


# PrunusBOT

## Aplicação da robótica à produção de pêssego e cereja



2022

PrunusBOT

# PrunusBOT

## Aplicação da robótica à produção de pêssego e cereja

### Ficha técnica

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

**Editores:**  
Maria Paula Simões e Carmo Martins

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

**Revisão:**  
Maria Paula Simões

**Grafismo da capa:**  
Super. Brand Consultants



### Financiamento

## Prefácio

O contínuo aumento da população mundial tem avultado a necessidade de bens alimentares, levando a um aumento das explorações agrícolas para garantir o fornecimento destes bens, de uma forma direta, às populações e de uma forma indireta a todas as indústrias transformadoras do ramo alimentar. Esta condição tem levado a agricultura a reinventar-se e a introduzir novas técnicas e ferramentas para garantir um maior controlo das colheitas e um aumento dos rendimentos na produção alimentar. No entanto, a falta de mão-de-obra aliada à evolução de infestantes resistentes a herbicidas, tem levado a crescentes estrangimentos numa produção agrícola que a cada dia que passa se pretende mais elevada e de melhor qualidade. Porém, com a crescente evolução das áreas da eletrónica, da automação e da robótica, surgem novos caminhos para responder a estes problemas. Em particular, a introdução da robótica em determinadas atividades como a colheita de frutos, controlo de infestantes, monitorização, poda, pulverização, manuseamento de solos, navegação autónoma, entre outras, é vista como um contributo da tecnologia a este setor. O Grupo Operacional PrunusBOT vem contribuir neste sentido, tendo desenvolvido uma solução robótica constituída por um drone e por um rover, autónomos, para previsão de produção e otimizar as tarefas de controlo de infestantes. Para a previsão da produção são usados veículos autónomos aéreo e terrestre, ambos munidos de câmaras RGB e multiespectrais. O processamento das imagens aéreas adquiridas pelas câmaras incorporadas no drone permite, por via da aplicação de um algoritmo de inteligência artificial, detetar, reconhecer e determinar a área da copa das árvores. Este resultado é depois dado de entrada de um modelo empírico da carga da árvore. Para complementar esta previsão, o processamento das imagens adquiridas pelas câmaras instaladas no rover terrestre, permite, por via da aplicação de um outro algoritmo de inteligência artificial baseado em redes neuronais artificiais, detetar, reconhecer e determinar a área de frutos na árvore. A conjugação destes dados possibilita uma previsão assertiva da carga de frutos das árvores.

Por outro lado, para o controlo de infestantes é proposto um sistema de pulverização de precisão, reduzindo a quantidade de herbicida a aplicar.

Também neste caso é usada visão computacional, com um algoritmo que permite distinguir as infestantes, e determinar o seu centróide para posicionar o bico de pulverização que irá atuar um tempo que dependerá da área das infestantes.

O livro começa com uma descrição no Cap. 1 e Cap. 2 sobre a fenologia e crescimento do pêsego, cultura alvo do desenvolvimento deste grupo operacional e suas necessidades de Horas de Frio e Graus Dia de Crescimento. É descrita a produtividade da cultura do pessegueiro e indicada a cultivar com maior potencial produtivo e com frutos de maior calibre. O Cap. 3 começa a expor tecnologia. Em particular, são neste capítulo apresentadas as especificações de hardware e de software do drone robótico aéreo. São também apresentadas as características técnicas das câmaras instaladas no veículo. O Cap. 4 apresenta o algoritmo de inteligência artificial para detecção e segmentação de copas de árvores, sendo exposta a boa discriminação conseguida entre árvores e sombras, o que denota a potencial escalabilidade da solução. Por sua vez, o Cap. 5 apresenta os requisitos de projeto e as características e especificações técnicas do robô terrestre que foi desenvolvido e testado. Os capítulos seguintes descrevem com maior pormenor os algoritmos do rover robótico que lhe proporcionam a capacidade de locomoção autónoma. O Cap. 6 expõe algoritmo de inteligência artificial aplicado às imagens frontais do rover, permitindo-lhe detetar e reconhecer os troncos das árvores, e de modo distanciar destes de modo a realizar a aplicação particularizada de herbicida debaixo da copa das árvores, mas simultaneamente, à distância da entrelinha, detetar e reconhecer frutos nas árvores dispostas na linha oposta. Com a aplicação dos modelos de inteligência artificial é possível apresentar uma previsão da contagem de frutos na árvore que se encontra exposta no Cap. 7. O modelo de detecção de objetos Faster R-CNN mostrou um desempenho relativamente bom e uma boa capacidade de generalização. O Cap. 8 descreve o método empírico desenvolvido para providenciar previsões dos resultados produtivos e económicos do pomar de pessegueiros. Faz uso dos dados adquiridos pelo drone. Este torna-se numa ferramenta útil para as tomadas de decisão relativa à logística das colheitas e da comercialização. O Cap. 8 descreve o algoritmo de detecção e reconhecimento, com grande precisão, as infestantes, por via de um sistema de visão computacional com base em redes

neurais convolucionais. É apresentado como o modelo foi implementado num mecanismo de pulverização e ser treinado numa aplicação de precisão. Na sequência do capítulo anterior, o Cap. 9 descreve os procedimentos de manutenção do solo em pomares de pessegueiro, tendo em conta a monitorização da ocupação do solo por infestantes. O livro encerra com o Cap. 11, que descreve um modelo baseado em redes neurais convolucionais para a deteção de copas de árvores com o objetivo de calcular índices vegetais como forma de inferir a condição da vegetação de árvores frutíferas em um pomar de pessegueiro. Os índices de vegetação foram calculados para inferir o vigor das árvores. Os valores dos índices GNDVI, NDRE e REGNDVI confirmam a análise realizada com o índice NDVI.

Este livro providencia orientações emergentes da agricultura de precisão e faz um resumo da robótica agrícola. Visa o livro na sua totalidade fornecer uma visão futurista sobre os próximos passos na evolução da agricultura de precisão e robótica agrícola e os fatores tecnológicos que irão impulsionar esta evolução.

Assim, o conjunto destes resultados permite ao fruticultor analisar detalhadamente e no terreno quais são as causas potenciais dessas variações e, eventualmente, corrigi-las. Exemplos como o utilizado neste trabalho são relevantes para apoiar a tomada de decisão nas atividades agrícolas, possibilitando otimizar recursos, reduzir tempo e custo, maximizar a produção, podendo ser utilizados por agricultores, agrónomos e pesquisadores.

Pedro Dinis Gaspar

Universidade da Beira Interior



## **AGRADECIMENTOS**

Os editores e autores agradecem ao Programa de Desenvolvimento Rural PDR2020, cofinanciado pelo FEADER no âmbito do Portugal 2020, que financiou este livro e o projeto que lhe deu origem, o projeto **PrunusBOT – Sistema robótico aéreo autónomo de pulverização controlada e previsão de produção frutícola**.

O projeto PrunusBOT resulta de uma parceria entre as associações APPIZÊZERE e AAPIM, o COTHN, o IPCB- ESA, a UBI, a Sociedade Agrícola Quinta de Lamaçais e os produtores Fernando Valério e Gonçalo Batista. Tendo sido realizada a candidatura à bolsa de iniciativas em outubro de 2015, foi submetido como projeto em novembro de 2016, aprovado em junho de 2017 e a sua execução decorreu entre janeiro de 2018 e dezembro de 2021, encerrando o projeto em junho de 2022. Este projeto envolveu uma equipa multidisciplinar de 25 pessoas onde se incluem os autores deste livro, que beneficiam do contributo de outros membros da equipa e aos quais são devedores. Um agradecimento especial aos colegas de equipa - Carmo Martins, do COTHN, Carlos Amado, da APPIZÊZERE, Abel Veloso, do IPCB-ESA, bem como aos Presidentes das duas associações, José Assunção, da AAPIM e Gonçalo Batista (2016 a 2021) e Francisco Chasqueira (2021 até ao presente momento), da APPIZÊZERE, pela constante disponibilidade, apoio e interesse.

Nesta numerosa equipa ocupam lugar de destaque os produtores, que disponibilizaram os seus pomares para a realização de todas as observações que são a base dos resultados agronómicos apresentados neste livro, nomeadamente Gonçalo Batista e Fernando Valério. A sua procura constante de conhecimento novo é um motor fundamental para a realização de todo o trabalho desenvolvido.

A dinâmica e interação do grupo de trabalho associado às Prunóideas foi um pilar fundamental para alcançar os objetivos deste projeto, que estão refletidos nesta publicação, assim como para valorizar o potencial humano e material existente na região, e é determinante no desenvolvimento e promoção da fruticultura na região, com especial destaque para as Prunóideas.

Este grupo de trabalho é também o porta voz dos produtores na necessidade de criar um Polo de Inovação para as Prunóideas que permita a realização de investigação continuada e dirigida, e se constitua como dinamizador científico e

experimental, contribuindo para a fixação de quadros técnicos altamente qualificados, fatores fundamentais para um desenvolvimento sustentado.

# **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 pêsego 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

# Índice

## Capítulo 1.....17

<b>Fenologia e crescimento do fruto</b> .....	17
1.1 Introdução.....	17
1.2 Material e métodos.....	18
1.3 Resultados.....	19
1.3.1. Fenologia .....	19
1.3.2 Crescimento do fruto .....	20
1.3.3 Produção.....	22
1.4 Considerações finais.....	23
Agradecimentos .....	23
Referências bibliográficas .....	24

## Capítulo 2..... 27

<b>Horas de frio, somatório de calor e sua relação com a fenologia do pessegueiro</b> .....	27
2.1 Introdução.....	27
2.2 Material e métodos.....	29
2.3 Resultados e discussão .....	30
2.3.1 Condições referentes à estação meteorológica da Soalheira .....	30
2.3.1.1 Horas de frio para EM Soalheira.....	30
2.3.1.2 Graus-dia para EM Soalheira.....	32
2.3.2. Condições referentes à estação meteorológica de Belmonte .....	33
2.3.2.1. Horas de frio para EM Belmonte .....	33
2.3.2.2 Graus-dia para EM Belmonte .....	34
2.3.3 Estação meteorológica do Ferro .....	35
2.3.3.1 Horas de Frio para EM Ferro.....	35
2.3.3.2 Graus-dia para EM Ferro.....	36
2.4 Horas de frio e graus.dia relativas a cada ciclo e Unidade de Observação	37
2.4.1. Unidade de Observação da Soalheira (UO-01).....	37
2.4.2 Unidade de Observação de Orjais (UO-02).....	39
2.3.3 Unidade de Observação de Ferro (UO-03) .....	40
2.3.4 Crescimento do fruto .....	41
2.4 Considerações finais.....	44

Agradecimentos .....	44
Referências bibliográficas .....	45

## **Capítulo 3.....49**

<b>Robô aéreo autônomo.....</b>	<b>49</b>
3.1 Introdução.....	49
3.2 Material e métodos.....	51
3.2.1 Robô aéreo autônomo.....	51
3.2.2 Algoritmo de otimização .....	51
3.2.3 Minimização entre pontos de interesse.....	53
3.2.4 Câmara multiespectral.....	54
3.3 Resultados e discussão .....	54
3.3.1 Robô aéreo autônomo .....	54
3.3.2 Imagens aéreas multiespectrais .....	55
3.4 Considerações finais.....	56
Agradecimentos .....	56
Referências bibliográficas .....	56

## **Capítulo 4..... 61**

<b>Deteção de Automática de Copas de Árvores.....</b>	<b>61</b>
4.1 Introdução.....	61
4.2 Materiais e métodos.....	62
4.2.1 Modelo de deteção de copas de árvores .....	62
4.2.2 Base de dados.....	63
4.3 Resultados e discussão .....	63
4.4 Considerações finais.....	68
Agradecimentos .....	68
Referências bibliográficas .....	68

## **Capítulo 5..... 73**

<b>Robô terrestre autônomo .....</b>	<b>73</b>
5.1 Introdução .....	73
5.2 Materiais e métodos .....	74
5.3 Resultados e discussão .....	76
5.4 Considerações finais.....	78

Agradecimentos .....	78
Referências bibliográficas .....	78

## **Capítulo 6.....81**

<b>Sistema de navegação autónoma baseado em visão computacional por deteção de troncos de árvores - Aplicação a pomares de pessegueiros .....</b>	<b>81</b>
6.1 Introdução.....	81
6.2 Materiais e métodos.....	82
6.2.1 Software .....	82
6.2.2 Hardware.....	83
6.2.3 Construção da base de dados.....	84
6.2.4 Estratégia de orientação.....	86
6.3 Resultados e discussão .....	89
6.4 Considerações finais.....	90
Agradecimentos .....	91
Referências bibliográficas .....	92

## **Capítulo 7..... 95**

<b>Deteção de frutos .....</b>	<b>95</b>
7.1 Introdução.....	95
7.2 Materiais e métodos.....	96
7.2.1 Modelo de deteção de frutos.....	96
7.2.2 Base de Dados.....	96
7.3 Resultados e discussão .....	97
7.3.1 Resultado do teste realizado em imagens do mesmo pomar onde o modelo foi treinado.....	97
7.3.2 Resultado do teste realizado em imagens de diferentes pomares onde o modelo foi treinado.....	98
7.3.2.1 Primeiro caso de teste.....	98
7.3.2.2 Segundo caso de teste.....	100
7.3.2.3 Terceiro caso de teste .....	101
7.3.3 Resultado do algoritmo de deteção aplicado a contagem de frutos.....	102
7.4 Considerações finais.....	102
Agradecimentos .....	103
Referências bibliográficas .....	103

## **Capítulo 8..... 107**

### **Avaliação da capacidade produtiva do pomar de pessegueiros**107

8.1. Introdução .....	111
8.2. Estimativa dos parâmetros.....	111
8.3. Resultados observados .....	113
8.4 Valores observados <i>versus</i> simulados.....	116
8.5 Simulação da carga “ótima” .....	118
8.6 Considerações finais e perspectivas futuras.....	121
Agradecimentos .....	122
Referências bibliográficas .....	123

## **Capítulo 9..... 127**

### **Deteção de infestantes** ..... 127

9.1 Introdução .....	127
9.2 Materiais e métodos .....	128
9.2.1 Modelo de deteção de infestantes.....	128
9.3 Resultados e discussão .....	129
9.4 Considerações finais.....	130
Agradecimentos .....	130
Referências bibliográficas .....	131

## **Capítulo 10 ..... 135**

### **Manutenção do solo em pomares de pessegueiro – monitorização da ocupação do solo por infestantes** ..... 135

10.1 Introdução.....	135
10.2 Material e métodos.....	139
10.3 Resultados e discussão .....	142
10.4 Considerações finais.....	148
Agradecimentos .....	149
Referências bibliográficas.....	149

## **Capítulo 11 ..... 153**

<b>Previsão do vigor e estado de vegetação de pomar de pessegueiro por processamento e análise de imagens multiespectrais capturadas por UAV .....</b>	<b>153</b>
11.1 Introdução .....	153
11.2 Materiais e métodos .....	155
11.2.1 Base de dados de imagem .....	155
11.2.2 Índices vegetais .....	155
11.2.3 Segmentação das copas .....	156
11.2.4 Método proposto .....	157
11.3 Resultados e discussão .....	158
11.3.1 Resultado do índice vegetal aplicado à imagem aérea .....	158
11.3.2. Índice de vegetação com imagem captada do solo .....	161
11.4 Considerações finais .....	165
Agradecimentos .....	165
Referências bibliográficas .....	165









# Capítulo 1

## Fenologia e crescimento do fruto

António Ramos<sup>1</sup>, Hugo Fonseca<sup>1</sup>, Dora Ferreira<sup>1</sup> e Maria Paula Simões<sup>1,2</sup>

<sup>1</sup>Instituto Politécnico de Castelo Branco | Escola Superior Agrária

<sup>2</sup>CERNAS - Centro de Estudos de Recursos Naturais, Ambiente e Sociedade

### 1.1 Introdução

O ciclo anual do pessegueiro (*Prunus persica* L.) divide-se em dois períodos distintos: um período de atividade vegetativa (durante a primavera e o verão) e um período de repouso invernal. Apesar de distintos, esses períodos são complementares numa estratégia de adaptação e sobrevivência das espécies face às mudanças cíclicas do clima, que originam períodos favoráveis ao crescimento separados por outros de crescimento diminuto ou, inclusivamente, ausente (Villiers, 1975).

O ciclo vegetativo é caracterizado através da fenologia, a ciência que estuda a morfologia e o desenvolvimento dos gomos florais ao longo do período de atividade vegetativa. As diferentes fases do desenvolvimento dos gomos são denominadas de estados fenológicos e, para o pessegueiro, os estados fenológicos podem consultar-se em Simões (2016). Para qualquer fruteira, os estados fenológicos mais importantes são a floração, onde se define o vingamento, ou seja, a transformação da flor em frutos, e a maturação do fruto, que condiciona a qualidade. A data de ocorrência dos estados fenológicos é

variável de ano para ano em função das condições meteorológicas, com especial destaque para a temperatura.

Os estudos da fenologia e a sua relação com as condições meteorológicas tem ampla aplicação na produção frutícola, nomeadamente no planeamento e determinação de realização das operações culturais como tratamentos fitossanitários, rega, fertilização e colheita, sendo também importantes na seleção de cultivares para novas áreas de produção e para a avaliação do impacte das alterações climáticas (Agustí, 2010; Rodrigues et al., 2016).

## 1.2 Material e métodos

Para a realização deste trabalho utilizaram-se 3 Unidades de Observação (UO) correspondentes a 3 pomares. Cada UO é constituída por 16 árvores marcadas de acordo com o esquema descrito no capítulo 9. Em cada árvore, marcou-se um ramo misto de comprimento entre 50 cm a 60 cm (Figura 1.1), num total de 16 ramos mistos/UO.

Durante o período de floração, que decorre desde o estado fenológico C até à queda das pétalas (estado fenológico G), realizaram-se observações semanais, contando os gomos em cada estado fenológico, nos ramos marcados. A data de plena floração (PF) é a data onde se observa a maior percentagem de gomos no estado fenológico F.


Após o vingamento foram marcados 1 fruto/árvore, num total de 16 frutos/UO, para avaliar o seu crescimento através da medição do diâmetro equatorial, utilizando uma craveira digital. A avaliação do crescimento dos frutos foi realizada com uma periodicidade semanal. A




**Figura 1.1** – Ramo misto marcado para monitorização da fenologia.





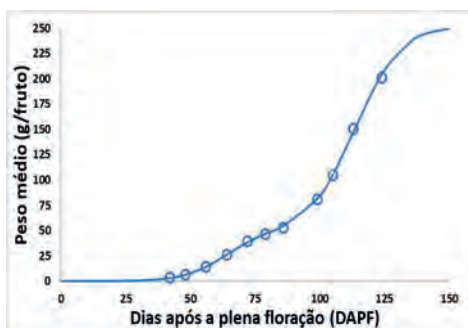


**Figura 1.4** – Curvas de crescimento do fruto da cv. Catherine, na UO-01, em 2020 e 2021.



**Figura 1.5** – Curvas de crescimento do fruto da cv. Royal Time, na UO-02, em 2020 e 2021.

Em 2020, relativamente às cultivares Catherine e Royal Time (UO-01 e UO-02), o menor crescimento do fruto observado pela monitorização do calibre dos frutos, foi confirmado com os resultados produtivos à colheita (ver capítulo 8). Na UO-02, as cargas foram semelhantes e os valores do peso médio do fruto à colheita foram de 130,9 g em 2020 e de 141,6 g em 2021. Na UO-01, o peso médio dos frutos foi de 158,8 g e em 2021 a ocorrência de granizo a cerca de 3 semanas da colheita impediu o seu registo.



**Figura 1.6** – Curva de crescimento do fruto da cv. Sweet Dream, em 2021, na UO-03.

No entanto, face às curvas de crescimento da Figura 4 seriam de esperar, em 2021, frutos com peso médio superior ao de 2020. A Figura 1.6 mostra a curva de crescimento da cv. Sweet Dream relativa à UO-03, em 2021. Esta cultivar tem data média de colheita em finais de julho, atingindo calibres bastante elevados, com um valor médio final próximo de 250 g/fruto. É uma cultivar de frutos muito grandes podendo observar-se frutos com 400 g/fruto, como é referido em Simões (2016).

Nesta UO, os pesos médios à colheita foram de 220,4 g em 2020 e de 248,6 g em 2021, observando-se menor peso médio por fruto em 2020, apesar da carga ser 39% mais baixa comparativamente a 2021.

## A RETER

O crescimento do pêssigo, expresso em peso fresco, pode ser representado por uma dupla sigmóide. A cv. Sweet Dream foi a que alcançou maiores calibres, com um peso médio de 220g/ fruto a 250 g/fruto. O peso médio da cultivares Catherine e Royal Time situou-se entre 140 g/fruto e 160 g/fruto.

### 1.3.3 Produção

O Quadro 1.1 apresenta os resultados de produtividade e calibre médio dos frutos ao longo do período acompanhado.

**Quadro 1.1 – Produtividade e calibre dos frutos por UO e ciclo vegetativo.**

	Densidade (plantas/ha)	ciclo	Produtividade (t/ha)	Calibre médio (g/fruto)	Calibre >A (%)
UO-01 cv. Catherine	800	2018	19,0	174,1	75,2
		2019	29,9	128,1	39,7
		2020	6,2	152,6	62,9
UO-02 cv. Royal Time	889	2020	12,3	130,9	44,4
		2021	13,7	141,6	55,3
UO-03 cv. Sweet Dream	808	2019	32,0	254,3	95,2
		2020	13,9	220,4	91,7
		2021	38,7	248,6	94,9

A produtividade da cv. Catherine variou entre 6,2 t/ha (em 2020) e 29,9 t/ha (em 2019), não se realizando a colheita em 2021 devido elevada incidência de *Fusicoccum amygdali*.

A produtividade da cv. Royal Time (UO-02) foi de 12,3 t/ha e 13,7 t/ha, com um calibre médio de 130 g/fruto e 141 g/fruto.

A cv. Sweet Dream foi a que apresentou produtividade mais elevada, com 32,0 t/ha em 2019, 13,9 t/ha em 2020 e 38,7 t/ha em 2021, com frutos de grande calibre de peso médio de 220 g/fruto e 260 g/fruto.

O ciclo 2020 foi o que apresentou produtividade mais baixa para qualquer das UO consideradas, resultando essa menor produtividade das condições meteorológicas adversas ocorridas (queda de neve em 30 março de 2020 e queda de granizo em 30 de maio de 2020), fenómenos extremos que caracterizaram este ciclo vegetativo.

## **A RETER**

**A produtividade da cultura do pessegueiro variou entre 9 t/ha e 48 t/ha. A cv. Sweet Dream é a cultivar com maior potencial produtivo e com frutos de maior calibre, com 90% da produção de calibre  $\geq$ A.**

### **1.4 Considerações finais**

O período de floração dos pessegueiros demora habitualmente 15 a 20 dias e a Plena Floração, determinada pela maior percentagem de gomos florais no estado fenológico F, ocorre maioritariamente no início de março. Como o pessegueiro é autofértil não é necessário haver coincidência de períodos de floração entre cultivares para ocorrer vingamento.

O peso médio dos frutos está associado às condições específicas de cada ciclo vegetativo, mas grandemente determinada pelo potencial da cultivar, destacando-se a cv. Sweet Dream pelos elevados calibres que proporciona.

## **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

Agustí, M. 2010. Fruticultura. Ed. Mundi-Prensa, Madrid.

Ferreira, D., Amaral, A., Silva, A.P., Ramos, C., Barateiro, A., Fragoso, P., Lopes, S. e Simões, M. P. 2019. Condições climáticas durante o período de floração do pessegueiro (cv. Royal Time): principais contributos da monitorização nos ciclos 2015-2019. International Congress on Engineering, “Engineering for Evolution”, University of Beira Interior, volume 2: 149-160. [EPUB] ISBN: 978-989-654-618-2.

Ramos, A. 2017. Avaliação da eficiência do pomar. Aplicação de modelos empíricos à produção de pêssego. *In* MP Simões (coord), +Pêssego (Vol. II): Inovação nas Técnicas de Produção: 239-262. COTHN. Alcobaca. ISBN: 978-972-8785-05-5.

Rodrigues, P., Prata, P., Gouveia, J.P., Pedroso, V., Marques, F., Rouxinol, N., Pinto, S., Moura, P., Carvalho, J., Gaião, D., Alves, I., Lopes, C. 2106. Modelos fenológicos para as castas Touriga Nacional, Jaen e Alfrocheiro na Região Demarcada do Douro. Atas do 10º Simpósio de Vitivinicultura do Alentejo, Vol. II: 127-136 (Évora, 4-6 maio).

Simões, M.P. 2016. Ciclo biológico do pessegueiro [*Prunus persica* (L.) Batsch]. *In* MP Simões (coord), +Pêssego (Vol. I): Guia Prático da Produção: 35-51. COTHN. Alcobaca. ISBN: 9789728785048.

Villiers, T.A. 1975. Dormancy and the Survival of Plants. Edward Arnold (Publishers) Limited. London.





## Capítulo 2

# **Horas de frio, somatório de calor e sua relação com a fenologia do pessegueiro**

**António Ramos<sup>1</sup>, Hugo Fonseca<sup>1</sup>, Dora Ferreira<sup>1</sup> e Maria Paula Simões<sup>1,2</sup>**

<sup>1</sup>Instituto Politécnico de Castelo Branco | Escola Superior Agrária

<sup>2</sup>CERNAS - Centro de Estudos de Recursos Naturais, Ambiente e Sociedade

### **2.1 Introdução**

A rentabilidade de qualquer atividade frutícola depende do conhecimento profundo do comportamento biológico da espécie e da dependência e adaptação às condições climáticas do local onde está instalada. Tendo por base esse conhecimento, é possível realizar e posicionar não apenas as operações culturais que visam a otimização do equilíbrio entre desenvolvimento vegetativo e produção, como também a maximização da rentabilidade económica, estando as duas interdependentes. Assim, o estudo de variáveis associadas às condições meteorológicas e a sua relação com o ciclo do pessegueiro podem ser de grande utilidade para a rentabilidade da cultura, pois poderá permitir prever o seu desenvolvimento e, sempre que possível, atuar de modo preventivo.

As espécies frutícolas de clima temperado caracterizam-se por um período de repouso invernal e um período de atividade vegetativa. O início, a duração, a intensidade e o final dos períodos de atividade vegetativa e de repouso são influenciados pelas condições meteorológicas em cada ano e em cada região, condicionando, por isso, as épocas de abrolhamento, floração e maturação dos

frutos. A fisiologia do repouso invernal está condicionada pelas baixas temperaturas, embora o processo ainda não esteja completamente esclarecido, sendo ainda objetivo de investigação frutícola (Velarde, 1989; Strand, 1999).

A contabilização do número de horas abaixo de um determinado umbral de temperatura (Agustí, 2010; Strand, 1999), ou horas de frio (HF) acumuladas, tem sido uma das metodologias mais utilizadas para caracterizar o período de repouso invernal. Este período pode ter origem na própria planta (endodormência) ou ser imposto pelo ambiente externo (ecodormência). A endodormência é quebrada pela exposição ao frio (HF), mas a planta pode manter-se inativa se as condições externas forem desfavoráveis, definindo-se esse período por ecodormência (Abreu, 2018). Deste modo, findo o período de frio mais intenso, os gomos respondem à subida paulatina das temperaturas, retomando a atividade vegetativa traduzida pelas diferentes fases do desenvolvimento dos gomos caracterizados através dos estados fenológicos.

Para o pessegueiro as necessidades de HF variam entre 400 HF e 1000 HF, dependendo das cultivares (Velarde, 1989). Para as regiões de invernos moderados estão mais adaptadas as cultivares menos exigentes em HF e para as regiões de invernos mais rigorosos as mais exigentes em HF. Quando uma cultivar exigente em HF se coloca em condições de invernos amenos, ou seja, as HF não são suficientes, observa-se uma elevada proporção de gomos que não abroham e, também, uma grande heterogeneidade no período de abrolhamento, levando a períodos de floração mais extensos e, conseqüentemente, a uma maior heterogeneidade na maturação dos frutos (Legave et al., 2010). Quando uma cultivar de baixas exigências de frio é colocada numa região com invernos mais rigorosos, existe um risco elevado de abrolhar demasiado cedo, quando se verificarem temperaturas favoráveis em janeiro (pois a cultivar já está no período de ecodormência), ficando deste modo muito vulnerável a condições adversas (prováveis até março) como a ocorrência de geadas na floração ou no vingamento dos frutos.

Com este trabalho, pretende-se caracterizar o ciclo do pessegueiro (desenvolvimento vegetativo e repouso invernal) e a sua relação com a evolução de algumas variáveis meteorológicas. Desta forma, procurou-se conhecer, para

cada pomar e respetiva área de localização, no conjunto de 4 ciclos (2018 a 2021), as horas de frio acumuladas e o somatório das temperaturas correspondentes ao período compreendido entre a plena floração e a data média de colheita. O crescimento do fruto após a plena floração foi já estudado através da aplicação de um modelo de crescimento em dupla sigmoide em função do número de dias após a plena floração (capítulo 1.7). Neste trabalho, o modelo de crescimento em dupla sigmoide será aplicado em função do somatório de temperaturas.

## 2.2 Material e métodos

Este trabalho teve por base as 3 Unidades de Observação que integram o projeto PrunusBOT, nomeadamente:

- UO-01, cv. Catherine, localizada na Soalheira;
- UO-02, cv. Royal Time, localizada em Orjais;
- UO-01, cv. Sweet Dream, localizada no Ferro (definida em 2020).

Para cada UO foi realizada a monitorização da fenologia e o crescimento dos frutos, cujos resultados se apresentaram no capítulo 1.

Para caracterizar o período de repouso invernal, de 2017/18 a 2020/21, utilizaram-se os dados de três estações meteorológicas (EM) da Beira Interior, cujos dados foram gentilmente cedidos pela DRAPC. As HF acumuladas foram calculadas pelo método de Crossa-Raynaud (1956), utilizando a seguinte fórmula:

$$HF = 24 \times [(7,2 - T_{\min}) / (T_{\max} - T_{\min})],$$

em que  $T_{\min}$  e  $T_{\max}$  são as temperaturas mínima e máxima diárias, respetivamente, considerando-se apenas os dias em que a temperatura mínima é inferior a 7,2°C (temperatura base ou umbral).

Para caracterizar o período de desenvolvimento vegetativo, de 2018 a 2021, utilizaram-se os dados meteorológicos das mesmas três EM, calculando-se o somatório das temperaturas médias diárias superiores a 7,0°C, considerando o período de 15 de fevereiro até à data de plena floração (PF) e desde a data de PF até à data de colheita (DeJong e Goudriaan, 1989; Agustí, 2010). Este somatório de temperaturas expressa-se em graus-dia (GD).

## **2.3 Resultados e discussão**

### **2.3.1 Condições referentes à estação meteorológica da Soalheira**

#### **2.3.1.1 Horas de frio para EM Soalheira**

Os resultados mais significativos da acumulação de horas de frio, na EM da Soalheira, apresentam-se na Figura 2.1, constatando-se que as HF acumuladas foram superiores no ciclo de 2017/2018 ( $\approx$  900 HF), enquanto o ciclo de 2019/20 foi o que apresentou menos HF acumuladas ( $\approx$  550 HF), de uma forma consistente (Figura 2.1-A). Os ciclos 2018/19 e 2020/21 observaram-se 750 a 790 HF.

É ainda de salientar que o ciclo de 2018/19 foi o que apresentou uma evolução mais regular das HF acumuladas, enquanto o ciclo de 2020/21 foi o mais irregular. Com efeito, evolução das HF acumuladas no ciclo de 2020/21 acompanhou de perto o ciclo de 2019/20 até finais de dezembro, tendo aumentado bruscamente até ao fim da 3ª semana de janeiro (correspondendo a um mês de janeiro muito frio) e voltando a crescer mais lentamente a partir daí.


Na Figura 2.1-B, observa-se a distribuição das HF acumuladas, de 2017/18 a 2020/21, nos meses de novembro a fevereiro. Apesar da amostragem ser apenas de 4 ciclos (baixo significado em termos de estudo climático), este facto parece indicar (nestes 4 ciclos) uma diminuição das HF no início (novembro) e fim (fevereiro) do período de repouso.

Essa diminuição refletirá um certo atraso na preparação para o período desfavorável (indução da dormência; acumulação de reservas; aclimação ao frio), correspondente ao mês de novembro e um certo adiantamento na preparação para o período favorável (quebra da dormência; mobilização de reservas; promoção do abrolhamento/floração), correspondente ao mês de fevereiro. A confirmar-se esta tendência, isto significaria outonos e primaveras mais longos e invernos mais curtos, quiçá em resultado das alterações climáticas.

O mês que mais contribui para o total de HF é janeiro, observando-se entre 200 HF e 400 HF.



**Figura 2.1-A** – Evolução das Horas de Frio diárias acumuladas (<7,2°C), de novembro a fevereiro.



**Figura 2.1-B** – Horas de Frio acumuladas mensalmente de novembro a fevereiro.



**Figura 2.1-C** – Desvios mensais das Horas de Frio de novembro a fevereiro em relação à média dos 4 ciclos.

**Figura 2.1** – Horas de frio acumuladas considerando os dados da EM da Soalheira.

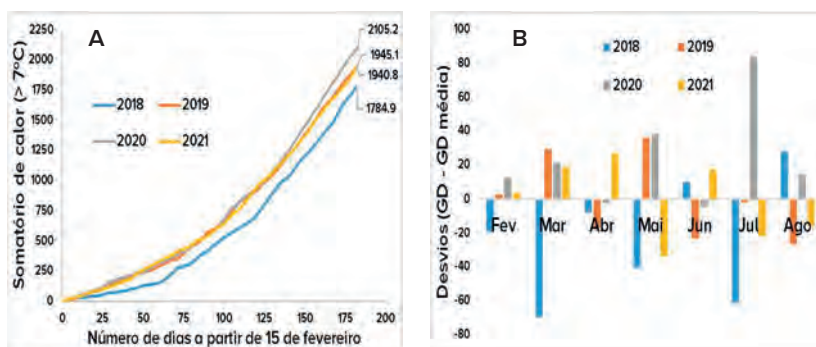
A Figura 2.1-C apresenta, com maior detalhe, as HF acumuladas mensalmente de novembro a fevereiro, pela diferença em relação à média dos 4 ciclos. Efetivamente, torna-se perfeitamente claro que os desvios são positivos no ciclo de 2017/18 e negativos no ciclo de 2019/20, os ciclos com mais e menos HF



acumuladas, respetivamente. Também é possível observar o comportamento errático do ciclo de 2020/21, com desvios muito positivos em janeiro e muito negativos em fevereiro.

### 2.3.1.2 Graus-dia para EM Soalheira

Os resultados mais significativos do somatório de temperaturas acima de 7,0°C, expresso em graus-dia, na EM da Soalheira, de 15 de fevereiro a 15 de agosto, apresentam-se na Figura 2.2.



**Figura 2.2** – Somatório de calor considerando os dados da EM da Soalheira. A: evolução do somatório dos GD diários (> 7,0°C) de 15 de fevereiro a 15 de agosto. B: Desvios mensais dos graus-dia de 15 de fevereiro a 15 de agosto em relação à média dos 4 ciclos.

Pela observação da Figura 2.2-A, constata-se que o referido somatório de temperaturas (GD) foi inferior no ano de 2018, de uma forma consistente, o que confirma o ciclo 2017/18 como o ano mais frio (Figuras 2.1-A e 2.1-C). Nos anos de 2018, 2020 e 2021 a evolução do somatório de GD é similar até meados de junho, época a partir da qual se observa um maior somatório de GD no ano de 2020, já referido como o ano menos frio (Figuras 2.1-A e 2.1-C). Na Figura 2.2-B, é possível verificar com mais detalhe a predominância dos desvios negativos no ano de 2018 e dos desvios positivos no ano de 2020 (especialmente em julho).

## 2.3.2. Condições referentes à estação meteorológica de Belmonte

### 2.3.2.1. Horas de frio para EM Belmonte

Os resultados mais significativos das HF acumuladas, relativos à EM de Belmonte, apresentam-se na Figura 2.3. Pela observação da Figura 2.3-A, constata-se que as HF acumuladas foram superiores no ciclo de 2017/2018 ( $\approx 1400$  HF), enquanto o ciclo de 2019/2020 foi o que apresentou menos HF acumuladas ( $\approx 950$  HF), de uma forma consistente, tal como observado na EM da Soalheira (Figura 2.1-A).




Figura 2.3-A – Evolução das Horas de Frio diárias acumuladas ( $<7,2^{\circ}\text{C}</math>), de novembro a fevereiro.$




Figura 2.3-B – Horas de Frio acumuladas mensalmente de novembro a fevereiro.




Figura 2.3-C – Desvios mensais das Horas de Frio de novembro a fevereiro em relação à média dos 4 ciclos.

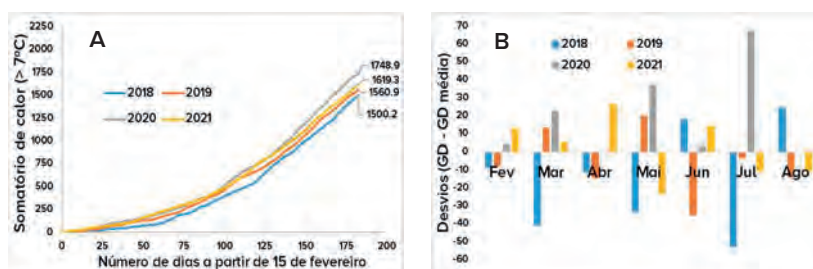
Figura 2.3 – Horas de frio acumuladas considerando os dados da EM de Belmonte.

Também na EM de Belmonte se confirma o comportamento errático das HF acumuladas no ciclo de 2020/21, com uma baixa acumulação inicial e um aumento brusco, que durou cerca de 3 a 4 semanas, abrandando posteriormente. Como seria de esperar pela sua localização mais a norte, as HF acumuladas são superiores na EM de Belmonte, relativamente à EM da Soalheira.

As Figuras 2.3-B e 2.3-C evidenciam resultados similares aos da EM da Soalheira, com uma notória redução da acumulação de HF de 2017/18 a 2020/21 nos meses de novembro e de fevereiro e o detalhe da acumulação errática de HF no ciclo de 2020/21, com desvios negativos em novembro e fevereiro e desvios positivos em dezembro e janeiro.

### 2.3.2.2 Graus-dia para EM Belmonte

Os resultados mais significativos do somatório de temperaturas acima de 7,0°C, expresso em graus-dia, na EM de Belmonte, apresentam-se na Figura 2.4.



**Figura 2.4** – Somatório de calor considerando os dados da EM de Belmonte. A: evolução do somatório dos GD diários (> 7,0°C) de 15 de fevereiro a 15 de agosto. B: Desvios mensais dos graus-dia de 15 de fevereiro a 15 de agosto em relação à média dos 4 ciclos.


À semelhança dos resultados do somatório de GD observados na EM da Soalheira (Figura 2.2), verifica-se que o ano mais quente foi 2020, com 1748,9 GD, e o mais frio de 2018, com 1500,2 GD. De notar apenas algumas diferenças na evolução do somatório de GD em 2019, 2020 e 2021 que seguiam muito semelhantes até meados de junho na EM de Soalheira (Figura 2.2), enquanto na EM de Belmonte (Figura 2.4), se notam algumas diferenças logo a partir de abril e uma maior diferença no valor final de 2019 e 2021 (que eram praticamente coincidentes na EM da Soalheira). Também é notória a influência da localização

mais a norte da EM de Belmonte, que apresenta valores de acumulação de calor inferiores à EM da Soalheira.


## 2.3.3 Estação meteorológica do Ferro

### 2.3.3.1 Horas de Frio para EM Ferro


Os resultados mais significativos da acumulação de horas de frio, na EM do Ferro, apresentam-se na Figura 2.5.



**Figura 2.5-A** – Evolução das Horas de Frio diárias acumuladas ( $<7,2^{\circ}\text{C}</math>), de novembro a fevereiro.$



**Figura 2.5-B** – Horas de Frio acumuladas mensalmente de novembro a fevereiro.



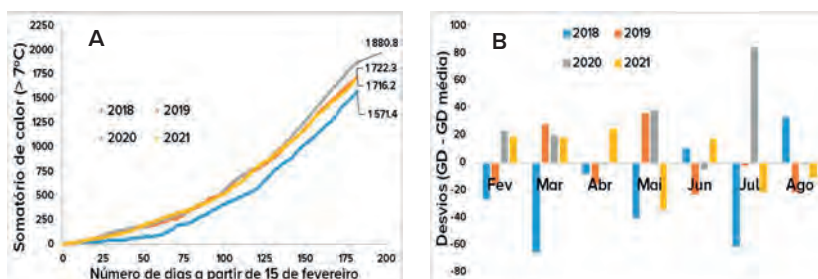
**Figura 2.5-C** – Desvios mensais das Horas de Frio de novembro a fevereiro em relação à média dos 4 ciclos.

**Figura 2.5** – Horas de frio acumuladas considerando os dados da EM do Ferro. Pela observação da Figura 2.5, confirmam-se todas as observações e tendências

já referidas para a EM da Soalheira (Figura 2.1) e de Belmonte (Figura 2.3). Como seria de esperar pela sua localização mais central, a acumulação de HF no Ferro apresenta valores intermédios entre as duas EM mais a norte e mais a sul, apesar das HF acumuladas em janeiro de 2021 terem sido superiores na EM do Ferro em relação à EM de Belmonte (Figura 2.3-B vs. Figura 2.5-B), provavelmente devido à sua localização a maior altitude.

### 2.3.3.2 Graus-dia para EM Ferro

Os resultados mais significativos do somatório de temperaturas acima de 7,0°C, expresso em graus-dia, na EM do Ferro, apresentam-se na Figura 2.6.



**Figura 2.6** – Somatório de calor considerando os dados da EM do Ferro. A: evolução do somatório dos GD diários (> 7,0°C) de 15 de fevereiro a 15 de agosto. B: Desvios mensais dos graus-dia de calor de 15 de fevereiro a 15 de agosto em relação à média dos 4 ciclos.

Pela observação da referida Figura, confirmam-se resultados similares aos valores do somatório de GD observados nas EM da Soalheira (Figura 2.2) e de Belmonte (Figura 2.4), nomeadamente o ano mais quente de 2020 e o mais frio de 2018. Também é notória a influência da localização mais central da EM do Ferro, que apresenta valores do somatório dos GD inferiores à da EM da Soalheira e superiores à EM de Belmonte, como seria de esperar.

O Quadro 2.1 resume as HF acumuladas e o somatório de GD nas 3 EM e nos 4 ciclos. De um modo geral, há uma correspondência clara entre os ciclos com HF acumuladas mais baixas no período de novembro a fevereiro e os ciclos com maior somatório de GD no período de 15 de fevereiro a 15 de agosto, exceto no ciclo correspondente a 2021, devido provavelmente ao período de acumulação

de HF muito rápido e concentrado nas três primeiras semanas de janeiro.

**Quadro 2.1** – Quadro resumo das Horas de Frio (HF) acumuladas (< 7,2°C) de novembro a fevereiro e do somatório das temperaturas > 7,0°C (GD) de 15 de fevereiro a 15 de agosto

	EM Soalheira		EM Belmonte		EM Ferro	
	HF	GD	HF	GD	HF	GD
<b>2017/18</b>	909,9	1784,9	1393,3	1500,2	1216,9	1571,4
<b>2018/19</b>	784,0	1945,1	1230,3	1560,9	1102,2	1722,3
<b>2019/20</b>	556,2	2105,2	948,9	1748,9	826,7	1880,8
<b>2020/21</b>	754,9	1940,8	1058,7	1619,3	1031,7	1716,2

## A RETER

Na região da Beira Interior, as Horas de Frio foram mais elevadas na zona a norte da serra da Gardunha, frequentemente > 1000 HF (EM de Belmonte e Ferro), comparativamente à zona sul da serra da Gardunha, onde se registou sempre um valor < 1000 HF (EM da Soalheira). O ciclo 2019/2020 foi o ciclo com menor valor de HF acumuladas, enquanto o ciclo 2017/18 foi o que apresentou valor mais elevado. Os ciclos com valores mais elevados de HF acumuladas corresponderam aos ciclos com menor somatório de GD e vice-versa.

## 2.4 Horas de frio e graus.dia relativas a cada ciclo e Unidade de Observação

### 2.4.1. Unidade de Observação da Soalheira (UO-01)

Os resultados das observações fenológicas, das HF acumuladas e do somatório de GD na UO-01 (Soalheira, cv. Catherine) resumem-se no Quadro 2.2. As datas de plena floração e de colheita foram mais temporãs no ciclo em que as HF acumuladas (de novembro a fevereiro) foram mais baixas (2020/21) e mais tardias no ciclo em que as HF acumuladas foram mais elevadas (2017/18). Estes resultados fazem supor que as necessidades de HF acumuladas (para a cv.

Catherine) foram satisfeitas relativamente cedo, permitindo o abrolhamento e a floração logo que as condições de temperatura o permitiram. Deste modo, pode inferir-se que o ciclo de 2020/21 induziu um período de ecodormência relativamente curto, enquanto um período de ecodormência bastante longo terá sido responsável pela floração mais tardia em 2017/18. No entanto, o somatório de GD desde 15 de fevereiro até à data da plena floração e desde a data da plena floração à data de colheita não permitiram identificar qualquer relação “causa-efeito” entre aqueles somatórios e a fenologia (datas de plena floração e colheita média), na cv. Catherine e na UO-01 (Soalheira).

**Quadro 2.2** – HF acumuladas (< 7,2°C) de 1 de novembro a 28/29 de fevereiro, datas da plena floração e da colheita, somatório de calor (GD > 7,0°C) e número de dias entre a data de plena floração (PF) e a data média de colheita observados na UO-01 (EM da Soalheira)

	HF	Plena Floração		Colheita média		Nº dias da PF à colheita
		Data	GD**	Data	GD***	
<b>2017/18</b>	909,9	24/mar	85,7	24/jul	1280,1	122
<b>2018/19</b>	784,0	09/mar	94,6	07/jul	1160,7	120
<b>2019/20</b>	556,2	05/mar	94,9	05/jul	1192,6	122
<b>2020/21</b>	754,9	16/mar	129,4	----*	----*	----*
<b>Média</b>	751,3		101,2		1211,1	121

\*colheita não efetuada por motivos de destruição pelo granizo.

\*\*somatório dos GD desde 15 de fevereiro até à plena floração.

\*\*\*somatórios dos GD desde a data da plena floração até à data média de colheita.

Relativamente à data de colheita, é de salientar o carácter regular do número de dias entre a plena floração e a data média de colheita, apesar das diferenças entre as datas de plena floração e as datas médias de colheita nos diferentes ciclos. O somatório de GD esteve compreendido entre 1160 e 1280 tendo uma diferença de 120 GD entre 2019/20 e 2017/18, o que poderá corresponder a 6 a 7 dias com uma temperatura média de 25°C. Assim, os dias entre PF e a colheita parece ser um fator mais constante e mais adequado para prever a data de colheita neste caso (UO-01, cv. Catherine). Embora variando de ano para ano e,

aparentemente, não se relacionando entre si, o valor do somatório de graus-dia entre a data da plena floração e a data média de colheita pode ser um bom indicador para caracterizar o crescimento e a qualidade dos frutos, eventualmente associado a outros fatores, tais como, o nível de carga das árvores e de produtividade do pomar. A carga e a produção, fatores que também influenciam o crescimento e maturação do fruto podem ser consultadas no capítulo 8.

## 2.4.2 Unidade de Observação de Orjais (UO-02)

Os resultados das observações fenológicas, das HF acumuladas e do somatório de GD relativamente à cv. Royal Time na UO-02 (Orjais) resumem-se no Quadro 2.3. Nesta UO, não existem registos da colheita nos dois primeiros ciclos, mas a data de plena floração mais temporã no ciclo em que as HF acumuladas (de novembro a fevereiro) foram mais baixas (2020/21) e mais tardia no ciclo em que as HF acumuladas foram mais elevadas (2017/18) parecem estar de acordo com o observado na UO-01 (Quadro 2.2). Os resultados da data de PF em relação às HF acumuladas também sugerem um longo período de ecodormência em 2017/18 e, por oposição, um período de ecodormência bastante mais curto em 2019/20.

**Quadro 2.3** – HF acumuladas (< 7,2°C) de 1 de novembro a 28/29 de fevereiro, datas da plena floração e da colheita, somatório de calor (GD > 7,0°C) e número de dias entre a data de plena floração (PF) e a data média de colheita observados na UO-02 (EM de Belmonte)

	HF	Plena Floração		Colheita média		Nº dias da PF à colheita
		Data	GD**	Data	GD***	
<b>2017/18</b>	1393,3	27/mar	54,3	----*	----*	----*
<b>2018/19</b>	1230,3	02/mar	24,6	----*	----*	----*
<b>2019/20</b>	948,9	24/fev	18,3	30/jun	958,1	127
<b>2020/21</b>	1058,7	07/mar	56,8	03/jul	913,3	118
<b>Média</b>	1157,8		38,5		935,7	123

\*colheita não registada (efetuada pelo produtor sem aviso prévio).

\*\*somatório dos GD desde 15 de fevereiro até à plena floração.

\*\*\*somatórios dos GD desde a data da plena floração até à data média de colheita.



Relativamente ao período de crescimento dos frutos observou-se um somatório GD de 913 e 958 e um número de 118 e 127 dias entre a PF e a colheita. Nesta UO-02, não se observou a mesma constância no intervalo de tempo (nos ciclos com informação) entre a plena floração e a colheita que se havia notado na UO-01. No ano de 2020, o número de dias entre a plena floração e a data de colheita média (127 dias), bem como o somatório de GD, foram superiores em relação ao ano de 2021 (118 Dias), o que poderá estar relacionado com a data de PF muito temporã.

### 2.3.3 Unidade de Observação de Ferro (UO-03)

Os resultados das observações fenológicas e das HF acumuladas e do somatório de GD (de 2021) relativos à cv. Sweet Dream, na UO-03 (Ferro) resumem-se no Quadro 2.4.

**Quadro 2.4** – HF acumuladas (< 7,2°C) de 1 de novembro a 28/29 de fevereiro, datas da plena floração e da colheita, somatório de calor (GD > 7,0°C) e número de dias entre a data de plena floração (PF) e a data média de colheita observados na UO-03 (EM do Ferro)

	HF	Plena Floração		Colheita média		Nº dias da PF à colheita
		Data	GD**	Data	GD***	
<b>2017/18</b>	1216,9	----	----	----	----	----
<b>2018/19</b>	1102,2	08/mar	61,9	30/jul	1410,2	144
<b>2019/20</b>	826,7	05/mar	69,9	22/jul	1377,8	139
<b>2020/21</b>	1031,7	10/mar	69,7	31/jul	1401,6	143
<b>Média</b>	1044,4		67,2		1396,5	142

\*sem registos (atraso na definição do pomar com UO).

\*\*somatório dos GD desde 15 de fevereiro até à plena floração.

\*\*\*somatórios dos GD desde a data da plena floração até à data média de colheita.

A definição do pomar do Ferro como UO foi efetuada apenas na primavera de 2020, razão pela qual não há registos detalhados da fenologia em anos anteriores a 2021. No entanto, foi possível recuperar ainda registos das datas de plena floração e de colheita de 2019 e 2020. Pelos resultados apresentados é possível verificar que as datas de colheita são mais tardias na cultivar Sweet

Dream (finais de julho) em comparação com as datas de colheita das cultivares Catherine e Royal Time, presentes nas UO-01 e UO-02, respectivamente. De referir também que o ciclo de 2019/20 foi o que apresentou uma data de plena floração e de colheita mais temporã e, simultaneamente, o valor mais baixo de HF acumuladas, confirmando-se um comportamento similar ao que se observou nas outras UO. Os GD até à data de plena floração foram muito semelhantes entre os 3 ciclos em estudo.

De referir, no entanto, que as datas de plena floração, o somatório de GD de 15 de fevereiro à plena floração e da plena floração à colheita na Sweet Dream foram mais regulares do que ocorreu nas outras cultivares, eventualmente devido à sua localização a maior altitude e/ou à maior duração do seu ciclo. Também é de assinalar a regularidade do intervalo de dias entre a plena floração e a colheita, apenas ligeiramente inferior em 2020, o ano com menor valor de HF acumulados e menor somatório de GD da plena floração à colheita.

## **A RETER**

**Para cada cultivar, a data de plena floração mais temporã parece estar relacionada com os ciclos em que as HF acumuladas (de novembro a fevereiro) são mais baixas, o que indica que estão satisfeitas as necessidades para quebrar a endodormência, estando a data de plena floração mais dependente das condições observadas na ecodormência.**

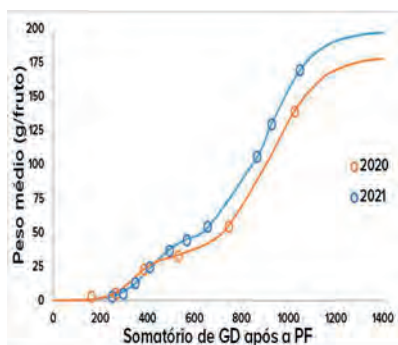
**O número de dias entre a PF e a colheita é um bom indicador para a previsão da colheita. O somatório de GD entre a PF e a colheita poderá também ser utilizado como previsão da colheita, mas é necessária mais informação e, provavelmente, a conjugação com outros parâmetros, para se tornar uma ferramenta mais fiável.**

### **2.3.4 Crescimento do fruto**

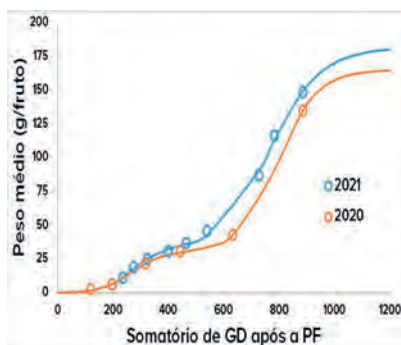
As curvas de crescimento do fruto apresentadas no capítulo 1 foram elaboradas em função do tempo, ou seja, o número de dias a partir da data da plena floração (DAPF). As mesmas curvas de crescimento também podem ser elaboradas em

função do somatório de calor, ou seja, do somatório das temperaturas superiores a 7,0°C, que se expressam em graus-dia (GD).

As Figuras 2.7 e 2.8 apresentam os resultados das curvas de crescimento do fruto em função do somatório dos graus-dia contados a partir da data de plena floração, para as cultivares Catherine (UO-01) e Royal Time (UO-3), respectivamente. Com esta representação das curvas de crescimento em função do somatório dos graus-dia, procurou-se estabelecer uma relação entre as condições meteorológicas e o crescimento do fruto. Em comparação com as curvas de crescimento em função do tempo (capítulo 1), há uma maior sobreposição das curvas nas fases iniciais do crescimento do fruto. Este resultado pressupõe uma maior dependência do crescimento inicial do fruto com o somatório das temperaturas até perto da fase de abrandamento do crescimento, relacionada com o endurecimento do endocarpo.



**Figura 2.7** - Curvas de crescimento do fruto em 2020 e 2021 relativas à cv. Catherine (UO-01), em relação ao somatório dos graus-dia (GD) após a plena Floração (PF).



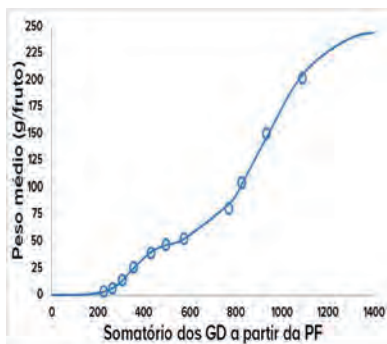
**Figura 2.8** - Curvas de crescimento do fruto em 2020 e 2021 relativas à cv. Catherine (UO-01), em relação ao somatório dos graus-dia (GD) após a plena Floração (PF).

A Figura 2.9 mostra a curva de crescimento da cv. Sweet Dream (UO-03) relativa a 2021, tendo faltado os dados de 2020 para se poder fazer uma comparação das curvas, de modo semelhante ao efetuado nas outras UO.

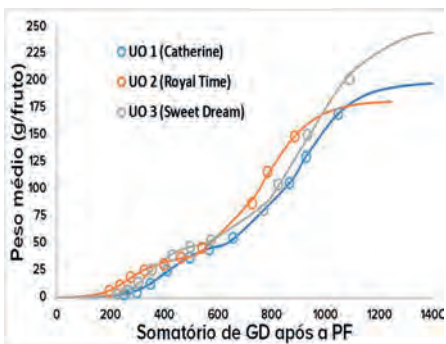
A Figura 2.10 faz a comparação entre locais e cultivares. Apesar de ser difícil fazer comparações, uma vez que são cultivares diferentes em cada local, é possível

verificar que o crescimento do fruto em função do somatório de GD a partir da PF segue uma pauta relativamente regular nas fases iniciais de crescimento, ocorrendo com menor somatório de GD na região mais fria (UO-02, Orjais) e com maior somatório de GD na região mais quente (UO-01, Soalheira).

O período de abrandamento do crescimento (endurecimento do endocarpo) tende a ocorrer com um somatório de GD similar nos 3 casos (450 a 550 GD), voltando a retomar a pauta de crescimento que se havia verificado antes, ou seja, com menor somatório de GD na região mais fria (UO-02, Orjais) e com maior somatório de GD na região mais quente (UO-01, Soalheira).



**Figura 2.9** – Curva de crescimento do fruto em 2021 relativa à cv. Sweet Dream (UO-03), em relação ao somatório dos graus-dia (GD) após a plena floração (PF).



**Figura 2.10** – Curvas de crescimento do fruto em 2021 relativas à cv. Catherine (UO-01), à cv. Royal Time (UO-02) e à cv. Sweet Dream (UO-03), em relação ao somatório dos graus-dia (GD) a partir da data da plena floração (PF).

O potencial genético da cv. Sweet Dream manifesta-se pelo maior valor do peso médio no período de endurecimento do endocarpo, pelo período de crescimento do fruto mais alargado, pelo maior ritmo de crescimento após o endurecimento do endocarpo e, ainda, pelo valor máximo que pode atingir no final do período de crescimento rápido.

## A RETER

O crescimento do pêssogo, em peso fresco, pode ser representado por uma dupla sigmoide em função do somatório das temperaturas superiores a 7,0°C,

podendo servir para relacionar o crescimento do fruto com as condições meteorológicas.

## 2.4 Considerações finais

Os ciclos anuais caracterizam-se pela alternância de períodos favoráveis e períodos desfavoráveis à atividade vegetativa e metabólica. O período invernal representa o período mais desfavorável e que obriga as plantas a estratégias de sobrevivência mais drásticas. Passado o período de temperaturas críticas do inverno, a subida paulatina das temperaturas em fevereiro e março (no pessegueiro) são fundamentais para que o processo de abrolhamento e a polinização decorram de forma adequada, expressando uma evolução regular dos estados fenológicos e garantindo um bom vingamento e produção. Condições meteorológicas irregulares, sejam subidas ou descidas abruptas da temperatura, eventualmente com ocorrência de geadas tardias, são responsáveis por perturbações na expressão da fenologia, acelerando ou retardando o processo e influenciando a taxa de vingamento, o ritmo de crescimento do fruto e, em última análise, a produção do pomar.

Neste contexto, poderá dizer-se que a duração e as condições que ocorrem no período de ecodormência, são aspetos críticos para a regular expressão da fenologia e desenvolvimento dos frutos no pessegueiro, quiçá um fator a merecer mais atenção em futuros estudos de caso.

## 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

Abreu, J.P.M. 2018. Agrometeorologia – Aplicação da meteorologia para maximizar a produção agrícola. Agrobook, Quântica Editora, Porto. ISBN 978-989-892-7200

Agustí, M. 2010. Fruticultura. Ed. Mundi-Prensa, Madrid.

Crossa-Raynaud, C. 1956. Effets des hivers doux sur le comportement des arbres fruitiers à feuilles caduques. Ann. Serv. Bot. Agron. 29: 1-22.

DeJong, T.M. e Goudriaan, J. 1989. Modeling peach fruit growth and carbohydrate requirements: reevaluation of the double-sigmoid growth pattern. J. Amer. Soc. Hort. Sci. 114 (5): 800-804.

Legave, J.M., Baculat, B. e Brisson, N. 20210. Assessment of chilling requirements of apricot floral buds: comparison of Three contrasting chilling models under mediterranean conditions. Acta Horticulturae, 872: 41-49.

Strand, L.L. 1999. Integrated pest management for Stone Fruits. University of California Division of Agriculture and Natural Resources. Publication 3389. ISBN 1-879906-36-8.

Velarde, F. Gil-Albert. 1989. Tratado de arboricultura frutal. Vol II – La ecología del árbol frutal Fruticultura. Ed. Mundi-Prensa, Madrid.









## Capítulo 3

# Robô aéreo autónomo

Ricardo Mesquita<sup>1</sup> e Pedro Dinis Gaspar<sup>1,2</sup>

<sup>1</sup>UBI – Universidade da Beira Interior| Departamento de Engenharia Eletromecânica

<sup>2</sup>C-MAST – Center for Mechanical and Aerospace Science and Technologies

### 3.1 Introdução

Novas tecnologias, como os Veículos Aéreos Não Tripulados (UAVs), comumente conhecidos como drones, têm sido cada vez mais utilizadas nas atividades agrícolas. Os UAVs são aeronaves não tripuladas já aplicadas na agricultura e usadas para superar as falhas dos sistemas tradicionais. Vários parâmetros caracterizam seus tipos, como estrutura, método de decolagem e pouso e número de motores. As principais configurações da estrutura são decolagem e pouso horizontal, multirrotor, helicóptero e decolagem e pouso vertical (VTOL), e sua arquitetura básica consiste em uma estrutura, motores sem escova, módulos de controlo eletrónico de velocidade (ESC), placa de controlo, Sistema de Navegação Inercial (INS) e um módulo transmissor / recetor (Daponte

et al., 2019). Dependendo de sua função, eles podem incluir compartimentos de carga, atuadores, sensores como módulos de detecção de luz e alcance (LiDAR) e câmaras multiespectrais para monitorizar o progresso e o crescimento das plantações em grande escala, fazendo uso dos índices vegetais. A possibilidade de coleta sistemática de dados, mapeamento da variabilidade do campo e melhores decisões leva agricultores e empresas a investirem em UAVs para a agricultura.

UAVs ou drones podem voar sem a presença dos pilotos a bordo (Narayanan & Ibe, 2015) e podem ser autônomos por meio de um controlador de voo eletrônico a bordo e um mapa de rota ou controlados remotamente a partir do solo (Mesquita & Gaspar, 2022). Essa tecnologia já é amplamente utilizada na agricultura em diferentes aplicações devido a sua alta mobilidade, versatilidade de tarefas, baixa manutenção e custo, e suas vantagens preenchem as desvantagens dos sistemas tradicionais. No entanto, existe o problema do curto tempo de voo. Esse problema pode ser trabalhado por meio da otimização de voo, usando o planejamento de trajetória e a expansão da capacidade das baterias, que representam uma das partes mais pesadas dos UAVs. Aumentar sua capacidade também aumenta o volume e o peso, tornando o drone mais pesado e menos eficiente e, na maioria dos produtos de prateleira, não é possível modificá-los. Portanto, é necessário otimizar a trajetória para garantir o voo mais eficiente em termos energéticos de acordo com o objetivo final.

Este capítulo apresenta um algoritmo de otimização de planejamento de caminho para UAVs para aplicação na agricultura, usando técnicas de otimização metaheurística e planejamento de voo baseado em pontos de interesse. Diferentes cenários são testados em simulação e em campo, estudando variáveis como tempo de processamento, número de iterações e consumo de energia. Este estudo foca na eficiência energética e na otimização do tempo de voo, o que pode ser uma mais-valia em UAVs em muitas aplicações.

## 3.2 Material e métodos

### 3.2.1 Robô aéreo autônomo

Os drones multirotores sendo de baixo custo, com boa manobrabilidade e capacidade VTOL, são adequados para tarefas de sensorização remoto de agricultura de precisão (Pradeep et al., 2018). O chassi do UAV utilizada neste estudo foi um multirotor com quatro motores (quadcopter), equipado com hélices auto-apertos que o tornam muito simples de montar e desmontar em campo e para transporte. Essa configuração também é uma das mais utilizadas na agricultura hoje em dia e pode levantar seu peso e equipamentos sem comprometer o tempo de voo. No entanto, por causa da curta duração de carga das baterias de polímero de lítio (Li-Po), os UAVs têm uma cobertura de área de campo menor por voo do que os aviões (Pradeep et al., 2018). Este trabalho utilizou quatro baterias Li-Po em série com capacidade de 5000 mAh.



**Figura 3.1** - Multirotor usado neste estudo.

Devido a este estudo ser de planeamento de caminho, não é essencial ter a melhor relação UAV/peso da bateria, mas este requisito é recomendado em uma aplicação da vida real. A Figura 3.1 mostra o multirotor usado neste estudo durante um voo de teste.

### 3.2.2 Algoritmo de otimização

O algoritmo de otimização apresentado neste estudo é generalizado para qualquer configuração de UAV e capacidades de tempo de voo. Assim, o componente essencial a ser considerado é o controlador de voo que precisa ter um piloto automático compatível com o GCS escolhido, sensores internos


adequados e a entrada / saída necessária de acordo com a configuração do UAV. Nesse caso, foi escolhido o Hex Cube Black (PX4, 2021), anteriormente conhecido como Pixhawk 2.1. Este piloto automático é flexível, destinado principalmente a fabricantes de sistemas comerciais. É baseado no projeto de hardware aberto FMUv3 do Pix-hawk-project e roda o PX4 no sistema operacional NuttX (PX4, 2021). É responsável e tem uma qualidade de construção premium com muita informação. Como recetor GPS Hex Cube Black, o HERE + foi escolhido pela qualidade de construção, compatibilidade e informação. Outro componente essencial é o bloco de energia que vem com o controlador de voo, que fornece energia para todos os componentes do UAV e mede o consumo de corrente e a tensão da bateria. Assim, é possível testar o algoritmo de otimização de planeamento de caminho em cenários do mundo real. Também é importante mencionar que durante a construção deste sistema, foi necessário o uso de técnicas de desenho auxiliado por computador (CAD) e impressão 3D via modelagem por deposição fundida (FDM) para acomodar toda a eletrónica. Os componentes fabricados através de FDM foram confeccionados em Acrilonitrila Butadieno Estireno (ABS) por ser resistente a mudanças de temperatura e impactos. O ABS é o material mais utilizado após o Ácido Polilático (PLA) e, além das características destacadas acima, também apresenta boas propriedades mecânicas, baixo preço e longa vida útil (Rodríguez-Panes et al., 2018).

Para ativar o plano de voo, foi utilizado o RadioKing TX18S, um transístor de sistema de radiofrequência (RF) multiprotocolo de 2,4 GHz, 16 canais (CH) e firmware open-source OpenTX [67] para rádios transmissores. Um rádio multiprotocolo foi escolhido porque ele pode se comunicar com o FrSky X8R, que é o recetor com o qual o UAV deste estudo foi construído, mas também é compatível com vários recetores de telemetria para trabalhos futuros. Porém, esses componentes não são os mais importantes para este trabalho de pesquisa, sendo necessário apenas garantir a compatibilidade transmissor / recetor e um modelo OpenTX com todas as configurações para um voo seguro. É imprescindível mencionar que às vezes acidentes relacionados ao desarmamento do drone acontecem involuntariamente.

Por esse motivo, foi programada uma sequência de interruptores no transmissor de rádio ao invés da manete do acelerador pré-definido, possível através das funções lógicas no OpenTX e alterando os parâmetros pré-definidos no GCS.

### 3.2.3 Minimização entre pontos de interesse

Dependendo do tipo de campo e da posição dos pontos de interesse (Pols), o UAV deve voar de acordo com as necessidades. É fundamental que o algoritmo receba os dados e estabeleça o caminho mais curto para economizar bateria para as áreas próximas ao Pol. O PSO para minimização é usado para calcular a rota mais rápida ou a distância mínima. Cada partícula contém uma sequência permuta de Pols, e a função objetivo é a soma das distâncias, usando a fórmula de Haversine, entre os pontos, a decolagem e a aterrissagem. No final, esta função enviará a distância mínima e a sequência de ordem dos Pols que o drone precisa para voar. A Figura 3.2 representa a importância de minimizar o caminho entre Pols com dois casos por meio de um exemplo. Um sem otimização, representado como a) e o outro com a otimização, representada como b). O caminho do cenário do primeiro caso tem uma distância total de 268,3m, enquanto o caminho do cenário do segundo caso tem 216,3m, o que representa uma redução de 52 m.



**Figura 3.2** - Exemplo da importância de minimizar o caminho entre Pols: a) Sem a função de otimização b) Com a função de otimização.

### 3.2.4 Câmara multiespectral

O robô aéreo está equipado com uma câmara fotográfica multiespectral Micasense RedEdge para aquisição das imagens (Figura 3.3). Esta câmara captura simultaneamente cinco bandas espectrais discretas (azul, verde, vermelho, próximo do vermelho e infravermelho). Em geral, estas imagens (5 bandas) são utilizadas para gerar informações precisas e quantitativas de plantações.



Figura 3.3 - Câmara multiespectral Micasense RedEdge.

## 3.3 Resultados e discussão

### 3.3.1 Robô aéreo autónomo



Figura 3.4 - Campo de estudo.


O robô aéreo autónomo apresenta-se como uma mais-valia na monitorização das culturas e dos solos. No que respeita às culturas, a deteção do volume das árvores através desta tecnologia permitirá uma interpretação mais célere e dinâmica do desenvolvimento das plantas.

Três estudos de caso foram desenvolvidos para estudar o algoritmo de otimização de planeamento de caminho, dois em simulação e um em campo. O estudo de caso # 1 usa vários Pols com um raio baixo, e o estudo de caso # 2 tem menos Pols, com um raio de waypoint aleatório alto para servir de comparação. Ambas as simulações são

usadas para entender melhor o desempenho do algoritmo e a influência de cada parâmetro. O estudo de caso # 3 foi desenvolvido para analisar a aplicação no mundo real e o impacto na autonomia da bateria e na influência da altura. Um pomar de pessegueiro em Orjais, Covilhã, em Portugal, marcado com a linha vermelha na Figura 3.4, foi usado como um campo de pesquisa em simulações e testes do mundo real.

### 3.3.2 Imagens aéreas multiespectrais

A Figura 3.5 ilustra as 5 bandas de uma imagem capturada num pomar de pessegueiros, pela câmara multiespectral transportada no robô aéreo.



**Figura 3.5** - As cinco bandas de uma imagem: 1) Canal B, 2) Canal G, 3) Canal R, 4) Canal NIR, 5) Canal RE.



Conforme mencionado na introdução desse capítulo, imagens multiespectrais possibilitam o cálculo de índices de vegetação que fornecem informações importantes sobre o desenvolvimento das plantas, da sua coloração que é associada à sua capacidade fotossintética.

### **3.4 Considerações finais**

Nesse trabalho foi desenvolvido um UAV multirrotor com quatro motores (quadcopter), equipado com hélices auto-apertos que o tornam muito simples de montar e desmontar em campo e para transporte. Adicionalmente, um algoritmo de otimização de planeamento de caminho foi proposto. O mesmo pode ser dividido em quatro etapas principais: Configuração de parâmetros; Minimização entre pontos de interesse; Maximização de pontos de passagem aleatórios; Criação de arquivo de missão pré-planeada. Assim, três estudos de caso foram criados para entender o desempenho e a variação dos parâmetros do algoritmo proposto. Em conclusão, este algoritmo pretende superar as falhas dos sistemas tradicionais, otimizando voos de UAV. O UAV foi equipado com uma câmara multiespectral no qual permite avaliações do estado das plantas, por intermédio de processamento de imagem, possam ser realizadas.

### **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**

Daponte, P., de Vito, L., Glielmo, L., Iannelli, L., Liuzza, D., Picariello, F., & Silano, G. 2019. A review on the use of drones for precision agriculture. *IOP Conference Series: Earth and Environmental Science*, 275(1), 012022.

- Mesquita, R., & Gaspar, P. D. 2022. A Novel Path Planning Optimization Algorithm Based on Particle Swarm Optimization for UAVs for Bird Monitoring and Repelling. *Processes*, 10(1), 62.
- Narayanan, R. G. L., & Ibe, O. C. 2015. Joint network for disaster relief and search and rescue network operations. In *Wireless Public Safety Networks 1* (pp. 163–193). Elsevier.
- Pradeep, P., Park, S. G., & Wei, P. (2018). Trajectory optimization of multirotor agricultural UAVs. *2018 IEEE Aerospace Conference*, 1–7.
- Rodríguez-Panes, A., Claver, J., & Camacho, A. M. 2018. The influence of manufacturing parameters on the mechanical behaviour of PLA and ABS pieces manufactured by FDM: A comparative analysis. *Materials*, 11(8), 1333.







## Capítulo 4

# Deteção de Automática de Copas de Árvores

Eduardo Assunção<sup>1</sup>, Pedro Dinis Gaspar<sup>1,2</sup>, Ricardo Mesquita<sup>1</sup> e Hugo Proença<sup>3,4</sup>

<sup>1</sup>UBI – Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

<sup>2</sup>C-MAST – Center for Mechanical and Aerospace Science and Technologies ()

<sup>3</sup>UBI – Universidade da Beira Interior | Departamento de Ciências da Computação

<sup>4</sup>UBI – Universidade da Beira Interior | Instituto de Telecomunicações

### 4.1 Introdução

A avaliação do tamanho das copas das árvores é um instrumento para avaliar o desempenho individual de cada planta. O tamanho da copa está relacionado com o vigor, e, como tal, com a capacidade produtiva, que, por sua vez, requer diferentes necessidades de água e de fertilizantes (LQARS, 2006). A capacidade produtiva das plantas e as operações culturais a que está sujeita, nomeadamente monda de frutos, fertilização e proteção fitossanitária (Ferreira et al., 2017; LQARS, 2006; MADRP, 1997; Simões, 2021; Barateiro et al., 2021) determinam 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 convolucional (CNN) (*Convolutional Neural Network*), nomeadamente, Mask R-CNN.

A literatura mostra alguns trabalhos realizados neste campo. Usando vários conjuntos de dados e o modelo de aprendizagem profunda U-Net, Kattenborn et al. (2019) testaram uma segmentação em imagens RGB de alta resolução baseadas em UAV para mapeamento fino de espécies de vegetação e comunidades com pelo menos 84% de precisão.

Zhao et al. (2018) criaram um conjunto de dados de árvores (romãzeiras) como auxílio de uma câmara comercial e um UAV a voar a 30 metros acima do solo. Em seguida, treinaram e testaram dois métodos baseados em rede convolucional, U-Net e Mask R-CNN, usando esse conjunto de dados. Por fim, compararam seus desempenhos com as imagens aéreas do conjunto de dados de romãzeiras.

Anagnostis et al. (2021) propõe uma abordagem para a segmentação de árvores de pomar usando imagens aéreas baseada em uma variante de rede neural convolucional de aprendizado profundo, a rede U-Net. O objetivo foi a detecção automatizada e localização da copa das árvores de pomar sob várias condições. O conjunto de dados implementado foi composto por imagens de três pomares de nogueiras. O modelo mais apurado alcançou 91%, 90% e 87% de precisão para treino, validação e teste, respetivamente.

## **4.2 Materiais e métodos**

### **4.2.1 Modelo de detecção de copas de árvores**

Neste trabalho, para a detecção das copas das árvores, foi usado o modelo Mask R-CNN (He et al., 2017). Esse modelo é baseado em aprendizagem profunda, funcionando em paralelo com a classificação e geração das caixas delimitadoras e criação de máscaras dos objetos de interesse (as copas das árvores).

## 4.2.2 Base de dados

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 pêsego, a norte e a sul da serra da Gardunha.

Foi utilizada uma câmara RGB acoplada a um drone para capturar as imagens. A Figura 4.1 ilustra a aquisição das imagens que compõe a base de dados. Essas imagens são manualmente anotadas (delimitação das copas) para serem utilizadas no processo de treino do modelo.

## 4.3 Resultados e discussão

Na Figura 4.2 é apresentada uma imagem de um pomar de pessegueiros.




**Figura 4.1** – Exemplo de imagem capturada para composição da base de dados de imagens. **A** – Árvores monitorizadas. **B** – Sinalização utilizada.


Na imagem, em algumas árvores, pode ver-se um círculo branco, que corresponde ao modo utilizado para sinalização de plantas monitorizadas individualmente. Essa metodologia consiste em colocar uma cana encimada por um prato e prender essa cana num ramo que esteja na parte superior da copa (Figura 4.1-B). Este é o tipo de imagem utilizado como teste.



Nas Figura 4.2 e 4.3 apresenta-se à esquerda a imagem de visão computacional enquanto, a direita, é apresentado o resultado de saída do sistema de inteligência artificial de detecção e segmentação de copas de árvores. As regiões coloridas são as máscaras que delimitam as regiões de interesse (isto é, as copas).




**Figura 4.2** – Exemplo 1 do resultado do algoritmo de detecção /segmentação Mask R-CNN em uma imagem de teste do pomar de pessegueiros. **A** – Imagem real. **B** – Área da projeção da copa.



**Figura 4.3** – Exemplo 2 do resultado do algoritmo de detecção /segmentação Mask R-CNN em uma imagem de teste do pomar de pessegueiros. **A** – Imagem real. **B** – Área da projeção da copa.

Com o modelo consegue-se segmentar as copas e os círculos brancos (pratos), obtendo-se assim as áreas (em pixels) das copas e dos círculos. Como a área do círculo é conhecida, então, por intermédio de uma conversão linear, consegue-se calcular as áreas das copas na unidade  $m^2$ .

A Figura 4.4 mostra o resultado das detecções/segmentações com o objetivo de medir o tamanho das áreas das copas e o Quadro 4.1 apresenta os valores das medições em m<sup>2</sup>.




**Figura 4.4**– Exemplo 3 do resultado do algoritmo de detecção /segmentação Mask R-CNN com o objetivo de medir o tamanho das áreas das copas.

Tendo em consideração a determinação da área de projeção da copa pela análise da imagem captada pelo UAV, podemos determinar o volume da copa das árvores. Para tal consideramos que maioritariamente as plantas de um pomar conduzido em vaso apresentam uma altura de 2,5 m. Essa altura é determinada na poda e é comum à maioria dos pomares pois permite que a colheita seja toda feita do chão.

Sabendo a área de projeção da copa e considerando a altura da planta uma constante (neste caso 2,5 m), podemos calcular o volume atribuindo uma forma

à copa das plantas, que pode ser esférica, paralelepípedica ou cilíndrica (Figura 4.5).



**Figura 4.5** – Forma da copa e relação entre a área de projeção da copa e o volume, para 3 hipóteses.

Se considerarmos que a forma da copa se assemelha a uma esfera (hipótese 1), o volume será calculado com base no raio médio da área de projeção da copa. Se considerarmos que a copa se desenvolve sobre a linha das plantas, a sua forma será mais paralelepípedica (hipótese 2), o volume será diretamente proporcional à área de projeção da copa uma vez que a altura será uma constante.

Quando as plantas ainda não ocupam integralmente a linha, o volume poderá aproximar-se de um cilindro cuja base será a área de projeção da copa (semelhante à hipótese 2).

Contudo, será ainda de considerar que, se a parte inferior da copa ocupa integralmente o espaço, na parte superior da copa tal não se observa, e há espaços vazios que advêm da forma de condução e do crescimento dos ramos. Assim, podemos estimar que a metade superior da copa corresponde apenas à ocupação de 50% do espaço (hipótese 3).

Com base nas hipóteses formuladas apresenta-se no Quadro 4.1 os volumes de copa obtidos para um dos pomares onde foi realizada a medição da área de projeção da copa.

**Quadro 4.1** – Valores obtidos das medições do tamanho das copas das árvores da Figura 4.4.

Identificação (ID)	Área de projeção (m <sup>2</sup> )	Volume da copa (estimado) (m <sup>3</sup> )		
		hipótese 1 esfera	hipótese 2 paralelepípedo	hipótese 3 75%paralelepípedo
0	2,41	7,3	6,0	4,5
2	2,35	6,8	5,9	4,4
3	2,38	7,1	6,0	4,5
4	1,89	3,5	4,7	3,5
5	2,16	5,3	5,4	4,1
6	1,60	2,1	4,0	3,0
7	1,55	1,9	3,9	2,9
8	1,77	2,9	4,4	3,3
9	1,51	1,8	3,8	2,8
<b>Média</b>	<b>1,96</b>	<b>4,31</b>	<b>4,89</b>	<b>3,67</b>

**Nota:** o volume da copa foi calculado considerando uma altura das plantas de 2,5 m e que metade da altura corresponde a uma ocupação de 100% e a outra metade uma ocupação de 50% do volume. Assim  $V=0,75 \cdot \text{altura} \cdot \text{área de projeção da copa}$

Os volumes diferem bastante, mas, a hipótese 2 e 3, apesar de valores distintos entre si, são múltiplos da área de projeção da copa, pelo que para efeito de avaliação do vigor, poder-se-á utilizar diretamente o valor da área de projeção. Já no caso de se considerar o volume da copa como uma esfera, a relação entre o volume e a área de projeção será uma relação exponencial.

Com base nas técnicas culturais da poda e da poda em verde parece-nos que a forma do volume das copas, de um pomar em plena produção, se assemelha mais a uma forma paralelepípedica, sendo a hipótese 3 a que melhor se ajusta ao modo de crescimento de pessegueiros conduzidos em vaso.

## 4.4 Considerações finais

Os resultados visuais mostram o bom desempenho do modelo de detecção/segmentação de copas de árvores. Embora as imagens de teste apresentem sombras das próprias árvores, o que poderia confundir, o modelo consegue uma boa discriminação entre árvores e sombras. Também, pode ser verificado que as máscaras de segmentação são bem precisas na delimitação das copas. Logo, o modelo poder ser considerado muito promissor para utilização em trabalhos de segmentação de copas de árvores.

## 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

Anagnostis, A., Tagarakis, A. C., Kateris, D., Moysiadis, V., Sørensen, C. G., Pearson, S., & Bochtis, D. 2021. Orchard Mapping with Deep Learning Semantic Segmentation. *Sensors*, 21(11), 3813.

- Barateiro, A., Ramos, C., Fragoso, P., Lopes, S., Vieira, F. e Abrantes, A. C. 2021. Monitorização e avaliação da eficácia da captura em massa da mosca do mediterrâneo em pomares de pessegueiro na região da Beira Interior. *Agrotec*, n.º 39: 24-29.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. 2017. Mask r-cnn. *Proceedings of the IEEE International Conference on Computer Vision*, 2961–2969.
- Ferreira, D., Veloso, A., Gavinhos, C., Barateiro, A., Ramos, C., Vieira, F., Silvino, P. Pedro Jordão, P., Calouro, F. e Simões, M.P. 2017. Monda de Flores – Avaliação da utilização do equipamento Saflower® Electric em pomares de pessegueiro. In Simões, M.P. (coord). +Pêssego – Inovação nas Técnicas de Produção, Centro Operativo e Tecnológico Hortofrutícola Nacional: 17-60. ISBN 9789728785055.
- Kattenborn, T., Eichel, J., & Fassnacht, F. E. 2019. Convolutional Neural Networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution UAV imagery. *Scientific Reports*, 9 (1): 1–9.
- LQARS – Laboratório Químico Agrícola Rebelo da Silva, 2006. Manual de fertilização das culturas. Ministério da Agricultura, do Desenvolvimento Rural e das Pescas, Lisboa.
- MADRP. 1997. Código de Boas Práticas Agrícolas. ISBN 972-8135-32-7.
- Simões, M.P. 2021. Manual de Boas Práticas do pessegueiro. *Revista FL&F*. 10º fascículo: 103-113. [https://www.inia.vpt/images/publicacoes/livrosmanuais/manual\\_de\\_fruticultura\\_pessegueiro.pdf](https://www.inia.vpt/images/publicacoes/livrosmanuais/manual_de_fruticultura_pessegueiro.pdf)
- Zhao, T., Yang, Y., Niu, H., Wang, D., & Chen, Y. 2018) Comparing U-Net convolutional network with mask R-CNN in the performances of pomegranate tree canopy segmentation. *Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques and Applications VII*, 10780, 107801J.









# Capítulo 5

## **Robô terrestre autónomo**

**André Veiros<sup>1</sup>, Ricardo Mesquita<sup>1</sup> e Pedro Dinis Gaspar<sup>1,2</sup>**

<sup>1</sup>UBI – Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

<sup>2</sup>C-MAST – Center for Mechanical and Aerospace Science and Technologies

### **5.1 Introdução**

O Rover Robótico para Aplicações Agrícolas (R2A2), é um robô terrestre agrícola multitarefa que tem por finalidade realizar de forma autónoma a pulverização de herbicida de forma particularizada em pomares de pessegueiro. O sistema robótico possui, basicamente, duas funções executadas em épocas distintas. A primeira, consiste na realização de pulverização de precisão de herbicida e a segunda função é a recolha dos pêssegos caídos no chão do pomar (Veiros & Gaspar, 2020). Para além dessas funções pretende-se ainda, através da captação e processamento de imagens, realizar a contagem dos frutos para previsão da produção.

A aplicação de herbicida ocorre em diversos momentos durante o ciclo vegetativo, mas a época principal será em abril (ver capítulo 10).

A recolha de frutos do solo será durante o período de colheita, e sempre que ocorrer uma queda de frutos elevada ou existir elevada quantidade de frutos de refugo.

Para a previsão da produção, o robô encontra-se munido de câmaras e de algoritmos de inteligência artificial que, através do processamento das imagens irão realizar a deteção de frutos, proceder à sua contagem e também a sua classificação, e desse modo providenciar uma previsão mais assertiva. Essa previsão permitirá ao fruticultor tomar as decisões de operações culturais que interferem com o rendimento, nomeadamente monda de frutos ou negociação mais precisa com os clientes.

No que respeita à aplicação de precisão de herbicida, o objetivo é não só otimizar o controlo de infestantes como reduzir o impacto ambiental, visto que, a quantidade de herbicida utilizada no controlo de infestantes será reduzida por conta da pulverização de precisão.

No que respeita à recolha dos pêssegos caídos no solo, o objetivo é não só promover a maximização da utilização da produção como, com elevada importância, evitar a proliferação de pragas e doenças que se desenvolvem nos frutos de refugo que ficam no solo e que se constituem como um inóculo para o ciclo vegetativo seguinte. São exemplos os pêssegos com ataque de mosca e a podridão causada por *Monilinia* sp ou *Botrytis cinerea*. Em alguns pomares a fruta caída no chão é retirada manualmente mas, o custo da operação é elevado e tenderá a ser ainda mais elevado com o aumento da escassez de mão-de-obra e correspondente aumento do seu custo. A remoção robótica permitiria uma redução dos custos e, portanto, uma maior probabilidade de realização da operação.

## 5.2 Materiais e métodos


R2A2 foi construído de forma que tivesse capacidade para se mover de forma autónoma no pomar e realizar tarefas junto ao tronco das árvores, sem passar entre árvores, deslocando-se apenas na entrelinha das árvores. O robô foi projetado para superar inclinações do terreno até 20° e mover-se sob vegetação até 600 mm. No Quadro 5.1 apresentam-se valores referentes às demais especificações do robô R2A2.

A modelação do protótipo foi desenvolvida com software CAD Solidworks. Com isso, foi realizado o planeamento de toda a construção e montagem do robô. Esse software também possibilitou a extração dos desenhos técnicos que auxiliaram na construção do sistema, inclusive todos os desenhos das peças que foram fabricadas com auxílio das máquinas CNC.

**Quadro 5.1** – Especificações técnicas do Rover Robótico para Aplicações Agrícolas (R2A2).

Especificação do robô	Valor
Peso aproximado	90 kg
Carga útil	15 kg
Velocidade Máxima	1,4 m/s
Aceleração	1 m/s <sup>2</sup>
Comprimento	1200 mm
Largura	1050 mm
Altura	500 mm

Na Figura encontra-se a vista explodida do veículo realizada pelo software CAD utilizado.



**Figura 5.1** – Vista explodida do robô.

A componente estrutural do robô é formada por perfil de alumínio com ranhuras em forma de T-slot 45 mm x 45 mm da marca Boch Rexroth, o que cria uma estrutura muito resistente e leve. Essa solução foi selecionada visto que é de

fácil montagem, e também, permite a fácil fixação de diferentes peças que possam ser adicionadas após a conclusão do projeto. Além do fácil reposicionamento e ajustabilidade da estrutura.

## 5.3 Resultados e discussão

A plataforma robótica possui um braço cartesiano destinado à realização de pulverização. Esse braço robótico possui 5 eixos e direciona o bico de pulverização e a garra que realizará a recolha dos pêssegos que estiverem caídos ao chão. Nesse caso, será possível realizar tarefas em extensão de 1200 mm, pois, os sistemas acionados podem trabalhar fora da estrutura do robô para realização de atividades próximo ao caule das culturas.

Na Figura 5.2 é mostrado a perspectiva isométrica do robô, ou seja, o desenho 3D final da plataforma robótica, já montado e com todas as componentes que lhe auxiliarão a desempenhar suas tarefas. O modelo 3D foi uma mais-valia pois possibilitou a otimização dos recursos construtivos, melhoria de componentes e restringiu possíveis erros de montagem. Com isso, foi possível realizar uma lista de materiais mais precisa que auxilia na gestão do projeto de montagem evitando que fosse interrompido por alguma falta de componente.

Após a montagem, foram realizados alguns testes em campo em que foi avaliada a sua manobrabilidade e deslocamento, que o mesmo executou sem maiores problemas. Entretanto, foi verificada algumas dificuldades ao realizar transporte de carga, como pedras e ramos caídos, pois o robô não conseguiu manter uma velocidade constante dada a derrapagem das rodas traseiras. O sistema de pulverização também foi testado e não apresentou problemas.

Na Figura 5.3 é possível observar o veículo em operação no campo.




Figura 5.2– Perspetiva isométrica do robô.



Figura 5.3 – Plataforma robótica em operação no campo.

## 5.4 Considerações finais

Aumentar a velocidade e a precisão da deteção de robôs para aplicações agrícolas são as principais dificuldades a serem comparadas aos exemplos industriais onde são alcançadas precisão e condições de trabalho muito altas.

O robô terrestre R2A2, que foi desenvolvido e testado, mostra-se promissor em diversas fases das culturas como no apoio à decisão do produtor.

## 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

Veiros, A., & Gaspar, P. 2020. Sistema robótico terrestre para apoio a atividades de manutenção de solo em pomares de prunóideas  
<https://ubibliorum.ubi.pt/handle/10400.6/10882>







## Capítulo 6

# **Sistema de navegação autónoma baseado em visão computacional por deteção de troncos de árvores - Aplicação a pomares de pessegueiros**

José Pedro Gouveia Pires Simões<sup>1</sup> e Pedro Dinis Gaspar<sup>1,2</sup>

<sup>1</sup>Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

<sup>2</sup>Center for Mechanical and Aerospace Science and Technologies (C-MAST)

### **6.1 Introdução**

O rover robótico (R2A2) faz uso de dois sistemas de controlo, regulação e comando da locomoção. Um é baseado em sistema de posicionamento global (GPS – Global Positioning System), permitindo que o trajeto autónomo a realizar pelo rover robótico possa ser pré-programado (Menezes et al., 2022). O outro sistema de controlo, regulação e comando da locomoção autónoma fará uso de uma câmara RGB (Red-Green-Blue) disposta sobre o rover e de um algoritmo de deteção de troncos (Simões et al., 2022). Este sistema será prioritário para evitar que a plataforma robótica choque com as árvores e para garantir que esta se desloque numa linha reta sem grandes desvios, com uma margem de erro reduzida. Este capítulo tem como objetivo caracterizar este sistema de locomoção.

O algoritmo tem como entrada imagens de vídeo a tempo real captado por uma câmara montada na plataforma e, através de técnicas de Inteligência Artificial por Aprendizagem Profunda (Deep Learning), mais especificamente por Redes Neurais Convolucionais (Convolutional Neural Networks – CNN) (Sandler et al., 2018), fará a deteção dos troncos das árvores. A estratégia de orientação é a criação de uma função linear, utilizando dois pontos dos limites de deteção de dois troncos, formando uma linha que acompanha aproximadamente a orientação da fila de árvores do pomar. Ordens serão enviadas ao robô para virar para a esquerda, direita ou prosseguir a marcha caso a caixa que delimita a deteção do tronco se encontra muito desviada da linha ou, no caso de detetar dois troncos, o declive da função linear atingir valores que indiquem que o robô segue uma trajetória irregular e potencial de choque.

Uma deslocação autónoma permite uma melhor gestão de tempo, pois não há necessidade de haver um operário a controlar a navegação do robô, logo o robô efetua uma tarefa demorada e mundana sem interrupções a qualquer hora do dia ou até mesmo da noite (Barawid Jr et al., 2007). Estas novas soluções tecnológicas aplicadas à agricultura conduzem ao aumento da eficiência dos processos e consequentemente ao aumento da produtividade, redução do desperdício, e maior resiliência aos fatores dinâmicos inerentes à atividade agrícola, como sejam as condições ambientais adversas, pragas e pestes.

## **6.2 Materiais e métodos**

### **6.2.1 Software**

O primeiro passo deste projeto consiste no desenvolvimento do algoritmo. A programação do algoritmo de deteção foi fundada em ambos os sistemas operativos Windows 10 e Linux na linguagem Python 3.9.5.

A biblioteca recorrida, suportada pela linguagem Python, adequada à implementação de CNN's foi Tensorflow (Dillon et al., 2017).

Tensorflow é o framework completo da Google para desenvolvimento de aplicações que executam tarefas de Machine Learning. Estas aplicações descobrem padrões num vasto número de dados injetados no algoritmo lidando

com incertezas e probabilidades. Segue-se, nos próximos parágrafos, uma explicação do funcionamento, potencialidade e alguns elementos importantes presentes no framework. O Object Detection API (disponível no GitHub oficial de Tensorflow), é um framework desenvolvido com base em Tensorflow que auxilia a construção e o treino de um modelo de detecção de objetos em imagens (Hongkun Yu et al., 2020).

O sistema de detecção de objetos selecionado neste projeto foi, então, o SSD (Single Shot Detector). Este sistema, criado por Liu et al. (2016), é mais rápido que outros detetores do estado-da-arte, tais como o Faster R-CNN, sem sacrificar o desempenho.

Esta vantagem faz com que o SSD seja o detetor mais indicado para situações onde se pretende implementar um modelo de detecção de objetos num dispositivo móvel incapaz de acarretar mais potência. Na Figura 6.1 encontra-se uma representação gráfica da arquitetura do modelo de detecção SSD.




Figura 6.1 – Modelo de detecção SSD. (Liu et al., 2016)

## 6.2.2 Hardware

Dado que o objetivo deste projeto é o estabelecimento de um sistema que permite que a plataforma robótica se desloque autonomamente, para conciliar o algoritmo com os controladores das rodas, o algoritmo de detecção dos troncos das árvores e a câmara que capta imagem em tempo real, é essencial um

controlador com extrema mobilidade e com capacidade computacional para acarretar tantas competências.

O Raspberry Pi 4 (Foundation Raspberry\_Pi, 2021) foi considerado a melhor solução para este problema. Um microcomputador de reduzidas dimensões, ideal para aplicações móveis e remotas, com uma capacidade de processamento computacional e de imagem (Lowe, 2017).

A câmara utilizada para a captação de imagem RGB do robô é a câmara módulo do Raspberry Pi versão 2 (Raspberry Pi, n.d.). Tem um sensor Sony IMX219 de 8 MP. Suporta resoluções como 1080 com 30 FPS e 720p com 60 FPS.

### **6.2.3 Construção da base de dados**

A base de dados é composta por fotografias e vídeos obtidos num pomar de pessegueiros, localizado em Orjais, Covilhã. Estes vídeos e fotografias foram tirados na perspetiva visual que a plataforma robótica irá ter quando praticar a sua locomoção correta, ou seja, encostada o mais à esquerda possível, e em locais aleatórios do pomar. Dessas fotografias, foram aproveitadas as que tinham uma imagem mais nítida dos troncos das árvores. No total, a base de dados estava com 89 imagens e suas anotações.

A Figura 6.2 mostra três amostras das fotografias obtidas no pomar que têm conceção evidente dos troncos das árvores. Todas as imagens foram recortadas e redimensionadas para uma dimensão de 640x640 para estarem compatíveis com a configuração de input do modelo de deteção SSD que foi utilizado.


Recorrendo ao labelling (Tzutalin, 2015) – uma ferramenta de anotação de imagens open-source – anotaram-se os troncos das imagens, criando uma área retangular com quatro coordenadas à volta dos troncos, e atribuíam-se os rótulos da classe (tronco) às caixas delimitadoras, ficando, estes dados, registados em ficheiros \*.xml. Uma amostra do processo da anotação está representada na Figura 6.3.



(a) Imagem Exemplo 1.



(b) Imagem Exemplo 2.



(c) Imagem Exemplo 3.



(d) Imagem Exemplo 4.


**Figura 6.2** - Exemplo de quatro fotografias consideradas adequadas para o treino do modelo de deteção, com a perspetiva pretendida, cortadas e redimensionadas para o treino.



**Figura 6.3** – Processo de anotação da classe dos troncos, nas imagens.

## 6.2.4 Estratégia de orientação

Com o modelo já treinado e a detetar os troncos corretamente, é necessário formar uma estratégia para indicar à plataforma robótica quando, e em que condições, terá que ajustar a sua trajetória. A câmara é montada na frente do robô e a visão que dispõe tem um panorama mais próximo da fila de árvores esquerda que da direita, como mostra a Figura 6.4.



**Figura 6.4** – Visão panorâmica da plataforma robótica (perspetiva topográfica).

Observando a perspetiva da plataforma robótica, nota-se uma particularidade: as filas das árvores, tanto da direita como da esquerda, formam uma linha que converge num ponto comum, sendo este o final do corredor do pomar, como está representado na Figura 6.5. Optou-se, então, que a tendência desta linha formada no lado esquerdo ter uma trajetória correta sem obstruções para o ponto de chegada da plataforma robótica seria o melhor método de orientação. Para abordar a técnica de orientação, recorreu-se à obtenção de coordenadas de dois pontos de duas caixas delimitadoras de troncos detetados, e, a partir destes, forma-se uma função linear que atualiza a cada quadro de vídeo que contém uma deteção da mesma configuração.

Uma função linear é, tipicamente, representada pela Equação (1), onde  $m$  é o declive da reta e  $b$  a ordenada na origem.

$$y = mx + b \quad (1)$$

Cada caixa delimitadora possui quatro valores: uma abcissa mínima ( $x_{\min}$ ) e máxima ( $x_{\max}$ ), e uma ordenada mínima ( $y_{\min}$ ) e máxima ( $y_{\max}$ ). Qualquer combinação das abcissas com as ordenadas resulta num vértice da caixa e, conhecendo a orientação dos eixos numa imagem, optou-se por se escolher o vértice com a abcissa máxima e ordenada máxima ( $x_{\max}$ ;  $y_{\max}$ ). Neste projeto, assumiu-se os dois pontos, A e B, como sendo vértices de duas caixas delimitadoras de dois troncos detetados com as abcissas e ordenadas máximas consideradas, estando um exemplo desta tática na Figura 6.6.



**Figura 6.5** – Linhas imaginárias para a estratégia de orientação.



**Figura 6.6** – Função linear gerada pela deteção de dois troncos de pessegueiros.

Após a primeira criação da função linear com dois troncos detetados, esta é guardada e atualizada posteriormente caso haja novamente deteção dupla. Esta função linear será o ponto base de orientação e terá duas condições que fazem com que a plataforma robótica se ajuste á trajetória.



A primeira condição é o desvio de um só tronco detetado. Haverá, inevitavelmente, devido a obstruções visuais, troncos de formas ambíguas e à própria imprecisão do modelo, algumas frações de tempo em que só é detetado um tronco. Com a função linear criada, o algoritmo recolhe a ordenada máxima ( $y_{max}$ ) do único tronco detetado e calcula uma abcissa pertencente à função ( $x_{ref}$ ). De seguida, esse valor  $x_{ref}$  é comparado com a abcissa máxima ( $x_{max}$ ) da caixa delimitadora e, dada uma tolerância segundo o eixo x de 150 pixéis, o algoritmo avalia se é necessário efetuar uma das três decisões:

- Se  $x_{max} > x_{ref} + 150$ , a plataforma vira à direita para deslocar a linha da função linear para ficar mais próxima do vértice da caixa em avaliação.
- Se  $x_{max} < x_{ref} - 150$ , a plataforma vira à esquerda para deslocar a linha da função linear para ficar mais próxima do vértice da caixa em avaliação.
- Se  $x_{ref} - 150 < x_{max} < x_{ref} + 150$ , o algoritmo assume que a plataforma está com uma boa orientação e prossegue a marcha.

Esta condição é essencial, mas não suficiente, porque o robô pode desviar-se demasiado da trajetória sem deteções e assim a estratégia de deteção do tronco relativamente à função linear pode dar indicações incorretas. Desse modo, para que a plataforma não tenha uma tendência, ou de colisão com a fila de árvores, ou de afastamento desta, é feita também uma avaliação do declive da função linear criada. Uma reta com uma inclinação muito acentuada pode significar que as árvores estão afastadas do panorama comum, ou, no caso contrário, se a reta estiver muito abatida, com um aspeto mais horizontal, significa que o robô tem uma tendência de deslocamento perpendicular relativamente à fila de árvores.

Para evitar esta situação, quando o declive é calculado, verifica-se se este está dentro de um intervalo aceitável de valores. As indicações são as seguintes:

- Se  $m < -1$ , significa que a reta criada pela função está a ficar mais acentuada, assim sendo a afastar-se, logo o robô ajusta a trajetória para a esquerda (imagem da direita da Erro! A origem da referência não foi encontrada.).
- Se  $m > 0,2$ , significa que a reta criada pela função está a ficar mais abatida, assim sendo em colisão com a fila, logo o robô ajusta a trajetória para a

direita (imagem da esquerda da Erro! A origem da referência não foi encontrada.).

- Se  $-1 < m < -0,2$ , o algoritmo assume que a trajetória da plataforma é aceitável e prossegue a marcha.

É importante dizer que, no início da marcha do robô, enquanto não houver uma detecção dupla de troncos, o robô continua o seu movimento a direito até adquirir informação para que possa fazer a avaliação do redor.

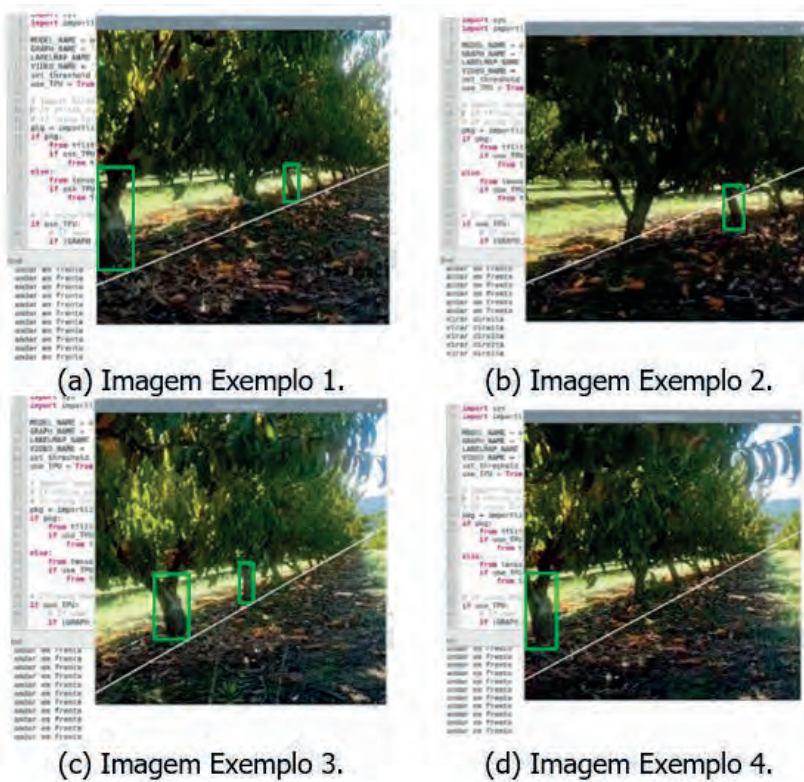
Esta estratégia é possível graças a um algoritmo criado que faz a detecção com o modelo treinado que, conseqüentemente, dará a ordem de movimentos segundo comandos de output e estruturas de seleção.

## 6.3 Resultados e discussão

Após ter sido verificado que a estratégia de orientação estava a funcionar corretamente, prosseguiu-se ao teste do modelo convertido para uint8 e compilado para suporte com Edge TPU. O intuito desta simulação é verificar se o desempenho foi afetado e o modelo está apto para orientar a plataforma robótica a tempo real.

No Capítulo 7 referente à detecção dos frutos, está representada a avaliação aritmética realizada ao modelo convertido, mostrando que se mantém semelhante ao original, sem perdas relevantes de desempenho. Realizou-se uma avaliação do tempo entre inferências para determinar se este é adequado para praticar a detecção simultaneamente dando ordens de orientação sem atraso de informação. Verificou-se que o início de execução levou aproximadamente 0,6 segundos e, daí em diante, as inferências tiveram um intervalo de tempo entre si de cerca de 0,37 segundos.

Na Figura são apresentadas imagens da simulação do modelo no Raspberry Pi 4 com a inferência e com a ordem de orientação.



**Figura 6.7** - Imagens da simulação feita no Raspberry Pi 4 num vídeo do modelo convertido para TFLite e compilado para Edge TPU.

## 6.4 Considerações finais

Reunindo os resultados das simulações e os valores das métricas dos vários modelos, obtiveram-se as seguintes conclusões:

Relativamente aos valores das métricas, matematicamente e estatisticamente, o modelo original tem um desempenho excelente com ambas uma precisão e revocação de 94,4%. No entanto, foi crucial a conversão e compilação de um modelo 32 float para 8 uint com suporte de Edge TPU. Só desta maneira se

conseguiu garantir uma maior velocidade de execução da inferência e um peso computacional muito mais reduzido para execução num Raspberry Pi 4, tornando, assim, o modelo ideal para tarefas móveis.

Feita a avaliação à inferência nas mesmas imagens de teste com o modelo quantizado e compilador, o valor da precisão mantém-se praticamente inalterado, provando que quase não existem deteções residuais. Porém, o modelo ficou com uma revocação mais baixa, podendo não identificar troncos por que passe. Todavia, após realizadas as simulações em vídeo, assume-se que esta baixa de valores é aceitável e o modelo está apto para ser testado no terreno.

A execução da inferência no Raspberry Pi 4, com a conversão e compilação do modelo original, é relativamente rápida com intervalos de tempo aproximadamente de 0,37 segundos. entre inferências dos quadros de vídeos, dando bastante tempo à plataforma robótica para se ajustar com uma informação do ambiente redor praticamente exata.

O comportamento do algoritmo mostrou-se adequado e a cumprir os objetivos propostos. As simulações em imagens e vídeos, tanto do modelo original como do convertido, mostraram resultados positivos, com poucas falhas de deteção. O algoritmo inferia a deteção dupla para criação da função linear de referência relativamente rápida e mesmo com deteções individuais, as ordens dadas eram as corretas.

## **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

- Barawid Jr, O.C., Mizushima, A., Ishii, K., & Noguchi, N. 2007. Development of an autonomous navigation system using a two-dimensional laser scanner in an orchard application. *Biosystems Engineering*, 96 (2), 139–149.
- Dillon, J. V., Langmore, I., Tran, D., Brevdo, E., Vasudevan, S., Moore, D., Patton, B., Alemi, A., Hoffman, M., & Saurous, R. A. 2017. Tensorflow distributions. *ArXiv Preprint ArXiv:1711.10604*.
- Foundation Raspberry\_Pi. 2021. Raspberry Pi 4. <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>.
- Hongkun Yu, Chen Chen, Xianzhi Du, Yeqing Li, Abdullah Rashwan, le Hou, Pengchong Jin, Fan Yang, Frederick Liu, Jaeyoun Kim, & Jing Li. 2020. TensorFlow Model Garden. <https://github.com/tensorflow/models>.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. 2016. Ssd: Single shot multibox detector. *European Conference on Computer Vision*, 21–37.
- Lowe, D. 2017. *Electronics All-in-One For Dummies (2nd Edition)*.
- Menezes, G., Gaspar, P.D., Mesquita, R., Assunção, E. e Simões, M.P. 2022. GPS Based-autonomous navigation system for multitask robotic rover for agricultural activities with augmented reality web application for supervision support – tests in peach orchards (*in press*).
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., e Chen, L.C. 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. *Proceedings*.
- Simões, J., Gaspar, P.D., Assunção, E., Mesquita, R., & Simões, M.P. 2022. Navigation System of Autonomous Multitask Robotic Rover for Agricultural Activities based on Computer Vision through Tree Trunk Detection - Application to Peach Orchards.
- Tzatalin. (2015). *LabelImg*. <https://github.com/tzatalin/labelImg>.





# Capítulo 7

## Deteção de frutos

**Eduardo Assunção<sup>1</sup>, Pedro Dinis Gaspar<sup>1,2</sup> e Hugo Proença<sup>3,4</sup>**

<sup>1</sup> Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

<sup>2</sup> Center for Mechanical and Aerospace Science and Technologies (C-MAST)

<sup>3</sup> Universidade da Beira Interior | Departamento de Ciências da Computação

<sup>4</sup> Universidade da Beira Interior | Instituto de Telecomunicações

### 7.1 Introdução

A previsão de produção e da necessidade de embalagem 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.

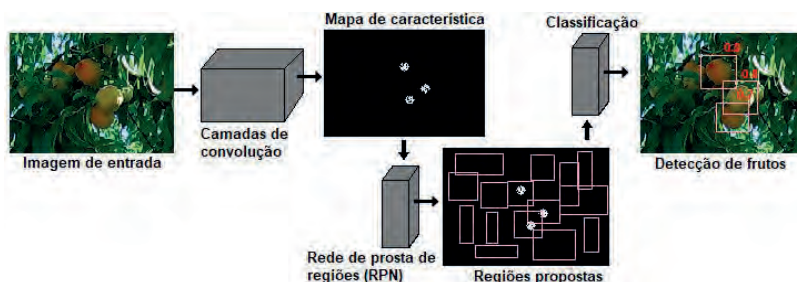
As redes neuronais artificiais convolucionais (CNNs) têm contribuído grandemente para o progresso da deteção e classificação de objetos. (Sa et al., 2016) propuseram a utilização da rede Faster R-CNN com o objetivo de detetar pimento, melão, maçã, abacate, manga, morango e laranja. O presente estudo 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 detecção 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 detecção para classificação dos objetos, bem como para um possível ajuste de posição do enquadramento da detecção do objeto na imagem de entrada. A Figura 7.1 mostra um esquema simplificado do método Faster R-CNN no contexto de detecção de pêsegos.



**Figura 7.1** – Esquema simplificado do método Faster R-CNN no contexto de detecção de pêsegos.

### 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 detecção 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.



**Figura 6** – Exemplo (2) de resultado de detecção de frutos de pêsesgos em imagem do mesmo pomar onde o modelo foi treinado.

### 7.3.2 Resultado do teste realizado em imagens de diferentes pomares onde o modelo foi treinado

Os seguintes resultados e discussão têm como objetivo mostrar a avaliação do modelo em um pomar diferente, com muitas variações em comparação com o pomar em que o modelo foi treinado, e visa avaliar com mais rigor a capacidade de generalização do modelo. O teste foi realizado em sete imagens com 91 frutos de pêsego e resultou numa precisão de 77% AP.

#### 7.3.2.1 Primeiro caso de teste

A Figura 7.4 mostra a primeira imagem de teste. A peculiaridade desta imagem é a iluminação, em que a luz é muito refletida nas folhas. A cor da fruta também é avermelhada. Essas características são completamente diferentes das imagens encontradas no conjunto de dados de treino. Como pode ser visto na Figura 7.5 o modelo detetou bem os frutos sem muita oclusão e agrupados, mas falha em detetar alguns frutos muito oclusos. Nesta imagem, o modelo falha apenas

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** – Imagem de teste (2). Os retângulos representam os locais onde espera-se que o modelo detete 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









## Capítulo 8

# **Avaliação da capacidade produtiva do pomar de pessegueiros**

**António Ramos<sup>1</sup>, Hugo Fonseca<sup>1</sup>, Dora Ferreira<sup>1</sup>, Anabela Barateiro<sup>2</sup>, Cristina Ramos<sup>2</sup>, Paulo Silvino<sup>3</sup>, Pedro Dinis Gaspar<sup>4,5</sup> e Maria Paula Simões<sup>1,6</sup>**

<sup>1</sup>Instituto Politécnico de Castelo Branco | Escola Superior Agrária

<sup>2</sup>APPIZÊZERE - Associação de Proteção Integrada e Agricultura Sustentável do Zêzere

<sup>3</sup>AAPIM – Associação de Agricultores p/a Produção Integrada de Frutos de Montanha

<sup>4</sup>Universidade da Beira Interior

<sup>5</sup>C-MAST - Centre for Mechanical and Aerospace Science and Technologies

<sup>6</sup>CERNAS - Centro de Estudos de Recursos Naturais, Ambiente e Sociedade

### **8.1. Introdução**

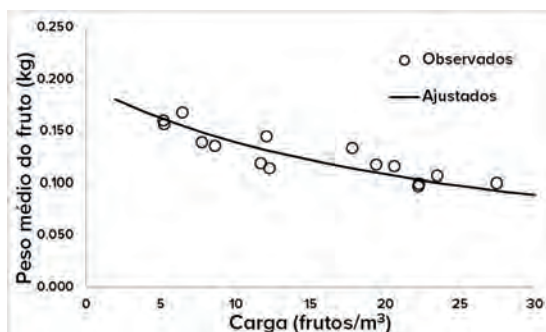
O sistema de plantação foi definido por Robinson et al. (1991), como sendo a combinação do porta-enxerto (vigor), do desenho da plantação (densidade e compasso), da forma de condução e do regime de poda. Como os ensaios de sistemas de plantação apenas dão informação sobre as condições particulares de 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<sup>2</sup>) e por unidade de volume da copa (kg/m<sup>3</sup>) são os indicadores mais utilizados para efeitos de comparação entre diferentes sistemas produtivos (Robinson e Lakso, 1991). 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) apresentou uma metodologia para o estudo da eficiência do sistema produtivo em pessegueiro, utilizando modelos empíricos baseados na relação negativa e amplamente divulgada (Dennis Jr., 2000; Link, 2000; Tromp, 2000; Whiting e Lang, 2004; Embree et al., 2007) entre a carga da árvore e o peso médio do fruto à colheita. A referida metodologia utiliza valores registados por árvore individual (V, volume em m<sup>3</sup>, calculado pelo produto da altura e largura da sebe e pela distância entre plantas na linha; contagem do nº de frutos e registo da produção à colheita) e pode resumir-se da seguinte forma:

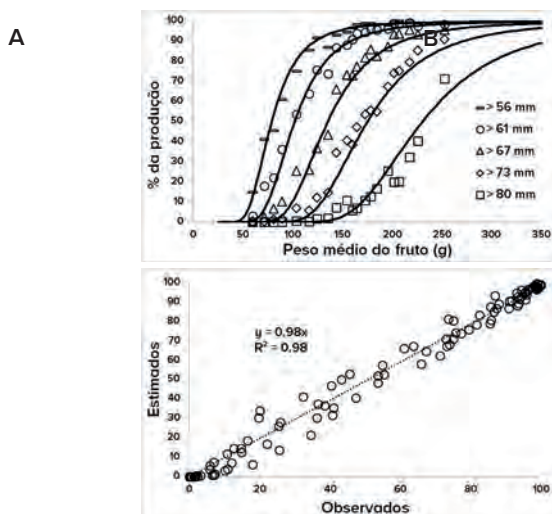
1. **Modelo de avaliação do desempenho (ou performance) da árvore:** relação entre a carga (X, nº de frutos/m<sup>3</sup>) e o peso médio do fruto (Y), com a seguinte equação:  $Y = 1 / (a.X + 1/b)$ , em que *a* e *b* são parâmetros do modelo (Figura 8.1).



**Figura 8.1** – Exemplo de representação gráfica do ajustamento não linear do peso médio do fruto em função da carga (UO-01/2019; n = 15 árvores individuais; RSME = 0,011).

2. **Modelo de distribuição da produção por classes de calibre:** dado que a

distribuição dos frutos por classes de calibre foi validada como uma distribuição normal (Zhang e Robson, 2002), a distribuição normal acumulada foi utilizada para estimar a percentagem da produção acima dos limites das classes de calibre, como uma variável contínua em função do peso médio do fruto (Figura 8.2) e, por diferença, a percentagem da produção total por cada classe de calibre.



**Figura 8.2** – Transformação da distribuição por classes de calibre numa variável contínua. **A** – Aplicação da distribuição normal acumulada à percentagem da produção acima do limite de cada classe de calibre em função do peso médio do fruto ( $n = 21$ ; cada ponto representa 5 calibrações). **B** – Relação  $\approx 1:1$  entre valores observados e valores estimados pela transformação da variável.

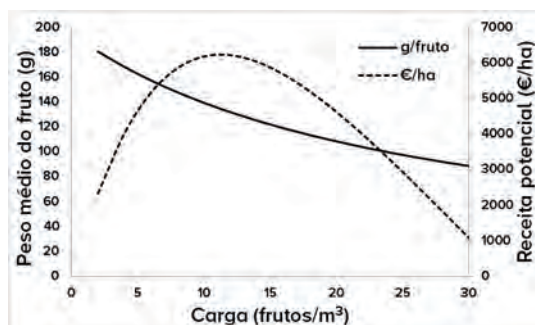
3. **Modelo de eficiência do processo produtivo:** resulta da conjugação do modelo de avaliação do desempenho da árvore com o modelo de distribuição da produção por classes de calibre, para uma determinada escala de preços (Quadro 8.1), obtendo-se uma curva de receita potencial do produtor (Figura 8.3). Esta curva apresenta um valor máximo, correspondente àquela que deverá ser a “carga ótima” da árvore à colheita, ou seja, a solução de compromisso entre a redução da carga e o acréscimo na valorização dos frutos, referida por Robinson et al. (2013).

Apesar do valor da receita potencial máxima não corresponder ao rendimento líquido do produtor, o lucro máximo ocorrerá com o mesmo nível de carga, uma vez que todos os custos de produção (à exceção do custo da colheita), são constantes em relação à área do pomar (por hectare), não variando com a carga (Johnson e Rasmussen, 1990). Por isso, o modelo de eficiência do processo produtivo (para estimar a “carga ótima”) inclui já um valor para a apanha (manual) de cada fruto individual (0,008 €/fruto). Apesar do custo de apanha de um fruto individual ser constante, o custo unitário da colheita (em €/kg) é variável, sendo mais baixo com frutos de maior calibre. Por exemplo, para frutos com 200 g são necessários 5 frutos para perfazer 1 kg, logo o custo da colheita será de 0,04 €/kg ( $5 \times 0,008 = 0,04$ ). Para frutos de 100 g, são necessários 10 frutos para perfazer 1 kg, logo o custo da colheita será de 0,08 €/kg ( $10 \times 0,008 = 0,08$ ).

**Quadro 8.1** – Escala de preços utilizada para a determinação da receita potencial do produtor.

Classe de calibre (mm)	< 56	56-61	61-67	67-73	73-80	> 80
Preço a pagar (€/kg)*	0,00	0,10	0,24	0,38	0,51	0,51

\*cotações médias de 2015 e 2016 (Veloso et al., 2017).



**Figura 8.3** – Representação gráfica, em função da carga, das estimativas do peso médio do fruto e da receita potencial para a escala de preços referida no Quadro 1 (exemplo da Figura 8.1).

Em suma, a monda de frutos no pessegueiro é um fator fundamental na eficiência do processo produtivo e a referência da carga, correspondente à máxima receita potencial do produtor, constitui-se como uma ferramenta útil para a tomada de decisão, particularmente em relação à necessidade e intensidade de monda. Embora carga e monda sejam conceitos similares, a monda é apenas um meio de redução da carga e muitos dos efeitos que se associam à monda (redução da produção e maior peso médio do fruto) são efetivamente efeitos da carga, ou seja, resultam do equilíbrio que se estabelece entre a área foliar da planta e o nº de frutos que ficam na árvore após a monda (e não com os que eliminam).

A área foliar da árvore interceta a radiação solar como fonte de energia para a assimilação do CO<sub>2</sub> atmosférico (através da fotossíntese) e produção das moléculas orgânicas necessárias ao metabolismo das plantas. A intercepção da radiação solar determina a capacidade produtiva das plantas (Loomis e Connor, 1992; Larcher, 1995) e a eficiência da captação da luz solar depende do sistema de plantação. Com efeito, a maior ou menor capacidade para intercetar a radiação solar depende da ocupação do espaço pela vegetação (folhas) e a ocupação do espaço depende, por sua vez, da distribuição das plantas no terreno (compasso; densidade) e da colonização do espaço aéreo (forma de condução; tamanho da árvore; poda; vigor). Pode dizer-se que o sistema de plantação representa a capacidade produtiva “instalada”.

Neste contexto, e partindo dos modelos de avaliação da eficiência do processo produtivo (expressos por unidade de volume), o objetivo deste trabalho é o estabelecimento de uma metodologia capaz de estimar (simular; prever) os resultados produtivos e económicos dos pomares de pessegueiro, como forma de capacitar as empresas com uma ferramenta útil nas tomadas de decisão relativas às logísticas da colheita, da conservação e da comercialização.

## 8.2. Estimativa dos parâmetros

Os parâmetros do modelo de avaliação do desempenho (*a* e *b*) são uma peça essencial na construção de um modelo de simulação da capacidade produtiva do pomar. Ao estabelecer a relação entre a carga e o peso médio do fruto,




esses parâmetros permitem estimar o peso médio do fruto para qualquer nível de carga. Contando o nº de frutos de uma árvore (ou o nº médio de frutos por árvore) e o volume da árvore (ou o volume médio por árvore) pode determinar-se o peso médio do fruto à colheita. Multiplicando o peso médio do fruto pelo nº frutos (por m<sup>3</sup>, por árvore ou por hectare), obtém-se a produção (por m<sup>3</sup>, por árvore ou por hectare). Obtido o peso médio do fruto também se pode estimar a distribuição da produção por classes de calibre e a receita potencial do produtor (por m<sup>3</sup>, por árvore ou por hectare) para uma dada escala de preços em função do calibre.

Com metodologias de análise de imagens que possam ser utilizadas, de forma prática e recorrente, na medição do volume (representando a capacidade produtiva “instalada”) e na contagem de frutos, o único elemento em falta para simular todos os resultados produtivos e económicos do pomar é o conhecimento sobre os parâmetros a e b da equação de desempenho da árvore.

Uma vez que o sistema produtivo se “normalizou” pela expressão da carga por unidade de volume, para fins de comparação de diferentes sistemas de plantação (Robinson e Lakso, 1991; Wright et al., 2006), tornou-se desde logo evidente que o parâmetro a (aquele que se relaciona com a carga, a.X) seria uma constante, uma vez que o todo (volume da árvore) de qualquer pomar se relacionaria de forma proporcional com a parte (unidade de volume). Se tal não ocorresse, a “normalização” do sistema produtivo para fins de comparação não faria sentido.

A relação do parâmetro b com o sistema de plantação (representado pelo volume da árvore) não foi tão imediata, mas acabou por se conseguir estabelecer uma relação não linear entre a razão A/b e o volume da árvore, sendo A o parâmetro da equação de desempenho da árvore quando se expressa a carga pelo volume médio (em vez de se expressar por unidade de volume). A Figura 8.4 mostra a referida relação não-linear, obtida para as cvs. Catherine e Sweet Dream, a partir de um histórico de 8 casos de estudo.



**Figura 8.4** – Relação não linear entre o volume da árvore (que representa a capacidade produtiva “instalada”) e a razão  $A/b$  (parâmetros do modelo de desempenho da árvore, representada pelo volume). A: UO-01 (Catherine); B: UO-02 (Royal Time).

A partir da referida relação não-linear, foi possível desenvolver um algoritmo para determinar o parâmetro  $\underline{b}$  em função da unidade de volume e do parâmetro  $\underline{a}$ . Desta forma, tornou-se possível a estimativa dos parâmetros de avaliação do desempenho da árvore, em função da carga, a partir da unidade de volume que, por sua vez, é uma função do sistema de plantação e representa “a capacidade produtiva instalada”.

### 8.3. Resultados observados

Os registos foram efetuados em 3 unidades de observação (UO) com diferentes localizações e cultivares. A UO-01 localiza-se na Soalheira e está plantada com a cv. Catherine, no compasso de 5,0 × 2,5 m (800 árvores/ha). A UO-02 localiza-se em Orjais e está plantada com a cv. Royal Time, no compasso de 4,5 × 2,5 m (889 árvores/ha). A UO-03 localiza-se no Ferro e está plantada com a cv. Sweet Dream, no compasso de 4,5 × 2,75 m (808 árvores/ha).

Os Quadros 8.2 a 8.4 apresentam os resultados dos registos efetuados nas referidas unidades de observação, UO-01, UO-02 e UO-03, respetivamente.

**Quadro 8.2** – Resultados produtivos e económicos obtidos na UO-01 (Soalheira, cv. Catherine). Preço médio refere-se à escala de preços apresentada no Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga (n <sup>o</sup> /m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	prod. > cat. A** (%)	Preço médio (€/kg)	Receita potencial (€/ha)
2018	24,3	6,0	174,1	1,0	75,2	0,39	6720,70
2019	21,9	14,6	128,1	1,8	39,7	0,26	6025,20
2020	23,7	2,5	152,6	0,4	62,9	0,34	1969,90
2021	22,7	---*	---*	---*	---*	---*	---*

\*colheita não efetuada devido à ocorrência de granizo. \*\*calibre ≥ 67 mm.

**Quadro 8.3** - Resultados produtivos e económicos obtidos na UO-02 (Orjais, cv. Royal Time). Preço médio refere-se à escala de preços apresentada no Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga (n <sup>o</sup> /m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	prod. > cat. A** (%)	Preço médio (€/kg)	Receita potencial (€/ha)
2018	18,4	---*	---*	---*	---*	---*	---*
2019	17,3	---*	---*	---*	---*	---*	---*
2020	19,3	5,7	130,9	0,7	44,4	0,28	2745,40
2021	18,7	6,0	141,6	0,8	55,3	0,31	3597,20

\*colheita não registada (efetuada pelo produtor sem pré-aviso). \*\*calibre ≥ 67 mm.

**Quadro 8.4** - Resultados produtivos e económicos obtidos na UO-03 (Ferro, cv. Sweet Dream). Preço médio refere-se à escala de preços apresentada no Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga (n <sup>o</sup> /m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	prod. > cat. A** (%)	Preço médio (€/kg)	Receita potencial (€/ha)
2018	---*	---*	---*	---*	---*	---*	---*
2019	28,4	5,5	254,3	1,4	95,2	0,48	14429,10
2020	28,9	2,7	220,4	0,6	91,7	0,46	6011,70
2021	28,0	6,9	248,6	1,7	94,9	0,48	17314,60

\*UO não incluída. \*\*calibre ≥ 67 mm.

Pela observação dos referidos Quadros, é possível verificar que os resultados são bastante variáveis com os anos, tendo-se verificado produtividades mais baixas no ano de 2020, em especial nas UO-01 e UO-03, associadas a cargas também mais baixas. As cargas mais reduzidas no ano de 2020 estarão relacionadas com eventuais problemas ao nível do vingamento do fruto, pois ocorreu um período de temperaturas baixas no final de março, tendo-se verificado queda de neve em alguns locais a maior altitude (Figura 8.5, UO-03, 30 de março de 2020). Para além da queda de neve ocorreu a queda de granizo muito intensa em 30 de maio de 2020.

Na UO-02, o período de baixas temperaturas parece não ter produzido idêntico efeito no vingamento do fruto, uma vez que as cargas foram similares nos dois anos (2020 e 2021).



**Figura 8.5** – Queda de neve na fase inicial de desenvolvimento dos frutos, na UO-03, no dia 30 de março de 2020.

Para além do efeito no vingamento do fruto, as condições particulares do ano de 2020 também foram desfavoráveis ao crescimento do fruto, como já foi referido nos capítulos 1 e 2. Este efeito é evidente na UO-03 em que o ano de 2020 foi o que apresentou menor carga e, ao mesmo tempo, menor peso médio do fruto. Na UO-01, apenas se pode constatar o menor peso médio do fruto em 2020 em relação a 2021, com cargas similares, não existindo dados relativamente a 2018 e 2019, que permitam avaliar a influência das condições associadas a cada ciclo vegetativo. Na UO-01, o menor peso médio do fruto ocorreu em 2019, mas deveu-se a uma carga elevada, pelo que se podem

comparar os pesos médios do fruto em 2020 e 2018. Nestes anos, os valores da carga e do peso médio mais baixos ocorreram em 2020, confirmando este ano como um ano em que as condições de vingamento e de crescimento do fruto foram bastante desfavoráveis.

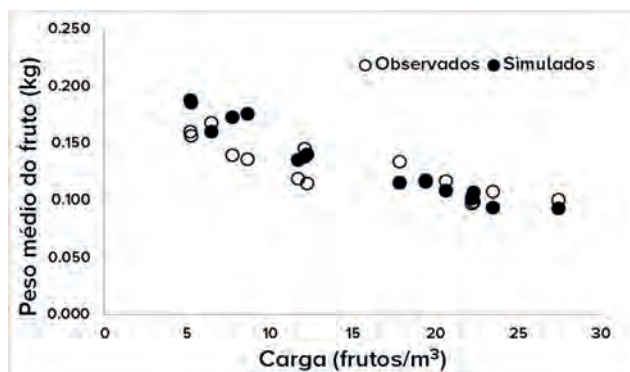
De salientar ainda que, para níveis de carga aproximados, o peso médio do fruto e a receita potencial do produtor (com base na escala de preços do Quadro 8.1) foram substancialmente superiores na UO-03 (cv. Sweet Dream) e mais baixos na UO-02 (cv. Royal Time), refletindo o efeito da componente genética. Certamente que em cultivares temporãs (maio/junho) a escala de preços será mais valorizada para calibres mais baixos (em relação ao Quadro 8.1), mas em cultivares de estação e meia-estação (julho) a utilização de cultivares de frutos pequenos a médios deixa margens muito baixas, com poucas vantagens para o produtor.

## **A RETER**

**O rendimento do produtor depende do potencial de crescimento das cultivares e das condições meteorológicas que ocorrem em cada ciclo. Assim, a seleção das cultivares é determinante no rendimento.**

### **8.4 Valores observados *versus* simulados**

A Figura 8.6 mostra a representação gráfica dos valores observados (e registados por árvore individual) do peso médio do fruto à colheita e as previsões do peso médio do fruto, correspondentes ao nº de frutos por árvore (carga), relativos ao caso de estudo apresentado na Figura 8.1. Nesta simulação, o parâmetro  $\underline{b}$  foi calculado, para cada árvore individual, em função do volume da árvore, através da aplicação do algoritmo desenvolvido a partir das relações representadas na Figura 8.4. Os Quadros 8.5 e 8.6 apresentam os resultados observados e simulados para o peso médio do fruto e para a produção, respetivamente, para todos os casos em que houve colheita.



**Figura 8.6** – Exemplo de representação gráfica dos pesos médios observados e simulados (previsões; estimativas) com o parâmetro  $\underline{b}$  calculado em função do volume da árvore (algoritmo) (UO-01/2019; n = 15 árvores individuais; RSME = 0,020).

**Quadro 8.5** – Pesos médios (kg/fruto) observados e estimados com o parâmetro  $\underline{b}$  calculado em função do volume da árvore (algoritmo) e respetivo RMSE

Ano	UO-01			UO-02			UO-03		
	Observ.	Estim.	RMSE	Observ.	Estim.	RMSE	Observ.	Estim.	RMSE
2018	0.181	0.178	0.060	---	---	---	---	---	---
2019	0.128	0.136	0.020	---	---	---	0.254	0.259	0.017
2020	0.159	0.201	0.094	0.131	0.144	0.017	0.220	0.307	0.093
2021	---	---	---	0.142	0.142	0.007	0.249	0.240	0.027

No exemplo da Figura 8.6, é possível verificar que a maior parte dos valores estimados (previsões) com o parâmetro  $\underline{b}$  estimado (pelo algoritmo) se aproximam bastante dos valores observados. Apesar de algumas diferenças visíveis, devidas aos diferentes volumes de cada árvore, o intervalo de variação dos valores estimados é similar ao intervalo de variação dos valores observados.

No Quadro 8.5, pode observar-se que as diferenças entre os pesos médios observados e previstos são relativamente baixas (10-15 g/fruto), sendo superiores apenas em 2020 (em especial nas UO-01 e UO-03), o ano em que as condições para o crescimento do fruto não foram as mais adequadas, como já se referiu.

**Quadro 8.6** – Produções médias (t/ha) observadas e estimadas com o parâmetro  $\underline{b}$  calculado em função do volume da árvore (algoritmo).

Ano	UO-01			UO-02			UO-03		
	Obser.	Estim.	Dif.	Obser.	Estim.	Dif.	Obser.	Estim.	Dif.
<b>2018</b>	19,6	18,4	<b>+ 1,2</b>	---	---	---	---	---	---
<b>2019</b>	30,1	31,5	<b>- 1,4</b>	---	---	---	31,9	32,4	<b>- 0,5</b>
<b>2020</b>	6,8	8,5	<b>- 1,7</b>	12,7	13,8	<b>- 1,1</b>	14,1	19,0	<b>- 4,9</b>
<b>2021</b>	---	---	---	13,9	14,1	<b>- 0,2</b>	38,6	37,1	<b>+ 1,5</b>

No Quadro 8.6, observa-se que as diferenças entre as produções observadas e as produções previstas são relativamente baixas (1-1,5 t/ha), exceto no ano de 2020, confirmando as diferenças assinaladas no Quadro 8.5. Apesar de não se pretender, com esta análise, validar o modelo de simulação (algoritmo), a sua aplicação mostra resultados bastante fiáveis e dentro de intervalos credíveis, em especial no que respeita à produção do pomar.

## A RETER

**Os resultados produtivos e económicos do pomar de pessegueiros podem ser simulados com parâmetros estimados em função do volume da árvore.**

### 8.5 Simulação da carga “ótima”

A determinação da carga correspondente à máxima receita do produtor foi já referida aquando da apresentação do modelo de eficiência do processo produtivo (Figura 8.3). Para ser útil como apoio às decisões da monda, a simulação dos resultados produtivos e económicos deve efetuar-se com bastante antecedência (abril/maio). Neste caso, é necessário dispor de uma estimativa do volume da árvore à colheita, ou utilizar o volume do ano anterior, no caso de pomares adultos em que as diferenças de volume não são expressivas de um ano para o outro.

Os Quadros 8.7 a 8.9 apresentam os resultados estimados nas três unidades de observação, relativos às três diferentes cultivares e para a escala de preços ao produtor apresentada no Quadro 8.1.

**Quadro 8.7** – Carga “ótima” e previsão dos resultados produtivos e económicos simulados para a UO-01 (Soalheira, cv. Catherine). O preço médio refere-se à escala de preços do Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga ótima (nº/m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	% produção > cat. A	Preço médio (€/kg)	Receita potencial (€/ha)
2018	24,3	11,8	144,3	1,7	58,7	0,32	8889,3
2019	21,9	11,5	139,9	1,6	54,5	0,31	7159,8
2020	23,7	11,7	143,2	1,7	57,7	0,32	8439,8
2021	22,7	11,6	141,4	1,6	56,0	0,32	7731,6

**Quadro 8.8** - Carga “ótima” e previsão dos resultados produtivos e económicos simulados para a UO-02 (Orjais, cv. Royal Time). O preço médio refere-se à escala de preços do Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga ótima (nº/m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	% produção > cat. A	Preço médio (€/kg)	Receita potencial (€/ha)
2018	18,4	10,5	125,2	1,3	38,4	0,26	4174,9
2019	17,3	10,4	124,7	1,3	37,8	0,26	3849,5
2020	19,3	10,5	125,7	1,3	38,9	0,26	4467,9
2021	18,7	10,5	125,4	1,3	38,6	0,26	4277,7

**Quadro 8.9** – Carga “ótima” e previsão dos resultados produtivos e económicos simulados para a UO-03 (Ferro, cv. Sweet Dream). O preço médio refere-se à escala de preços do Quadro 8.1.

Ano	Volume (m <sup>3</sup> )	Carga ótima (nº/m <sup>3</sup> )	Peso médio (g)	Produtividade (kg/m <sup>3</sup> )	% produção > cat. A	Preço médio (€/kg)	Receita potencial (€/ha)
2018	----	----	----	----	----	----	----
2019	28,4	13,7	180,7	2,5	81,6	0,41	21030,6
2020	28,9	13,7	181,4	2,5	81,8	0,42	21571,3
2021	28,0	13,7	180,1	2,5	81,3	0,41	20477,1

\*UO não incluída



Pela observação dos Quadros 8.7 a 8.9, salienta-se que as previsões para as cargas ótimas, determinadas com os parâmetros estimados em função do volume (algoritmo) são bastante uniformes para cada cultivar, uma vez que são pomares adultos (volume pouco variável) e consideram um bom desempenho da árvore. Em comparação com os valores observados (ponto 8.3), na generalidade dos casos as cargas observadas ficaram abaixo das cargas ótimas, exceto na UO-01 em 2019, o que poderá estar relacionado com as irregularidades nas condições meteorológicas dos últimos anos, ou com intensidades de monda desadequadas por falta de referência para as tomadas de decisão relativas àquela operação.

De salientar, ainda, que as cargas ótimas, o peso médio do fruto, a produtividade, o calibre, a valorização dos frutos e a receita potencial do produtor previstas pelas simulações são mais elevadas na UO-03 (cv. Sweet Dream) e menores na UO-02 (cv. Royal Time), demonstrando, uma vez mais, a importância do potencial genético das cultivares na performance dos pomares e no rendimento dos produtores.

A simulação da carga ótima pode ser efetuada para cada pomar, conforme a sua estrutura (compasso e volume), e para cada cultivar. Por enquanto, apenas se obtiveram os algoritmos para determinar o parâmetro  $\underline{b}$  em função do volume para as 3 cultivares em estudo neste projeto. Com esses algoritmos pode determinar-se a carga ótima e a capacidade produtiva de qualquer pomar dessas 3 cultivares, a partir apenas da medição do volume das árvores e da contagem dos frutos após a monda. Para outras cultivares, terão que se efetuar estudos de caso específicos para determinar os algoritmos respetivos.

## **A RETER**

**A simulação da carga ótima, se efetuada atempadamente, permite obter uma referência importante para a tomada de decisão relativa à monda de frutos.**

## 8.6 Considerações finais e perspectivas futuras

A simulação do processo produtivo e as previsões dos resultados produtivos e económicos do pomar de pessegueiros é uma ferramenta útil para as tomadas de decisão. Se efetuada de meados de abril a meados de maio, constitui um referencial crítico para a tomada de decisão sobre a necessidade e a intensidade da monda de frutos. Se efetuada 3-4 semanas antes da colheita e mediante contagem (por amostragem) do nº médio de frutos no pomar, é fundamental para a tomada de decisão relativa à logística das colheitas e da comercialização.

O processo de medição do volume das árvores pode ser influenciado por uma certa subjetividade, se medido manualmente com uma fita métrica, e a contagem dos frutos é uma tarefa morosa e dispendiosa. Contar os frutos da árvore, fazer a monda e verificar a carga deixada, com uma nova contagem, tornaria a monda ainda mais onerosa e difícil de implementar. A medição do volume das árvores e a contagem de frutos por meios automatizados são objetivos de outra componente do GO PrunusBOT (capítulo 4 e capítulo 7) e serão uma mais-valia, pois podem reduzir a subjetividade da medição dos volumes e tornar a contagem de frutos mais rápida e menos onerosa.

Apesar das vantagens das ferramentas digitais, há um alerta que importa fazer. A contagem de frutos por análise de imagens (fotos ou vídeos) pode ser efetuada com relativa precisão perto da colheita, quando os frutos se destacam pela sua cor (amarela ou vermelha), mas na época da monda são verdes e difíceis de distinguir das folhas. Para além da cor, há também o problema do volume. Efetivamente, o pessegueiro é conduzido em vaso, apresentado um problema de “profundidade” das imagens, associado ao preenchimento do interior do vaso com nova rebentação, em geral vigorosa e não eliminada por podas em verde. Estes problemas não são exclusivos da contagem de frutos por análise de imagem. Mesmo nas contagens “manuais”, efetuadas como controlo, é difícil efetuar uma contagem precisa dos frutos, como se mostra nos Quadros 8.10 a 8.12.

**Quadro 8.10** – Contagens de frutos (controlo) efetuadas na UO-01 (Soalheira)

Ano	1ª contagem	2ª contagem	3ª contagem	Contagem final (à colheita)
2018	157	156	---	139
2019	305	271	258	302
2020	79	68	66	51
2021	29	---	---	---

**Quadro 8.11** – Contagens de frutos (controlo) efetuadas na UO-02 (Orjais)

Ano	1ª contagem	2ª contagem	3ª contagem	Contagem final (à colheita)
2018	192	147	---	---
2019	26	23	24	---
2020	109	93	120	107
2021	126	123	111	110

**Quadro 8.12** – Contagens de frutos (controlo) efetuadas na UO-03 (Ferro).

Ano	1ª contagem	2ª contagem	3ª contagem	4ª contagem	Contagem final (à colheita)
2018	---	---	---	---	---
2019	---	---	---	---	156
2020	93	51	65	62	77
2021	207	198	185	---	194

## 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

- Dennis, Jr. F.G. 2000. The history of fruit thinning. *Plant Growth Regulation*, 31: 1-6.
- Embree, C.G., Myra, M.T.D., Nichols, D.S. e Wright, A.H. 2007. Effect of blossom density and crop load on growth, fruit quality, and return bloom in 'Honeycrisp' apple. *HortScience*, 42 (7): 1622-1625.
- Johnson, R.S. e Rasmussen, J. 1990. Peach optimization model. *Acta Horticulturae*, 276: 247-255.
- Larcher, W. 1995. *Physiological plant ecology: ecophysiology and stress physiology of functional groups* (3ª ed). Springer-Verlag. Berlin.
- Link, H. 2000. Significance of flower and fruit thinning on fruit quality. *Plant Growth Regulation*, 31: 17-26.
- Loomis RS e Connor DJ (1992). *Crop ecology: Productivity and management in agricultural systems*. Cambridge University Press. Cambridge.
- Ramos, A. 2017. Avaliação da eficiência do pomar. Aplicação de modelos empíricos à produção de pêssego. In MP Simões (coord), +Pêssego (Vol. II): Inovação nas Técnicas de Produção, pgs. 239-262. COTHN. Alcobaça. ISBN: 978-972-8785-05-5.
- Robinson, T.L. e Lakso, A.N. 1991. Bases of yield and production efficiency in apple orchard systems. *J. Amer. Soc. Hort. Sci.* 116 (2): 188-194.
- Robinson, T.L., Lakso, A.N. e Carpenter, S.G. 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, T.L., Lakso, A.N., Greene, D. e Hoying, S. 2013. Precision crop load management. *NY Fruit Quarterly*, 21 (2): 3-9.
- Tromp, J. 2000. Flower-bud formation in pome fruits as affected by fruit thinning. *Plant Growth Regulation*, 31: 27-34.
- Veloso, A., Ferreira, D., Gavinhos, C., Simões, M.P., Barateiro, A., Ramos, C., Fragoso, P., Lopes, S., Vieira, F., Silvino, P., Calouro, F. e Jordão, P. 2017. Monda de flores – Avaliação da utilização do equipamento Saflower Electric em pomares de pessegueiro. In MP Simões (coord), +Pêssego (Vol. II): Inovação nas Técnicas de Produção, pgs. 15-60. COTHN. Alcobaça. ISBN: 978-972-8785-05-5.
- Wright ,A.H., Embree, C.G., Nichols, D.S., Prange, R.K., Harrison, P.A. e DeJong, J.M. 2006. Fruit mass, colour and yield of 'Honeycrisp'™ apples are influenced by manually-

adjusted fruit population and tree form. *J. Hort. Sci. & Biotech.* 81 (3): 397-401.

Zhang, J. e Robson, A. 2002. Fitting normal distribution to apple fruit and its application. *Acta Horticulturae*, 584: 169-175.





## Capítulo 9

### **Deteção de infestantes**

**Eduardo Assunção<sup>1</sup>, Pedro Dinis Gaspar<sup>1,2</sup> e Hugo Proença<sup>3,4</sup>**

<sup>1</sup>UBI – Universidade da Beira Interior | Departamento de Engenharia Eletromecânica

<sup>2</sup>C-MAST – Center for Mechanical and Aerospace Science and Technologies

<sup>3</sup>UBI – Universidade da Beira Interior | Departamento de Ciências da Computação

<sup>4</sup>UBI – Universidade da Beira Interior | Instituto de Telecomunicações

#### **9.1 Introdução**

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 et al., 2016). 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). Depois da primeira aplicação, que habitualmente corresponde a uma faixa de 2 m (1m para cada lado da linha das plantas),




observa-se sempre a emergência ou resistência de algumas infestantes, que se pretende que sejam eliminadas de forma particularizada (ver capítulo 10).

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 (Shanmugam et al., 2020). Este estudo propõe um método para deteção de infestantes que pode ser embutido em dispositivos móveis.

## 9.2 Materiais e métodos

### 9.2.1 Modelo de deteção 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 .1 ilustra o modelo simplificado.




**Figura 9.1** – 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.

### 9.3 Resultados e discussão


Na Figura 9.2-A é apresentada uma imagem de entrada (de teste) do sistema de visão computacional enquanto na Figura -B é apresentado o resultado de saída do sistema de inteligência artificial de detecção de infestantes.



**Figura 9.2** – Aplicação do algoritmo de inteligência artificial por aprendizagem profunda via CNN para detecção de infestantes: A - Imagem original; B -Imagem segmentada com as obtenções dos contornos e centróides.

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.

A Figura apresenta um teste em laboratório do protótipo de pulverização com o auxílio do algoritmo da detecção de ervas.



**Figura 9.3** - Realização de testes no protótipo de pulverização.

## 9.4 Considerações finais

A monitorização das infestantes indica as vantagens de um controlo particularizado das infestantes que aparecem depois do controlo realizado no final do inverno, antes ou junto ao abrolhamento (ver capítulo 10). O sistema de visão computacional para deteção de infestantes com base em redes neuronais convolucionais (um ramo da inteligência artificial), foi capaz de segmentar infestantes com grande precisão.

O modelo foi implementado num mecanismo de pulverização e treinado para conseguir fazer uma aplicação de precisão.

## 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 nº 340 / Iniciativa 130

nº 140, promovida pelo PDR2020 e cofinanciada pelo FEADER no âmbito do Portugal 2020.

## Referências bibliográficas

- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation. Proceedings of the European Conference on Computer Vision (ECCV), 801–818.
- 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 Third IEEE International Conference on Robotic Computing (IRC), 146–152.
- Simões, M.P. 2016. Manutenção do solo. *In* Simões, M.P. (coord). +pêssego – Guia Prático da Produção. Centro Operativo e Tecnológico Hortofrutícola Nacional: 57-72. ISBN 9789728785048.
- Simões, M.P. 2021. Manual de Boas Práticas do pessegueiro. Revista FL&F. 10º fascículo: 103-113.  
[https://www.inia.pt/images/publicacoes/livrosmanuais/manual\\_de\\_fruticultura\\_pessegueiro.pdf](https://www.inia.pt/images/publicacoes/livrosmanuais/manual_de_fruticultura_pessegueiro.pdf)
- Shanmugam, S., Assunção, E., Mesquita, R., Veiros, A., & Gaspar, P. D. 2020. Automated weed detection systems: A review. *KnE Engineering*, 271–284







## Capítulo 10

# **Manutenção do solo em pomares de pessegueiro – monitorização da ocupação do solo por infestantes**

**Abel Veloso<sup>1,2</sup>, Hugo Fonseca<sup>1</sup>, Anabela Barateiro<sup>3</sup>, Cristina Ramos<sup>3</sup>, Sandra Lopes<sup>3</sup>, Preciosa Fragoso<sup>3</sup>, Francisco Vieira<sup>4</sup>, Paulo Silvino<sup>4</sup>, Dora Ferreira<sup>1</sup>, António Ramos<sup>1,2</sup>, Pedro Dinis Gaspar<sup>5,6</sup> e Maria Paula Simões<sup>1,2</sup>**

<sup>1</sup>IPCB – Instituto Politécnico de Castelo Branco | Escola Superior Agrária

<sup>2</sup>CERNAS – Centro de Estudos de Recursos Naturais, Ambiente e Sociedade

<sup>3</sup>Associação de Proteção Integrada e Agricultura Sustentável do Zêzere

<sup>4</sup>Associação de Agricultores para Produção Integrada de Frutos de Montanha

<sup>5</sup>UBI – Universidade da Beira Interior

<sup>6</sup>C-MAST - Centre for Mechanical and Aerospace Science and Technologies

### **10.1 Introdução**

A produtividade das culturas é maximizada quando se reduzem ao mínimo os fatores limitantes. Assim, uma gestão otimizada de todos os fatores de produção é a condição para se alcançarem níveis elevados de produtividade e qualidade dos frutos, de modo a alcançar um rendimento elevado. A maximização da produção exige que as plantas tenham sempre ao seu dispor os nutrientes, a água e a luz que necessitam para as funções básicas, nomeadamente, fotossíntese, respiração, transpiração e absorção de água e sais minerais, e, simultaneamente, que as plantas estejam sãs, ou seja, protegidas dos seus inimigos.



Em zonas de verões quentes e secos, como a região da Beira Interior, a água é o fator de produção chave para almejar a otimização do funcionamento das plantas de modo a obter os calibres elevados atualmente exigidos pelo mercado. Contudo, a rega é também favorável ao desenvolvimento de infestantes que competem com a cultura, não só pela água, como por nutrientes e, por vezes, quando atingem grande desenvolvimento, também competem pela luz. Para além do consumo de nutrientes e água as infestantes podem contribuir para maior densidade de vegetação na copa da árvore (Figura 10.1) aumentando a humidade que é uma das condições mais favoráveis à incidência de doenças como a moniliose e o oídio (Luz, 2018).

As técnicas culturais de controlo do desenvolvimento das infestantes são designadas genericamente por manutenção do solo, sendo o sistema mais comum em pomares de pessegueiro da região da Beira Interior um sistema misto constituído por solo nu na linha e enrelvamento na entrelinha (Figura 10.2).



**Figura 10.1** – Grande desenvolvimento das infestantes na linha de plantas.



**Figura 10.2** – Sistema misto de solo nu na linha e enrelvamento com vegetação espontânea na entrelinha.

Este sistema apresenta grandes vantagens para os produtores. O solo nu na linha elimina/minimiza a competição exercida pelas infestantes. O enrelvamento da entrelinha permite a entrada da maquinaria no pomar mesmo após a ocorrência de chuva, fator determinante para a proteção fitossanitária dos pomares e, simultaneamente, protege o solo da erosão, da compactação, promovendo a sua fertilidade que resulta da decomposição das plantas (Tworkoski e Glenn, 2008), da presença de leguminosas com capacidade de fixar azoto e da melhoria da vida microbiana do solo que têm um papel chave no ciclo dos nutrientes.

A área de terreno correspondente à linha e a área de terreno correspondente à entrelinha requerem uma gestão diferencial. Hammermeister (2016) vai mais longe e distingue 3 zonas distintas: a linha, a entrelinha e a zona de transição entre linha e entrelinha.

Se a manutenção do enrelvamento da entrelinha se consegue com facilidade através do regular corte do coberto vegetal, operação mecanizada com base na utilização de destroçadores, a manutenção do solo nu na linha é um objetivo mais dificilmente atingido, observando-se frequentemente grande desenvolvimento das infestantes junto às plantas, sobretudo nos primeiros ciclos vegetativos (Figura 10.1).

O controlo das infestantes na linha também pode ser conseguido através da mobilização, sendo então solo nu mobilizado, baseando-se na utilização de diversas alfaiais descentradas que destroem as infestantes através da mobilização superficial. Contudo, a mobilização tem como grandes desvantagens a destruição das raízes na camada superficial do solo e a possibilidade de fazer feridas nos troncos das plantas, tal como referido em Simões (2016). Acresce ainda que o pessegueiro tem uma vegetação retombante na parte inferior da copa resultante da empa dos ramos pelo peso dos frutos, facto que dificulta a operacionalidade das alfaiais na área da linha durante o ciclo de vegetação.

Considerando as vantagens que apresenta, a prática de solo nu não mobilizado foi amplamente adotada pelos produtores, e a aplicação de herbicidas é o modo de controlo de infestantes na linha.

O controlo das infestantes pela aplicação de herbicida, ou seja, a eficácia desta operação está dependente:

- das infestantes presentes;
- da substância ativa utilizada;
- da dose de aplicação;
- do método de aplicação;
- da época de aplicação;
- das condições culturais existentes;
- das condições meteorológicas durante e após a aplicação,

Uma ampla revisão bibliográfica da gestão de infestantes em vinhas, oliveiras e pomares de macieiras e pereiras, com indicação das substâncias ativas homologadas, foi realizada por Portugal et al. (2017).

Na região da Beira Interior, embora cada pomar tenha a sua individualidade, as espécies de infestantes mais observadas nos pomares são *Polygonum aviculare*, *Cynodon dactylon* e *Chenopodium album*, tendo também alguma expressão *Echinochloa colona* e *Digitaria sanguinalis* (Simões et al, 2017).

Relativamente às substâncias ativas utilizadas nos pomares de pessegueiros, embora não haja nenhum trabalho científico desenvolvido, a informação geral é que as substâncias mais utilizadas são o glifosato e glufosinato de amónio.

A aplicação é realizada com barra de herbicida acoplada ao trator.

A época de aplicação é determinante no controlo das infestantes. Em fruticultura de região temperada, a aplicação de herbicida antes do abrolhamento apresenta uma particular importância no controlo das infestantes (Figura 10.3), sendo um dos fatores determinantes para o seu sucesso, devendo ser realizada 2 a 3 semanas antes do abrolhamento, quando são usados herbicidas sistémicos. Este controlo permite que a planta possa dispor da água retida no solo, sendo particularmente importante em anos de primaveras secas.



**Figura 10.3** – Aplicação de herbicida em fevereiro antes do abrolhamento dos pessegueiros (esquerda) e pessegueiro em abrolhamento sem aplicação de herbicida (direita).

Posteriormente pode observar-se mais 1 ou 2 aplicações de herbicida. De acordo com Simões et al (2017), tendo por base 4 pomares de pessegueiro, registou-se mais uma aplicação no final da primavera/início de verão (maio/junho), e, na parcela onde se registou uma terceira aplicação em finais de agosto foi aquela onde o controlo de infestantes foi mais eficaz. Esta aplicação no final do agosto, junto ao fim da época de colheita das cultivares de estação, contribui fortemente para a diminuição da quantidade de sementes das infestantes de primavera-verão que ficam do solo.

Neste trabalho pretendeu-se fazer uma monitorização do desenvolvimento das infestantes em 3 pomares de pessegueiros na região da Beira Interior, identificados como Unidades de Observação (UO), compilando a informação necessária para uma evolução no sentido da agricultura de precisão onde se prevê a aplicação particularizada de herbicida através de equipamento robótico terrestre.

## 10.2 Material e métodos

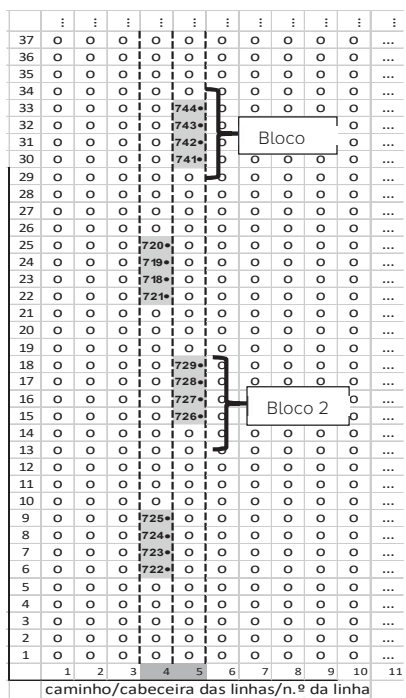
Para a realização deste trabalho utilizaram-se 3 Unidades de Observação (UO), que correspondem a 3 pomares de pessegueiros, base para a parte experimental do projeto PrunusBOT.

As 3 UO estão localizadas respetivamente na freguesia da Soalheira (concelho de Castelo Branco), Orjais e Ferro (concelho da Covilhã).

Em cada UO marcaram-se 4 blocos de 4 plantas contíguas, segundo o esquema da Figura 10.4. Neste trabalho é de particular importância que as plantas marcadas para observação sejam contíguas para facilitar a testagem de qualquer metodologia de controlo de infestantes, quer seja através da utilização de equipamento convencional quer através da utilização do equipamento robótico em construção, aproximando-nos do teste de desempenho de maquinaria em situação real.

Ao longo de 4 ciclos vegetativos foi realizada a monitorização da ocupação do solo por infestantes, na linha e na entrelinha. Para tal utilizou-se a metodologia referida por Simões et al. (2017) e que consistiu em determinar a percentagem de ocupação do solo por infestantes utilizando uma grelha de 64 quadrículas de 7,5 cm x 10 cm, correspondente a uma área total de 0,48 m<sup>2</sup> (Figura 10.5). A grelha é colocada na linha das plantas utilizando o espaço entre as plantas 2 e 3 e 3 e 4 de cada bloco, fazendo-se 2 observações por bloco, 8 observações por UO. Após isso, mede-se a altura do coberto vegetal (Figura 10.6).

Para cada ciclo realizaram-se 2 ou 3 observações, nomeadamente, no início do ciclo vegetativo (fevereiro), correspondentes à fase de abrolhamento, e no meio do ciclo



**Figura 10.4** – Esquema de campo de uma Unidade de Observação (UO).

(maio/junho/julho), correspondente à fase de grande desenvolvimento dos frutos e das plantas, podendo coincidir com o período de maturação e colheita dos frutos.



**Figura 10.5** – Grelha para avaliação da ocupação do solo por infestantes.

Para a entrelinha foi realizada uma avaliação visual, registrando a ocupação por vegetação, expressa em porcentagem e a altura das infestantes. Para facilidade de tratamento estatístico e conjugação do resultado com outras variáveis foi ainda atribuída uma

classificação para a ocupação e porte das infestantes utilizando uma escala de 1 a 5, de acordo com o Quadro 10.1.



**Figura 10.6** – Avaliação da altura das infestantes. **A**- infestantes 30 a 40 cm; **B**- infestantes com altura < 10 cm; **C** - entrelinha com vegetação controlada após a passagem de destróador.

Nesta escala, o valor 1 representa a situação mais favorável e o 5 a situação mais desfavorável em termos da competição que as infestantes exercem sobre a cultura.

**Quadro 10.1** – 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		< 10 cm	10-15 cm	15-25 cm	> 25 cm
ocupação					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					

### 10.3 Resultados e discussão

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 (Figura 10.7).

A primeira aplicação de herbicida ocorre durante o mês de fevereiro, observando-se uma maior percentagem de cobertura vegetal na linha, quando as observações foram realizadas em 12 de fevereiro de 2019 relativamente a 27 de fevereiro de 2020, nomeadamente 39% na UO 01, 22% na UO 02 e 30% na UO 03, em 2019, comparativamente a 23% na UO 01, 4% na UO 02 e 3% na UO 03, em 2020 (Quadros 10.2, 10.3 e 10.4). Este resultado está associado ao efeito do herbicida. Quando a observação foi realizada a 27 de fevereiro corresponde a um maior período após a aplicação do herbicida e, por isso, menor ocupação por infestantes.



**Figura 10.7** – Solo nu não mobilizado na linha e enrelvamento da entrelinha.

Esta eliminação/controlo das infestantes no final do inverno permite que o abrolhamento e início da atividade vegetativa dos pessegueiros ocorra com o mínimo de competição e, simultaneamente, se conserve o teor de água no solo durante esse período inicial de desenvolvimento, o que é particularmente importante nesta região da Beira Interior, onde podem ocorrer períodos longos sem chuva na primavera.

**Quadro 10.2** – Desenvolvimento das infestantes na linha e entrelinha na UO 01.

UO 01	Linha			Entrelinha		
	Altura infestantes (cm)	Ocupação (%)	Classificação	Altura infestantes (cm)	Ocupação (%)	Classificação
2018-06-21	<5	5	1	10 a 20	100	2
2019-02-27	10 a 15	23	2	20 a 30	100	4
2019-05-19	5 a 15	34	2,5	20 a 50	100	5
2020-02-12	10 a 15	39	3	> 30	100	5
2020-06-03	5 a 10	34	2,5	20 a 50	100	5
2021-03-04	<5	2	1	50 a 60	100	5
2021-05-21	<5	2	1	50 a 60	100	5

**Quadro 10.3** – Desenvolvimento das infestantes na linha e entrelinha na UO 02.

UO 02	Linha			Entrelinha		
	Altura infestantes (cm)	Ocupação (%)	Classificação	Altura infestantes (cm)	Ocupação (%)	Classificação
2018-06-21	<5	7	1	10 a 15	100	2
2019-02-27	5 a 10	4	1	<5	100	1
2019-05-19	5 a 10	8	1	<5	100	1
2020-02-12	10 a 15	22	2	10 a 15	100	2
2020-06-03	5 a 10	20	2	<5	50	1
2021-03-04	5 a 10	6	1	11	100	1
2021-05-21	<5	2	1	30	100	4



**Quadro 10.4** – Desenvolvimento das infestantes na linha e entrelinha na UO 03.

UO 03	Linha			Entrelinha		
	Altura infestantes (cm)	Ocupação (%)	Classificação	Altura infestantes (cm)	Ocupação (%)	Classificação
2018-06-21	<5	21	2	10 a 15	100	2
2019-02-27	5 a 10	3	1	<5	100	1
2019-05-19	5 a 15	24	2	5 a 10	100	2
2020-02-12	10 a 15	30	2	20 a 30	100	3
2020-06-03	<5	11	1	<5	80	1

**Nota:** não foram realizadas observações em 2021.

## A RETER

O controlo das infestantes na linha foi realizado pela aplicação de herbicida, sendo a primeira aplicação realizada em fevereiro, o que permite que o período de floração ocorra sem a competição do coberto vegetal.

Nas observações realizadas em maio/junho, de 2019 a 2021, a ocupação por infestantes na **linha** foi:

- UO 01 de 5% (2019), 34% (2020) e 2% (2021);
- UO 02 de 7% (2019), 20% (2020) e 2% (2021);
- UO 03 de 11% (2019) e 24% (2020).

É de realçar o controlo menos eficaz que ocorreu em 2020 relativamente a 2019 e 2021, relacionado com a maior precipitação ocorrida em 2020 e, portanto, condições mais favoráveis ao desenvolvimento das infestantes.

Globalmente, a época de maio/junho corresponde a grande desenvolvimento das plantas e maioritariamente à fase II de crescimento dos frutos (Velarde, 1998) e, portanto, correspondente a uma grande demanda de água e nutrientes. O desenvolvimento das infestantes neste período reduz a disponibilidade destes fatores e afeta a qualidade dos frutos (Cavender et al., 2014). A influência na redução do calibre dos frutos pode apresentar impacto significativo no valor da

produção e no rendimento da cultura. Mas, a influência direta da competição das infestantes no calibre dos frutos não é fácil de avaliar e quantificar, pois coexistem uma multiplicidade de outros fatores, com especial destaque para a disponibilidade de água, que simultaneamente contribuem para esse desenvolvimento, sendo impossível (em contexto real) conseguir individualizar a influência específica de cada um dos fatores.

Os resultados obtidos indicam que a aplicação de herbicida no final do inverno/início da primavera (ao abrolhamento) não é suficiente para controlar o desenvolvimento das infestantes, existindo sempre algumas infestantes que permanecem e posteriormente encontram as condições ideais para se desenvolverem. É habitual realizarem-se pelo menos 2 aplicações de herbicida por ciclo vegetativo, o que é corroborado pela conta de cultura para a cultura do pessegueiro (Dias et al., 2017) e pode ser observado na Figura 10.8 que mostra a rápida evolução das infestantes no final de abril relativamente a março (2021-03-04 e 2021-04-22). A mesma figura indica que foi realizado novo controlo/intervenção das infestantes entre 22 de abril e 21 de maio, pois o espaço da linha apresenta menor taxa de ocupação.

A oportunidade para a realização desta 2ª intervenção corresponde a um período de tempo muito curto, uma vez que, devido aos hábitos de frutificação dos pessegueiros, com o desenvolvimento e correspondente aumento de peso dos frutos, os ramos passam de um porte ascendente para um porte descendente, o que torna mais arriscado o controlo químico com utilização da barra de herbicida.

## **A RETER**


**Observa-se habitualmente uma 2ª aplicação de herbicida no período de abril – maio. Mas, a oportunidade para a realização deste 2º controlo de infestantes é bastante curto pois não só as infestantes apresentam uma taxa muito elevada de crescimento, como os ramos dos pessegueiros passam de um porte ascendente para descendente em virtude do aumento do peso dos frutos, tornando mais arriscada para a aplicação de herbicida.**

Nas observações realizadas em maio/junho, de 2019 a 2021, a ocupação da **entrelinha** por infestantes em cada UO foi sempre de 100%. Para o mesmo período, a altura das infestantes em cada UO foi de:

- **UO 01** – 10 cm a 20 cm (2018), 20 cm a 50 cm (2019), 20 cm a 50 cm (2020) e 50 a 60 cm (2021);
- **UO 02** – 10 cm a 15 cm (2018), < 5 cm (2019), < 5 cm (2020) e 30 cm (2021);
- **UO 03** – 10 cm a 15 cm (2018), < 5 cm (2019), < 5 cm (2020) e 30 cm (2021);


Apenas a UO 01 em 2021 apresentou uma classificação de 4 para o período de desenvolvimento dos frutos, resultado relacionado com a baixa produção que se observou neste pomar neste ciclo vegetativo de 2021, resultante de uma forte incidência de cancro fúngico (*Fusicoccum amygdali*).

Na Figura 10.8 apresenta-se a evolução da cobertura vegetal **na linha** para a UO 01 no período de primavera do ciclo 2021, onde se pode observar que, no mês de abril, há um rápido desenvolvimento das infestantes, que, se não houver controlo, se desenvolvem para dentro da copa das plantas.



**Figura 10.8** – Evolução da cobertura do solo na **linha**, na **UO 02**, em **2021** (fotografias de António Ramos).

Na Figura 10.9 apresenta-se a evolução da cobertura vegetal **na entrelinha** para a UO 02 ao longo do ciclo 2021, onde se pode observar que pode ser necessário realizar 2 a 3 cortes da vegetação da entrelinha durante o período de março a junho.



**Figura 10.9** – Evolução da cobertura do solo na **entrelinha**, na **UO 02, 2021** (fotografias de António Ramos).

Sempre que se ultrapassa esta janela de oportunidade há a possibilidade de os produtores optarem pelo corte das infestantes com motorroçadoras, que tem como principal desvantagem o facto de ter um efeito pouco duradouro, especialmente em pomares com rega por mini-aspersão, sistema de rega mais apropriado para solos de textura mais ligeira (Duarte, 2016).

As observações realizadas demonstram que após a primeira aplicação de herbicida no final do repouso invernal, há sempre infestantes que permanecem e que, ficando sem grande concorrência, encontrando condições muito favoráveis ao seu desenvolvimento (Figura 10.10).

Assim, surge aqui uma oportunidade para um controlo particularizado das infestantes que não foram eliminadas nessa primeira aplicação de herbicida no final do inverno. O período será abril quando a vegetação dos pessegueiros ainda está no início e apresenta um porte ascendente porque o peso dos frutos ainda é diminuto e, simultaneamente, ainda se observam as infestantes individualizadas, o que permitirá a sua classificação (Fawakherji, 2019). A solução que se propõe é uma aplicação particularizada através de um sistema robótico, incidindo a aplicação em cada infestante, visando uma prática mais sustentável, resultante não só da diminuição da quantidade de herbicida, como também da precisão da sua aplicação.



**Figura 10.10** – Infestantes remanescentes após aplicação de herbicida.

O desenvolvimento de uma solução tecnológica com estas características enquadra-se na agricultura de precisão, que tem vindo a ganhar cada vez mais relevo numa perspetiva mais de produção mais ecológica com redução da utilização de pesticidas sem pôr em causa a rentabilidade económica da cultura. O eficaz controlo das infestantes está associado a uma maior eficiência de outros fatores como a água e fertilizantes, não podendo deixar de haver uma gestão integrada de todos os fatores. Assim, a redução de utilização de pesticidas deverá passar não pela sua eliminação, mas pela redução da quantidade a utilizar através da aplicação de precisão utilizando novas tecnologia de equipamentos, incluindo robôs e sistemas de visão computacional (Chen et al., 2018).

## 10.4 Considerações finais

O controlo das infestantes num pomar de pessegueiros é importante para reduzir ao mínimo a competição que estas exercem sobre as plantas do pomar. Esse controlo é realizado através da aplicação de herbicida na linha e corte da

vegetação na entrelinha. Na linha a 1ª intervenção é realizada em fevereiro, sendo habitual a realização de uma 2ª intervenção em abril – maio. Contudo esta 2ª intervenção tem um período de realização muito curto, apresentando-se aqui uma oportunidade para a realização de controlo de infestantes, associada a uma agricultura de precisão, com base na aplicação dirigida apenas às infestantes que se mantiveram após a 1ª intervenção e que se apresentam individualizadas. Uma intervenção de precisão permitiria reduzir o uso de herbicida e atuar de modo mais sustentável ao mesmo tempo que se reduzia o seu efeito competitivo com as plantas do pomar.

## 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

- Cavender, G., Liu, M., Hobbs, D., Frei, B., Strik, B. e Zhao, Y. 2014. Effects of different organic weed management strategies on the physicochemical, sensory, and antioxidant properties of machine-harvested blackberry fruits. *J. Food Sci.* 79, S2107–S2116
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., e Adam, H. 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation, *European Conference on Computer Vision (ECCV 2018)*, 833-851.
- Dias, C., Gomes, P.C., Alberto, D., Barateiro, A., Ramos, C., Fragoso, P., Lopes, S. e Simões, M.P. 2017. Contas de cultura do pessegueiro na Beira Interior. In Simões, M.P. (coord). +Pêssego – Resultados de Apoio à Gestão, Centro Operativo e Tecnológico Hortofrutícola Nacional: 107-140. ISBN 9789728785062.
- Fawakherji, M., Youssef, A., Bloisi, D., Pretto, A. e Nardi, D. 2019. Crop and weeds classification for precision agriculture using context-independent pixel-wise segmentation. *2019 Third IEEE International Conference on Robotic Computing (IRC)*, 2019, 146-152, doi: 10.1109/IRC.2019.00029.
- Hammermeister, A.M. 2016. Weed management in perennial fruits. *Scientia Horticulturae*, 208: 28-42. <http://dx.doi.org/10.1016/j.scienta.2016.02.004> 0304-4238.

- Luz, J. P. 2018. Doenças do Pessegueiro, Cadernos Técnicos do COTHN, nº 2, ISBN: 978-972-8785-09-3
- Portugal, J., Monteiro, A. E Luz, J.P. 2017. Gestão de infestantes em vinhas, olivais e pomares. Revista das Ciências Agrárias, vol 40 (4), 839-853.
- Simões, M.P., Ferreira, D. e Veloso, A. 2017. Efeito da manta Ecoblanket no controlo das infestantes. In Simões, M.P. (coord). +Pêssego – Inovação nas Técnicas de Produção, Centro Operativo e Tecnológico Hortofrutícola Nacional: 117-138. ISBN 9789728785055.
- Twooski, T.J. e Glenn, D. M. 2008. Orchard Floor Management Systems. In Layne, D. R. e Bassi, D. The peach – botany, production and uses. Cab International. ISBN 978-1-84593-386-9.
- Velarde, F. Gil-Albert. 1998. Tratado de arboricultura frutal. Vol. 3: La ecologia del árbol frutal. 4ª Ed. Ministerio de Agricultura, Pesca







## Capítulo 11

# **Previsão do vigor e estado de vegetação de pomar de pessegueiro por processamento e análise de imagens multiespectrais capturadas por UAV**

João Cunha<sup>1</sup>, Pedro Dinis Gaspar<sup>2,3</sup>, Eduardo Assunção<sup>2</sup> e Ricardo Mesquita<sup>2</sup>

<sup>1</sup>UBI – Universidade da Beira Interior | Departamento de Ciências Médicas

<sup>3</sup>UBI – Universidade da Beira Interior | Departamento de Eletromecânica

<sup>2</sup>C-MAST- Center for Mechanical and Aerospace Science and Technologies

### **11.1 Introdução**

A agricultura atual associada a sistemas de produção mais intensivos e de vastas áreas está cada vez mais dependente de sistemas baseados em novas tecnologias, que envolvem robótica, processamento de imagens, monitorização remota e até mesmo inteligência artificial no desenvolvimento de métodos de apoio à tomada de decisão e uso de informações relevantes para a evolução da agricultura (Shanmugam et al., 2020).

Tem havido muitos esforços para ir além da avaliação dos aspetos funcionais da condição da vegetação. A condição da vegetação é a medida da resposta

da vegetação ao stresse. Boas condições estão associadas à vegetação verde e fotossinteticamente ativa, enquanto fatores de stresse como deficiência de água, carência ou excesso de nutrientes, incidência de pragas ou doenças, resultam em condições de vegetação deficiente, com uma multiplicidade de sintomas específicos, mas que se traduzirão sempre na coloração da planta. Fisiologicamente, as plantas respondem ao stresse reduzindo a produção de clorofila e, por consequência a atividade fotossintética, desequilibrando a proporção com outros pigmentos. Essas respostas podem ser medidas no sinal (imagem) de sensorização remota, tanto no infravermelho visível quanto no infravermelho próximo (NIR) (Schrodt et al., 2020). Há uma forte correlação entre a composição, estrutura e função da vegetação e as assinaturas observadas por instrumentos de sensorização remota. Esses sistemas de sensorização remota podem ser usados para identificar e mapear uma diversidade de fenômenos, incluindo pequenas a grandes variações nas características e condição da vegetação de uma cultura ou mesmo de uma paisagem (Serbin & Townsend, 2020).

Dados de sensorização remota de satélites e sensores aerotransportados normalmente têm grandes áreas de cobertura e são altamente dependentes da constelação de ângulos de visão e iluminação e das condições atmosféricas (Dorigo et al., 2007). Para resolver esses problemas, a aplicação de dados de imagem multiespectral baseados em UAV (veículo autônomo não tripulado) é usada para avaliar a condição da vegetação *in-situ*, ao invés de usar dados de sensorização remota (satélites).

O índice de vegetação é gerado a partir de combinações de duas ou três bandas espectrais (sendo as mais utilizadas o vermelho e infravermelho próximo), cujos valores são somados, divididos ou multiplicados para produzir um único valor (índice) que pode ser usado como um indicador do vigor da vegetação (Precisionhawk, 2021).

Para calcular os índices de vegetação é necessário delinear a área de interesse, ou seja, áreas da copa da árvore, que podem ser suportadas por um método de visão computacional.

Existem vários métodos tradicionais de segmentação, sendo algumas manuais.

Neste capítulo pretende-se apresentar a utilização do método de inteligência artificial de segmentação de imagens denominado Faster R-CNN (Faster Region-based Convolutional Neural Network (Ren et al., 2015) para a extração de índices de vegetação. Este modelo, relativamente a métodos tradicionais, tem como principal diferença e vantagem o facto da obtenção e características das imagens ser automatizadas e otimizadas. O Índice de Vegetação por Diferença Normalizada (NDVI) foi usado para avaliar o estado das plantas em pomares de pessegueiros.

## **11.2 Materiais e métodos**

### **11.2.1 Base de dados de imagem**

A base de dados de imagens de pomares de pessegueiros foi obtida com a câmara MicaSense RedEdge-MX acoplada a um drone de acordo com o descrito do capítulo 3. As imagens foram captadas no pomar de pessegueiro que constitui a UO 03, localizado na freguesia do Ferro (Portugal) e descrita no capítulo 1.

Para este estudo, foram utilizadas 20 imagens multispectrais dos cinco canais Vermelho (R), Verde (G), Azul (B), Near IR (NIR) e Red Edge (RE). Em cada imagem, há aproximadamente 16 copas de árvores de pessegueiro. Portanto, o banco de dados inclui um total de aproximadamente 320 copas das árvores.

Os canais de imagem R, G, B, NIR e RE estão (ligeiramente) desalinhados espacialmente devido à distância física entre cada conjunto de sensor / lente. Este fenómeno é conhecido como paralaxe. Para resolver este problema, o fabricante da câmara fornece um software de alinhamento (Micasense, 2021). Este software foi usado para alinhar as 5 bandas das respetivas imagens.

### **11.2.2 Índices vegetais**

A luz vermelha é fortemente absorvida pelos pigmentos fotossintéticos localizados nas folhas verdes, enquanto a luz do infravermelho próxima se cruza ou é refletida por tecidos foliares vivos, independentemente de sua cor, atuando

na faixa espectral reflexiva solar entre 390 nm e 1040 nm. Cada índice de vegetação é um número gerado por alguma combinação de bandas de sensores remotos (imagens obtidas pela câmara) e tem alguma relação com a quantidade de vegetação (que pode ser densa ou esparsa) em um determinado pixel de imagem.

O índice vegetal NDVI (do inglês: Normalized Difference Vegetation Index) é um dos índices mais utilizado para este fim (USGS, 2018).

A diferença entre a refletância NIR e R é dividida pela soma das duas refletâncias, conforme mostrado na Equação 1.

$$NDVI = \frac{NIR - R}{NIR + R} \quad (1)$$

Os valores de NDVI variam de +1,0 a -1,0. Áreas de rocha, areia ou neve geralmente apresentam valores de NDVI menor que 0,1. Vegetação esparsa, como arbustos, pastagens ou culturas com fraco desenvolvimento podem resultar em valores moderados de NDVI entre 0,2 e 0,5. Valores elevados de NDVI entre 0,6 e 0,9 correspondem à vegetação densa ou em seu pico de crescimento. (USGS, 2018)

### 11.2.3 Segmentação das copas

Existem vários métodos de detecção e segmentação de objetos em imagens digitais, como o método Faster R-CNN (Ren et al., 2015) e Mask R-CNN (Mask Region-based Convolutional Neural Network) (He et al., 2017). Esses modelos são apenas alguns dos métodos mais modernos de localização e segmentação. Neste estudo, o modelo Faster R-CNN foi usado para detectar as copas das árvores. Este modelo é baseado em uma rede neuronal convolucional que aprende a extrair automaticamente as características necessárias de uma imagem digital para resolver uma tarefa de visão computacional. A rede Faster R-CNN recebe uma imagem digital como entrada e produz na saída as várias localizações dos objetos encontrados na imagem de entrada. Usando o “framework” de aprendizado de máquina TensorFlow e o software de

processamento de imagem de código aberto OpenCV, o modelo proposto é executado nos passos que se seguem.

- 1) Alinhamento das 5 bandas (canais) de imagens usando a estrutura Micasense.
- 2) Anotação de imagens visando localizar manualmente os objetos sobre os quais a rede será treinada. Para este trabalho, a ferramenta de anotação "Labelimg" (Tzutalin, 2021) foi usada para anotar as regiões de copa das árvores nas imagens de treino.
- 3) Treino do modelo Faster R-CNN, que está disponível no repositório Github Tensorflow Model Garden (Yu et al., n.d.). Para tal dividimos o conjunto de dados de imagens anotadas em treino e validação e executamos o treino no modelo.

#### **11.2.4 Método proposto**

O método proposto para verificar o vigor/densidade de folhagem de uma árvore é avaliar os diversos índices de vegetação de uma região onde uma copa de uma árvore está localizada na imagem, uma vez que esses índices de vegetação podem refletir a condição de vegetação da árvore. Por exemplo, vegetação saudável resulta em altos valores de NDVI e plantas velhas ou não saudáveis resultam em valores moderados de NDVI (Saravanan et al., 2019; USGS, 2018).

O pipeline para o método proposto é o seguinte:

- 1) Realizar a detecção das copas usando o modelo Faster R-CNN. Os resultados são caixas delimitadoras retangulares das copas das árvores.
- 2) Cada região de interesse retangular detetada pelo modelo Faster R-CNN (etapa 1) é aproximada a uma elipse usando a biblioteca OpenCV. Uma vez que as copas das árvores são relativamente circulares.
- 3) Calcular os índices de vegetação dentro das elipses.

## 11.3 Resultados e discussão

### 11.3.1 Resultado do índice vegetal aplicado à imagem aérea

Este estudo apresenta um método baseado em redes neurais convolucionais para detecção de copas de árvores, bem como a aplicação de índices de vegetação como forma de avaliar a condição das árvores no pomar de pessegueiro. A Figura 11.1 mostra o resultado visual obtido em uma imagem teste do pomar da UO 03 (Covilhã, Portugal).



Figura 11.1 - Resultado visual do método proposto.

Os retângulos representam as detecções realizadas pelo modelo Faster R-CNN. As elipses são as regiões de interesse, obtidas a partir dos retângulos encontrados tentando ajustar a forma computacional à forma da copa das

árvores. Os índices de vegetação correspondentes a cada árvore serão determinados na área correspondente à elipse.

Pode-se verificar que o modelo realizou detecção em todas as árvores. Além disso, a detecção está bem centrada na copa. Assim, evidencia-se que o modelo é robusto e eficiente para o detetar as copas das árvores.

O Quadro 11.1 mostra os resultados da análise do índice de vegetação NDVI para cada árvore na imagem de teste.

**Quadro 11.1** - Análise do índice de vegetação NDVI para as copas das árvores na imagem de teste. A cor verde é o valor mais alto e o vermelho é o valor mais baixo encontrado.

Análise NDVI			
Árvore	Média	Máximo	Mínimo
1	0.94	0.99	0.32
2	0.95	0.99	0.47
3	0.88	0.99	0.25
4	0.94	0.99	0.35
5	0.94	0.99	0.51
6	0.94	0.99	0.34
7	0.90	0.99	0.32
8	0.91	0.98	0.36
9	0.93	0.99	0.26
10	0.92	1.00	0.37
11	0.94	0.99	0.33
12	0.95	1.00	0.44
13	0.91	0.99	0.32
14	0.93	1.00	0.33
15	0.90	0.99	0.32

De acordo com o Quadro 11.1 das 15 árvores da imagem de teste, uma (árvore 3) teve um valor médio de NDVI de 0.88, indicando que esta era a árvore com o menor vigor em comparação com as outras árvores. A análise visual dessa



árvore (Figura 11.2) mostra que seus ramos são mais esparsos. Ou seja, essa árvore é um pouco menos densa. Esta observação justifica seu valor médio de NDVI inferior em comparação com as outras árvores.


Também pode ser visto que existem duas árvores (2 e 12) com um NDVI médio de 0.95. De acordo com o índice, essas duas árvores são as mais saudáveis ou mais desenvolvidas do que as outras. A maioria das árvores (1, 4, 5, 6, 9, 11 e 14) tem um NDVI médio entre 0.93 e 0.94. Essas árvores também são muito saudáveis e com grande vigor.

O Quadro 11.2 mostra os resultados de outros quatro índices vegetais, cujos valores são normalizados para que uma comparação direta entre os resultados possa ser realizada.


**Quadro 11.2** - Valores médios de cinco índices de vegetação para as copas das árvores na imagem de teste. A cor verde é o valor mais alto e o vermelho é o valor mais baixo.

ID	NDVI	GNDVI	NDRE	REGNDVI
Árvore	Média	Média	Média	Média
1	0.94	0.86	0.58	<b>0.57</b>
2	<b>0.95</b>	0.84	0.54	<b>0.57</b>
3	<b>0.88</b>	<b>0.79</b>	<b>0.48</b>	<b>0.51</b>
4	0.94	0.86	0.58	0.56
5	0.94	0.85	0.57	<b>0.57</b>
6	0.94	0.84	0.54	<b>0.57</b>
7	0.90	0.81	0.51	0.52
8	0.91	0.8	0.49	0.53
9	0.93	0.85	0.57	0.54
10	0.92	0.82	0.50	0.55
11	0.94	0.84	0.53	<b>0.57</b>
12	<b>0.95</b>	<b>0.88</b>	<b>0.59</b>	0.56
13	0.91	0.80	0.48	0.52
14	0.93	0.85	0.58	0.56
15	0.90	0.80	0.50	0.52

Os valores do GNDVI (Índice de Vegetação por Diferença Normalizada de Verde), NDRE (Índice de Diferença Normalizada de Vegetação por Diferença Normalizada), REGNDVI (Índice de Vegetação por Diferença Normalizada de Vermelha próximo) confirmam a análise feita anteriormente com o índice NDVI. A árvore 3 é a menos desenvolvida, pois seu índice de vegetação é inferior ao das outras árvores. Já a árvore 12 é a que apresenta os maiores valores na maioria dos índices, portanto, apresenta o maior vigor na comparação. A Figura 11.2 mostra a curva de perda de treino para as 320 imagens de treino e 10.000 iterações. A Figura 11.3 mostra a Precisão Média (mAP) para validação durante o treino.



**Figura 11.2** - Curva de perda do treino do modelo.



**Figura 11.3** - Curva de precisão do modelo durante o treino.

### 11.3.2. Índice de vegetação com imagem captada do solo

Também foi realizado um estudo com imagens multiespectrais obtidas próximas ao solo (Figura 11.4). O campo de visão compreende uma vista lateral do pessegueiro.

**A Erro! A origem da referência não foi encontrada.** 11.5 mostra as regiões de interesse da imagem que são analisadas por intermédio dos índices.

A Figura 11.6 apresenta o resultado visual da aplicação do índice vegetal NDVI no qual combina-se as bandas R e NIR.



**Figura 11.4** – Representação de uma imagem composta com os canais RGB da câmara multiespectral.



**Figura 11.5** – Estão assinaladas as regiões de interesse da imagem que são analisadas por intermédio dos índices.



**Figura 11.6** - Resultado visual da aplicação do índice vegetal NDVI.

O Quadro 11.3 apresentamos valores NDVI para cada região de interesse, nomeadamente, 1 - céu, 2 - fruto e 3 - folhas.

Pode-se verificar que os valores NDVI para a região de interesse 1 é bastante baixo, da ordem de 0,23, como era de se esperar, visto que nessa região não contem componentes vegetais e, portanto, a cor predominante é azul.

Já os valores para região de interesse 2 (fruto) apresenta um valor elevado, da ordem de 0,92.

Na região de interesse 3 (folhas), o valor do índice é o mais elevado, sendo da ordem de 0,97.

**Quadro 11.3** - Valores NDVI de conforme com as diferentes regiões da região de interesse 1 (céu).

1 - Céu	2 - Fruto	3- Folhas
0.25 0.25 0.25 0.25 0.22	0.95 0.95 0.95 0.95 0.95	0.98 0.98 0.97 0.97 0.97
0.23 0.21 0.24 0.26 0.23	0.95 0.95 0.95 0.95 0.95	0.98 0.98 0.97 0.97 0.98
0.23 0.26 0.23 0.22 0.24	0.95 0.95 0.94 0.94 0.94	0.98 0.97 0.97 0.97 0.96
0.23 0.22 0.21 0.23 0.23	0.93 0.95 0.94 0.92 0.91	0.97 0.97 0.97 0.97 0.97
0.25 0.21 0.19 0.23 0.22	0.91 0.91 0.89 0.88 0.87	0.97 0.96 0.96 0.97 0.96
0.22 0.25 0.22 0.23 0.22	0.86 0.84 0.81 0.77 <b>0.73</b>	0.98 0.98 0.98 0.98 0.99
0.22 0.21 <b>0.18</b> 0.24 0.24	0.80 0.90 0.93 0.95 0.96	0.98 0.97 0.98 0.98 0.96
0.23 0.26 0.25 0.23 0.23	0.95 0.95 0.95 0.95 0.95	0.97 0.97 0.98 0.98 0.97
0.23 0.23 0.22 0.22 0.22	0.95 0.96 0.95 0.95 0.95	0.98 0.97 0.97 0.97 0.97
0.22 0.23 0.24 0.21 0.21	0.95 0.95 0.94 0.95 0.94	0.97 0.97 0.97 0.97 0.97
0.24 0.19 0.22 0.23 0.25	0.94 0.94 0.93 0.93 0.92	0.96 0.95 <b>0.93 0.93</b> 0.95
0.21 0.21 0.23 0.20 0.20	0.93 0.92 0.90 0.90 0.88	0.97 0.98 0.98 0.98 0.98
0.22 0.23 0.20 0.21 0.23	0.87 0.86 0.85 0.81 0.77	0.98 0.99 0.98 0.98 0.98
0.23 0.24 0.25 0.24 0.25	0.80 0.90 0.93 0.94 0.95	0.97 0.97 0.97 0.98 0.98
0.27 0.24 0.25 0.23 0.21	0.95 0.95 0.95 0.95 0.95	0.97 0.97 0.97 0.97 0.97
0.23 0.25 0.21 0.25 <b>0.26</b>	0.95 0.96 0.96 0.95 0.95	0.97 0.97 0.97 0.97 0.97
0.23 0.19 0.24 0.20	0.95 0.95 0.95 <b>0.96</b>	0.97 0.97 0.94 <b>0.90</b>
0,23 (min-0,18; max-0,26)	0,92 (min-0,73; max-0,96)	0,97 (min-0,90; max-0,98)

Um outro índice aplicado as imagens multiespectrais foi o índice Clgreen (Chlorophyll Index Green), descrito na Equação **Erro! A origem da referência não foi encontrada..**

$$Clgreen = \frac{NIR}{G} - 1 \quad (3)$$

Este índice combina os canais NIR e G de acordo com a Equação **Erro! A origem da referência não foi encontrada..** A Figura mostra o resultado visual da aplicação do índice Clgreen.

Na Figura 11.7, as regiões claras presentes na imagem representam uma elevada quantidade de clorofila.



**Figura 11.7** - Resultado visual da aplicação do índice vegetal Clgreen.

## 11.4 Considerações finais

Este trabalho aplicou um método baseado em redes neurais convolucionais para a detecção de copas de árvores com o objetivo de calcular índices vegetais como forma de inferir a condição da vegetação de árvores frutíferas em um pomar de pessegueiro. O modelo realizou a detecção das copas de todas as árvores, o que resulta em sua robustez e eficiência. Alguns índices de vegetação foram calculados para inferir o vigor das árvores. Os valores dos índices GNDVI, NDRE e REGNDVI confirmam a análise realizada com o índice NDVI. Na imagem de teste, distinguem-se árvores cujo vigor é menor, enquanto outras apresentam valores superiores à média. Esses resultados permitem ao fruticultor analisar detalhadamente e no terreno quais são as causas potenciais dessas variações e, eventualmente, corrigi-las. Exemplos como o utilizado neste trabalho são relevantes para apoiar a tomada de decisão nas atividades agrícolas, possibilitando otimizar recursos, reduzir tempo e custo, maximizar a produção, podendo ser utilizados por agricultores, agrônomos e pesquisadores.

## 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

- Dorigo, W. A., Zurita-Milla, R., de Wit, A. J. W., Brazile, J., Singh, R., & Schaepman, M. E. (2007). A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *International Journal of Applied Earth Observation and Geoinformation*, 9(2), 165–193.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. *Proceedings of the IEEE International Conference on Computer Vision*, 2961–2969.

- Micasense. (2021). *Active Image Alignment*. <https://micasense.github.io/imageprocessing/Alignment.html> Accessed 15 December 2020.
- Precisionhawk. (2021). *Derive precise vegetative health measures from high-resolution spectral imagery*. <https://www.precisionhawk.com/agriculture/multispectral>. Accessed April 2020.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28, 91–99.
- Saravanan, S., Jegankumar, R., Selvaraj, A., Jennifer, J. J., & Parthasarathy, K. S. S. (2019). Utility of landsat data for assessing mangrove degradation in Muthupet Lagoon, South India. In *Coastal zone management* (pp. 471–484). Elsevier.
- Schrodt, F., de la Barreda Bautista, B., Williams, C., Boyd, D. S., Schaeppman-Strub, G., & Santos, M. J. (2020). Integrating biodiversity, remote sensing, and auxiliary information for the study of ecosystem functioning and conservation at large spatial scales. In *Remote sensing of plant biodiversity* (pp. 449–484). Springer, Cham.
- Serbin, S. P., & Townsend, P. A. (2020). Scaling functional traits from leaves to canopies. In *Remote Sensing of Plant Biodiversity* (pp. 43–82). Springer, Cham.
- Shanmugam, S., Assunção, E., Mesquita, R., Veiros, A., & Gaspar, P. D. (2020). Automated weed detection systems: A review. *KnE Engineering*, 271–284.
- Tzutalin. (2021). *LabelImg*. <https://github.com/tzutalin/labelImg>
- USGS. (2018, December 27). *NDVI, the Foundation for Remote Sensing Phenology*. [https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology?qt-science\\_center\\_objects=0#qt-science\\_center\\_objects](https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology?qt-science_center_objects=0#qt-science_center_objects)
- Yu, H., Chen, C., Du, X., Li, Y., Rashwan, A., Hou, L., Jin, P., Yang, F., Liu, F., Kim, J., & Li, J. (n.d.). *TensorFlow Model Garden*. Retrieved December 18, 2021, from <https://github.com/tensorflow/models>





