

TREINAMENTO DE ALGORITMO PARA IDENTIFICAÇÃO DE MUDAS DE CAFÉ POR MEIO DE IMAGENS AÉREAS

Lucas Santos Santana²; Gabriel Henrique Ribeiro dos Santos³; Gabriel Araújo e Silva Ferraz⁴; Luana Mendes dos Santos⁵; Brenon Diennevan Souza Barbosa⁶; Nicole Lopes Bento⁷

¹ Trabalho financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ)

² Doutorado, Engenharia Agrícola, Universidade Federal de Lavras, Lavras-MG, lucas.santana1@estudante.ufla.br

³ Graduando, Engenharia de controle a automação, Universidade Federal de Lavras, Lavras-MG, gabriel.santos6@estudante.ufla.br

⁴ Professor, DSc, Universidade Federal de Lavras, Lavras-MG, gabriel.ferraz@ufla.br

⁵ Doutoranda, Engenharia Agrícola, Universidade Federal de Lavras, Lavras-MG, luanna_mendess@yahoo.com.br

⁶ Doutorado, Engenharia Agrícola, Universidade Federal de Lavras, Lavras-MG, b.diennevan@outlook.com

⁷ Mestrando, Engenharia Agrícola, Universidade Federal de Lavras, Lavras-MG, nicolelbento@gmail.com

RESUMO: Aplicação de sistemas computacionais na agricultura vem se tornando necessidade, para incrementos de produtividade. A cafeicultura é considerada um dos mais importantes ramos do agronegócio brasileiro, mas alguns pontos ainda podem ser melhorados. A contagem de mudas de café é feita manualmente a campo, considerada uma técnica que apresenta baixa agilidade principalmente em grandes plantações, causando perda de tempo e desconforto à pessoa encarregada por este trabalho. A utilização de tecnologias avançadas no campo surge no contexto da agricultura de precisão. Esta pesquisa tem como intuito apresentar treinamento de um algoritmo para contagem automática de mudas de cafeeiros a partir de imagens obtidas por veículo aéreo não tripulado (VANT). O algoritmo desenvolvido é baseado numa rede neural artificial do tipo convolucional (RNC). A pesquisa foi realizada em uma área experimental de café em 2 estágios 3 e 6 totalizando 0,4 hectares no município de Bom Sucesso MG. Para a coleta das imagens foi utilizado um veículo aéreo não tripulado (VANT) modelo phantom 4, com capacidade de coletar imagens na composição Red Blue e Green (RGB). Os voos foram feitos com 30 metros de altura, velocidade de 3 m/s, sobreposição frontal e lateral de 80%. Para a criação do ortomosaico as imagens foram processadas no software Agisoft Photoscan e posteriormente tratadas no software Arcgis 10.2. Em seguida foi submetido a fase de treinamento, para a detecção automática das mudas no ortomosaico. Primeiramente foi necessário a criação de um banco de dados, com a finalidade de treinar e validar a rede neural YOLO (You Only Look Once). Após o treinamento foi utilizada a técnica de usar pequenos recortes de uma imagem se chama janelamento, na qual foram realizados 762 recortes. As imagens usadas para o treino da rede neural são distintas das imagens usadas para validação para assim o software demonstrar o aprendizado. Os resultados apresentados em plantas de 3 meses não foram satisfatórios, pois ocorreu confusão na identificação entre mudas e plantas daninhas e sombras. Nas imagens de 6 meses foi observado melhor desempenho na identificação por meio de treinamento de algoritmos. A partir do treinamento de algoritmo por meio de aprendizado foi possível detectar mudas de cafeeiros a campo. Portanto para um refinamento e maior precisão do algoritmo é necessário o treinamento em diversas áreas e cultivares diferentes.

PALAVRAS-CHAVE: Agricultura de precisão, ARP, visão computacional, plantio cafeeiro.

ALGORITHM TRAINING FOR COFFEE SEEDLING IDENTIFICATION BY AERIAL IMAGES

ABSTRACT: Application of computer systems in agriculture has become a necessity for productivity increases. Coffee is considered one of the most important branches of Brazilian agribusiness, but some points can still be improved. Coffee seedlings are counted manually in the field, considered a technique that presents low agility especially in large plantations, causing waste of time and discomfort to the person in charge of this work. The use of advanced technologies in the field arises in the context of precision agriculture. This research aims to present training of an algorithm for automatic counting of coffee seedlings from unmanned aerial vehicle images (UAV). The algorithm developed is based on a convolutional artificial neural network (RNC). The research was conducted in an experimental coffee area in 2 stages 3 and 6 totaling 0.4 hectares in the municipality of Bom Sucesso MG. To collect the images, we used an unmanned aerial vehicle images (UAV) model phantom 4, capable of collecting images in the composition Red Blue and Green (RGB). The flights were made 30 meters high, 3 m / s speed, 80% front and side overlap. For the creation of orthomosaic images were processed in Agisoft Photoscan software and later processed in Arcgis 10.2 software. He was then submitted to the training phase for the automatic detection of seedlings in the orthomosaic. First, it was necessary to create a database to train and validate the YOLO (You Only Look Once) neural network. After training, the technique of using small clippings of an image called window was used, in which 762 clippings were performed. The images used for neural network training are distinct from the images used for validation so the software demonstrates learning. The results presented in plants of 3 months were not satisfactory, because there was confusion in the identification between seedlings and weeds and shadows. In the 6-month images, better identification performance was observed through training of algorithms. From the algorithm training through learning it was possible to detect

seedlings of coffee trees in the field. Therefore, for a refinement and greater precision of the algorithm the training in several different areas and cultivars is necessary.

KEY WORDS: Precision agriculture, RPA, computer vision, coffee planting.

INTRODUÇÃO

Aplicações de tecnologias no campo produtivo já fazem parte do contexto atual do agronegócio. O conhecimento de que existe uma variabilidade nas áreas de produção, que pode ser devido às variações do relevo, solo, vegetação e também do histórico de uso vem sendo difundido sistematicamente. Conhecido como agricultura de precisão (AP), essa técnica pode trazer informações preciosas para técnicos e produtores rurais (MACHADO et al. 2017). Entre as tecnologias aplicadas no agronegócio o sensoriamento remoto é apresentado como uma técnica emergente na agricultura. Quando comparado a obtenção tradicional de amostras, o sensoriamento remoto é o método mais econômico para monitoramento e análises em larga escala na agricultura (KHANAL et al. 2017). Imagens a capturas a partir satélites e veículos aéreos não tripulados (VANT) são os mais utilizados em (AP). O imageamento com satélites tem grande contribuição nas análises de campo, portanto suas informações são limitadas quando se leva em consideração resolução espacial e temporal. Para suprir essa necessidade, aeronaves de pequeno porte como o VANT demonstra sua eficiência quando empregados ao mapeamento de pequenas áreas, proporcionando resolução temporal na ordem de minutos e alta resolução espacial (PEGORARO e PHILIPS 2011). A partir de altas resoluções espaciais obtidas em imagens coletadas por VANT, pode ser possível realizar observações a respeito do vigor e falhas na lavoura. Para isso técnicas de processamento digital e inserção de visão computacional são exploradas para melhoria dessas identificações. A visão computacional pode ser relacionada com a interação de técnicas de processamento digital de imagens com auxílio de ferramentas providas da inteligência artificial. Sua consequência são algoritmos capazes de classificar e detectar objetos específicos de interesse em fotos e vídeos. Em muitos problemas de visão computacional as redes neurais de convolução apresentam bons resultados (VARGAS et al.,2016).

Em culturas perenes, a implantação é feita por meio de mudas. No processo de plantio das mudas pode ocorrer falhas e interferir na produtividade. Na cafeicultura ainda são encontrados falhas após o plantio, fazendo que o produtor estime a quantidade a ser transplantada a partir de amostras. A aplicação de técnicas de sensoriamento remoto e visão computacional, podem oferecer resultados satisfatórios, na identificação e contagem de plantas no campo. Diante do contexto com o presente trabalho objetivou-se, propor um protótipo de algoritmo de contagem de plantas de café a partir de reconhecimento de padrão.

MATERIAL E MÉTODOS

A região de estudo compreende uma área experimental de 0.4 hectares. Nesse experimento encontra-se implantado uma área cafeeira com a cultivar Catuaí IAC 99. Propriedade rural denominada Fazenda Bom Jardim (Figura 01), situada no município de Bom Sucesso, Minas Gerais, sob as coordenadas 21°00'55.55" S e 44°54'57.75" O.

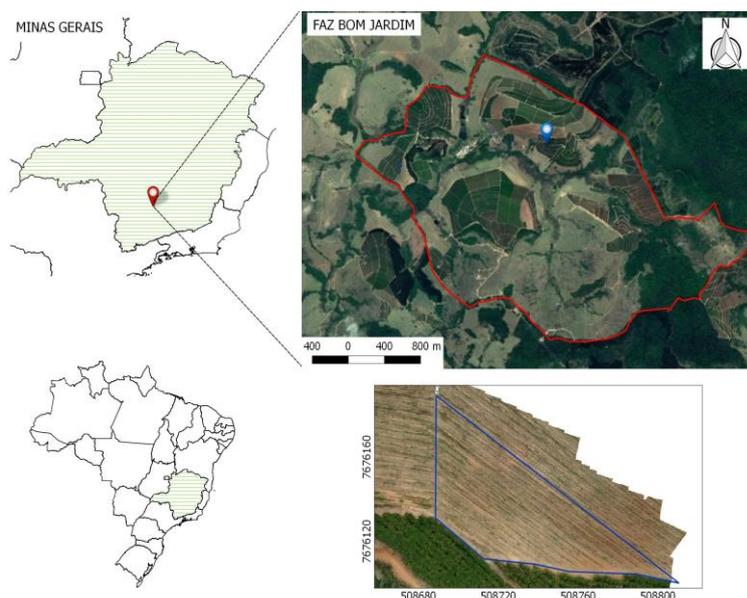


Figura 1. Localização da área de estudo.

A imagens foram capturadas por meio de uma aeronave remotamente pilotada (ARP), modelo Phantom 4 Advance com as seguintes características: Sistema de Posicionamento GPS/GLONASS equipado com sensor CMOS de 1 polegada para capturar fotos de até 20 megapixels. O planejamento de voo se iniciou com o reconhecimento da área, para definir as configurações do plano de voo, em seguida foi definido o ponto de pouso e decolagem, denominado “home”. Verificou se também as condições climáticas do ambiente como, quantidades de nuvens, níveis de insolação, velocidade do vento e presença de pássaros. Os voos foram realizados no horário de 12:00 horas por questões de baixa presença de nuvens e pouca interferência de sol. A missão foi definida com as seguintes características de plano de voo: altura de 30 m, velocidade 3m/s e sobreposição frontal e longitudinal de 80%, obtendo uma resolução espacial de 1,68 cm em três bandas espectrais Red, Blue e Green (RGB).

O tratamento das imagens foi realizado por meio do software Agisoft PhotoScan 1.4, por meio das seguintes etapas: alinhamento das imagens pelo processo de foto-triangulação. Nuvem de pontos esparsa, (densificação da triangulação). Modelo digital que possibilita representar de forma fiel o terreno mapeado tridimensionalmente. Aplicação textura no modelo obtido na etapa anterior para melhorar o aspecto visual e distinção entre objetos. Modelo de Elevação Digital (DEM) e ortomosaico em que são associadas todas as imagens coletadas. Na etapa seguinte o ortomosaico foi tratado em um software de SIG (Ggis 2.18), para recorte e reconhecimento da área de estudo.

Para a detecção automática das mudas no ortomosaico primeiramente foi necessário a criação de um banco de dados, com a finalidade de treinar e validar a rede neural YOLO (You Only Look Once). YOLO consiste em um modelo unificado em que uma única rede prevê a região em que um objeto está enquadrado informa a qual classe o objeto detectado pertence. Isso faz com que YOLO seja extremamente rápida, sendo executada em até 45 quadros por segundo (FPS) em sua versão convencional e até 155 (FPS) em sua versão reduzida (COSTA et al 2019). A criação do banco de dados consiste de imagens providas de pequenos recortes feitos do ortomosaico, onde cada recorte possui seu respectivo arquivo de texto denominado rótulo, onde se encontra a informação sobre a localização em pixels das mudas, assim como as suas dimensões, no respectivo recorte. A técnica de usar pequenos recortes de uma imagem muito grande se chama janelamento. As imagens usadas para o treino da rede neural são distintas das imagens usadas para validação. Após o treinamento da rede neural, foi feita a validação do modelo com os recortes não usados no processo de treino, onde se obtém a detecção das mudas representadas por retângulos superpostos a imagem do recorte original. Para o treinamento da rede neural foram utilizados 762 recortes em todo processo.

A segmentação é o processo que permite que uma imagem seja subdividida em partes constituintes ou regiões, a partir de propriedades dos pixels, tais como nível de cinza e textura (Hussain, 1991). A partir dessa técnica realizou-se a detecção das mudas, na qual foram utilizadas ferramentas de processamento de imagens da biblioteca OpenCV, em linguagem Python. Inicialmente é feito a fusão de todos os recortes resultantes do janelamento, para que assim seja reconstruído o ortomosaico de contagem. Feito isso, a última etapa consiste em contar a quantidade de retângulos em toda imagem, assim tem-se a quantidade de mudas identificadas. Esse teste foi realizado em nas plantas com 3 e 6 meses.

RESULTADOS E DISCUSSÃO

Após o treinamento da rede neural, foram feitas a detecção das mudas com as imagens do conjunto de teste. Ressalta-se que no conjunto de teste havia imagens de mudas com idades diferentes, assim como no conjunto de treino. As imagens que podem ser observadas na figura 2, são os resultados obtidos na detecção automática de plantas.

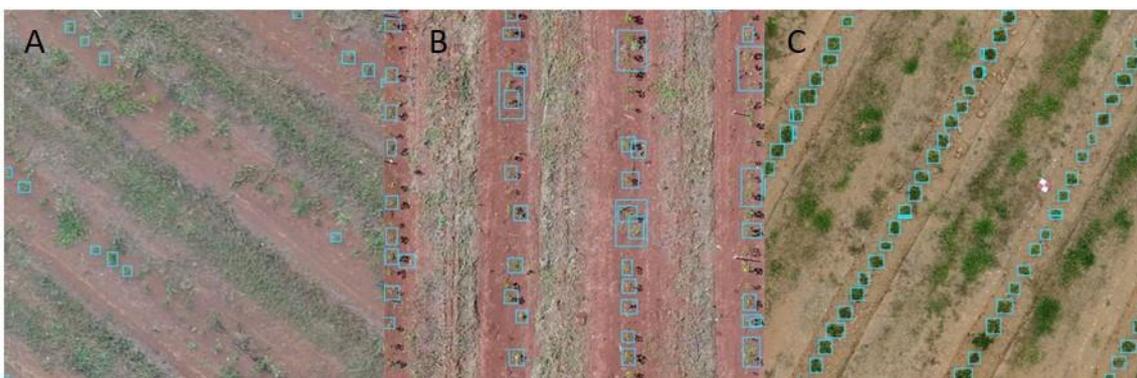


Figura 2. Detecção das mudas, (A e B) 3 meses e (C): 6 meses.

Observa-se que nas imagens com mudas de idades de 3 meses, não se obteve resultados satisfatórios de detecção que possam nos dar uma boa estimativa da quantidade de mudas na próxima etapa. Isso pode ter acontecido pelo fato de que no conjunto de treino havia mudas com diferentes idades. Supostamente, como as mudas de 6 meses são bem maiores do que as outras mais jovens, elas possuem muito mais informação de textura e forma, sendo muito mais determinante para a definição dos pesos sinápticos da rede neural durante o treino. Talvez o ideal fosse treinar a rede com um conjunto de imagens de mudas com a mesma idade das mudas das imagens de treino. Ou seja, para a detecção de mudas

com 3 meses de idade, treina-se a rede com mudas de 3 meses de idade. Sendo assim, levamos adiante apenas as imagens com mudas de 6 meses para o processamento de contagem. No processo de contagem, por meio de técnicas de segmentação da biblioteca OpenCV em Python (figura 3), obteve-se as seguintes imagens até a obtenção do resultado final.

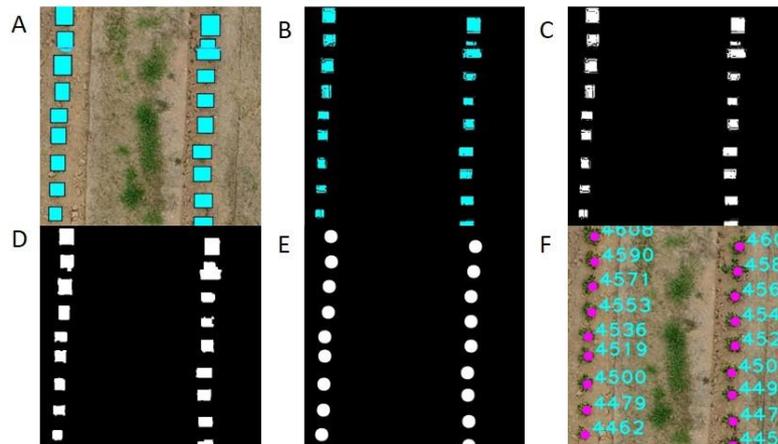


Figura 3. Processo de segmentação: Detecção com retângulos cheios (A); Segmentação da cor magenta (B); Binarização (C); Dilatação (D); Determinação do centro do menor círculo inscrito de cada área encontrada e contagem de círculos (E); Sobreposição dos círculos com os números no ortomosaico original(F).

A biblioteca OpenCV foi projetada com o intuito de tornar o desenvolvimento de sistemas de visão computacional mais rápido, eficiente e otimizado em diversas áreas, como a interação homem-máquina, em sistemas de tempo real e robótica (NEU, 2014). A maior dificuldade encontrada nesse processo é na junção dos retângulos da detecção de uma mesma muda que está na adjacência de uma imagem com a outra. O que pode ter ocorrido em plantas com o fechamento de copa ou confusão entre mudas de café e plantas invasoras. Isso ocorre devido a técnica de janelamento. Boa parte desse problema é neutralizada pela dilatação das áreas encontradas na binarização. Com imagens binárias, a dilatação conecta áreas que estão separadas por espaços menores que o elemento estruturante e adiciona pixels no perímetro de cada objeto da imagem (DOS SANTOS, 2011). Porém nos casos em que a dilatação falha pode acarretar a duplicação na contagem de áreas, mas como não são detectadas todas as mudas pela rede neural acaba acontecendo certa compensação na quantidade final. Falha na contagem ou falta de uniformidade no campo produtivo ainda pode ser um entrave na detecção de mudas no campo. Portanto sabe que mudas de café recém-plantadas pode ser confundida com outras espécies e o fechamento de copa o algoritmo pode considerar apenas uma planta.

CONCLUSÕES

- 1 - A partir do treinamento de algoritmo por meio de aprendizado foi possível detectar mudas de cafeeiros a campo. Portanto para um refinamento e maior precisão do algoritmo é necessário o treinamento em diversas áreas e cultivares diferentes.
- 2 - Para contagem e identificação de mudas a campo essa pesquisa demonstrou o melhor desempenho na detecção de mudas com seis meses.

REFERÊNCIAS BIBLIOGRÁFICAS

- COSTA, P. B., ALMEIDA, J. D. S., TEIXEIRA, J. A. M., JÚNIOR, G. B., DE PAIVA, A. C. Identificando a Paralisia do Sexto Nervo Ótico em Vídeos Através de Redes Neurais Convolucionais e Curvatura Isophotes. In Anais do XIX Simpósio Brasileiro de Computação Aplicada à Saúde (pp. 246-257). SBC. 2019.
- DOS SANTOS, R. M. Um estudo de processamento de imagens com Opencv. 2011
- HUSSAIN, Z. Digital Image Processing: practical applications of parallel processing techniques. Ellis Horwood. 406p. 1991.
- KHANAL, S., FULTON, J., SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. *Computers and Electronics in Agriculture*, 139, 22-32. 2017.
- MACHADO, J., DE FÁTIMA PADILHA, M. D. R., DE LIRA, F. P., DE OLIVEIRA, J. G., DA SILVA, R. S., CAETANO, M. B. C. Agricultura de Precisão e abertura de novas fronteiras no Brasil| Precision agriculture and opening new frontiers in Brazil. *Revista Geama*, 4(1), 49-53. 2017.
- MANZATTO, C.V.; BHERING, S.B.; SIMÕES, M. Agricultura de precisão: propostas e ações da Embrapa solos. EMBRAPA Solos. (1999) Disponível na Internet. <http://www.cnps.embrapa.br/search/pesqs/proj01/proj01>.
- NEU, C V. Desenvolvimento de um sistema de reconhecimento de sinais de trânsito utilizando processamento de imagens com OpenCV para um robô humanóide. Dissertação Unisc 2014.

NISHIDA, W. Uma rede neural artificial para classificação de imagens multiespectrais de sensoriamento remoto. Dissertação UFSC 1998.

PEGORARO, A. J. PHILIPS, J.W. “Quadrirotor/Microdrone como Portadores de Geosensores aplicados ao Cadastro Territorial”. In XV Simpósio Brasileiro de Sensoriamento Remoto -SBSR, Curitiba-PR, Brasil, INPE, 8461-8468, 2011.

VARGAS, A. C. G., PAES, A., VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: *Proceedings of the XXIX Conference on Graphics, Patterns and Images*. p. 1-4. 2016.

ZEILER, M.D; FERGUS, R. Computer Vision – ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, Proceedings, Part I. Springer International Publishing, ch. Visualizing and Understanding Convolutional Networks, pp. 818–833. 2014.