

Análise de eficiência do uso de algoritmo de correspondência de modelo para contagem de plantas

Efficiency analysis of the use of model matching algorithm for plant counting

Análisis de eficiencia del uso del algoritmo de comparación de modelos para el conteo de plantas

Recebido: 16/05/2020 | Revisado: 19/05/2020 | Aceito: 24/05/2020 | Publicado: 30/05/2020

Bruno Henrique Tondato Arantes

ORCID: <https://orcid.org/0000-0001-6339-5052>

Universidade Federal do Rio Grande do Sul, campus do Vale, Brasil

E-mail: bhtondato@gmail.com

Leticia Tondato Arantes

ORCID: <https://orcid.org/0000-0002-5541-1304>

Universidade Estadual Paulista “Júlio de Mesquita Filho”, campus Sorocaba, Brasil

E-mail: letondato@gmail.com

Janyne Moura Dos Santos

ORCID: <https://orcid.org/0000-0003-1235-9750>

Instituto Federal Goiano, campus Rio Verde, Brasil

E-mail: janymoura0310@hotmail.com

Matheus Vinicius Abadia Ventura

ORCID: <http://orcid.org/0000-0001-9114-121X>

Instituto Federal Goiano, campus Rio Verde, Brasil

matheusvinicius10@hotmail.com

Luiz Fernando Gomes

ORCID: <https://orcid.org/0000-0002-8279-7409>

Instituto Federal Goiano, campus Rio Verde, Brasil

E-mail: luizfernandoz4@hotmail.com

Resumo

Muitas das vezes o produtor não sabe o número exato de árvores frutíferas em sua propriedade ou passa a desconhecer com o passar dos anos devido a morte de muitas plantas. Em função disso, a fim de evitar a necessidade de uma ida em campo para uma contagem manual, esta pesquisa teve como objetivo utilizar um algoritmo de correspondência de modelo em paralelo com o uso de um drone de baixo custo para avaliar sua eficiência na contagem automática de plantas de copas espaçadas e juntas. Foram utilizadas as bandas do vermelho, verde e azul capturadas pelo *Phantom 4 Advanced*, e a banda do vermelho com realce linear pela opção de corte, para facilitar a distinção do pomar e o restante dos alvos na imagem e obter um melhor resultado na detecção das árvores frutíferas. O voo foi realizado a uma altura de 80 metros com uma sobreposição entre faixas de 70 % e na mesma faixa de 80 %. Como resultado, 97,98 % das árvores frutíferas foram detectadas em plantas com copas bem espaçadas e 88,52 % foram identificadas em plantas com copas juntas. Os números de falsos positivos encontrados foram pequenos para todas as situações testadas, sendo esses falsos positivos plantas daninhas. Conclui-se que a técnica é eficiente para a contagem de plantas com copas juntas e espaçadas, podendo ser melhorada a detecção quando se tem um bom contraste entre o que se quer detectar e o os alvos que não são de interesse.

Palavras-chave: Árvores frutíferas; Sensoriamento remoto; Drone; Agricultura de precisão.

Abstract

Often the producer does not know the exact number of fruit trees on his property or is unaware over the years due to the death of many plants. As a result, in order to avoid the need for a field trip for manual counting, this research aimed to use a model matching algorithm in parallel with the use of a low-cost drone to assess its efficiency in automatic counting of spaced canopy plants and joints. The red, green and blue bands captured by the *Phantom 4 Advanced* were used, and the red band with linear enhancement for the cut option, to facilitate the distinction of the orchard and the rest of the targets in the image and to obtain a better result in the detection of fruit trees. The flight was performed at a height of 80 meters with an overlap between bands of 70% and in the same range of 80%. As a result, 97.98% of fruit trees were detected in plants with well-spaced crowns and 88.52% were identified in plants with crowns together. The numbers of false positives found were small for all situations tested, these false positives being weeds. It is concluded that the technique is efficient for counting plants with fair and spaced crowns, and detection can be improved when there is a good contrast between what you want to detect and the targets that are not of interest.

Keywords: Fruit trees; Remote sensing; Drone; Precision agriculture.

Resumen

A menudo, el productor no sabe la cantidad exacta de árboles frutales en su propiedad o no se da cuenta a lo largo de los años debido a la muerte de muchas plantas. Como resultado, para evitar la necesidad de un viaje de campo para el conteo manual, esta investigación tuvo como objetivo utilizar un algoritmo de comparación de modelos en paralelo con el uso de un dron de bajo costo para evaluar su eficiencia en el conteo automático de plantas de dosel espaciadas y juntas. Se utilizaron las bandas rojas, verdes y azules capturadas por el Phantom 4 Advanced, y la banda roja con mejora lineal para la opción de corte, para facilitar la distinción del huerto y el resto de los objetivos en la imagen y para obtener un mejor resultado en la detección de árboles frutales. El vuelo se realizó a una altura de 80 metros con una superposición entre bandas del 70% y en el mismo rango del 80%. Como resultado, el 97.98% de los árboles frutales se detectaron en plantas con coronas bien espaciadas y el 88.52% se identificaron en plantas con coronas juntas. El número de falsos positivos encontrados fue pequeño para todas las situaciones evaluadas, siendo estos falsos positivos las malas hierbas. Se concluye que la técnica es eficiente para contar plantas con coronas justas y espaciadas, y la detección se puede mejorar cuando hay un buen contraste entre lo que desea detectar y los objetivos que no son de interés.

Palabras clave: Arboles frutales; Detección remota; Drone; Agricultura de precisión

1. Introdução

As informações sobre o número exato de árvores frutíferas em uma propriedade são importantes para se prever sua produtividade e para estimar a taxa de sobrevivência das plantas (Li et al., 2017). Geralmente, o processo de contagem é realizado manualmente por trabalhadores em terra, um método intensivo em horas-homens (Malek et al., 2014; Abidin et al., 2017). Em contrapartida, o sensoriamento remoto permite a aquisição de informações sem o contato direto com os alvos (Centeno, 2003), tornado o processo de contagem de plantas automático com o uso de imagens de alta resolução espacial (Li et al., 2017) e de algoritmos.

Todavía, o sucesso da detecção de um conjunto de plantas de forma individual, depende da resolução espacial da imagem, da dominância da árvore dentro do estande (por exemplo, dominante, sub-dominante, suprimida), da geometria do alvo, da topografia e do tipo de sensor utilizado (Hirschmugl et al., 2007; Shafri et al., 2011; Santoro et al., 2013).

Não existe uma única metodologia específica para detecção e contagem de árvores, mas sim vários estudos utilizando o sensoriamento remoto. Com o uso de dados de um espectrômetro de imagem no ar de alta resolução espacial é possível obter uma precisão média de 95 % na contagem de dendzeiros. Tal resultado foi alcançado através da análise espectral, análise de textura, do aprimoramento de bordas, do processo de segmentação, da análise morfológica e por meio da análise de *blob* (Shafri et al., 2011).

No trabalho de Santoro et al. (2013) um procedimento automático com um algoritmo em quatro etapas para identificação individual de árvores frutíferas usando dados do sensor GeoEye-1 foi apresentado. O teste foi destinado a árvores cítricas, com um bom resultado na contagem, havendo algumas confusões com a presença de mais de uma espécie crescendo no mesmo campo ou com as mesmas espécies de árvores em diferentes idades.

Tem-se também o método de correspondência de modelo para a contagem de plantas, cuja é uma técnica de reconhecimento de padrões que utiliza um modelo predefinido para detectar alvos em uma imagem (Brunelli, 2009). A detecção de objetos baseado na correspondência de modelo é composta por duas etapas principais, segundo Cheng e Han (2016). A primeira consiste na geração de um modelo genérico para cada classe de objeto a ser detectado e a segunda no uso de uma imagem de origem, no qual o modelo criado na primeira etapa é utilizado para corresponder à imagem em cada posição possível para encontrar as melhores correspondências, de acordo com as medidas mínimas de distorção ou correlação máxima, levando em consideração todas as alterações permitidas de translação, rotação e escala.

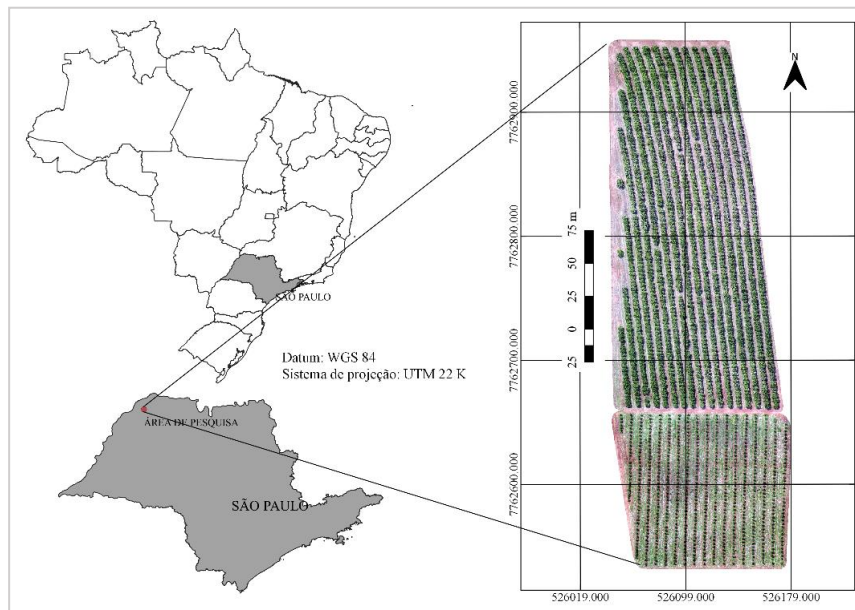
O algoritmo de correspondência de modelo foi proposto nesse trabalho, para avaliar sua eficiência na contagem de plantas de copas espaçadas e juntas através do uso de bandas da faixa do visível coletadas por um drone de baixo custo. Também foi selecionado a banda que proporcionou o melhor número de detecção de plantas em dosséis espaçados e juntos para analisar a possibilidade de se melhorar seu contraste e consequentemente melhorar a detecção de plantas que não foram detectadas com as bandas do visível em seu estado bruto de processamento.

2. Metodologia

A área desta pesquisa, localiza no interior do estado de São Paulo no município de Aspásia, foi definida em uma propriedade rural de produção de laranjas e limões localizadas nas coordenadas 20° 13' 55'' S e 50° 44' 55'' O (Figura 1). Segundo o último senso da

produção agrícola municipal de Aspásia, no ano de 2018, a área colhida de limões e laranjas foi de 769 hectares, perdendo apenas para a cana-de-açúcar que foi de 800 hectares. Entretanto em reais, a produção de limões e laranjas ultrapassa os 29 milhões ficando à frente da cana-de-açúcar que foi de 4,69 milhões (Sidra, 2020).

Figura 1: Mapa de localização da área de estudo.



Fonte: Arantes, 2020.

Quanto ao equipamento utilizado e softwares, na área de estudo (Figura 1), tem-se um drone de baixo custo para a captura das imagens, o *DroneDeploy* para o planejamento de voo, o *pix4d* para geração do ortomosaico, o algoritmo *eCognition Developer* para contagem de plantas e o *Qgis 3.12* para a elaboração dos mapas. O drone utilizado, um *Phantom 4 Advanced* carregava em sua plataforma uma câmera de bandas vermelha, verde e azul.

A primeira etapa do trabalho, a elaboração do plano de voo, foi definida a uma altura de 80 metros e uma sobreposição entre faixas de 70 % e na mesma faixa de 80 %, com boas condições de iluminação solar e sem a presença de nuvens. Os valores definidos na sobreposição lateral e longitudinal foi para evitar falhas de captura entre as faixas consecutivas e de mesma faixa, e para a construção de um bom ortomosaico, já que pode ocorrer a deriva do drone devido a fortes ventos, variações do relevo do terreno mapeado e inclinações das imagens capturadas, gerando distorções e buracos nos ortomosaicos.

Para o processamento das imagens, nenhum ponto de apoio foi utilizado e manteve-se os valores digitais em vez da reflectância. No processo de formação do ortomosaico, o *pix4d*

buscou automaticamente os parâmetros de orientação interior e exterior da câmera, sendo necessário, que apenas o usuário carregue as imagens na plataforma (Arantes et al., 2020).

Já dentro no software *eCognition Developer* usando o algoritmo de correspondência de modelo que é baseado na elaboração de modelos genéricos que buscam nas imagens os objetos com características comuns, permitindo a contagem de objetos de forma automática (Norzaki & Tahar, 2019; Isip et al., 2018), vários testes de contagem de plantas foram realizados usando as bandas vermelha, verde e azul e a banda do vermelho com uma modificação em seu histograma pela técnica de realce linear, cuja foi definido valores mínimos e máximos de cortes.

O algoritmo de correspondência de modelo retorna como resultado um número de plantas contadas, que foi definido como contagens corretas (plantas detectadas pelo algoritmo) e os falsos positivos (alvo que não seja o pomar), cuja são pontos no ortomosaico que foram detectados como plantas, mas que não são. Por conseguinte, para se determinar as plantas não detectadas pelo algoritmo, as árvores frutíferas existentes não contabilizadas (plantas não detectadas pelo algoritmo) foram marcadas manualmente.

Os histogramas foram utilizados para evidenciar o nível de contraste e brilho (Halazonetis, 2004) entre as plantas e o restante dos alvos presentes na imagem, e o realce linear para dar um maior destaque ao pomar a fim de melhorar ainda mais o resultado de contagem de plantas e obter uma boa separação dos níveis de cinza das plantas para os demais alvos na imagem (Centeno, 2003; Al-Amri et al., 2010; Liu et al., 2017). Para a transformação linear da banda vermelha relacionadas a contagem de plantas com copas espaçadas, os valores mínimo e máximo de cortes foram definidos respectivamente em 86 e 110 e para as plantas de copas juntas o valor mínimo de corte foi de 115 e o máximo de corte foi 166. Por conseguinte, o valor de corte mínimo é fixado ao valor de brilho 0 e o valor de corte máximo ao valor de brilho 255, e qualquer valor dentro do intervalo é, linearmente, reescalado entre 0 e 255.

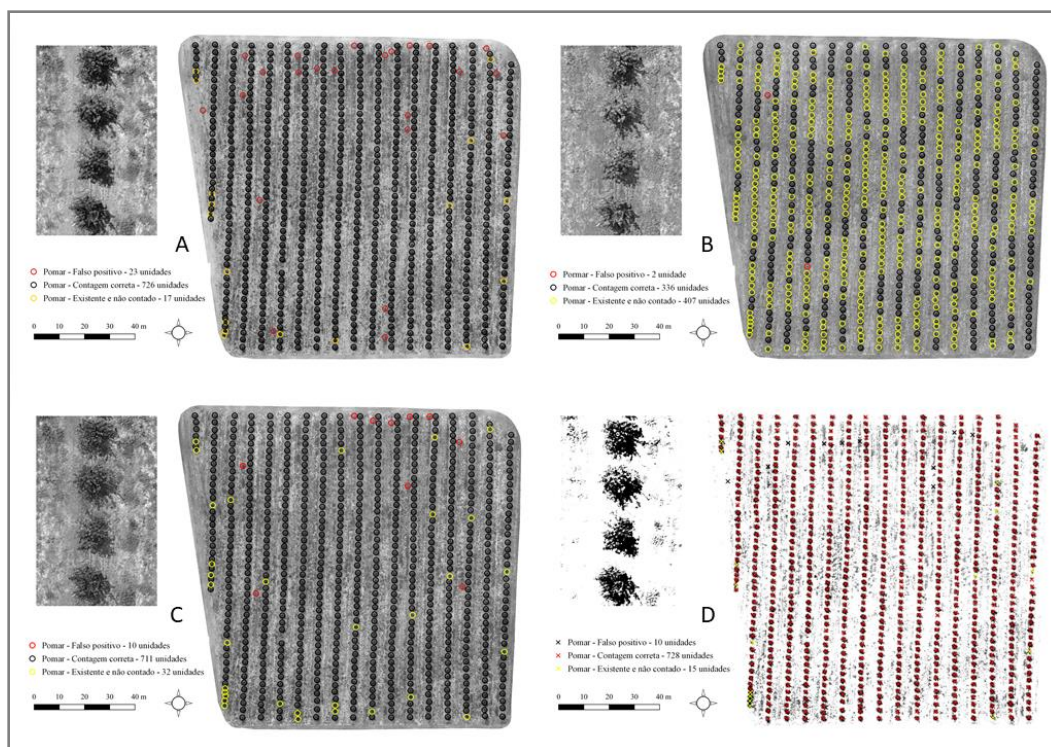
Por fim, com as contagens fornecidas pelo algoritmo de correspondência de modelo, as contagens corretas, os falsos positivos e as plantas existentes não contabilizadas foram marcadas nas imagens e estimada as suas porcentagens com relação ao valor verdadeiro do número de plantas existente na área de estudo, para evidenciar a eficiência de todos os processos de contagem. Em seguida, mapas foram elaborados utilizando o software *Qgis 3.12*.

3. Resultados e Discussão

Ao contrário de imagens de baixas resoluções espaciais, as imagens aéreas permitem uma boa determinação do tamanho de copa de plantas, bem como uma correta identificação do dossel de cada planta individualmente. Por este motivo, é que o algoritmo de correspondência de modelo, juntamente com as características do histograma da imagem, consegue elaborar modelos genéricos de uma planta a fim de identificar plantas de forma automática.

Nos ortomosaicos em plantas com copas bem espaçadas, fica fácil a identificação de cada planta, havendo, no entanto, uma pequena mudança de brilho e contraste em função do comportamento do histograma de cada mapa, cuja define qual nível de brilho e contraste se torna melhor para contagem de plantas (Figura 2).

Figura 2: Contagem de plantas com copas bem espaçadas utilizando a banda do vermelho (A), verde (B), azul (C) e com o realce linear por corte da banda do vermelho (D).




Fonte: Arantes, 2020.

Visualmente, o mapa que utiliza da banda do vermelho (Figura 2A) apresenta uma melhor distinção entre o pomar e o restante dos alvos presentes no mapa, quando comparado com as bandas verde e azul. Isso se deve a um histograma mais equalizado do que os outros, o

que permite uma distribuição mais uniforme de intensidade ao longo dos níveis de cinzas (Wan et al., 2018), trazendo imagens com maiores contrastes (Pratt, 2013; Poddar et al., 2013; Wong et al., 2016) (Figura 3).

Figura 3: Histograma de frequência de cada banda das plantas com copas bem espaçadas.



Fonte: Arantes, 2020.

A banda do vermelho com realce linear pela opção de corte apresentou um nível de acerto nas detecções de 97,98 %, deixando de contar apenas 2,02 % de plantas, contra 45,22 % de plantas identificadas e uma omissão de 54,78 % na detecção de plantas utilizando a banda do verde. A porcentagem pequena de árvores frutíferas contadas através da banda do verde, está relacionado ao comportamento do histograma, cuja apresenta a maioria das frequências concentradas em apenas uma faixa dos níveis de cinzas fornecida pela resolução radiométricas do sensor (Tabela 1), que segundo Centeno (2003), quando a maioria das frequências estão distribuídas em uma faixa muito pequena de níveis de cinzas, como no caso da banda do verde, a variação da imagem é pequena, ou seja, menor é o contraste.

Tabela 1: Porcentagem de falsos positivos, de acertos e de plantas existentes e não contabilizadas em plantas com copas espaçadas.

Bandas	Contagem correta (%)	Existente e não contado (%)	Falso positivo (%)
Vermelha com realce	97,98	2,02	1,35
Vermelha	97,71	2,29	3,09
Azul	95,69	4,31	1,35
Verde	45,22	54,78	0,27

Fonte: Arantes, 2020.

O realce linear pela opção de corte aplicado a banda do vermelho das plantas com as copas bem espaçadas, não trouxe melhores significativa nas classes de contagem correta e existente não contado (Figura 2D), porém, reduziu o número de falsos positivos de 3,09%

para 1,35%. Todas as imagens apresentaram um número muito pequeno de falsos positivos, sendo tais pontos marcados, plantas daninhas, que apresentavam uma geometria e níveis de cinza similar ao modelo genérico elaborado pelo algoritmo de correspondência de modelo para a detecção e contagem de plantas.


Quando a contagem de plantas é direcionada a plantas com o dossel unido, os resultados de contagem correta em todas as bandas tendem a ser inferior a de plantas com copas bem espaçadas, com exceção do verde (Tabela 2), cuja apresentou um histograma bem equalizado, o que justificaria a melhora da quantificação (Figura 4).

Tabela 2: Porcentagem de falsos positivos, de acertos e de plantas existentes e não contabilizadas em plantas com copas juntas.

Bandas	Contagem correta (%)	Existente e não contado (%)	Falso positivo (%)
Vermelha com realce	88,52	11,48	1,88
Vermelha	83,58	16,42	1,67
Azul	75,78	24,22	1,25
Verde	66,04	33,96	1,04

Fonte: Arantes, 2020.

Figura 4: Histograma de frequência de cada banda de plantas com copas juntas.

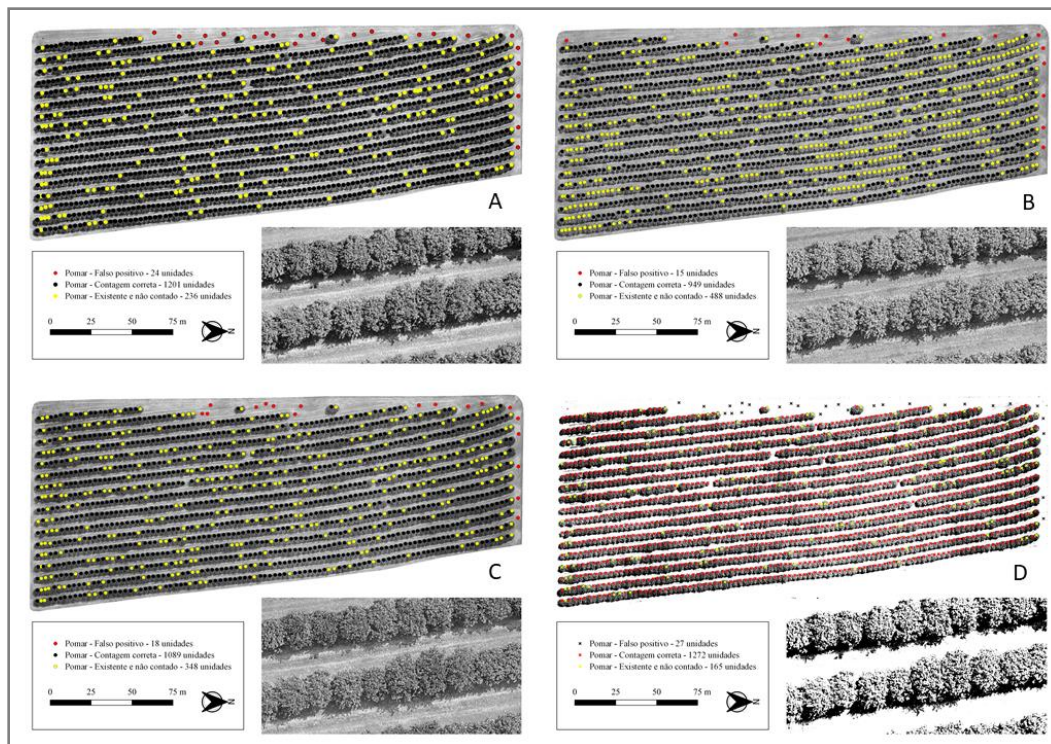


Fonte: Arantes, 2020.

Apesar da boa distribuição das barras do histograma ao longo dos níveis de cinzas na Figura 4, as bandas do vermelho e do azul apresentam uma melhor equalização do histograma, o que poderia justificar melhores resultados na contagem. Todavia, quando se realiza o realce linear por corte na banda do vermelho, uma melhora de quase 5 % ocorre na detecção de plantas (Tabela 2), sendo justificada pelo aumento de contraste proporcionado pela técnica de processamento de imagem aplicada, que proporcionou uma boa separação dos níveis de cinza das plantas para os demais alvos na imagem (Figura 5) (Centeno, 2003; Al-

Amri et al., 2010; Liu et al., 2017), produzindo um robusto modelo genérico pelo algoritmo de correspondência de modelo.

Figura 5: Contagem de plantas com copas juntas utilizando a banda do vermelho (A), verde (B), azul (C) e com o realce linear por corte da banda do vermelho (D).



Fonte: Arantes, 2020.

Todavia, os valores da contagem correta da banda do vermelho com realce linear e sem realce, a banda do azul e do verde foram respectivamente de 88,52 %, 83,58 %, 75,78 % e 66,04, uma diferença de 22,48 % da melhor imagem (Figura 5D) para a pior imagem (Figura 5B) em plantas com copas juntas. Esta diferença é ainda maior para as plantas de copas bem espaçadas, cuja é de 52,76 %.

Outros trabalhos também apresentaram bons resultados para a contagem de indivíduos utilizando o algoritmo de correspondência de modelo. Rex et al. (2018) conseguiu um acerto de 88,4 % na identificação de copas de *Araucaria angustifolia* em uma área densa de vegetação nativa e Norzaki e Tahar (2019) de 95,3% de precisão na contagem de árvores. Por último, em uma contagem de mangueiras, uma precisão de 88,89 % foi obtida por Isip et al. (2018), com copas espaçadas.

4. Considerações Finais

O uso do algoritmo de correspondência de modelo para a contagem de plantas apresentou bons resultados para plantas com copas separadas e juntas, sendo melhor o número de acertos obtidos quando a copa se encontra separada. Nota-se na pesquisa, que a elaboração de um bom modelo genérico para detecção de plantas está intimamente relacionada a resolução espacial, a resolução radiométrica e ao comportamento do histograma, podendo ser melhorado com técnica de processamento de imagem por realce linear pela opção de corte.

As recomendações para novas pesquisas é que outras técnicas de processamento de imagem sejam testadas, e que voos com alturas maiores sejam definidas para avaliar a eficiência algoritmo de correspondência de modelo para a contagem de plantas. Voos mais altos podem trazer cobertura de áreas maiores, recomendado para áreas de grandes dimensões. Além disso, é recomendado também uso de melhores resoluções radiométricas e espectrais para avaliar uma possível melhora na contagem de plantas com copas juntas.

Referências

Abidin, H.; Samad, MN.; Ping, LY & Noor, MKAM (2017). Evaluation of ecognition software for oil palm tree counting under different planting conditions and ages. *International Conference on Big Data Applications in Agriculture*.

Al-Amri, SS.; Kalyankar, NV & Khamitkar, SD (2010). Linear and non-linear contrast enhancement image. *International Journal of Computer Science and Network Security*, 10(2), 139-143.

Arantes, BHT.; Arantes, LT; Giongo, PR.; Moraes, VH.; Costa, EM & Silva, PC (2020). Eficiência de distribuição do sistema de irrigação, por meio de um veículo aéreo não tripulado de baixo custo/Efficiency of irrigation system distribution through a low-cost unmanned aerial vehicle. *Brazilian Journal of Development*, 6(4), 20332-20346.

Brunelli, R (2009). *Template matching techniques in computer vision: theory and practice*. John Wiley & Sons.

Centeno, JAS (2003). Sensoriamento remoto e processamento de imagens digitais. *Curitiba: UFPR*, 219.

Cheng, G & Han, J (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 11-28.

Halazonetis, DJ (2004). What does the histogram of an image show? *American journal of orthodontics and dentofacial orthopedics*, 125 (2), 220-222.

Hirschmugl, M.; Ofner, M.; Raggam, J & Schardt, M (2007). Single tree detection in very high resolution remote sensing data. *Remote Sensing of Environment*, 110(4), 533-544.

Isip, MF.; Camaso, EE.; Damian, GB & Alberto, RT (2018). Estimation of Mango Tree Count and Crown Cover Delineation using Template Matching Algorithm, 6(3), 1955-1960.

Li, W.; Fu, H.; Yu, L & Cracknell, A (2017). Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sensing*, 9(1), 22.

Liu, J.; Zhou, C.; Chen, P & Kang, C (2017). An efficient contrast enhancement method for remote sensing images. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1715-1719.

Malek, S.; Bazi, Y.; Alajlan, N.; AlHichri, H & Melgani, F (2014). Efficient framework for palm tree detection in UAV images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), 4692-4703.

Norzaki, N & Tahar, KN (2019). A comparative study of template matching, ISO cluster segmentation, and tree canopy segmentation for homogeneous tree counting. *International Journal of Remote Sensing*, 40(19), 7477-7499.

Poddar, S.; Tewary, S.; Sharma, D.; Karar, V.; Ghosh, A & Pal, SK (2013). Non-parametric modified histogram equalisation for contrast enhancement. *IET Image Processing*, 7(7), 641-652.

Pratt, WK (2013). *Introduction to digital image processing*. CRC press.

Rex, FE.; Dalla Corte, AP.; Machado, S. A & Sanquetta, CR (2018). Identificação e extração de copas de *Araucaria angustifolia* (Bertol.) Kuntze a partir de dados lidar. *Advances in Forestry Science*, 5(2), 319-323.

Santoro, F.; Tarantino, E.; Figorito, B.; Gualano, S & D'Onghia, AM (2013). A tree counting algorithm for precision agriculture tasks. *International Journal of Digital Earth*, 6(1), 94-102.

Shafri, HZ.; Hamdan, N & Saripan, MI (2011). Semi-automatic detection and counting of oil palm trees from high spatial resolution airborne imagery. *International journal of remote sensing*, 32(8), 2095-2115.

SIDRA - Sistema IBGE de Recuperação Automática: Produção Agrícola Municipal. Acesso em 12 de março de 2020, em <https://sidra.ibge.gov.br/tabela/5457>.

Wan, M.; Gu, G.; Qian, W.; Ren, K.; Chen, Q & Maldague, X (2018). Infrared image enhancement using adaptive histogram partition and brightness correction. *Remote Sensing*, 10(5), 682.

Wong, CY.; Jiang, G.; Rahman, MA.; Liu, S.; Lin, SCF.; Kwok, N.; Shi, H.; Yu, YH & Wu, T (2016). Histogram equalization and optimal profile compression based approach for colour image enhancement. *Journal of Visual Communication and Image Representation*, 38, 802-813.

Porcentagem de contribuição de cada autor no manuscrito

Bruno Henrique Tondato Arantes – 20%

Leticia Tondato Arantes – 20%

Janyne Moura Dos Santos – 20%

Matheus Vinicius Abadia Ventura – 20%

Luiz Fernando Gomes – 20%