

Sistema de coleta de imagens para previsão de produção em pomares de maçã

Image collection system for forecasting production in apple orchards

Darlan Alaor Selzlein¹, Carlos Moyses Abrahão Auzi Ribeiro², Luciano Gebler³, Pedro Luiz de Paula Filho⁴

¹Bacharel, Ciência da Computação, Universidade Tecnológica Federal do Paraná, Medianeira (PR), Brasil, slz.darlan@gmail.com

²Graduando, Ciência da Computação, Universidade Tecnológica Federal do Paraná, Medianeira (PR), Brasil, carlosmoyses@gmail.com

³Engenheiro Agrônomo, Pesquisador, Embrapa Uva e Vinho, Vacaria (RS), Brasil, luciano.gebler@embrapa.br

⁴Professor Doutor, Ciência da Computação, Departamento de Computação (DACOM), Universidade Tecnológica Federal do Paraná, Medianeira (PR), Brasil, pedrol@utfpr.edu.br

RESUMO

A coleta de imagens é uma importante ferramenta para a agricultura de precisão. Porém, certas culturas, como a da maçã, dificultam sua realização devido ao uso de telas de proteção antigranizo, o que dificulta a utilização de drones. Diante disso, foi elaborado um sistema para a coleta de 4.062 imagens usando-se uma câmera acoplada a um veículo de solo, em um pomar de maçãs localizado no campo experimental da Embrapa Uva e Vinho, em Vacaria, estado do Rio Grande do Sul, Brasil. As imagens foram posteriormente utilizadas na geração de uma imagem panorâmica que compreendesse toda a lateral das fileiras de árvores do pomar e também foram empregadas no treinamento de uma rede neural convolucional, que foi utilizada para a contagem das frutas nas imagens panorâmicas, na intenção de obter uma contagem próxima à real, para que uma estimativa de produção pudesse ser feita. A contagem, no entanto, não obteve resultados estáveis, necessitando aprimoramentos na geração da imagem panorâmica e no treinamento da rede neural. Contudo, o projeto demonstrou a viabilidade e aplicabilidade da ideia.

Palavras-chave: agricultura de precisão; rede neural convolucional; imagem panorâmica.

ABSTRACT

Image collection is an important tool for precision agriculture. However, in certain crops, such as apples, anti-hail screens hinder the use drones for this collection. Therefore, a system was developed to collect 4062 images using a camera attached to a ground vehicle, in an apple orchard located in the experimental field of Embrapa Uva e Vinho, in Vacaria, state of Rio Grande do Sul, Brazil. The images were later used to generate a panoramic image that covered the entire side of the orchard's tree rows. They were also used in a convolutional neural network training to count the fruits in the panoramic images and obtain a count close to the real one to be able to estimate the production. The count, however, did not obtain stable results, requiring improvements in the generation of the panoramic image and the training of the neural network. However, the project demonstrated the viability and applicability of the idea.

Keywords: precision agriculture; convolutional neural network; panoramic image.

<https://doi.org/10.4322/978-65-86819-38-0.1000026>

 Este é um capítulo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution-NonCommercial-NoDerivatives, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que sem fins comerciais, sem alterações e que o trabalho original seja corretamente citado.

1 INTRODUÇÃO

No sentido de acompanhar o contínuo aumento da necessidade de alimentos, o desenvolvimento tecnológico vem buscando aumentar o potencial produtivo através de transformações nos sistemas agrícolas (Santos; Nascimento, 2009).

Entre as diversas técnicas utilizadas pela agricultura de precisão, pode ser citada a coleta de imagens aéreas, sendo utilizada em trabalhos como o de Feng et al. (2020), os quais, através destas, realizaram um estudo sobre a qualidade de emergência de plantas de algodão, ou em Ferreira et al. (2023), que utilizaram imagens aéreas para confecção de mapas de índices vegetativos em videira. Assim, imagens coletadas de uma área agrícola permitem a realização de estudos, como a estimação de produção ou a previsão de cenários; porém, culturas perenes como a da maçã possuem obstáculos que dificultam a coleta das fotos. Santos e Gebler (2021), em um trabalho sobre modelagem de previsão de colheita em maçã, já haviam detectado este tipo de problema, seja pela configuração da planta em 3-D ou, de ocorrência comum em pomares de maçã, pela utilização de telas de proteção contra intempéries do clima e insetos, impossibilitando a coleta de imagens aéreas e tornando necessária a utilização de uma ferramenta capaz de obter as fotos a partir do solo, por baixo da tela de proteção.

A obtenção das imagens a partir do solo, no entanto, sofre com o desafio de registrar toda a área agrícola com riqueza de detalhes, devido à sua extensão. Com o objetivo de solucionar esse problema, técnicas de processamento de imagens como o *stitching* podem ser utilizadas para o pré-tratamento das fotos e para o estudo e a extração de informações. Essa técnica consiste na colagem de diferentes imagens por meio da sobreposição de áreas semelhantes, formando um mosaico único (Wang; Yang, 2020). A utilização dessa técnica pode ser observada no trabalho de Tarallo et al. (2014), que a utilizam para realizar a colagem de imagens aéreas, posteriormente utilizadas no diagnóstico de queimadas e no reconhecimento de pragas em diversas culturas.

Para extrair informações das imagens obtidas, podem-se utilizar as redes neurais convolucionais (RNC), que são um tipo de inteligência artificial capaz de, após devido treinamento, reconhecer e categorizar padrões em imagens (Aggarwal, 2018), como o reconhecimento de maçãs (Tian et al., 2019).

Diante do exposto, buscou-se a elaboração de uma ferramenta capaz de capturar imagens de pomares de maçãs a partir do solo e que fosse adequada para a aplicação da técnica de *stitching*, para realização da

contagem de maçãs e da estimativa da produção por meio do uso de uma RNC.

2 MATERIAL E MÉTODOS

Os pomares de macieiras são geralmente organizados com as árvores distribuídas em fileiras com espaçamento variando de 1,8 a 3,4 metros, e que podem atingir uma altura de até quatro metros (Anzolin et al., 2021).

Para coletar as imagens do pomar a partir do solo, foi montado um sistema de baixo custo embarcado em um trator, composto por uma estrutura retangular de madeira, presa no contrapeso do trator e reforçada por duas travessas a 74 e 82 cm de altura, para o suporte e a estabilização de travessas diagonais laterais do sistema. Também foram utilizadas três câmeras de 720p com conexão USB 2.0 conectadas a um microcomputador Raspberry Pi com 1GB de memória RAM e processador de quatro núcleos. As câmeras foram instaladas a 50 cm uma das outras e anguladas em 45 graus avante para a tomada de imagens verticais de toda a fileira de árvores opostas à sua posição, para permitir uma maior distância focal.

O sistema foi montado de maneira que permitisse a obtenção de imagens de toda a altura da árvore e o microcomputador foi programado para armazenar as imagens das câmeras em intervalos de meio segundo, com o objetivo de garantir que toda a fileira de árvores pudesse ser fotografada. A estrutura montada pode ser observada na Figura 1.

A coleta das imagens foi realizada no campo experimental da Embrapa Uva e Vinho, em Vacaria-RS, no dia 4 de março de 2022. Foram coletadas 2.626 imagens no período da manhã e 1.436 imagens no período da tarde, de ambas as laterais de quatro fileiras de árvores, totalizando 4.062 imagens.

Após a coleta das imagens, diferentes técnicas de *stitching* foram testadas, buscando gerar a imagem panorâmica de toda a lateral de cada fileira do pomar, sobrepondo maçãs que aparecem em mais de uma imagem. Também foram montados panoramas sem realizar a sobreposição das maçãs, mas utilizando diferentes coeficientes de sobreposição vertical e horizontal, para eliminar regiões repetidas nas imagens.

As imagens coletadas também tiveram suas maçãs marcadas, compondo um conjunto de dados para o treino de um modelo de rede neural convolucional (RNC) que fosse capaz de reconhecer as maçãs. O modelo foi então aplicado na contagem de frutas em imagens panorâmicas geradas e os resultados obtidos foram comparados com os resultados reais.



a) Imagem frontal

b) Detalhe do suporte

c) Esquemático

Figura 1. Sistema para coleta de fotos de pomar de maçãs montado em trator.



Figura 2. Imagens coletadas pelas três câmeras do sistema ao mesmo tempo.

3 RESULTADOS E DISCUSSÃO

As imagens coletadas, em absoluta maioria, tiveram qualidade adequada de acordo com a capacidade das câmeras utilizadas, além de possuírem entre si áreas de sobreposição, necessárias para a realização do *stitching*. Na Figura 2, é possível observar a sobreposição entre as três câmeras ao identificar o mesmo grupo de maçãs em todas as fotos. De maneira semelhante, é possível observar a sobreposição entre as imagens coletadas pela mesma câmera em momentos vizinhos, na Figura 3.

Essas imagens foram utilizadas na tentativa de geração de imagens panorâmicas de toda a lateral da fileira de árvores por meio de algoritmos de *stitching* já existentes e utilizados em aplicações reais. Contudo, o excesso de detalhes, a grande quantidade de fotos

e a diferença de perspectiva entre estas impediu que esses algoritmos fossem capazes de reconhecer as regiões de sobreposição e realizar a colagem de maneira bem sucedida.

Diante disso, foram criadas imagens panorâmicas artificiais, geradas por meio da colagem das imagens obtidas, utilizando uma taxa de sobreposição vertical e horizontal para eliminar as regiões da imagem presentes nas imagens vizinhas. A colagem de imagens verticais pode ser observada na Figura 4. A colagem das imagens horizontais foi feita de maneira análoga. Os valores utilizados para as taxas de sobreposição foram 0, 0,2, 0,4, 0,6 e 0,8, e foram gerados panoramas para todas as combinações desses valores entre ambas as taxas. Foram obtidos 50 panoramas diferentes para uma fileira de árvores para va-



Figura 3. Imagens pela mesma câmera em tempos vizinhos.

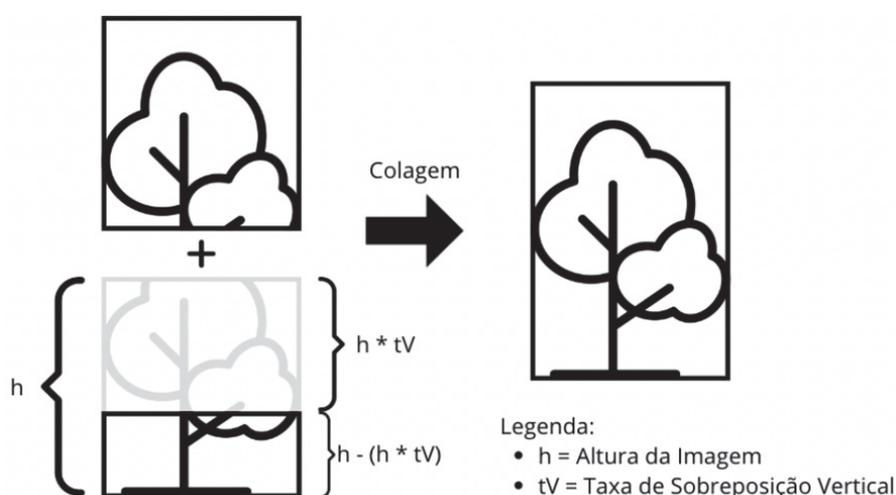


Figura 4. Colagem de imagens na vertical para a geração de panorama artificial.

lidar qual taxa permitiria uma contagem de maçãs mais próxima da real.

As imagens coletadas também tiveram suas maçãs anotadas para que pudessem ser utilizadas para o treinamento do modelo de RNC da família de RNCs YOLOv5. O melhor modelo treinado obteve uma precisão de 82,5% e uma cobertura de 77,8%. Um exemplo de maçãs sendo detectadas pela RNC pode ser observado na Figura 5, na qual as maçãs identificadas estão destacadas e rotuladas com um número que representa a certeza que a rede tem de que o objeto destacado é efetivamente da classe “apple”.

Esse modelo foi então utilizado na contagem de maçãs em todos os panoramas gerados. O melhor resultado de contagem foi para o panorama com as taxas de sobreposição vertical e horizontal 0 (zero), ou seja, para o panorama em que as imagens foram simples-

mente coladas, sem a remoção da região de sobreposição. A contagem de maçãs no panorama foi de 2.062 maçãs e a quantidade real de maçãs colhidas na mesma fileira foi de 1.999. A mesma taxa de sobreposição foi utilizada para a criação de panoramas de outras duas fileiras, e a contagem foi novamente realizada e comparada com os resultados reais. Os valores obtidos podem ser observados na Tabela 1.

Uma vez que anteriormente toda a previsão de colheita era baseada em análise visual por amostragem com base empírica (experiência do avaliador), sendo o resultado agrupado como a média de produtividade para um único talhão produtivo, esta abordagem de contagem é um avanço considerável, demandado pelos produtores, pois pode ser aplicada em toda a extensão do pomar, possibilitando a criação de mapas de produção de maçãs por planta.



Figura 5. Detecção de maçãs realizada pelo modelo de RNC treinado com as imagens coletadas pelo sistema embarcado.

Tabela 1. Contagem de maçãs feita pela RNC em panoramas de diferentes fileiras de árvores.

Fila	Contagem RNC	Contagem Real
1	2062	1999
2	1219	1706
3	1629	2620

Esses mapas podem revelar a variabilidade espacial da produção no pomar, permitindo a identificação de áreas com diferentes níveis de produtividade dentro do talhão e possibilitando assim a criação de zonas de manejo segundo a produtividade das plantas. Esse processo pode, por sua vez, auxiliar na gestão agrícola, ao identificar plantas mais e menos produtivas, bem como na delimitação de zonas homogêneas de produtividade, subsidiando tomadas de decisão mais assertivas, como, por exemplo, para o preparo da logística de colheita.

4 CONCLUSÕES

O sistema para a coleta de fotos dos pomares de maçãs a partir do solo se mostrou capaz de coletar ima-

gens adequadas para a realização de estudos. Porém, melhorias devem ser estudadas para que se aumente a eficiência do processo.

A coleta das imagens foi realizada de maneira bem sucedida, demonstrando a viabilidade prática do protótipo de obtenção das imagens. Entretanto, a utilização de câmeras com maior definição pode permitir o melhor uso das imagens coletadas

Não foi possível realizar o *stitching* das imagens utilizando ferramentas de *software* já disponíveis, porém, com a aplicação de uma técnica paralela para a geração de imagens panorâmicas, mostrou-se possível a obtenção de resultados mais confiáveis.

O treinamento do modelo de RNC demonstrou que é possível realizar o reconhecimento e a contagem de maçãs com as imagens obtidas, porém ainda há bastante espaço para aprimoramento através de novos treinamentos ou uso de diferentes modelos para a obtenção de resultados ainda melhores na identificação das frutas pela rede.

O uso do modelo de RNC para a contagem de maçãs nas imagens panorâmicas foi eficaz, realizando a contagem das frutas de uma fileira inteira de árvores de maneira rápida. Os números da contagem, no entanto, demonstraram instabilidade nos resultados. Para que resultados mais estáveis sejam obtidos, são necessárias melhorias na técnica de colagem das imagens, bem como no treinamento do modelo.

Embora o protótipo criado não tenha realizado uma contagem precisa, foi capaz de demonstrar a aplicabilidade da ideia, que pode ser aprimorada, bem como associada a outras tecnologias, como a utilização de geolocalizadores para a geração de mapas de produtividade ou zonas de manejo nos talhões produtivos.

AGRADECIMENTOS

À Embrapa, pelo suporte e pela disponibilização do campo experimental para a realização dos experimentos, e a Tassiane Barbara Perico Anzolin, por ter realizado os estudos iniciais que culminaram na realização deste trabalho.

REFERÊNCIAS

AGGARWAL, C. C. **Neural networks and deep learning**. Cham: Springer, 2018. DOI: <http://doi.org/10.1007/978-3-319-94463-0>.

ANZOLIN, T. B. P.; PAULA FILHO, P. L.; GEBLER, L.; TONIN, P. C. Desenvolvimento de mosaico de imagens para automatização de processos na fruticultura de precisão. In: CONGRESSO LATINO-AMERICANO DE SOFTWARE LIVRE E TECNOLOGIAS ABERTAS, 18., 2021, Foz do Iguaçu.

- Anais** [...]. Foz do Iguaçu: Latinoware, 2021. DOI: <http://doi.org/10.5753/latinoware.2021.19926>.
- FENG, A.; ZHOU, J.; VORIES, E.; SUDDUTH, K. A. Evaluation of cotton emergence using uav-based narrow-band spectral imagery with customized image alignment and stitching algorithms. **Remote Sensing**, v. 12, p. 1764, 2020. DOI: <http://doi.org/10.3390/rs12111764>.
- FERREIRA, R. A.; CARVALHO, L. F. D.; OLIVEIRA FOGAÇA, A.; PAULA AMARAL, L.; GEBLER, L.; AMADO, T. J. C. Análise da variabilidade espacial e zonas de produtividade em vinhedos, no Vale Central Gaúcho. **NATIVA**, v. 11, p. 297-308, 2023. DOI: <http://doi.org/10.31413/nat.v11i3.15696>.
- SANTOS, A.; NASCIMENTO, F. Transformações ocorridas ao longo da evolução da atividade agrícola: algumas considerações. **Enciclopédia Biosfera**, v. 5, n. 8, 2009.
- SANTOS, T. T.; GEBLER, L. A methodology for detection and localization of fruits in apples orchards from aerial images. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 13., Bagé. **Anais** [...]. Bagé: Unipampa, 2021. p. 1-9. DOI: <http://doi.org/10.5753/sbiagro.2021.18369>.
- TARALLO, A. S.; HIRAGA, A. K.; GAVIRA MARTINEZ, G. A.; PAIVA, M. S. V.; JORGE, L. A. C.; SENER, H. Uso de mosaico de imagens aéreas como ferramenta de auxílio ao diagnóstico de diversas culturas. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Eds.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 157-164.
- TIAN, Y.; YANG, G.; WANG, Z.; WANG, H.; LI, E.; LIANG, Z. Apple detection during different growth stages in orchards using the improved yolo-v3 model. **Computers and Electronics in Agriculture**, v. 157, p. 417-426, 2019. DOI: <http://doi.org/10.1016/j.compag.2019.01.012>.
- WANG, Z.; YANG, Z. Review on image-stitching techniques. **Multimedia Systems**, v. 26, p. 413-430, 2020. DOI: <http://doi.org/10.1007/s00530-020-00651-y>.