


# PrunusBOT

Aplicação da robótica  
à produção de pêsego  
e cereja



**COTHN**  
CENTRO OPERATIVO E TECNOLÓGICO  
HORTOFRUTÍCOLA NACIONAL



PrunusBOT

# **PrunusBOT**

## **Aplicação da robótica à produção de pêssego e cereja**

**Maria Paula Simões**

(COORDENAÇÃO)

VOLUME I

CENTRO OPERATIVO E TECNOLÓGICO HORTOFRUTÍCOLA NACIONAL –  
CENTRO DE COMPETÊNCIAS

## **Ficha Técnica**

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

**Coordenação:** Maria Paula Simões

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

### **Autores e copyright:**

Abel Veloso

Anabela Barateiro

André Veiros

António Ramos

Cristina Canavarro

Cristina Ramos

Dora Ferreira

Eduardo Assunção

Francisco Vieira

Hugo Fonseca

Hugo Proença

João Cunha

José Pedro Simões

Maria Paula Simões

Paulo Silvino

Pedro Dinho Silva

Pedro Dinis Gaspar

Preciosa Fragoso,

Ricardo Mesquita

Sandra Lopes

**Revisão:** Maria Paula Simões

**Design Editorial:** SUPER Brand Consultants

**Tiragem:** 300 exemplares

**Impressão e Acabamento:** Empresa Diário do Porto, Lda.

**Data de Impressão:** Abril de 2022

**Depósito Legal:** 497599/22

**ISBN:** 978-972-8785-21-5

## Capítulo 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 autónomo 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 multiespectrais 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 neuronais 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	0.57
2	0.95	0.84	0.54	0.57
3	0.88	0.79	0.48	0.51
4	0.94	0.86	0.58	0.56
5	0.94	0.85	0.57	0.57
6	0.94	0.84	0.54	0.57
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	0.57
12	0.95	0.88	0.59	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 Cgreen (Chlorophyll Index Green), descrito na Equação **Erro! A origem da referência não foi encontrada.**

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

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 Cgreen.

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 Cgreen.

## 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 Barrera 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.
- Tzotalin. (2021). *Labellmg*. <https://github.com/tzotalin/labellmg>
- 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>