


PrunusBOT

Aplicação da robótica
à produção de pêsego
e cereja



COTHN
CENTRO OPERATIVO E TECNOLÓGICO
HORTOFRUTÍCOLA NACIONAL



PrunusBOT

PrunusBOT

Aplicação da robótica à produção de pêssego e cereja

Maria Paula Simões

(COORDENAÇÃO)

VOLUME I

CENTRO OPERATIVO E TECNOLÓGICO HORTOFRUTÍCOLA NACIONAL –
CENTRO DE COMPETÊNCIAS

Ficha Técnica

Título: PrunusBOT – Aplicação da robótica à produção de pêssego e cereja

Coordenação: Maria Paula Simões

Editor: COTHN-CC – Centro Operativo e Tecnológico Hortofrutícola Nacional – Centro de Competências

Autores e copyright:

Abel Veloso

Anabela Barateiro

André Veiros

António Ramos

Cristina Canavarro

Cristina Ramos

Dora Ferreira

Eduardo Assunção

Francisco Vieira

Hugo Fonseca

Hugo Proença

João Cunha

José Pedro Simões

Maria Paula Simões

Paulo Silvino

Pedro Dinho Silva

Pedro Dinis Gaspar

Preciosa Fragoso,

Ricardo Mesquita

Sandra Lopes

Revisão: Maria Paula Simões

Design Editorial: SUPER Brand Consultants

Tiragem: 300 exemplares

Impressão e Acabamento: Empresa Diário do Porto, Lda.

Data de Impressão: Abril de 2022

Depósito Legal: 497599/22

ISBN: 978-972-8785-21-5

Capítulo 7

Deteção de frutos

Eduardo Assunção¹, Pedro Dinis Gaspar^{1,2} e Hugo Proença^{3,4}

¹Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

²Center for Mechanical and Aerospace Science and Technologies (C-MAST)

³Universidade da Beira Interior | Departamento de Ciências da Computação

⁴Universidade da Beira Interior | Instituto de Telecomunicações

7.1 Introdução

A previsão de produção e da necessidade de embalamento no início da campanha agrícola são muito importantes para os produtores agrícolas e de embalagens. A previsão possibilita o planeamento da colheita, o espaço de trabalho, o armazenamento, apresentando outros benefícios adicionais.

As redes neuronais artificiais convolucionais (CNNs) têm contribuído grandemente para o progresso da deteção e classificação de objetos. (Sa et al., 2016) propuseram a utilização da rede Faster R-CNN com o objetivo de detetar pimento, melão, maçã, abacate, manga, morango e laranja. O presente estudo baseia-se neste estudo científico como base de trabalho. Dada a inexistência de estudos científicos com pêssegos, este artigo apresenta os resultados de deteção de pêssegos aplicando o método de deteção de objetos Faster R-CNN (Assunção et al., 2022).

7.2 Materiais e métodos

7.2.1 Modelo de deteção de frutos

No modelo Faster R-CNN, as saídas das camadas de convolução são denominadas de “mapas de características”. Numa segunda fase, utiliza-se a última camada de convolução como entrada de “Rede de proposta de regiões”, no qual produzem as regiões de interesses (ROIs-Region Of Interest) que contém os possíveis objetos. Essas ROIs são utilizadas na última fase do modelo de deteção para classificação dos objetos, bem como para um possível ajuste de posição do enquadramento da deteção do objeto na imagem de entrada. A Figura 7.1 mostra um esquema simplificado do método Faster R-CNN no contexto de deteção de pêssegos.

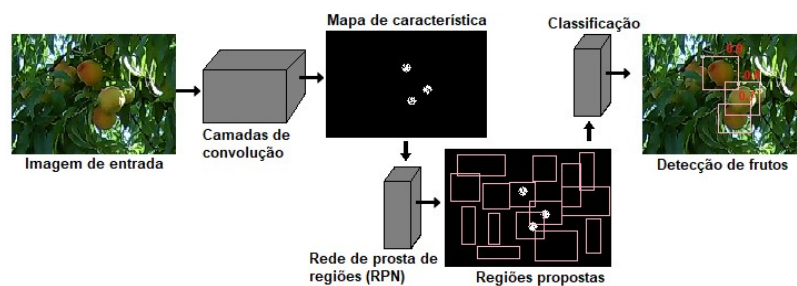


Figura 7.1 – Esquema simplificado do método Faster R-CNN no contexto de deteção de pêssegos.

7.2.2 Base de Dados

Uma base de dados de imagens foi construída com imagens de pomares de pessegueiros localizados na região da Beira Interior (Portugal), mais especificamente no Ferro, Orjais e Soalheira. Foi utilizada uma câmara Eken H9R para capturar as imagens. As imagens foram dimensionadas para um tamanho de 2736x1824. Para treino do modelo foram utilizadas 200 imagens de pessegueiros com canais RGB e 40 para teste. Para avaliar o desempenho de deteção foi utilizado a métrica AP (Average Precision).

7.3 Resultados e discussão

Nesse trabalho foi utilizada a métrica AP para avaliar a detecção dos pêssegos. Foi considerado como detecção o valor de IoU de 0,5, conforme o utilizado na maioria dos trabalhos de detecção de objetos. O valor de AP foi calculado (com IoU = 0,5). A seguir apresenta-se os resultados obtidos das detecções realizadas em imagens provenientes do mesmo pomar onde o modelo foi treinado, bem como em diferentes pomares com o objetivo de avaliar a capacidade de generalização do modelo.

7.3.1 Resultado do teste realizado em imagens do mesmo pomar onde o modelo foi treinado

Para este caso de estudo a precisão alcançada pelo modelo foi de 90% AP. As Figura 7.2 e Figura 7.3 mostram os resultados visuais.

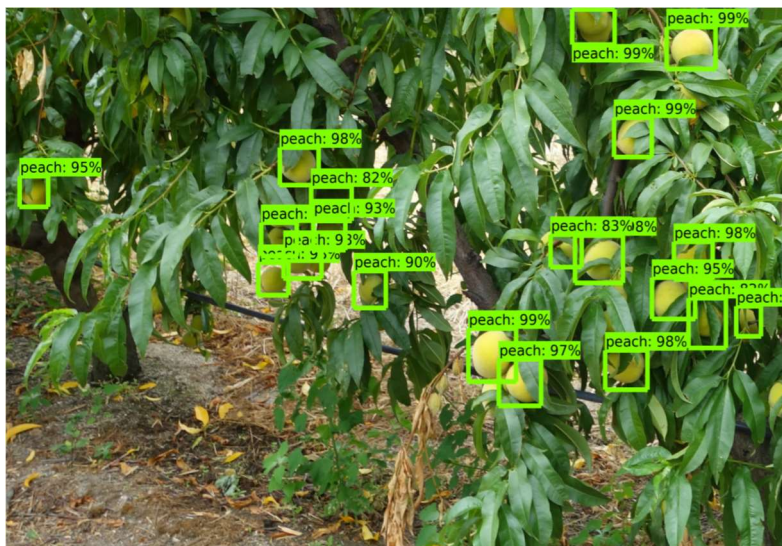


Figura 7.2 – Exemplo (1) de resultado de detecção de frutos de pêssegos em imagem do mesmo pomar onde o modelo foi treinado.

no caso mais difícil de detecção (muito ocluso). Para melhorar a precisão do modelo, as amostras deste pomar precisam ser incluídas no conjunto de dados de treino.




Figura 7.4 - Imagem de teste (1). Os retângulos representam os locais onde espera-se que o modelo detete frutos.



Figura 7.5 - Imagem de teste (1). Os retângulos representam os locais onde espera-se que o modelo detete frutos.

7.3.2.2 Segundo caso de teste

A Figura 7.6 e 7.7 mostram as imagens do segundo teste, observando-se que a iluminação não é boa pelo que não ajuda a distinguir frutos de folhas. Também, existem vários pequenos frutos.



Figura 7.6 – Imagem de teste (2). Os retângulos representam os locais onde espera-se que o modelo detecte frutos.



Figura 7.7 - Resultado da detecção (2). Os retângulos são as corretas detecções pelo modelo. Os círculos vermelhos são falhas, ou seja, detecções perdidas.

7.3.2.3 Terceiro caso de teste

A Figura 7.8 e 7.9 mostram as imagens do terceiro teste, observando-se que as folhas são amarelas, o que pode confundir o modelo pois os frutos são também amarelos. Contudo na Figura 7.9 pode verificar-se o excelente resultado da detecção.



Figura 7.8 - Imagem de teste (3). Os retângulos representam os locais onde espera-se que o modelo detete frutos.




Figura 7.9 - Resultado da detecção (3). Os retângulos são as corretas detecções pelo modelo. Os círculos vermelhos são falhas, ou seja, detecções perdidas.

O modelo lida bem com folhas amarelas, inferindo-se que, o que poderia afetar a precisão do modelo, não se verificou. Há apenas uma detecção falsa para folhas amarelas, uma para fruto ocluso e duas para frutos pequenos.

7.3.3 Resultado do algoritmo de detecção aplicado a contagem de frutos

O algoritmo de detecção foi aplicado para realizar contagem de frutos presentes em um vídeo capturado em um pomar de pessegueiro. A Figura 7.10 apresenta o resultado visual de um “frame” do vídeo.



Figura 7.10 - Exemplo de resultado da aplicação do algoritmo de detecção de frutos para contagem de frutos em vídeo.

7.4 Considerações finais

Os resultados preliminares para detecção de pêssegos utilizando o modelo de detecção de objetos Faster R-CNN mostraram um desempenho relativamente bom, inclusive para frutos agrupados e oclusos. Além disso, o modelo mostrou uma boa capacidade de generalização por detectar, com boa precisão, frutos de

pomares diferentes. Uma possível alternativa para melhorar o resultado de detecção dos pêssegos apresentado nesse trabalho, seria o aumento da quantidade de imagens de treino e também definir um melhor limite na oclusão dos frutos. Os resultados mostraram um grande potencial da aplicação do modelo Faster R-CNN para detecção de pêssegos, com o objetivo de implementar um sistema de estimação de produção em pomares. A metodologia utilizada para a detecção de frutos também pode ser estendida para aplicação de controlo de doenças.

Agradecimentos

Este trabalho foi desenvolvido no âmbito do projeto PrunusBOT – Sistema robótico aéreo autónomo de pulverização controlada e previsão de produção frutícola, Operação n.º PDR2020-101-031358 (Líder), Parceria n.º 340 / Iniciativa n.º 140, promovida pelo PDR2020 e cofinanciada pelo FEADER no âmbito do Portugal 2020.

Referências bibliográficas

- Assunção, E., Diniz, C., Gaspar, P. D., & Proença, H. (2020). Decision-making support system for fruit diseases classification using Deep Learning. *2020 International Conference on Decision Aid Sciences and Application (DASA)*, 652–656.
- Assunção, E., Gaspar, P. D., Mesquita, R., Simões, M. P., Ramos, A., Proença, H., & Inacio, P. R. M. (2022). Peaches Detection Using Deep Learning Technique—A Contribution to Yield Estimation, Resources Management and Circular Economy. *MDPI*.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks. *Sensors*, *16*(8), 1222