)
Kent	3,54	Baixa	3,07 <sup>aA</sup>	24,6 <sup>aA</sup>
		Média	3,06 <sup>aA</sup>	12,2 <sup>aB</sup>
		Elevada	3,07 <sup>aA</sup>	6,15 <sup>aC</sup>
Palmer	4,00	Baixa	2,12 <sup>cA</sup>	17,0 <sup>aA</sup>
		Média	2,11 <sup>cA</sup>	8,45 <sup>aB</sup>
		Elevada	2,11 <sup>cA</sup>	4,22 <sup>aC</sup>
Tommy Atkins	0,86	Baixa	2,58 <sup>bA</sup>	20,7 <sup>aA</sup>
		Média	2,60 <sup>bA</sup>	10,4 <sup>aB</sup>
		Elevada	2,61 <sup>bA</sup>	5,22 <sup>aC</sup>

Observação: Letras minúsculas (a, b, c) diferentes significam diferença significativa ( $p < 0,05$ ) entre as diferentes áreas, enquanto letras maiúsculas (A, B, C) diferentes são relativas à diferentes qualidades de processamento. GSD: Ground Sample Distance.

Fonte: Autores (2021).

Os modelos digitais do terreno (MDT), da superfície (MDS) e de altura (MDH) são apresentados nas Figuras de 4 a 6 (B, C e D, respectivamente). Nota-se a partir do MDT que o desnível do solo é

pequeno para a área de 3,54 ha do pomar de ‘Kent’ (Figura 4B), assim como para o pomar de 4,0 ha da cultivar ‘Palmer’ (Figura 5B). Essas duas áreas estão relativamente próximas, apresentando características

topográficas semelhantes. Contudo, tratando-se do porte arbóreo das duas cultivares, as plantas de ‘Palmer’ (Figura 5D) são menores comparadas às plantas de ‘Kent’ (Figura 4D), característica observada por meio do MDH. Verifica-se que caso da ‘Palmer’ ocorrem poucas árvores com maior altura, que se destacam na cor branca (Figura 5D), com alturas em torno de 5,1 m, enquanto no pomar de ‘Kent’ a quantidade de árvores com porte mais elevado é bem maior (Figura 4D). Por se tratar de um pomar comercial de mangueiras, as árvores destacadas com maior altitude no pomar de ‘Palmer’, são oriundas de erro de plantio com a variedade de manga do tipo ‘Espada’.

O GSD associado aos modelos digitais não apresentou diferença estatística entre os pomares, porém, a qualidade dos processamentos (baixa, média e alta) resultou em diferentes qualidades dos modelos digitais (Tabela 2), sendo que os maiores valores foram verificados, em ordem decrescente, nas qualidades baixa, média e alta, quase dobrando entre elas. Isso implica que a maior qualidade de processamento resultou em maior resolução dos modelos digitais, que apresentaram quantitativamente muitos mais pontos.

Ao se analisar os produtos digitais obtidos a partir do processamento das imagens coletadas no pomar da cultivar ‘Tommy Atkins’, nota-se maior detalhamento e uniformidade do dossel das árvores (Figura 6A). A partir do MDT percebe-se também que o desnível do terreno é quase irrelevante para a área de aproximadamente 0,86 ha do pomar. Em se tratando de uma área experimental, as plantas estão mais espaçadas (Tabela 1) e o voo nesta área foi realizado a 50 m de altura, permitindo gerar o ortomosaico e os produtos digitais com menor GSD.

Segundo Arantes et al. (2020), ortomosaicos com copas de plantas bem espaçadas, torna mais fácil a identificação semiautomática de cada indivíduo. Em geral, imagens aéreas de altas resoluções

espaciais em áreas pequenas possibilitam a análise mais nítida da dimensão das copas das árvores, bem como a identificação correta do dossel de cada planta individualmente. Por este motivo, os produtos digitais do pomar da ‘Tommy Atkins’, especialmente o ortomosaico, permitem analisar com mais detalhes o dossel das plantas do campo.

Na construção dos modelos digitais foram observados valores negativos para o MDH de todos pomares (Figuras 4D, 5D e 6D). Ao perceber esse mesmo comportamento, Morte, Carvalho, Barros (2020) explicaram que mesmo os valores negativos sendo próximos a zero, o que ocorre em virtude de superestimativas da altitude do relevo, apesar de serem poucos, podem interferir no cálculo da altura média da copa das árvores, já que esses valores estariam incluídos no trechos de solo, portanto, para diminuir esses ruídos, os autores recomendam a aplicação de filtros para a eliminação dos valores inferiores a zero, gerando assim Modelos Digitais de Altura com maior precisão.

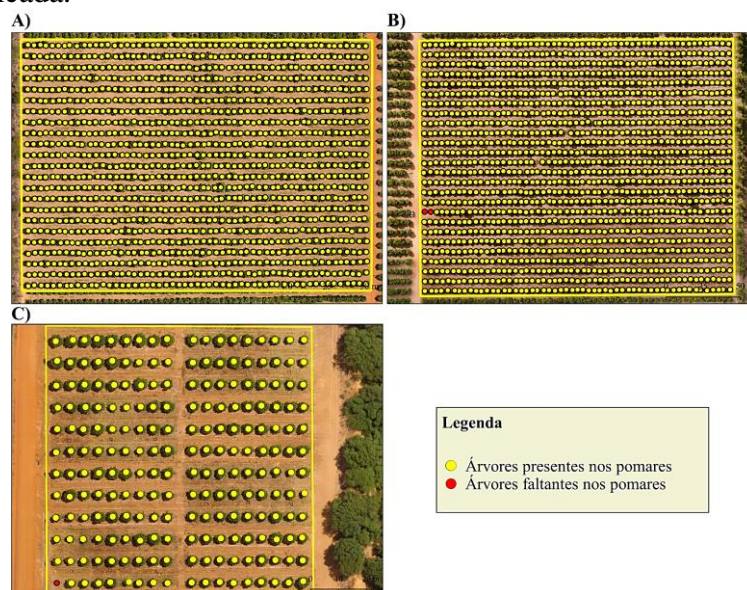
Após a geração dos produtos digitais, foi realizada a contagem manual das árvores de cada pomar para a validação dos resultados da detecção automática obtidos pelos *plugins*, conforme Wagner et al. (2018) e Weinstein et al. (2019). A contagem manual foi realizada em campo para fins de comprovação dos resultados e no *software* QGIS, utilizando como produto digital o ortomosaico, gerando um arquivo *shape points* para comparação com os resultados dos *plugins*. Nesse processo são adicionados pontos, um a um, sobre cada árvore identificada visualmente. Essa técnica não é classificada como a mais eficiente entre as demais, principalmente por requerer maior tempo e atenção do operador, para que não haja erros de omissão ou adição, no processo de interpretação visual..

Na Figura 7 são apresentados os resultados da contagem manual das árvores, totalizando 1.265 árvores no pomar de

manga ‘Kent’; 1.423 árvores no pomar da ‘Palmer’ e 215 árvores no pomar da mangueira ‘Tommy Atkins’. A partir do cálculo do estande de plantas para cada área e da análise visual dos ortomosaicos foram detectadas duas árvores faltantes no pomar

de manga ‘Palmer’ e uma árvore faltante no pomar da ‘Tommy Atkins’. Esses resultados foram usados para comparação com as saídas dos *plugins* testados em cada pomar, utilizando os produtos digitais nas diferentes resoluções.

**Figura 7.** Identificação manual de árvores para cada pomar: A) pomar de mangueira ‘Kent’ com 1.265 árvores presentes identificadas; B) pomar de mangueira ‘Palmer’ com 1.423 árvores presentes e duas árvores faltantes identificadas; C) pomar de mangueira ‘Tommy Atkins’ com 215 árvores presentes e uma árvore faltante identificada.



**Fonte:** Autores (2021).

No pomar da ‘Kent’ o melhor resultado para detecção semiautomática de árvores foi possível por meio do processamento em qualidade elevada e uso do *plugin* SAGA GIS, resultando em 1.251 árvores detectadas corretamente, o equivalente a 98,9% do estande real (Figura 8), restando apenas 14 árvores faltantes. Contudo, o total de pontos detectados e objetos incorretos com esse mesmo procedimento foi de 1.563.070 e 1.561.819, respectivamente. Este resultado, permite observar que a viabilidade da identificação de árvores não está associada apenas a qualidade do processamento, pois embora esta escolha tenha gerado o maior percentual de acertos, muitos pontos que não representam árvores também foram

identificados, demandando mais tempo ao operador para eliminação dos pontos detectados incorretamente. Em outras palavras, a detecção correta representa a identificação do pixel mais alto identificado na copa das árvores (FREITAS, 2021). Outros autores também obtiveram resultados semelhantes para a contagem de indivíduos, como Isip et al. (2018), que obtiveram uma precisão de 88,89% ao realizar a contagem de mangueiras com copas bem espaçadas, utilizando algoritmos para a detecção das árvores.

O processamento em qualidade média e uso do *plugin* *Tree Density*, classificado como o quarto melhor tratamento para detecção semiautomática de árvores, teve um resultado importante ao

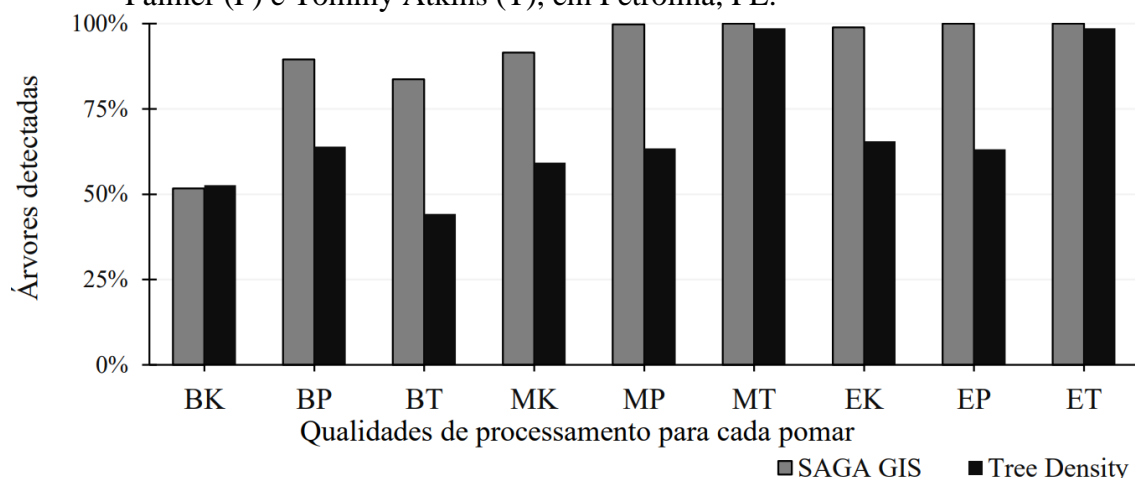
detectar apenas 1 objeto incorretamente, embora tenha identificado 750 árvores no pomar da ‘Kent’, o equivalente a 59,3% (Figura 8) do estande real e 515 árvores faltantes. Este foi o processamento que resultou no menor número de objetos identificados incorretamente.

O processamento em qualidade elevada e com o plugin SAGA GIS para o pomar da ‘Palmer’, resultou na identificação de 100% das árvores presentes no pomar (Figura 8), ou seja, de 1.426 árvores, saldo esse significativamente superior aos obtidos por meio do processamento realizado com o *plugin Tree Density*. Contudo, como observado no pomar da ‘Kent’, o número de pontos detectados (6.377.445 pontos) e objetos detectados incorretamente (6.376.019 pontos) é bastante superior ao valor real (1.426 árvores). Ainda sobre o uso do SAGA GIS, os processamentos nas qualidades média e baixa obtiveram resultados distintos, porém ambos com a mesma característica para a detecção de muitos objetos incorretos, a maioria dos pontos aglomerados nas extremidades das imagens e o restante em cima de árvores com copas interligadas. Quanto aos resultados

obtidos no pomar da ‘Palmer’ por meio do *plugin Tree Density*, estes não diferiram expressivamente quanto às qualidades de processamento, comportamento semelhante ao observado pelo mesmo tratamento aplicado para o pomar da ‘Kent’. A adoção desse *plugin* viabilizou a obtenção de informações sobre o estande de plantas em um tempo mais hábil para esse pomar, pois a obtenção dos modelos digitais com qualidade elevada requer muito mais tempo comparado ao processamento em qualidade baixa. Observou-se que o *plugin Tree Density* permitiu obter resultados satisfatórios independentemente da qualidade de processamento.

Quanto aos resultados obtidos no pomar da ‘Tommy Atkins’ (Figura 8) observou-se que o processamento realizado nas qualidades média e elevada permitiram a detecção de 100% das árvores ao utilizar-se o SAGA GIS e 98,6% com o *Tree Density*, sendo identificadas 215 e 212 árvores, respectivamente. O resultado obtido a partir do processamento em qualidade baixa e uso do *plugin Tree Density* se mostrou menos eficiente, ao identificar apenas 95 árvores.

**Figura 8.** Percentual de árvores detectadas corretamente (revocação) utilizando os *plugins* SAGA GIS e *Tree Density* para o processamento realizado nas qualidades baixa (B), média (M) e elevada (E), nos pomares de mangueira das cultivares Kent (K), Palmer (P) e Tommy Atkins (T), em Petrolina, PE.



Fonte: Autores (2021).

Na Tabela 3 são apresentados os valores para os índices de precisão, revocação e F1-Score considerando os tratamentos analisados. O índice de Precisão foi mais elevado para o processamento em qualidade baixa, independentemente da cultivar e do *plugin* avaliados; enquanto o índice de Revocação apresentou maiores valores no processamento em qualidade média e elevada, indicando que quanto maior a qualidade do processamento, maior a chance de acertar na contagem de árvores, uma vez que os modelos digitais obtidos apresentaram maior densidade de pontos. Para esse índice (Revocação), os melhores resultados foram verificados com o *plugin* SAGA GIS (Tabela 3). Em um estudo

anterior que compartilhou algumas das metodologias propostas nesta pesquisa, Gonçalves et al. (2019), alcançaram melhor detecção por meio do *plugin* SAGA GIS, ao avaliar espécies invasoras. Para seleção de *plugin*, considerou-se o F1-Score, que associa tanto a precisão quanto a revolução, em um único índice. Assim, no presente estudo, os maiores valores médios de F1-Score foram observados para o *plugin* *Tree Density* com processamento na resolução baixa. De fato, na prática, esse tratamento permite maior operacionalização para uso técnico, sendo indicado para uso na contagem de árvores de mangueira irrigada no Submédio do Vale São Francisco.

**Tabela 3.** Índices de precisão, revocação e F1-Score para avaliação de *plugin* e da qualidade de processamento de imagens de VANTs obtidas em pomares de mangueira no Submédio do Vale São Francisco.

<i>Plugin</i>	Cultivar	Qualidade	Precisão	Revocação	F1-Score
SAGA GIS	Kent	Baixa	0,970	0,517	0,675
		Média	0,449	0,915	0,602
		Elevada	0,001	0,989	0,002
	Palmer	Baixa	0,700	0,895	0,785
		Média	0,004	0,998	0,008
		Elevada	0,000	1,000	0,000
	Tommy Atkins	Baixa	0,184	0,837	0,301
		Média	0,001	1,000	0,003
		Elevada	0,000	1,000	0,000
<i>Tree Density</i>	Kent	Baixa	0,991	0,526	0,688
		Média	0,999	0,593	0,744
		Elevada	0,654	0,655	0,655
	Palmer	Baixa	0,997	0,640	0,779
		Média	0,516	0,635	0,569
		Elevada	0,091	0,632	0,159
	Tommy Atkins	Baixa	0,168	0,442	0,244
		Média	0,200	0,986	0,332
		Elevada	0,080	0,986	0,149

Fonte: Autores (2021).

## 6 CONCLUSÕES

A identificação de árvores de mangueira em um processo semiautomático utilizando produtos digitais obtidos de

imagens de veículos aéreos não tripulados (VANTs) e o uso dos *plugins* *Tree Density* e SAGA GIS foi possível, de forma similar, por meio do processamento digital realizado em qualidades baixa, média e alta. Assim,

em função do menor tempo necessário para se alcançar os produtos finais, recomenda-se o processamento em qualidade baixa, principalmente para empresas de tecnologia voltadas para a área agrícola, que necessitam entregar os resultados ao cliente em uma escala de tempo relativamente menor.

Os *plugins Tree Density* e SAGA GIS tiveram melhor desempenho para detecção de árvores no pomar de mangueira ‘Kent’, que tinha maior área cultivada e apresentava árvores maiores, demonstrando que o emprego desses *plugins* pode ocorrer em pomares de tamanhos variados. Dentre os *plugins*, o ‘*Tree Density Calculator*’ apresentou melhor desempenho para a detecção semiautomática de árvores de mangueira, sendo esse o mais recomendado, uma vez que apresentou maior quantidade de acertos e menor necessidade de ações de manuais para obtenção dos resultados finais.

O presente artigo apresenta um protocolo para identificação e contagem remota de árvores de mangueiras de forma semiautomática por meio da utilização de imagens aéreas obtidas por VANTs,

*softwares* e *plugins* gratuitos. De forma similar, em função da eficiência observada no presente estudo, recomenda-se que esse protocolo seja avaliado na detecção de árvores de outras espécies de cultivos.

## 7 AGRADECIMENTOS

Os autores agradecem o apoio concedido pelo Projeto Embrapa ET-VANT (20.18.04.003.00.00). Carlos A. S. Sá agradece à Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) pela Bolsa de Mestrado (BOL 0724/2020). Josicleda D. Galvêncio agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade de pesquisa (PQ 302934/2018-9) e pelo financiamento do Projeto Universal processo 402834/2016-0. Rodrigo Q. Miranda agradece à Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) por meio do processo APQ 0646-9.25/16.

## 8 REFERÊNCIAS

ABIDIN, H.; SAMAD, M. N.; PING, L. Y.; NOOR, M. K. A. M. Evaluation of recognition software for oil palm tree counting under different planting conditions and ages. *In: INTERNATIONAL CONFERENCE ON BIG DATA APPLICATIONS IN AGRICULTURE*, 11., 2017, Serdang. **From Nursery to Field**. Serdang: Institute of Plantation Studies, 2017. v. 1, p. 124-133.

ÁLVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. de M.; SPAROVEK, G. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, Berlin, v. 22, n. 6, p. 711-728, 2013.

AMARAL, F. C. S. **Sistema Brasileiro de Classificação de Terras para Irrigação**: enfoque na região semiárida. Rio de Janeiro: Embrapa Solos, 2011.

ARANTES, B. H. T.; ARANTES, L. T.; SANTOS, J. M.; VENTURA, M. V. A.; GOMES, L. F. Efficiency analysis of the use of model matching algorithm for plant counting. **Research, Society and Development**, Vargem Grande Paulista, v. 9, n. 7, p. e668974576, 2020.

BARNES, C.; BALZTER, H.; BARRETT, K.; EDDY, J.; MILNER, S.; SUÁREZ, J. C.

Individual tree crown delineation from airborne laser scanning for diseased larch forest stands. **Remote Sensing**, Basel, v. 9, n. 3, p. 231, 2017. DOI: <https://doi.org/10.3390/rs9030231>. Disponível em: <https://www.mdpi.com/2072-4292/9/3/231>. Acesso em: 29 abr. 2021.

BRANDÃO, S. da S.; GIONGO, V.; OLSZEWSKI, N.; SALVIANO, A. M. Coquetéis vegetais e sistemas de manejo alterando a qualidade do solo e produtividade da mangueira. **Revista Brasileira de Geografia Física**, Recife, v. 10, n. 4, p. 1079-1089, 2017.

CRABBÉ, A. H.; CAHY, T.; SOMERS, B.; VERBEKE, L.P.; VAN COILLIE, F. **Tree Density Calculator Software**. Versão 1.5.3. Ghent: Laboratory of Forest Management and Spatial Information Techniques, 2020. Disponível em: <https://bitbucket.org/kul-reseco/localmaxfilter>. Acesso em: 4 abr. 2020.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BOHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1. 4. **Geoscientific Model Development**, Gottingen, v. 8, n. 7, p. 1991-2007, 2015. DOI: <https://doi.org/10.5194/gmd-8-1991-2015>. Disponível em: <https://gmd.copernicus.org/articles/8/1991/2015/>. Acesso em: 10 fev. 2021.

DJI PHANTOM. Especificações: Phantom 3 Standard. Página Consumo. Disponível em: <https://www.dji.com/br/phantom-3-standard>. Acesso em: 27 de abr. de 2021a.

DJI PHANTOM. Especificações: Phantom 4 Pro V2.0. Página Consumo. Disponível em: <https://www.dji.com/br/phantom-4-pro-v2/specs>. Acesso em: 27 de abr. de 2021b.

FAO. FAOSTAT 2019. Disponível em: <http://www.fao.org/faostat/en/#data/>. Acesso em: 18 de jan. 2022.

DRONE SHOW. **Contagem automática de árvores em imagens obtidas com drones**. Curitiba: Mundo GEO, 2021. Disponível em: <https://droneshowla.com/contagem-automatica-de-arvores-em-imagens-obtidas-com-drones/>. Acesso em: 10 mai. de 2021.

GONÇALVES, J.; PÔÇAS, I.; MARCOS, B.; MÜCHER, C. A.; HONRADO, J. P. SegOptim - A new R package for optimizing object-based image analyses of high-spatial resolution remotely-sensed data. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 76, p. 218-230, 2019. DOI: <https://doi.org/10.1016/j.jag.2018.11.011>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0303243418303556>. Acesso em: 12 mai. 2021.

HERNÁNDEZ-HERNÁNDEZ, J.; GARCÍA-MATEOS, G.; GONZÁLEZ-ESQUIVA, J.; ESCARABAJAL HENAREJOS, D.; RUIZ-CANALES, A.; MOLINA-MARTÍNEZ, J. Optimal color space selection method for plant/soil segmentation in agriculture. **Computers and Electronics in Agriculture**, Amsterdam, v. 122, p. 124-132, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.01.020>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916000259?via%3Dihub>. Acesso em: 11 fev. 2021.



HYSLOP, K.; GALDINO, S.; QUARTAROLI, C. F.; ZOLIN, C. A.; TOSTO, S. G. Avaliação de diferentes Modelos Digitais de Superfície (MDS) na delimitação da bacia hidrográfica do Rio Piririm-AP utilizando o software Invest. *In: CONGRESSO INTERINSTITUCIONAL DE INICIAÇÃO CIENTÍFICA*, 14., 2020, Campinas. **Anais [...]**. Campinas: Embrapa Informática Agropecuária, 2020.

IBGE. **Produção agrícola municipal 2020**. Tabela 1613. Brasília, DF: SIDRA, 2020. Disponível em: <https://sidra.ibge.gov.br/tabela/1613>. Acesso em: 17 jan. 2022.

ISIP, M. F.; CAMASO, E. E.; DAMIAN, G. B.; ALBERTO, R. T. Estimation of Mango Tree Count and Crown Cover Delineation using Template Matching Algorithm. **International Journal for Research in Applied Science and Engineering Technology**, [s.l.], v. 6, n. 3, p. 1955-1960, 2018.

LI, Y.; CAO, Z.; LU, H.; XIAO, Y.; ZHU, Y.; CREMERS, A. B. In-field cotton detection via region-based semantic image segmentation. **Computers and Electronics in Agriculture**, Amsterdam, v. 127, p. 475-486, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.07.006>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816991630480X>. Acesso em: 17 fev. 2021.

LI, W.; FU, H.; YU, L.; CRACKNELL, A. Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. **Remote Sensing**, Basel, v. 9, n. 1, p. 22-35, 2017. DOI: <https://doi.org/10.3390/rs9010022>. Disponível em: <https://www.mdpi.com/2072-4292/9/1/22>. Acesso em: 17 fev. 2021.

MASCHLER, J.; ATZBERGER, C.; IMMITZER, M. Individual Tree Crown Segmentation and Classification of 13 Tree Species Using Airborne Hyperspectral Data. **Remote Sensing**, Basel, v. 10, n. 8, p. 1218-1247, 2018. DOI: <https://doi.org/10.3390/rs10081218>. Disponível em: <https://www.mdpi.com/2072-4292/10/8/1218>. Acesso em: 03 mai. 2021.

MORTE, C. L. B.; CARVALHO, L. F. S. G.; BARROS, R. S. Uso de vant como ferramenta para estimativa de altura de dossel em manguezal: um estudo investigativo em Guaratiba, Rio de Janeiro, Brasil. **Revista Tamoios**, São Gonçalo, v. 16, n. 3, p. 42-51, 2020. DOI: <https://doi.org/10.12957/tamoios.2020.55745>. Disponível em: <https://www.e-publicacoes.uerj.br/index.php/tamoios/article/view/55745>. Acesso em: 06 mai. 2021

OJEDA-MAGAÑAA, B.; RUELAS, R.; QUINTANILLA-DOMÍNGUEZ, J.; GÓMEZ-BARBA, L.; LÓPEZ DE HERRERA, J.; ROBLEDO-HERNÁNDEZ, J. G.; TARQUIS, A. M. Automatic identification of the area covered by acorn trees in the dehesa (pastureland) Extremadura of Spain. **Computers and Electronics in Agriculture**, Amsterdam, v. 172, p. 105289-105298, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105289>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169919318526>. Acesso em: 10 fev. 2021.

PÁDUA, L.; ADÃO, T.; SOUSA, A.; PERES, E.; SOUSA, J. J. Individual grapevine analysis in a multi-temporal context using UAV-based multi-sensor imagery. **Remote Sensing**, Basel, v. 12, n. 1, p. 139-160, 2020. DOI: <https://doi.org/10.3390/rs12010139>. Disponível em: <https://www.mdpi.com/2072-4292/12/1/139>. Acesso em: 10 fev. 2021.

PASSOS, F. G.; FONTES, C. H. O.; NASCIMENTO, A. N. Avaliação da eficiência de uma empresa exportadora de manga do Vale do São Francisco: um modelo em análise envoltória de dados. **Revista Custos e Agronegócio online**. Recife, v. 16, edição especial, p. 105-141, 2020.

R CORE TEAM. **The R Project for Statistical Computing**. Viena: R Core Team, 2020.

Disponível em: [www.r-project.org/](http://www.r-project.org/). Acesso em: 30 abr. 2021.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; OLIVEIRA, J. B.; COELHO, M. R.; LUMBRERAS, J. F.; CUNHA, T. J. F. (ed.). **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: Embrapa Solos, 2006.

WAGNER, F. H.; FERREIRA, M. P.; SANCHEZ, A.; HIRYE, M. C.; ZORTEA, M.; GLOOR, E.; PHILLIPS, O. L.; SOUZA FILHO, C. R.; SHIMABUKURO, Y. E.; ARAGAO, L. E. Individual tree crown delineation in a highly diverse tropical forest using very high-resolution satellite images. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 145, p. 362-377, 2018. DOI: <https://doi.org/10.1016/j.isprsjprs.2018.09.013>.

Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271618302582>.

Acesso em: 10 fev. 2021

WEINSTEIN, B. G.; MARCONI, S.; BOHLMAN, S.; ZARE, A.; WHITE, E. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks.

**Remote Sensing**, Basel, v. 11, n. 11, p. 1309-1322, 2019. DOI:

<https://doi.org/10.3390/rs11111309>. Disponível em: <https://www.mdpi.com/2072-4292/11/11/1309>. Acesso em: 06 mai. 2021.

ZHANG, X. Quick Aboveground Carbon Stock Estimation of Densely Planted Shrubs by Using Point Cloud Derived from Unmanned Aerial Vehicle. **Remote Sensing**, Basel, v. 11, n. 24, p. 2914-2932, 2019. DOI: <https://doi.org/10.3390/rs11242914>. Disponível em:

<https://www.mdpi.com/2072-4292/11/24/2914>. Acesso em: 29 abr. 2021.