

Estimativa da produção de uma lavoura de agricultura familiar através de imagens digitais capturadas por veículo aéreo não tripulado (VANT)

Gerson L. Serejo¹, Viviane A. Santos¹, Ana C. S. Gomes², Alexandre F. B. Silva¹

¹ Universidade Federal do Pará, Campus Tucuruí, Rodovia BR 422, Km 13, Canteiro de Obras - UHE, Tucuruí, Pará, Brazil.

²Instituto Senai de Inovação - ISI, Av. Brás de Aguiar, nº 548, Belém, Pará, Brazil.

gerson.serejo@tucuruui.ufpa.br, vsantos@ufpa.br,
claudia.isi@senaipa.org.br, alexandre.fb.silva@gmail.com

Abstract. *Family farming has become an important alternative means of ensuring the sustainability of food production systems in Brazil. At Tucuruí/PA there are a lot of farms of this type but they lack information to assist them in decision making. The objective of this work is to estimate the harvesting of cassava by a small producer in the region, by employing digital image processing (DIP) and computer vision (CV) techniques.*

Resumo. *A agricultura familiar tem se tornado uma alternativa importante para garantir a sustentabilidade dos sistemas de produção de alimentos no Brasil. Em Tucuruí/PA, existem muitas fazendas deste tipo, mas carecem de informações que auxiliem na tomada de decisões. O objetivo deste trabalho é estimar a colheita de mandioca de um pequeno produtor da região, através do emprego de técnicas de processamento digital de imagens (PDI) e visão computacional (VC).*

1. Introdução

A agricultura familiar consiste no cultivo de terras em pequenas propriedades por membros da família. Sua importância para o sistema global de produção de alimentos é enorme. No Brasil, cerca de 70% da produção de alimentos vem da agricultura familiar e não da agricultura em grande escala [SEAD 2017]. Este sistema tem um efeito positivo na produção agrícola, pois beneficia o solo e reduz o desperdício de recursos naturais. Também tem implicações sociais porque leva a um maior crescimento de empregos e rendas do que em grandes empresas rurais modernizadas [CONTAG 2017].

O município de Tucuruí, no estado do Pará, faz parte de uma região de agricultura familiar. Essa região se destaca pelo plantio de mandioca na época das chuvas [FAPESPA 2015]. Segundo a Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA (2018), a Região Norte do Brasil é a maior produtora dessa cultura com 36,1% da produção nacional. No Pará, 60,66% das terras são cultivadas e isso responde por 56,96% da produção da região. Porém, mesmo ocupando grandes áreas plantadas e tendo atualmente a maior produção de mandioca do País, ocupa apenas a 4ª posição em produtividade, com uma produção de 1,5 kg/m², contra 2,2 kg/m² alcançada pelo primeiro lugar. Vários fatores são responsáveis pela baixa produtividade agrícola do Pará, mas a principal causa é a forma de produção artesanal predominante.

Este estudo exploratório, realizado em Tucuruí, buscou estimar a produtividade de uma safra de mandioca. Há uma escassez de estudos de PDI e VC em lavouras de mandioca, principalmente quando se trata de estudos envolvendo imagens adquiridas por VANT. A pesquisa fornece detalhes de como os resultados foram obtidos por meio de índices de vegetação, como: *Excess Green* (ExG) [Woebbecke et al. 1995], *Excess Green Minus Excess Red* (ExGR) [Meyer et al. 2004] e o *Maximum Green* (MaxG) [Moorthy et al. 2015], aplicados às imagens. Como contribuição científica, este estudo provê um processo para a obtenção da produtividade agrícola que considera: procedimentos de pré-processamento de imagens, seleção de índices de vegetação, segmentação de imagens, avaliação da acurácia dos índices, reconhecimento e contagem de mudas. O algoritmo utilizado na contagem automática está disponível nos códigos-fonte do projeto¹ para consulta e pesquisas futuras.

Este artigo está organizado como segue: na Seção 2 são apresentados os trabalhos relacionados; na Seção 3, a metodologia aplicada no estudo é descrita; na Seção 4 são apresentados os resultados e as discussões; e na Seção 5, as conclusões.

2. Revisão da Literatura

O processo de aquisição de imagens digitais de VANT para tomada de decisão está se tornando mais acessível e fornecendo resolução de melhor qualidade do que imagens geradas por satélite [Anguiano e Morales et al. 2018]. VANTs também fornecem uma alternativa para as plataformas de detecção de solo e resolução espacial permitindo a extração de informações em escala [Varela et al. 2018]. Com o auxílio de imagens aéreas digitais, é possível aplicar as técnicas de PDI e VC para separar o verde das imagens de forma mais clara e, assim, permitir a contagem das mudas, de forma que uma estimativa de sua produção pode ser feita posteriormente. Uma das principais técnicas baseadas em imagens empregadas na agricultura é conhecida como segmentação, que envolve a aplicação de índices de vegetação para separar plantas (colheitas e ervas daninhas) de seu fundo (solo e resíduos).

Hamuda et al. (2016) fizeram uma revisão dos principais índices verdes considerados adequados para segmentação de plantas, que são: *Normalized Difference Index* (NDI) [Woebbecke et al. 1993], *Excess Green Index* (ExG) [Woebbecke et al. 1995], *Excess Red Index* (ExR) [Meyer et al., 1998] [Meyer et al. 1999], *The Color Index of Vegetative Extraction* (CIVE) [Kataoka et al. 2003], *Excess Green Minus Excess Red* (ExGR) [Meyer et al. 2004], *Normalized Green Red Difference Index* (NGRDI) [Hunt et al. 2005], *Vegetative Index* (VEG) [Hague et al. 2006]. Eles conduziram uma avaliação detalhada discussão sobre pré-processamento e segmentação, e destacou os desafios de envolver métodos de limiar para as condições complexas que podem ser encontradas em campos agrícolas.

Gnädinge e Schmidhalter (2017) usaram técnicas PDI para imagens capturadas a 50m de altura com um octocóptero equipado com câmera de 10 MP capturando imagens a cada 5 segundos. Foi utilizado um procedimento de realce de contraste, o que melhorou a diferenciação das cores nas imagens. Em média, o erro entre as plantas contadas visualmente e digitalmente foi $\leq 5\%$. A cobertura do solo, conforme determinado pela análise de pixel verde, variou de 76% a 83% nessas fases. No entanto,

¹ <https://github.com/gerson-serejo/matlab>

a correlação entre a cobertura do solo e as plantas contadas digitalmente foi muito baixa. A presença de ervas daninhas e o efeito borrado nas imagens representaram possíveis erros na contagem de plantas.

Netto et al. (2018) também avaliaram os índices de vegetação mencionados acima (ExG, ExGR e NDI) para o desempenho de três métodos de limiarização automatizados Otsu, Riddler [Riddler 1978] e Triangle [Zack et al. 1977] em termos de precisão para uma cultura de milho. Os resultados mostraram que o método Triangle teve um desempenho superior quando precedido pelos índices NDI (90,70%) e ExGR (90,23%) e os métodos Otsu e Riddler quando precedido pelo NDI com taxas de acurácia de 89,06% e 89,03%, respectivamente.

Varela et al. (2018) desenvolveu um método para contar plantas de milho usando o índice de vegetação ExG. Eles aplicaram aprendizado de máquina ao método usando um procedimento de treinamento escalonável com dois modos de treinamento. O método de precisão aplicado atingiu 96%, quando a resolução da imagem atingiu altitudes de 2,4 m e 10 m.

Ghosal et al. (2019) usaram uma rede neural convolucional (*CNN-Convolutional Neural Network*) para detectar e contar plantas com cabeça de sorgo. Eles demonstraram que é possível reduzir o trabalho necessário para a rotulagem humana sem prejudicar o desempenho do modelo final usando um modelo semi-treinado da CNN. Ao adotar sua abordagem, os usuários podem ter uma melhor compreensão do aprendizado profundo treinado e ser capazes de confiar em suas decisões. Outra técnica também foi utilizada para esse fim, que foi a representação gráfica em 3D, aplicada por Feng et al. (2019); este processou imagens ortomosaicas e um modelo digital de elevação para medir a altura da planta. Eles também conduziram uma análise de correlação para estimar os rendimentos com erros aceitáveis.

Além disso, algoritmos específicos foram criados para estimar com precisão a densidade da cultura junto as ervas daninhas. McCraine et al. (2019) usou a abordagem baseada na transformada de Hough. Os resultados mostraram que seu grau de acurácia foi de 82,3%, o que reforça a necessidade de aprimorá-lo.

Os trabalhos acima mencionados confirmam que existem soluções neste domínio, embora seja necessário ultrapassar o problema dos erros de contagem e garantir a precisão. Meyer, Camargo e Neto (2008) explicaram que existem dois problemas não resolvidos em relação à pesquisa do índice de vegetação, que são a falta de uma definição clara do tipo de limiar (manual ou automático) que deve ser aplicado durante a fase de binarização da imagem, e a falta de evidências sobre a precisão do índice de vegetação. A maioria das pesquisas examinadas nesta seção é baseada na seleção de limiar, seja manualmente, selecionando um tom de verde de intensidade variável (a análise de histograma), ou automaticamente usando métodos de limiar. Outra preocupação é como validar as soluções atuais envolvendo diversos fatores, como as condições de campos agrícolas reais, altura da imagem, intensidade da cor, etc.

3. Metodologia

Nesta seção são apresentadas a área do estudo, os materiais utilizados e os procedimentos metodológicos realizados.

3.1 Área de estudo

A Figura 1 (a) mostra a localização da Fazenda Bela Vista, que possui área total de 23.000m² e suas características de relevo são de morro. As coordenadas da fazenda são 3 ° 39'17,0 "S 49 ° 46 '32,7" W.

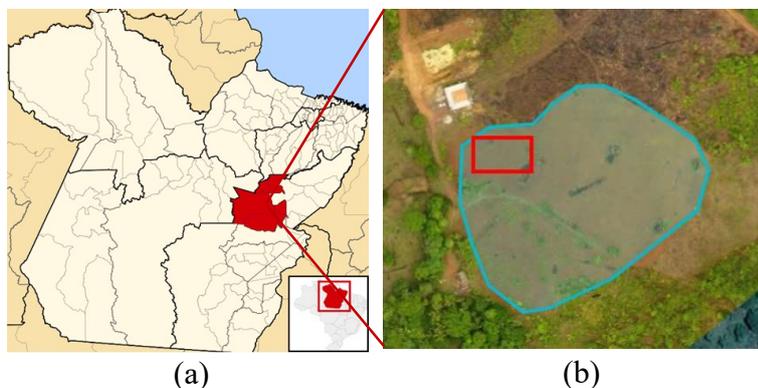


Figura 1 – (a) Localização da Fazenda Bela Vista. (b) Área total (azul) e área selecionada (vermelho) da plantação.

A Figura 1 (b) exhibe a área da plantação em azul com dimensão de 12.234 m². Já a área em vermelho possui 327 m² e foi escolhida para a aplicação dos índices de vegetação neste estudo, pois possui o melhor preparo do solo, de acordo com o agricultor, e uma área mais plana, com menos desníveis possíveis e linhas de plantio mais definidas.

3.2. Aquisição de imagens

As imagens foram capturadas por um VANT² em visitas programadas à fazenda. Todos os voos foram realizados de forma automática.

3.3. Índices de vegetação escolhidos

Para identificar as mudas de mandioca na imagem, foram aplicados três índices de vegetação: ExG que é um dos mais usados na literatura para destacar o verde das imagens; ExGR que tem se tornado um índice bastante eficiente para plantações; e MaxG que consiste na separação dos pixels da cor verde.

3.4. Segmentação

Esta técnica é usada para separar partes de interesse de uma imagem [Schalkoff 1989], como a separação da vegetação do solo. O método mais utilizado na agricultura é a limiarização, que consiste em segmentar a imagem, escolhendo um ponto de corte.

No estudo, a limiarização para cada índice de vegetação foi aplicada por meio de seleção automática e manual (Figura 2). A seleção automática baseou-se no Método Otsu [Otsu 1979], enquanto a seleção manual baseou-se em uma escolha empírica, que foi feita após alguns testes visuais, onde o limiar estava mais próximo do tom da cor da plantação de mandioca. A nomenclatura usada para a seleção manual de limiar (SML) foi: **ExG + SML**, **ExGR + SML** e **MaxG + SML**. Já os índices que utilizaram o

² *DJI Phantom 4* com peso de 1.388 g, autonomia de cerca de 25 minutos por bateria, velocidade máxima de 72 km/h, câmera RGB de resolução de 12 MP estabilizada por um GIMBAL tri-axial.

método Otsu foram designados como **ExG + Otsu**, **ExGR + Otsu** e **MaxG + Otsu**. Após a limiarização foi realizada a binarização da imagem.

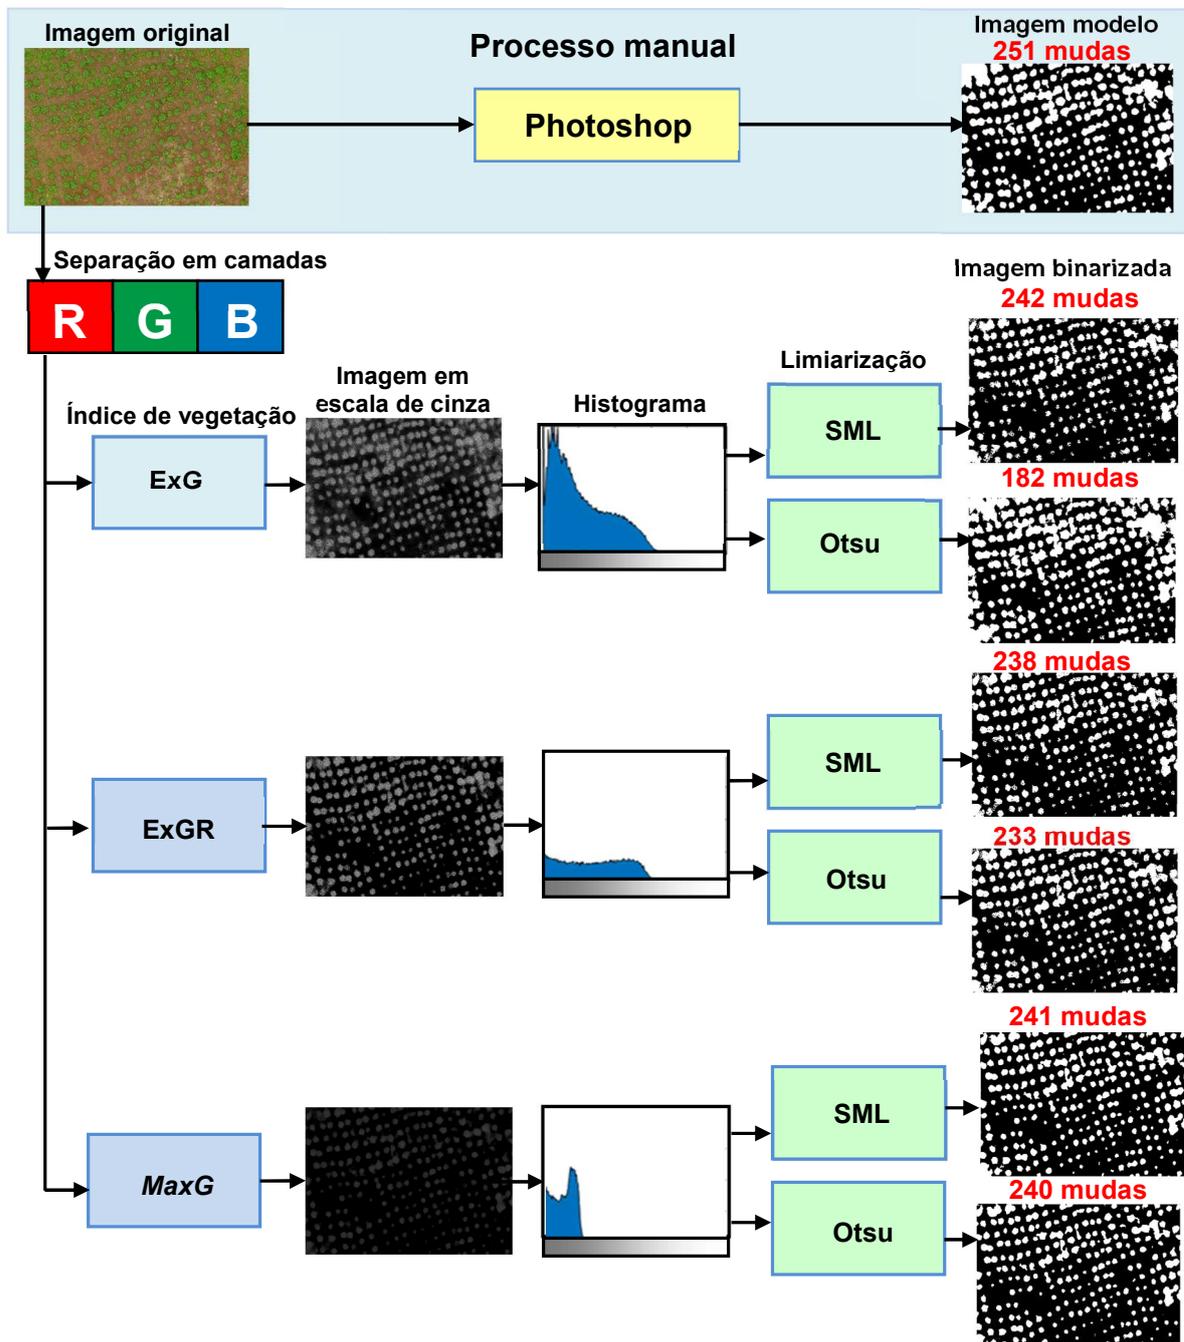


Figura 2 – Fluxograma das etapas do processo de contagem automática em comparação com o processo manual.

3.5. Avaliação da acurácia dos índices

Avaliou-se a acurácia dos índices de vegetação através do fator de qualidade definido pelo ATRWG e utilizado por Meyer e Camargo - Neto (2008). Na avaliação deste fator de qualidade, quanto mais próximo de 1,0 melhor é a separação de todos os pixels de classe selecionados. Próximo de zero representa uma pior separação dos pixels em

relação a imagem B. O fator de qualidade foi aplicado a cada planta extraída da binarização automática e manual.

A Figura 2 apresenta de maneira esquemática as etapas do pré-processamento, aplicação dos índices de vegetação, histogramas, limiarização, binarização e contagem das mudas nas imagens. A imagem gerada pelo processo manual³ foi utilizada na comparação dos resultados. O número total de mudas para o processo manual (251 mudas) conforme a Figura 2 serve como comparação para o processo de contagem automática.

3.6. Estimativas

Para a contagem das mudas de mandioca foi feita a estimativa de mudas para a área segmentada (Figura 2) e depois para a área total, através de uma regra de três simples. De acordo com a EMBRAPA (2018), cada muda de mandioca pode gerar em média até 1,5 kg de raiz. Portanto, com a contagem total de mudas da plantação, multiplicou-se pelo peso médio em kg da raiz produzida por cada muda para se estimar a produção.

4. Resultados e Discussão

Os valores para os índices de vegetação foram calculados a partir dos histogramas apresentados na Tabela 1. Nos histogramas percebeu-se que a alta incidência de curvas acentuadas causa maior interferência na luminosidade e, assim, leva a uma maior gama de cores no espectro. Isso significa que existe a necessidade de uma seleção de limiares para melhorar a quantificação da cultura, conforme apontado por Soares (2017).

O histograma do ExG tem uma curva acentuada, o que significa que este índice reconheceu mais tons de verde do que ExGR e MaxG. Na Tabela 1, ExG+SML e ExG+Otsu alcançaram valores superiores de 0,29 e 0,25 respectivamente, para os tons verdes detectados. Esse resultado está de acordo com o encontrado na literatura [Hamuda et al. 2016; Moorthy et al. 2015; Meyer e Camargo-Neto 2008], uma vez que comparações envolvendo ExG para separação de plantas e não-plantas apresentaram resultado satisfatório.

A taxa de acurácia foi de aproximadamente 83% para ExG+SML, o que é satisfatório para separação de vegetação. O ExGR+Otsu também demonstrou um bom índice de qualidade de segmentação de 78%, próximo ao encontrado na literatura [Hamuda et al. 2016; Meyer e Camargo-Neto 2008]. MaxG+Otsu apresentou a menor acurácia de 69%. No entanto, MaxG+SML ultrapassou a qualidade de segmentação do ExGR. A razão de acurácia obtida neste estudo é comparável a de outros estudos que adotam métodos semelhantes. Por exemplo, Varela (2018) obteve 96% para ExG na imagem original e este diminuiu para 89%, 85% e 68%, respectivamente, após a redução da resolução da imagem.

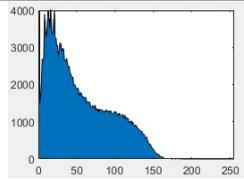
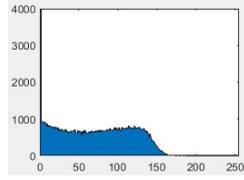
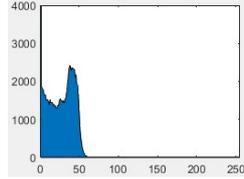
Na Figura 2, pode-se observar que a imagem binarizada do ExG+SML, proporcionou um delineamento mais claro do formato das folhas da mandioca, o que difere das imagens binarizadas do ExGR e MaxG. Assim, nesta condição, o ExG estaria mais sujeito a auxiliar na detecção do formato das folhas da mandioca.

³ Este processo foi feito no Adobe Photoshop C S6 (13.0) aplicando-se o filtro de ajuste de contraste (valor = 35) e brilho (valor = 0).

Devido a limiarização do ExGR e MaxG não ter se mostrado significativo para a interpretação das respectivas imagens resultantes, a contagem das mudas para a análise empírica e automática do histograma para estes índices foram próximas, o que sugere a possibilidade de ser desnecessário o uso de limiarização nestes tipos de índice, pois a acurácia pode independer da seleção do limiar. Meyer e Camargo - Neto (2008) denominam este tipo de situação de limiar zero incorporado, ou seja, não precisa de definição de limiar para a interpretação da imagem. Isto permite que um sistema de VC seja não-supervisionado na definição do limiar.

Com relação aos índices aplicados, o ExG obteve o melhor desempenho para a quantificação das mudas ao obter uma taxa de contagem de 96,4%, seguido do MaxG que contabilizou 96% das mudas de mandioca. Como as plantas estavam em estágio de germinação no momento da coleta das imagens, ExG foi provavelmente o melhor porque ainda havia muito solo na imagem. Como os autores do índice ExG e outros estudos recentes afirmam [Guerrero 2012; Hamuda 2016], ExG é a melhor escolha para separar plantas do solo nu em condições de campo.

Tabela 1 - Valores dos índices aplicados

<i>Índice</i>	<i>Histograma</i>	<i>Método</i>	<i>Valor do Índice</i>	<i>Q_{Seg}</i>	<i>% Acurácia</i>	<i>Contagem de Mudanças</i>	<i>Taxa de contagem</i>
ExG		SML	0,29	0,8280	83%	242	96,4%
		Otsu	0,25	0,8067	81%	182	72,5%
ExGR		SML	0,24	0,7250	73%	238	94,8%
		Otsu	0,21	0,7770	78%	233	92,8%
MaxG		SML	0,05	0,7529	75%	241	96%
		Otsu	0,07	0,6882	69%	240	95,6%

Após a quantificação das mudas, foi feita uma estimativa da produção (Tabela 2) da colheita em toneladas. Ao final da safra, a produção reportada pelo agricultor foi de 14 toneladas, valor próximo ao estimado para o processo manual. Assim, o índice ExG obteve 13,5 toneladas e obteve o melhor resultado para a fixação da imagem em estudo, ao contar 96,4% das mudas com índice de acurácia de 83%. O MaxG também obteve um resultado promissor com uma taxa de contagem de 96% das mudas, mas a taxa de acurácia foi menor, o que significa que é necessário melhorar esta taxa. As taxas de contagem poderiam ser aprimoradas com a aplicação de métodos de processamento de imagem morfológica para desconectar plantas acopladas, conforme percebido nas imagens binarizadas da Figura 2.

Tabela 2 – Estimativas totais de mudas e da produção

<i>Índice</i>	<i>Número total de mudas (Na área total 12.234 m²)</i>	<i>Estimativa da produção em toneladas</i>
Contagem manual	9287	14.0
ExG+SML	8954	13.5
ExG+Otsu	6734	10.0
ExGR+SML	8806	13.2
ExGR+Otsu	8621	13.0
MaxG +SML	8917	13.4
MaxG +OTSU	8880	13.3

Os resultados sugerem que as imagens baseadas em VANT têm potencial para quantificar plantas e estimar a produção agrícola com uma taxa de erro satisfatória de 17% para ExG, 25% para MaxG e 27% para ExGR, o que é aceitável, conforme mencionado por Guijarro (2011).

5. Conclusões

Esta pesquisa adotou técnicas de pré-processamento, aplicação de índices de vegetação, segmentação, extração e interpretação de imagens capturadas por um VANT. As imagens foram utilizadas para quantificar mudas de mandioca e estimar sua produtividade em uma fazenda de pequeno porte em Tucuruí/PA, localizada na região amazônica que se caracteriza por este tipo de atividade fundiária. Os procedimentos adotados proporcionaram resultados satisfatórios, quando comparados com a quantificação final da safra e estimativa de produtividade do próprio agricultor.

Na etapa de aquisição da imagem, notamos a importância da seleção de uma área representativa que servirá de linha de base para a estimativa final. Na etapa de segmentação de imagens, quando os índices foram aplicados, o índice ExG+SML obteve o melhor resultado, ao contar 96,4% das mudas com índice de acerto de 83%.

Como contribuições práticas para o agricultor, este estudo possibilitou a conscientização da importância de prever a estimativa da colheita para melhor planejar a negociação da produção, os plantios posteriores e a busca por recursos para aumentar a área mecanizada da cultura. Também foi possível perceber a necessidade de preparar as linhas de plantio, de melhorar o preparo do solo e a irrigação.

References

- Anguiano-Morales, M., Corral-Martínez, L. F., Trujillo-Schiaffino, G., Salas-Peimbert, D. P., García-Guevara, A. E. (2018) “Topographic investigation from a low altitude unmanned aerial vehicle”, *Optics and Lasers in Engineering*: 110, 63-71.
- CONTAG - Confederação Nacional dos Trabalhadores na Agricultura (2017) “Development of family farming”, *Anais do Congresso Nacional de Trabalhadores Rurais Agricultores e Agricultoras Familiares*, Março, pp. 36-39, Cidade Gráfica.
- EMBRAPA (2018) “Análises gráficas dos principais produtos agropecuários do Estado do Pará”, <https://www.embrapa.br/congresso-de-mandioca-2018/mandioca-em-numeros>.

- FAPESPA - Fundação Amazônia de Amparo a Estudos e Pesquisas do Pará (2015) "Boletim Agropecuário do Estado do Pará", http://www.fapespa.pa.gov.br/sites/default/files/Boletim_Agropecuario_do_Estado_do_Para_2015.pdf.
- Feng, A., Zhang, M., Sudduth, K. A., Vories, E. D., Zhou, J. (2019) "Cotton yield estimation from UAV-based plant height", *Trans. of the ASABE*: 62(2), 393-404.
- Gnädinger, F.E, Schmidhalter, U. (2017) "Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs)", *Remote Sensing*: 9(6), 544-559.
- Hamuda, E., Glavin, M., Jones, E. (2016). "A survey of image processing techniques for plant extraction and segmentation in the field", *Computers and Electronics in Agriculture*: 125, pages 184-199.
- Hague, T. Tillet, N. D., Wheeler, H. (2006), "Automated crop and weed monitoring in widely spaced cereals", *Precision Agriculture*: 7, 21-32. Springer.
- Hunt, E. R., Cavigelli, M., Daughtry, C. T., McMurtrey, J. Walthall, S. L. (2005), "Evaluation of digital photography from model aircraft for remote sensing of crop biomass", *Precision Agriculture*: 6(4), 359-378, Springer.
- Kataoka, T., Kaneko, T., Okamoto, H., Hata, S.(2003), "Crop growth estimation system using machine vision", In *Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2003)*: Vol. 2, pp. b1079-b1083. IEEE.
- Ghosal, S., Zheng, B., Chapman, S. C., Potgieter, A. B., Jordan, D. R., Wang, Singh, A. K., Singh, A., Ganapathysubramanian, B., Hirafuji, A., Ninomiya, S. (2019) "A weakly supervised deep learning framework for sorghum head detection and counting", *Plant Phenomics*: pages 1-14.
- Guerrero, J. M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M. (2012) "Support vector machines for crop/weeds identification in maize fields", *Expert Systems with Applications*: 39(12), pages 11149-11155.
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P. J., Burgos-Artizzu, X. P., Ribeiro, A. (2011) "Automatic segmentation of relevant textures in agricultural images", *Computers and Electronics in Agriculture*: 75(1), pages 75-83.
- McCraine, C. D., Samiappan, S., Czarnecki, J. M. P., Dodds, D. M. (2019) "Plant density estimation and weeds mapping on row crops at emergence using low altitude UAS imagery", In *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping: IV(11008)*, p. 110080Y. International Society for Optics and Photonics.
- Meyer, G. E., Camargo-Neto, J., Jones, D. D., Hindman, T. W. (2004) "Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images", *Computers and electronics in agriculture*: 42(3), pages 161-180.
- Meyer, G. E., Camargo Neto, J. (2008) "Verification of color vegetation indices for automated crop imaging applications", *Computers and electronics in agriculture*: vol. 63, pages 282-293. Elsevier.
- Moorthy, S., Boigelot, B., Mercatoris, B. C. N. (2015) "Effective segmentation of green vegetation for resource-constrained real-time applications", In *Precision agriculture*: 15, pages 93-98. Wageningen Academic Publishers.

- Netto, A. F. A., Martins, R. N., de Souza, G. S. A., Araújo, G. D. M., de Almeida, S. L. H., Capelini, V. A. (2018), "Segmentation of RGB images using different vegetation indices and thresholding methods", *Nativa: Pesquisas Agrárias e Ambientais*, 6(4), 389-394.
- Otsu, N. (1979) "A threshold selection method from gray-level histogram". *IEEE Transactions on Systems Man and Cybernetics*: 9(1), pages 62-66.
- Riddler, T. W., Calvard, S. (1978), "Picture thresholding using an iterative selection method", *IEEE trans syst Man Cybern*: 8(8), 630-632.
- SEAD - Secretaria Especial de Agricultura Familiar e do Desenvolvimento Agrário (2017) "Brasil: 70% dos alimentos que vão à mesa dos brasileiros são da agricultura familiar", <http://www.mda.gov.br/sitemda/noticias/brasil-70-dos-alimentos-que-v%C3%A3o-%C3%A0-mesa-dos-brasileiros-s%C3%A3o-da-agricultura-familiar>, acessado em 11/08/2019.
- Schalkoff, R.J. (1989) *Digital Image Processing and Computer Vision*, Wiley, 1th edition.
- Soares, G. A. (2017) "Identificação de linhas de plantio por meio da transformada de Hough", Trabalho de conclusão de curso, Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais.
- Varela, S., Dhodda, P. R., Hsu, W. H., Prasad, P. V., Assefa, Y., Peralta, N. R., T., Griffin, A., Sharda, A., Ferguson, Ciampitti, I. A. (2018) "Early-season stand count determination in corn via integration of imagery from unmanned aerial systems (UAS) and supervised learning techniques", *Remote Sensing*: 10(2), 343.
- Woebecke, D. M., Meyer, G. E., Von Bargaen, K., Mortensen, D. A. (1993) "Plant species identification, size, and enumeration using machine vision techniques on near-binary images", In *Optics in Agriculture and Forestry*: (1836), 208-219.
- Woebecke, D. M., Meyer, G. E., Von Bargaen, K., Mortensen, D. A. (1995) "Color indices for weed identification under various soil, residue, and lighting conditions", *Transactions of the ASAE*: (38), 259-269.
- Zack, G. W., Rogers, W. E., Latt, S. A. (1977). "Automatic measurement of sister chromatid exchange frequency", *Journal of Histochemistry & Cytochemistry*: 25(7), 741-753.