

Grupos Operacionais de Fruticultura 2018-2022



Ficha técnica

Título: Grupos Operacionais de Fruticultura no período 2018-2022

Editores: Maria Paula Simões e Carmo Martins

Propriedade e edição: Centro Operativo e Tecnológico Hortofrutícola Nacional - Centro de Competências (COTHN-CC)

Revisão do texto: Maria Paula Simões

Grafismo da capa: Super. Brand Consultants

Depósito legal:

Data de impressão: 2021

ISBN: 978-972-8785-18-5

GO PrunusBOT - Sistema robótico aéreo autónomo de pulverização controlada e previsão de produção frutícola



Parceria

UBI – Universidade da Beira Interior (**Líder**);
AAPIM - Associação de Agricultores p/a Produção Integrada de Frutos de Montanha;
APPIZÊZERE - Associação de Proteção Integrada e Agricultura Sustentável do Zêzere;
COTHN-CC- Centro Operativo e Tecnológico Hortofrutícola Nacional- Centro de Competências;
IPCB-ESA – Instituto politécnico de Castelo Branco | Escola Superior Agrária;
Produtor – Fernando Valério;
Produtor – Gonçalo Batista;
Sociedade Agrícola Quinta de Lamaçais - Organização de Produtores.

Palavras-chave: pêssego; robótica autónoma; pulverização de infestantes; previsão de produção.

Website: <https://goprunus.wixsite.com/prunoideas>

Investimento total: 430 556,09€

Logótipos dos Parceiros



Gonçalo Batista

Fernando Valério

Objetivos do GO PrunusBOT

1. Conceber, desenvolver e testar sistemas robóticos aéreo e terrestre autónomo destinado à locomoção nas entrelinhas de pomares, incorporando câmaras multiespectrais, para que através de algoritmos de análise e processamento de dados, seja efetuado:
 - o reconhecimento e classificação de infestantes;
 - o reconhecimento e classificação de frutos em árvores.
2. Desenvolver e testar um pulverizador regulável de alta precisão (adaptável) e respetivo controlador a incorporar ao sistema robótico terrestre autónomo para controlo de infestantes.
3. Avaliar o impacto da aplicação particular de herbicida nas infestantes na produção e qualidade dos frutos.
4. Avaliar a precisão das previsões de produção por análise de imagens multiespectrais, utilizando, para validação:

A avaliação real da produção com base no método tradicional de contabilização da produção de uma amostra de árvores (médias e variâncias);

A avaliação da eficiência técnica e económica do pomar através de modelos empíricos em função da carga;

A previsão da carga ótima com modelos empíricos para fins de execução de uma “monda de precisão”;

A integração da informação sobre o histórico de anos transatos, as condições edafoclimáticas, o estado sanitário e as práticas de fertilização.

5. Apanha e recolha de frutos caídos, através de uma garra acoplada a um braço cartesiano montado num sistema robótico terrestre.

Equipa do GO PrunusBOT

Entidades	Pessoas
UBI	Hugo Proença
	Pedro Dinis Gaspar
	Pedro Inácio
	Paulo Fiadeiro
	André Veiros (bolseiro)
	Eduardo Assunção (bolseiro)
	Ricardo Mesquita (bolseiro)
AAPIM	Francisco Vieira
	Paulo Silvino
APPIZÊZERE	Anabela Barateiro
	Ana Rita Gago Marques
	Cristina Ramos
	Preciosa Fragoso
	Sandra Lopes
COTHN	Carmo Martins;
	Pedro Turras
	Helder Coelho
IPCB-ESA	António Ramos
	Cristina Canavarro
	João Pedro Luz
	José Nunes e Turras
	José Sarreira Monteiro
	Maria Paula Simões
	Dora Ferreira (bolseira)
	Hugo Fonseca (bolseiro)
COTHN	Carmo Martins
Produtores	Gonçalo Batista
	Fernando Valério
SAQL	Paulo Parente

PrunusBOT - Sistema robótico aéreo autónomo de pulverização controlada e previsão de produção frutícola

Pedro D. Gaspar^{1,2*}, Eduardo Assunção¹, Ricardo Mesquita¹, André Veiros¹, António Ramos³ e Maria Paula Simões^{3,4}

¹UBI – Universidade da Beira Interior, Rua Marquês d’Ávila e Bolama, 6201-001 Covilhã, Portugal

²C-MAST - Centre for Mechanical and Aerospace Science and Technologies, Covilhã

³IPCB-ESA -Instituto Politécnico de Castelo Branco, Escola Superior Agrária, Quinta da Senhora de Mércules, 6001-909 Castelo Branco, Portugal

⁴CERNAS - Centro de Estudos de Recursos Naturais, Ambiente e Sociedade, Instituto Politécnico de Castelo Branco, Av. Pedro Álvares Cabral 12, 6000-084 Castelo Branco

*Email: dinis@ubi.pt

Resumo

A robótica autónoma destinada a operações de análise e atuação nas culturas agrícolas tem vindo a evoluir, existindo exemplos de monitorização de culturas, de rega automatizada (que integra diferente informação edáfica e meteorológica), de aplicação localizada de fertilizantes e de herbicidas, de colheita automatizada e de manuseamento/transporte de cargas.

Este projeto pretendeu conceber um sistema robotizado para previsão da colheita e aplicação particularizada de herbicida para controlo de infestantes. O sistema descrito neste artigo é composto por robôs autónomos, terrestre e aéreo com visão computacional por câmaras RGB e multiespectrais, que possibilitam i) deteção e reconhecimento de infestantes para aplicação precisa de produtos fitofarmacêuticos, ii) deteção e reconhecimento de frutos em árvores e copas destas, para caracterização das plantas e estimativa de produção.

O reconhecimento, quer seja de infestantes como de frutos, é realizado através do método de inteligência artificial Faster R-CNN, aplicado aos datasets de imagens recolhidas em campo. No reconhecimento das infestantes é calculado o seu centróide, para onde é deslocado o bico

de pulverização, anexo ao braço robótico cartesiano incorporado no robô terrestre autónomo. A função de reconhecimento dos frutos conduz à sua contagem, permitindo uma previsão da produção. Esta deteção é dificultada pela variação da iluminação natural, oclusão de frutos causada por folhas, ramos e outros frutos e múltiplas deteções da mesma fruta em imagens sequenciais. Os resultados experimentais de deteção de infestantes e de frutos em imagem de vídeo indicam uma precisão média de 85%.

A estimativa da produção é complementada pela previsão do volume da copa da árvore obtido por aquisição de imagem captada via câmara montada em drone, destinada a suportar modelos empíricos de carga das árvores. A função de pulverização de infestantes é complementada com a capacidade de apanha de frutos caídos no chão. Pretende-se assim contribuir para um sistema de produção mais sustentável através da redução de utilização de produtos fitofarmacêuticos e simultaneamente apoiar o produtor na gestão da carga do pomar com reflexos na gestão da cadeia comercial.

Palavras-chave: pêssego; robótica autónoma; pulverização de infestantes; previsão de produção.

Abstract

Autonomous robotics for analysis operations and operations in agricultural crops has been evolving, with examples of crop monitoring, automated irrigation that integrates different soil and meteorological information, localized application of fertilizers and herbicides, automated harvesting, handling/transport of loads.

This project aimed to design a robotic system for harvest prediction and individualized application of herbicide to control weeds. The system described in this article is composed of autonomous robots, land and air with computer vision by RGB and multispectral cameras, which enable i) detection and recognition of weeds for precise application of plant

protection products, ii) detection and recognition of fruits in trees and crowns of these, for plant characterization and production estimate.

The recognition, whether of weeds or fruits, is carried out using the Faster R-CNN artificial intelligence method, applied to the datasets of images collected in the field. In the recognition of weeds, their centroid is calculated, where the spray nozzle, attached to the Cartesian robotic arm incorporated in the autonomous land robot, is moved to. The fruit recognition function leads to their counting, allowing a production forecast. This detection is hampered by varying natural lighting, occlusion of fruits caused by leaves, branches and other fruits, and multiple detections of the same fruit in sequential images. Experimental results of weed and fruit detection in video image indicate an average accuracy of 85%.

The production estimate is complemented by the prediction of the tree canopy volume obtained by acquiring an image captured via a camera mounted on a drone, designed to support empirical models of tree load. The weed spraying function is complemented with the ability to pick up fallen fruit. The aim is thus to contribute to a more sustainable production system by reducing the use of plant protection products and simultaneously supporting the producer in managing the load of the orchard, with consequences in the management of the commercial chain.

Keywords: peach; autonomous robotics; weed spraying; production forecast.

Introdução

O processo de produção frutícola envolve a gestão de um vasto conjunto de técnicas culturais. Entre estas podem salientar-se as questões relacionadas com a manutenção do solo em pomares, que tem como objetivo o controlo das espécies infestantes, e a manutenção ou aumento da fertilidade do solo, tendo em consideração a sua preservação. É importante salientar que esta técnica tem um impacto

direto no desenvolvimento das plantas (Ferreira et al., 2017) e na gestão de água (Simões et al., 2017). Outra atividade de relevo consiste na previsão da produção para gerir todos os aspetos relacionados com a colheita e comercialização, entre os quais os contratos de fornecimento, até à definição dos valores de seguros de colheita. Para a previsão da colheita, atualmente é realizada uma seleção aleatória de um determinado número de árvores onde se procede à contagem dos frutos, podendo ser apoiada por medições de calibre. A precisão da estimativa da produção aumenta com o tamanho da amostra, mas requer mais trabalho e tempo, o que se traduz em maiores custos. Paralelamente, denota-se o desenvolvimento de soluções robóticas autónomas destinadas a operações de análise e atuação nas culturas, existindo hoje exemplos de sistemas robóticos destinados à monitorização de culturas, à rega automatizada que integra diferente informação edáfica e meteorológica, à aplicação localizada de fertilizantes e de herbicidas, à colheita automatizada e ao manuseamento/transporte de cargas. Neste sentido pretende-se desenvolver sistemas robóticos aéreo e terrestre autónomos, capazes de realizar duas funções: aplicação precisa de herbicida e estimativa da produção, pela análise/processamento de dados de imagens digitais de câmaras RGB e multiespectrais. Dois algoritmos de caracterização de análise serão desenvolvidos. O 1º algoritmo distingue a mancha de infestantes localizada na linha das plantas para aplicação precisa de herbicida. Um 2º algoritmo caracteriza a árvore, determina a copa e distingue os frutos, calculando as suas dimensões, para realizar a previsão da produção, transitando o sistema robótico nas entrelinhas do pomar para captar imagens laterais e de topo das árvores.

O desenvolvimento de um equipamento robótico com estas características destina-se ao controlo de infestantes numa fase inicial do seu desenvolvimento visando a utilização de menor quantidade de herbicida, quer pelo menor volume das infestantes, quer pela precisão da aplicação que será apenas dirigida aos objetos de cor verde, quer pela autonomia de realização da tarefa. A precisão do controlo das

infestantes e a menor quantidade de herbicida contribuem para o aumento da rentabilidade do pomar, quer por via da possível diminuição dos custos variáveis, quer pelo aumento da produção resultante da maior disponibilidade de água e fertilizantes. Adicionalmente, estes resultados enquadram-se numa melhoria da sustentabilidade ambiental da cultura provada pela redução da aplicação de produtos fitossanitários.

Por outro lado, a previsão mais assertiva da produção com os algoritmos de análise e processamento de imagem de caracterização das árvores e de segmentação e classificação dos frutos, possibilita aos produtores uma melhor gestão da carga e previsão da produção, podendo gerir melhor a necessidade de monda de frutos para aumentar o seu calibre e negociar com maior confiança as quantidades e a qualidade (calibre) dos frutos na celebração de contratos de fornecimento. Esta vantagem resulta numa maior rentabilidade da produção e na promoção das relações Produtor/Retalhista, contribuindo para a redução do desperdício alimentar devido à rejeição de produto, já que este poderá ser conduzido atempadamente para outro fim.

Após o desenvolvimento desta tecnologia em pomares de Prunóideas, esta poderá ser adaptada a outro tipo de pomares (Pomóideas) com repercussões a nível regional e nacional.

Deteção de frutos

A previsão de produção e da necessidade de embalamento no início da campanha agrícola são muitos 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 detecção de pêssegos aplicando o método de detecção de objetos Faster R-CNN.

Deteção de copas de árvores

A avaliação do tamanho das copas das árvores é um instrumento para avaliar o desempenho individual de cada planta, permitindo estimar as necessidades de água, de fertilizantes e de pesticidas e o rendimento de produção. Com veículos aéreos não tripulados e câmaras minimizadas de alta resolução é possível estimar o tamanho das copas das árvores usando imagens e modelos de visão computacional. Nesse trabalho, sugerimos uma metodologia para detecção de copas de árvores que tem como base a aprendizagem profunda e CNN.

Manutenção do solo em pomares de pessegueiro

O controlo das infestantes é uma operação cultural que visa diminuir a competição que estas exercem com a cultura pelos fatores água e nutrientes. Na região da Beira Interior, o tipo de manutenção do solo mais comum em pomares de pessegueiro é um sistema misto constituído por solo nu não mobilizado na linha e enrelvamento na entrelinha (Simões, 2017). A aplicação de herbicida no início do ciclo vegetativo apresenta uma particular importância no controlo das infestantes, sendo um dos fatores determinantes para o seu sucesso, devendo ser realizada 2 a 3 semanas antes do abrolhamento (Simões, 2021). Após essa primeira aplicação, que correspondente a toda a área da linha das plantas (habitualmente corresponde a uma faixa de 2 m (1 m para cada lado da linha das plantas), observa-se sempre a presença de algumas infestantes, que se pretende que sejam eliminadas de forma particularizada.

A deteção automática de infestantes é uma das soluções viáveis para redução ou exclusão eficiente de produtos químicos na produção. Os estudos e pesquisas têm focado e combinando abordagens modernas que analisam e avaliam automaticamente infestantes em imagens. Este

estudo propõe um método para deteção de infestantes que pode ser embutido em dispositivos móveis.

Modelos empíricos no estudo da eficiência do sistema produtivo em pessegueiro

O sistema de plantação foi definido por Robinson et al. (1991), como sendo a combinação do porta-enxerto (vigor), do desenho da plantação (densidade e compasso), da forma de condução e do regime de poda. Como os ensaios de sistemas de plantação apenas dão informação sobre as condições particulares de cada caso, Robinson e Lakso (1991) estabeleceram as bases da “eficiência produtiva” para permitir uma melhor compreensão sobre o desempenho da árvore ou do pomar. A expressão da produção por unidade de área transversal da secção do tronco (kg/cm^2) e por unidade de volume da copa (kg/m^3) são os indicadores mais utilizados para efeitos de comparação entre diferentes sistemas produtivos. Considerando fatores produtivos e económicos, um índice de eficiência do pomar deve corresponder à máxima receita do produtor. Esta, por sua vez, deverá ser uma solução de compromisso entre a redução da carga e o acréscimo na valorização dos frutos, através de uma eficiente tecnologia de monda de frutos (Robinson et al., 2013).

Ramos (2017) desenvolveu modelos empíricos a partir de uma base de sete casos estudados (case-studies) com o pessegueiro ‘Catherine’ na zona sul do concelho do Fundão, de forma a efetuar a previsão empírica da capacidade produtiva do pomar.

Robô terrestre autónomo

A robótica terrestre agrícola surge em 1920 com a pesquisa de métodos de orientação autónoma de veículos para agricultura. Entre os anos de 1950 e 1960, são iniciados os primeiros protótipos e apenas na década de 80, com o desenvolvimento do computador, a orientação com recurso à visão computacional tal se tornou possível (Veiros et al., 2019). A evolução da tecnologia juntamente com a necessidade de otimizar os processos de produção agrícola, deu origem a uma robótica

apta a executar tarefas, como o controlo de infestantes, monitorização de áreas, colheita, poda, pulverização, entre outros, nas mais diversas culturas. Independentemente do atual progresso da robótica terrestre, esta continua a apresentar-se como uma área de difícil aplicação na agricultura, devido à complexidade requerida e à dificuldade em generalizar os sistemas, nomeadamente, a variabilidade nos contextos extrínsecos, como as condições ambientais e obstáculos físicos à circulação, e intrínsecos, como o crescimento das culturas e a heterogeneidade de cor.

São já vários os robôs terrestres autónomos desenvolvidos para aplicação agrícola. Relativamente ao combate às infestantes existem sistemas robotizados terrestres que fazem uso de visão computacional para detetar a infestante e braços robóticos para posicionar o bico de pulverização (Sukkarieh, 2016; Wendel & Underwood, 2016; McCool, et al., 2018; Ecorobotix; 2019). Foram desenvolvidos e estão disponíveis um conjunto de robôs terrestres destinados a operações em vinhas (Diago et al., 2015; Naio Technologies, 2019; Agrob, 2019). Outros robôs foram desenvolvidos para tarefas associadas ao manuseamento, transporte, entrega, sementeira e recolha de dados de plantas e solos (Blender et al., 2016; Grimstad & From, 2017; Harvestai, 2019; Earthsense, 2019).

Robô aéreo autónomo

Veículos aéreos não tripulados, habitualmente denominados por drones, são sistemas eletrónicos de baixa manutenção e alta versatilidade. Esta tecnologia tem sido cada vez mais estudada e desenvolvida ao longo dos anos, sendo também aplicada da agricultura. Atualmente, os drones têm já impacto direto na agricultura através da realização de tarefas específicas, destacando-se a monitorização e apoio na tomada de decisão dos produtores. Um exemplo é o DJI AGRAS T20 (DJI, 2020), que foi desenvolvido para possibilitar a pulverização autónoma, fazendo uso de um sistema de Posicionamento Cinemático em Tempo-Real (Real-Time Kinematic - RTK). Trata-se de drone com certificado IP67, possuindo um radar omnidirecional para deteção de

obstáculos, sejam estes objetos ou solo, e um sistema de monitorização em tempo real. Segundo Veroustraete (2015), o maior ganho desta tecnologia na agricultura é o seu uso com câmaras multiespectrais e RGB para monitorizar o progresso e o crescimento das plantações em grande escala, fazendo uso do Normalized Difference Vegetative Index (NDVI) e de sensores near-infrared (NIR).

Materiais e Métodos

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 da “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 1 mostra um esquema simplificado do método Faster R-CNN no contexto de deteção de pêssegos.




Figura 1 - Esquema simplificado do método Faster R-CNN no contexto de deteção de pêssegos.

Uma base de dados de imagens foi construída com imagens de pomares de pessegueiro 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).

Modelo de deteção de copas de árvores

Neste estudo foi criada uma base de dados de imagens com imagens de pomares de pessegueiro localizados na Beira Interior (Portugal), nomeadamente Ferro, Orjais e Soalheira, compreendendo duas zonas distintas de produção de pêssego, a norte e a sul da serra da Gardunha. Foi utilizada uma câmara RGB acoplada a um drone para capturar as imagens. A Figura 2 ilustra a aquisição das imagens que compõe a base de dados.



Figura 14 – Exemplo 1 de imagem capturada para composição da base de dados de imagens.

O mesmo modelo (Faster R-CNN) foi utilizado para a deteção de frutos e para a deteção das copas das árvores. A diferença residiu na base de dados em que o modelo foi treinado. O modelo Faster R-CNN tem como saída os retângulos que delimitam os objetos detetados. No entanto, as copas das árvores diferem muito geometricamente de retângulos. Como forma de reduzir esta diferença, foi proposta a aproximação geométrica de um retângulo para uma elipse conforme ilustrado na Figura 3.




Figura 3 – Exemplo de resultado de deteção de copas de árvores, ajustando a um retângulo ou uma elipse.

Manutenção do solo em pomares de pessegueiro

Para a realização deste trabalho utilizaram-se 3 Unidades de Observação (UO), que correspondem a 3 pomares de pessegueiros. Em cada UO marcaram-se 4 blocos de 4 plantas contíguas. Ao longo de 3 ciclos vegetativos foi realizada a monitorização da ocupação do solo por infestantes, tanto na linha como na entrelinha. Para tal, utilizou-se a metodologia referida por Simões et al. (2017), que consistiu em determinar a percentagem de ocupação do solo por infestantes

utilizando uma grelha de 64 quadrículas de 7,5 cm × 10,0 cm. A ocupação por infestantes foi classificada de acordo com o Quadro 1, para poder ser posteriormente relacionada a ocupação de infestantes com o volume de copa e a produção.

Quadro 1 – Classificação do desenvolvimento das infestantes na linha e entrelinha.

Linha	altura infestantes				Entrelinha	altura infestantes			
	< 10 cm	10-15 cm	15-20 cm	> 20 cm		ocupação	< 10 cm	10-15 cm	15-25 cm
ocupação									
0-20%	1	1	2	2	<50%	1	1	2	3
20-40%	1	2	3	3	50 a 80%	1	2	3	4
40-60%	2	3	3	4	80 a 100%	1	3	4	5
60-80%	3	3	4	4					
100%	3	4	4	5					

Modelo de detecção de infestantes

Foi empregue um algoritmo de inteligência artificial por aprendizagem profunda (Deep Learning) com uma CNN com uma estrutura encoder-decoder de segmentação de imagens, nomeadamente a Deeplabv3 (Chen et al., 2018; Fawakherji et al., 2019), adaptada e treinada para segmentar as imagens das infestantes no pomar de pessegueiros. A Figura 4 ilustra o modelo simplificado.




Figura 4 – Descrição simplificada do modelo com rede neuronal de segmentação de infestantes.

O sistema de visão computacional tem a finalidade de fornecer às componentes mecânicas do pulverizador, isto é, ao manipulador robótico cartesiano, as localizações espaciais (coordenadas) dos centróides das infestantes, para que o manipulador robótico se possa movimentar no plano x-y para cada uma destas localizações em coordenação com a locomoção do rover robótico e ativar o bico de pulverização para aplicação do herbicida. O manipulador robótico também se movimenta segundo z no sentido de afastar (abrir) ou aproximar (fechar) a área de pulverização em função da área da infestante.

Previsão da capacidade produtiva do pomar com modelos empíricos (ex.: pessegueiro ‘Catherine’)

Na época da colheita do pêssego ‘Catherine’ foi realizada: a) medição da altura (A) e da largura (L) máxima (direção da entrelinha) para determinar o volume de 15 árvores individuais ($V = A \times L \times D$), sendo D a distância entre plantas na linha; e b) registo do peso da produção e do número de frutos por cada árvore individual. A avaliação do efeito da carga (X, nº de frutos por árvore) no peso médio do fruto (Y, g/fruto) foi efetuada por ajustamento não linear, de acordo com a Equação (1):

$$Y = 1/(a \times X + 1/b) \quad (1)$$

Em que a e b são os parâmetros do modelo (equação não linear). Pela equação do modelo é possível verificar que o peso médio do fruto pode ser estimado em função da carga e dos parâmetros a e b. Com o peso médio do fruto também se pode estimar a distribuição da produção por classes de calibre (Ramos, 2017). Deste modo, para além da contagem de frutos são necessários, apenas, os parâmetros a e b para calcular todos os resultados produtivos e económicos do pomar. A aplicação do modelo a cada case-study leva à obtenção de diferentes parâmetros a e b quando se utilizam as cargas expressas por árvore, mas o parâmetro a revelou-se constante quando as cargas se expressam por unidade de volume (nº de frutos/m³).

Principais resultados

Modelo de detecção de frutos

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) para as inferências das detecções das 40 imagens de teste e 200 imagens de treino, obtendo-se o resultado de 0,87. Este valor obtido indica uma boa precisão na detecção dos frutos, conforme se pode confirmar pela análise da Figura 5.




Figura 5 – Exemplo de resultado de detecção de frutos de pêssegos.

Modelo de detecção de copas de árvores

A métrica AP foi utilizada para avaliar a detecção das copas de árvores. O valor de AP foi calculado para as inferências das detecções de 30 imagens de teste, obtendo-se o resultado de 0,85. Um exemplo de resultado de detecção pode ser visualizado na Figura 6. Uma possível

alternativa para melhorar o resultado de deteção da copa das árvores apresentado nesse trabalho seria a utilização do modelo de deteção/segmentação Mask R-CNN (He et al., 2017). Figura 6, mostra uma ilustração do resultado de saída do modelo Mask R-CNN. Nesse modelo, além da posição das árvores (deteção) também são fornecidos os pixéis pertencentes a cada copa da árvore (segmentação).



Figura 6 – Exemplo de como será o resultado de deteção de copas de árvores com o modelo Mask R-CNN.

Manutenção do solo em pomares de pessegueiro

Das observações realizadas verifica-se que todas as UO apresentam solo nu não mobilizado na linha e enrelvamento da entrelinha, obtidos por aplicação de herbicida na linha e destroçamento do enrelvamento na entrelinha. Os resultados obtidos indicam também que todos os produtores fazem um primeiro controlo no final do inverno, próximo do abrolhamento, com aplicação de herbicida numa faixa de 90 a 100 cm para cada lado da linha. Contudo, a aplicação de herbicida no final

do inverno não é suficiente para controlar o desenvolvimento das infestantes, existindo sempre algumas infestantes que permanecem e, posteriormente, encontram as condições ideais para se desenvolverem, sendo habitual duas aplicações de herbicida/ciclo vegetativo, de acordo com a conta de cultura (Dias et al., 2017). Assim, evidencia-se a necessidade de controlar o desenvolvimento das infestantes que surgem após a primeira aplicação de herbicida (Figura 7) e que, ao terem menos competição entre si, poderão atingir grande porte ou colonizar rapidamente o solo, tornando-se dominantes.

A aplicação particularizada através de um sistema robótico, permitiria uma eliminação numa fase do ciclo vegetativo correspondente ao início do crescimento dos frutos, tendo como vantagem não só a eliminação da infestante em si, mas a diminuição da quantidade de herbicida visando uma prática agrícola mais sustentável.



Figura 7 – Infestantes remanescentes após aplicação de herbicida.

Modelo de deteção de infestantes

Na Figura 8-A é apresentada uma imagem de entrada do sistema de visão computacional enquanto na Figura 8-B é apresentado o resultado de saída do sistema de inteligência artificial de deteção de infestantes. As regiões em cor azul correspondem às segmentações das infestantes e os pontos em cor verde correspondem às coordenadas dos centróides das regiões segmentadas que representam as localizações das infestantes. O manipulador robótico, em coordenação com a locomoção do R2A2 irá movimentar-se para cada uma das coordenadas x-y dos centróides das infestantes, sendo aí ativado o bico de pulverização, a uma distância mais próxima ou mais afastada, de acordo com a área ocupada pela infestante.




Figura 8 – Aplicação do algoritmo de inteligência artificial por aprendizagem profunda via CNN para deteção de infestantes: **A** - Imagem original; **B** - Imagem segmentada com as obtenções dos contornos e centróides

Modelos empíricos no estudo da eficiência do sistema produtivo

A Figura 9 mostra, como exemplo, a aplicação do modelo à produção do pessegueiro ‘Catherine’ em 2019. Apesar de algumas diferenças que

se notam entre alguns valores observados e os respetivos valores estimados (relação 1:1, $R^2 = 78\%$), é de salientar que a amplitude de variação dos pesos médios por árvore individual é semelhante e que o peso médio observado e estimado do conjunto das 15 árvores é idêntico (quadrados). Estes resultados sugerem que a previsão empírica pode ser uma ferramenta útil para avaliar a capacidade produtiva do pomar, por simples medição do volume e contagem dos frutos, e um importante complemento às metodologias de análise de imagens, sempre e quando estas possam ser utilizadas de forma prática e recorrente na medição do volume e na contagem de frutos das árvores.

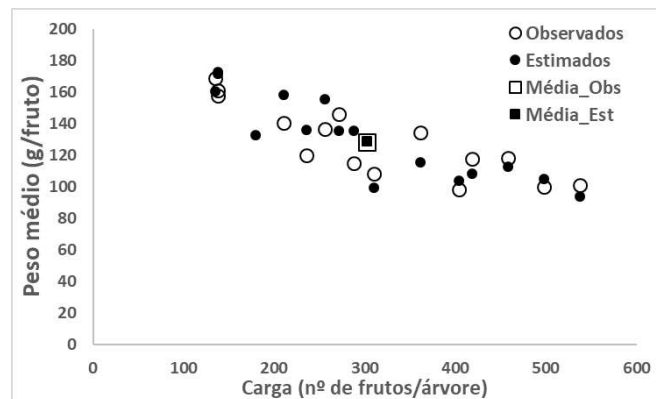


Figura 9 - Representação gráfica dos valores observados do peso médio do fruto em função da carga e dos correspondentes valores estimados.

Robô terrestre autónomo

No âmbito deste projeto está a ser desenvolvido o robô terrestre R2A2 (Robotic Rover for Agricultural Activities). Durante o desenvolvimento do robô foi necessário garantir os seguintes requisitos: movimentação autónoma; altura máxima de 60 cm (altura a que se iniciam os ramos das árvores); capacidade de desenvolver tarefas perto do tronco sem danificar as árvores e ultrapassar rampas de até 20º de inclinação. O R2A2 (Figura 10) foi construído em perfis de alumínio, com uma estrutura de T, criando uma estrutura leve e resistente.

Devido a configuração dos perfis, o robô é de fácil montagem, sendo possível anexar novos segmentos ao longo do seu desenvolvimento. O R2A2 contém um sistema de quatro rodas, cada uma com um motor independente alargando desta forma os movimentos do robô. Cada motor está equipado internamente com uma caixa de multiplicação e um driver que providencia 25 Nm, a cada roda, controlados por um microcontrolador. O R2A2 integra um bico pulverizador acoplado a um braço robótico, um reservatório de herbicida e um sistema de visão computacional de deteção de infestantes. Na Figura 10 encontra-se uma imagem do R2A2 com a localização dos vários componentes: (1) Reservatório de herbicida; (2) Sistema de visão computacional composto por câmara RGB; (3) Manipulador robótico cartesiano com bico pulverizador e (4) Sistema de controlo composto por microcomputadores Raspberry Pi 4 e microprocessadores ESP32.



Figura 10 – Rover Robótico de Aplicações Agrícolas. Legenda: 1) Reservatório de herbicida. 2) Sistema de visão computacional. 3) Manipulador robótico cartesiano com bico pulverizador. 4) Sistema de controlo.

364

O sistema é alimentado por duas baterias de 12 V conectadas em série através da placa de alimentação (Figura 10), resultando numa tensão de alimentação de 24 V e uma capacidade conjunta de 55 Ah. São também utilizados um conjunto de conversores DC-DC para regular a diferença de potencial dos vários componentes eletrónicos. Para o posicionamento, tanto da garra como do sistema de pulverização, é utilizado um eixo linear controlado por um motor de passo em conjunto com um sistema de uma câmara, um minicomputador e um dos algoritmos de visão computacional descritos anteriormente.

Em suma, os robôs terrestres desenvolvidos para a agricultura já são uma realidade, mostrando um papel importante, tanto nas diversas fases das culturas como no apoio à decisão do produtor. De igual forma, pode-se verificar que o robô terrestre R2A2, mostra resultados promissores no combate à poluição ambiental, no desperdício alimentar e no desenvolvimento de tecnologia relacionada com a área. Futuros trabalhos estarão associados com a otimização do sistema, tal como na validação dos dados.

Robô aéreo autónomo

Com o objetivo de monitorização das culturas e solos, deteção do volume das árvores e desenvolvimento de tecnologias futuras relacionadas com a área, foi construído um veículo aéreo não tripulado. Para se encontrar em conformidade com todas as exigências foi necessário garantir que o drone cumpria com as seguintes características: voos autónomos, carga máxima superior ao peso de



Figura 11 – Imagem do primeiro teste de voo do drone construído.

uma câmara multiespectral e visível, sistema aberto e alto alcance. Após análise e para que todos os requisitos fossem cumpridos optou-se por um drone (Figura 11) de seis motores, equipado com uma Pixhawk Cube 2.1 permitindo, desta forma, o planeamento dos voos por pontos em conjunto com o programa de código aberto Mission Planner. Como antena GPS optou-se pela Here+ e um recetor/emissor TBS Crossfire, este é alimentado por uma bateria 4S de 5000 mAh.

Considerações finais

O modelo de deteção de objetos Faster R-CNN foi utilizado para deteção de imagens de pêssegos, mostrando um bom desempenho, inclusive para frutos agrupados e oclusos. Para a deteção de copas de árvores, o resultado para as inferências das deteções foi de 0,85 AP. Já para o algoritmo de deteção de infestante, que utiliza técnicas de visão computacional tradicional, obteve uma precisão de 80%. A monitorização das infestantes indica as vantagens de um controlo particularizado das infestantes que aparecem depois do controlo realizado no final do inverno/início do abrolhamento.

Os modelos empíricos representam ferramentas bastante úteis para estudar e caracterizar a eficiência do sistema produtivo, permitindo ainda fazer previsões/simulações do desempenho da árvore em função da capacidade produtiva instalada. Neste contexto, o algoritmo de determinação do volume das árvores a partir de imagens captadas pelo drone, vem possibilitar previsões mais acertada dada a obtenção de mais dados (volume) das árvores.

O robô terrestre R2A2, que se encontra em desenvolvimento, mostra-se promissor em diversas fases das culturas como no apoio à decisão do produtor. Tal como este, o robô aéreo autónomo apresenta-se como uma mais-valia na monitorização das culturas e solos, deteção do volume das árvores e desenvolvimento de tecnologias futuras relacionadas com a área.

Referências Bibliográficas

- Agrob. 2019. <http://agrob.inesctec.pt/>
- Bargoti, S. & Underwood, J. 2017. Deep fruit detection in orchards. ICRA, 3626–3633.
- Bargoti, S. & Underwood, J.P. 2017. Image segmentation for fruit detection and yield estimation in apple orchards. J. Field Robotics 34:1039–1060.
- Blender, T., Buchner, T., Fernandez, B., Pichlmaier, B., & Schlegel, C. 2016. Managing a Mobile Agricultural Robot Swarm for a seeding task. IECON 2016, Florence, 2016, pp. 6879-6886.
- Bradski, G. 2000. The OpenCV Library. Dr. Dobb's Journal of Software Tools.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., e Adam, H. 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation, ECCV 2018, 833-851. <https://arxiv.org/abs/1802.02611>
- Diago, M. P., et al. 2015. Vinerobot: On-the-go vineyard monitoring with non-invasive sensors. In 9th GiESCO Meeting, France.
- DJI. 2020. <https://www.dji.com/pt/t20?site=ag&from=nav>
- Dorj, U.O., Lee, M. & Yun, S.-s. 2017. An yield estimation in citrus orchards via fruit detection and counting using image processing. Comput. Electron. Agric., 140:103-112.
- Earthsense. 2019. <https://www.earthsense.co/>
- Ecorobotix. 2019. <https://www.ecorobotix.com/en/autonomous-robot-weeder/>
- Fawakherji, M., Youssef, A., Bloisi, D., Pretto, A., Nardi, D. 2019. Crop and weeds classification for precision agriculture using context-independent pixel-wise segmentation. 2019 IRC, 146-152, doi: 10.1109/IRC.2019.00029.
- Ferreira, D. Simões, M.P. 2017. Efeito da manta Ecoblanket no crescimento das plantas. In Simões, M.P. (coord). +Pêssego – Inovação nas Técnicas de Produção, COTHN: 191-199. ISBN 9789728785055.
- Grimstad, L., From, P. J. 2017. The Thorvald II agricultural robotic system. Robotics, 6(4), 24.

-
- Häni, N., Roy, P., Isler, V. 2019. A comparative study of fruit detection and counting methods for yield mapping in apple orchards. *J. Field Rob* 1-20.
- Harvestai. 2019. <https://www.public.harvestai.com/>
- He, K., Gkioxari, G., Dollár, P. & Girshick, R. 2017. Mask R-CNN. *IEEE ICCV 2017, Venice*, 2980-2988.
- J. L. Elser et al. 2019. Measuring bird damage to three fruit crops: A comparison of grower and field estimates. *Crop Prot.*, 123, pp. 1–4.
- Javier J. C., Xesús P. G., Mar V., & José M. M. 2019. Water Management Using Drones and Satellites in Agriculture. *Water* 11, no. 5: 874.
- Koirala, A., Walsh, K.B., Wang, Z., & McCarthy, C. 2019. Deep learning for real-time fruit Detection and orchard fruit load estimation: benchmarking of ‘mangoyolo’. *Precision Agriculture* 1107–1135.
- McCool, C. et al. 2018. Efficacy of Mechanical Weeding Tools: A Study into Alternative Weed Management Strategies Enabled by Robotics. *IEEE Robotics and Automation Letters*, 3(2), 1184-1190.
- Naiot Technologies. 2019. Vineyard weeding robot TED. <https://www.naiotechnologies.com/en/agricultural-equipment/vineyard-weeding-robot/>
- Ramos A. 2017. Avaliação da eficiência do pomar. Aplicação de modelos empíricos à produção de pêssego. In *MP Simões, +Pêssego (vol. II): Inovação nas Técnicas de Produção*, pg. 239-262. COTHN. Alcobaça (ISBN: 978-972-8785-05-5).
- Robinson TL e Lakso AN. 1991. Bases of yield and production efficiency in apple orchard systems. *J. Amer. Soc. Hort. Sci.* 116 (2): 188 194.
- Robinson TL, Lakso AN e Carpenter SG. 1991. Canopy development, yield, and fruit quality of ‘Empire’ and ‘Delicious’ apple trees grown in four orchard production systems for ten years. *J. Amer. Soc. Hort. Sci.* 116 (2): 179-187.
- Robinson TL, Lakso AN, Greene D e Hoying S. 2013. Precision crop load management. *NY Fruit Quarterly*, 21 (2): 3-9.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T. & Mccool, C. 2016. Deepfruits: A fruit detection system using deep neural networks. *Sensors* 16:1222.

- Simões, M.P. 2016. Manutenção do solo. In Simões, M.P. (coord). +pêssego – Guia Prático da Produção. COTHN: 57-72. ISBN 9789728785048.
- Simões, M.P., Ferreira, D. e Barateiro, A. 2017. Efeito da manta Ecoblanket em alguns parâmetros físico-químicos do solo. In Simões, M.P. (coord). +Pêssego – Inovação nas Técnicas de Produção, Centro Operativo e Tecnológico Hortofrutícola Nacional: 93-113. ISBN 9789728785055.
- Sukkarieh, S. 2016. An intelligent farm robot for the vegetable industry. VG12104. Sydney: Hort. Innovation Australia (ISBN 0 7341 3765 6).
- Veiros, A., Mesquita, R. & Gaspar, P.D. 2019. Current status and future trends in agricultural robotics. ICEUBI2019, Covilhã, Portugal.
- Veroustraete, F. 2015. The Rise of the Drones in Agriculture. EC Agriculture 2.2 (2015): 325-327.
- Wall-ye. 2019. <https://wall-ye.com/index-2.html>
- Wendel, A. & Underwood, J. 2016. Self-supervised weed detection in vegetable crops using ground based hyperspectral imaging. 2016 IEEE ICRA, Stockholm, 2016, pp. 5128-5135, doi: 10.1109/ICRA.2016.7487717.