



Sistema de apoio à tomada de decisão de classificação automática de doenças em pêssegos através de inteligência artificial por rede neuronal convolucional

Catarina Diniz¹, Eduardo Assunção², Pedro Dinis Gaspar^{1,2*}, Hugo Proença^{1,3}, Anabela Barateiro⁴

¹ Universidade da Beira Interior, Convento de Sto. António, 6201-001, Covilhã, Portugal,

²C-MAST –Centre for Mechanical and Aerospace Science and Technologies, Universidade da Beira Interior, Convento de Sto. António, 6201-001, Covilhã, Portugal,

³ IT - Instituto de Telecomunicações, Universidade da Beira Interior, Convento de Sto. António, 6201-001, Covilhã, Portugal

⁴ APPIZÊZERE - Associação de Proteção Integrada e Agricultura Sustentável do Zêzere, Av Eugénio de Andrade, Lote 80, R/ C, 6230-291 Fundão,
E-mail: * dinis@ubi.pt

Resumo

As doenças dos frutos são um perigo constante para as produções dos agricultores. Pela aplicação de técnicas baseadas em visão computacional a agricultura de precisão auxilia os agricultores nas decisões a tomar para controlar as doenças. A extração de características para analisar as doenças dos frutos é uma tarefa essencial para a aplicação de técnicas de inteligência artificial com os dados recolhidos por visão computacional. Atualmente, no geral, essa extração é feita manualmente. No entanto, os resultados obtidos empiricamente em diferentes domínios confirmam que a extração feita através de redes neuronais convolucionais (*Convolutional Neural Networks* - CNN) fornecem uma melhoria significativa na precisão dos resultados, contrariamente à extração feita manualmente e, portanto, as CNN têm sido aplicadas em várias tarefas de visão computacional, substituindo os modelos feitos manualmente. No geral, é necessária uma grande base de dados de imagens para treinar uma CNN. Contudo, não existem muitas imagens de doenças do fruto disponíveis para formar a base de dados. Foi treinada uma pequena e eficiente CNN, desenvolvida para operar em aparelhos móveis, capaz de classificar pêssegos saudáveis e duas classes de doenças de pêssegos, crivado (*Stigmia carpophila*) e oídio (*Podosphaera pannosa*). Baseado em técnicas de transferência de aprendizagem e estratégias de aumento de dados, o modelo proposto atinge uma macro média “F1-score” de 98%. No futuro, esta rede neuronal artificial poderá ser incluída num veículo robótico autónomo, terrestre ou aéreo, que captando regularmente imagens nos pomares, permite detetar precocemente o surgimento destas doenças, possibilitando ao fruticultor tomar medidas que restrinjam os efeitos negativos que possam acarretar à produção ou à qualidade final dos produtos.

Palavras-chave: Redes neuronais convolucionais, pequenas bases de dados, agricultura de precisão, crivado (*Stigmia carpophila*), oídio (*Podosphaera pannosa*)

Abstract

Fruit diseases are a continuous danger to farmers. By applying computer vision-based techniques, precision agriculture can support the farmers in the decision making for fruit disease control. Features extraction is an important task for the application of artificial intelligence techniques supported by computer vision. These days, in general, feature extraction for fruit diseases are handcrafted. However, empirical results in different



domains confirm that features learned by Convolutional neural networks (CNN) provide significant improvements in accuracy over handcrafted features. CNN have been applied in many computer vision tasks, replacing the hand engineered models. In general, a large-scale image dataset is necessary for training a CNN. Even though, there are not innumerable fruit disease images available to build the dataset. A little and efficient CNN was trained and developed to run in the mobile devices to classify healthy peach fruits and two peach diseases: gumspot or shot-hole (*Stigmia carpophila*) and powdery mildew (*Podosphaera pannosa*). Based on transfer learning techniques and data augmentation strategies, the proposed model achieves a Macroaverage F1-score of 0.98. In the future, this artificial neuronal network may be included in an autonomous robotic vehicle, terrestrial or aerial, which regularly captures images in the orchards, allows the early detection of the appearance of these diseases, enabling the fruit grower to take measures to restrict the negative effects that may cause the production or the final quality of the products.

Keywords: Deep convolutional network, small dataset, precision agriculture, gumspot or shot-hole, (*Stigmia carpophila*), powdery mildew (*Podosphaera pannosa*)

Introdução

As doenças dos frutos são um contínuo perigo para as produções agrícolas e responsáveis por perdas económicas substanciais. A antracnose é um exemplo de doença do fruto, que se não for controlada pode levar à ocorrência da podridão das frutas (*Peach Disease - Anthracnose*, n.d.). No sentido de fazer esse controlo, a agricultura de precisão fornece várias tecnologias para suportar as decisões que os agricultores precisam tomar.

A revisão da literatura remete-nos para vários trabalhos publicados que utilizam modelos de visão computacional para identificar ou classificar doenças dos frutos. Dubey & Jalal (2012) propõem um método para a classificação das doenças da maçã (mancha, podridão e crivado) que consiste na segmentação de imagens de frutas aplicando K-Means, extração de características de imagens segmentadas (histograma de cor global, vetor de coerência de cor e binário local), e em seguida, aplicaram uma máquina de vetores de suporte (*Support Vector Machine - SVM*) como classificador. O método atingiu uma precisão média de 0,93 utilizando 50 imagens por classe. Este método extrai os vetores de características, manualmente, para discriminar cada classe de doença de fruta. Samajpati e Degadwala (2016) fundem características de cor e textura de imagens de maçã e usam um meta estimulador, que ajusta vários classificadores, para classificar crivado, podridão e doenças de manchas. Estes utilizaram 70 imagens para treino e 10 para teste de cada classe. Esse método, não automático, exigia a seleção manual das características (cor e textura) que representavam cada classe de doenças das frutas. Conforme mencionado, os modelos apresentados anteriormente utilizam vetores de características selecionados à mão. Porém, este tipo de característica tem uma representação de baixo nível (El-gayar et al., 2013). Por outro lado, a técnica de inteligência artificial baseada em redes neuronais convolucionais (*Convolutional Neural Networks - CNN*) tem a capacidade de extrair características de baixo, médio e alto nível (Oquab et al., 2014). Behera et al. (2018) propõem uma abordagem de classificação da doença da laranja com pré-processamento, segmentação e extração de características. Na fase de pré-processamento, é realizado o realce da imagem e transformação da cor L^*a^*b . É usada a matriz de co-ocorrência de nível Gary para extrair as seguintes características: contraste, correlação, energia, homogeneidade, média, desvio padrão, entropia, RMS, variância, suavidade, assimetria e IDM. Os autores usaram o classificador SVM, realizaram testes em 40 imagens e alcançaram uma precisão de 0,9. Abirami e Thilagavathi (2019) propuseram um método para classificação de doenças de



frutas usando redes neuronais como classificadores. Primeiramente, realizaram o pré-processamento da imagem, depois a segmentação para produzir imagens binárias por limiar e, finalmente, criaram vetores de características aplicando o padrão binário local. Estes autores relataram uma precisão para um teste com 100 imagens de 0,92 para doenças bacterianas e 0,86 para doenças fúngicas com dez camadas ocultas de redes neurais.

Resultados empíricos de diferentes domínios confirmam que as representações adquiridas por CNN fornecem melhorias significativas na precisão obtida quando comparados com os processos manuais (Collins, n.d.). Uma vez que as CNN contêm milhões de parâmetros, para se obter uma boa precisão e generalização é necessário ter muitos dados para o treino da rede. Infelizmente, para doenças do fruto, não existem muitas imagens disponíveis que permitam criar uma grande base de dados. Uma abordagem que se utiliza para ultrapassar este problema é a aplicação de técnicas de transferência de aprendizagem (*transfer learning* - TL) e técnicas de aumento de dados (Shorten & Khoshgoftaar, 2019).

Neste artigo aplicaram-se técnicas de transferência de aprendizagem utilizando a CNN MobileNetV2 (Sandler et al., 2018), pré-treinada no conjunto de dados ImageNet (Deng et al., 2009), e aumentaram-se os dados, por forma a investigar os resultados da classificação das doenças que compõem a nossa pequena base de dados de imagens de doenças do pêsego, tal como ilustrado na Figura 1. Apesar de a CNN já ter sido utilizada em contextos diferentes (por exemplo, para avaliar a doença da folha numa base de dados de grande amplitude (Mohanty et al., 2016), as novidades deste trabalho estão diretamente relacionadas com a capacidade de inferência considerando que é utilizado um pequeno conjunto de dados de doenças do pêsego para esta análise e com o facto de o modelo ser projetado para funcionar em dispositivos móveis.

Materiais e Métodos

A base de dados de imagens de doenças do pêsego é composta por imagens RGB obtidas das seguintes páginas abertas da internet: Forestry Images (*Forestry Images: Forest Health, Natural Resources, Fire, Trees, Wildlife, Silviculture Photos*, n.d.), PlantVillage (*Peach | Diseases and Pests, Description, Uses, Propagation*, n.d.), Pacific Northwest Pest Management Handbooks (*Walnut-Codling Moth | Pacific Northwest Pest Management Handbooks*, n.d.), Utah State University (*Peach/Nectarine Insects and Diseases | USU*, n.d.), University of Georgia (*Peach Scab - Story - News & Events | College of Agricultural & Environmental Sciences*, n.d.). Para além disso, fazem parte da base de dados, imagens fornecidas pela APPIZÊZERE (Associação de Proteção Integrada e Agricultura Sustentável do Zêzere). A base de dados utilizada tem 207 imagens RGB divididas em três classes: pêsegos saudáveis (124 imagens, sendo que 99 foram utilizadas para treino e 25 para validação), com oídio (58 imagens das quais 46 serviram para treinar a rede e 12 para validar os dados) e crivado (25 imagens, sendo 20 utilizadas para treino e 5 para validação). A Figura 2 demonstra alguns exemplos visuais de imagens utilizadas das diferentes classes.

Tal como referido anteriormente, quando existe uma base de dados pequena, as CNN podem obter resultados pouco favoráveis. Uma abordagem comum para ultrapassar este problema consiste em aplicar a técnica de aumento de dados. Esta técnica foi aplicada neste trabalho de acordo com o Quadro 1, uma vez que após se proceder à aplicação de outras técnicas de aumento, estas foram as que demonstraram ter melhores resultados. Para avaliar o desempenho do modelo foram utilizados os seguintes critérios: precisão (1), “recall” (2) e “F1-score” (3), que é uma função de precisão e métricas de “recall”.



$$Precisão = \frac{VP}{VP+FP} \quad (1)$$

$$Recall = \frac{VP}{VP+FN} \quad (2)$$

$$F1 - score = \frac{2 \times Precisão \times Recall}{Precisão + Recall} \quad (3)$$

Onde VP são “Verdadeiros Positivos”, ou seja, o número de imagens corretamente classificadas; FP são “Falsos Positivos” (a rede classifica como doentes pêssegos saudáveis); FN são “Falsos Negativos”, ou seja, a CNN classifica como saudáveis pêssegos doentes.

Já anteriormente foi mencionado o problema de sobre ajuste das CNN devido a uma pequena quantidade de dados para treino. Infelizmente, os conjuntos de dados de doenças de frutas disponíveis têm uma quantidade relativamente pequena de imagens. Levando em conta essa restrição, foi selecionado o modelo MobileNetV2 CNN para investigar as doenças do pêssego. A MobileNetV2 é uma rede neuronal de visão computacional de propósito geral projetada para suportar classificação, detecção de objetos, segmentação semântica e execução em dispositivos móveis e aplicações em tempo real.

1) MobileNetV1: A principal chave para reduzir o custo computacional e o tamanho do modelo é dividir a convolução típica em duas camadas: uma convolução em profundidade e uma convolução pontual. A convolução em profundidade é realizada aplicando um filtro por canal de entrada e a convolução em ponto aplicando uma combinação linear na camada de saída em profundidade. No total, o MobileNetV1 possui 28 camadas (Sandler et al., 2018).

2) MobileNetV2: Possui uma camada inicial totalmente de convolução seguida de 19 camadas “bottleneck”, de acordo com o Quadro 2. O seu bloco de construção (camada “bottleneck”) é baseado na estrutura MobileNetV1 com duas camadas adicionais que realizam a expansão na entrada de baixa dimensão para uma dimensão alta e filtrada com uma convolução de profundidade leve. No final, os recursos são novamente projetados de volta para uma representação de baixa dimensão com uma convolução linear.

A experiência foi desenvolvida nas estruturas de aprendizagem profunda Keras, TensorFlow e TensorFlow-Hub.

1) Keras é uma interface de programação de aplicações (*Application Programming Interface* - API) de aprendizagem profunda de alto nível executada na plataforma de aprendizagem da máquina TensorFlow, que executa com eficiência operações de tensor de baixo nível na CPU, GPU ou TPU. Usa-se a aplicação Keras versão 1.0.8 e TensorFlow-GPU 2.0.0. O redimensionamento e aumento de dados de imagem também foram realizados com a biblioteca de processamento Keras.

2) TensorFlow Hub: o TensorFlow Hub é um repositório para publicação e consumo de partes reutilizáveis de modelos de aprendizagem máquina (*Machine Learning* - ML). No TensorFlow Hub, um módulo é uma parte do gráfico do TensorFlow. Neste trabalho foi usado um módulo classificador MobileNetV2 pré-treinado. A dimensão de entrada da imagem para o modelo é 224x224x3.

3) Experiência: Usando a API Keras, uma camada totalmente conectada e uma função de ativação Softmax foram adicionados ao modelo. O modelo foi compilado com



o otimizador Adam, entropia cruzada categórica esparsa de função de perda e precisão métrica. O conjunto de dados foi dividido de acordo com o anteriormente referido e o treino foi realizado com 20 iterações e com um tamanho de lote de 16.

Resultados e Discussão

Este artigo propõe o uso de uma solução baseada em aprendizagem profunda para classificação de oídio e crivado em pêsego, o que representa uma contribuição, visto que os métodos anteriores eram todos feitos manualmente. Usamos a CNN MobileNetV2 pré-treinada na base de dados ImageNet e treinamos a última camada da rede na nossa base de dados de pêsegos, utilizando a técnica de aumento de dados.

A Figura 3(a) mostra o relatório de treino para o melhor resultado alcançado. O erro de treino e validação (visível na Figura 3(b)) é de cerca de 0,1, e a diferença entre eles é muito pequena, indicando que o modelo não sofre sobre ajustes durante as 20 iterações de treino. Pela análise do relatório de classificação pode-se visualizar que o melhor desempenho de classificação para uma classe individual é a doença crivado com pontuação “F1-score” de 1,00. A Figura 2(c) mostra que as manchas pretas visuais podem fornecer recursos úteis para discriminar o crivado. O oídio apresenta um resultado de classificação “F1-score” de 0,96. E por último, a classe de frutos saudáveis apresenta um “F1-Score” de 0,98. O desempenho total do modelo atingiu a pontuação macro média de “F1-score” de 0,98. Na Figura 3(c) é possível encontrar os resultados resumidos da classificação que demonstram a importância do uso de CNN para controlar doenças permitindo ao agricultor poupar custos.

Conclusões

A doença com melhores resultados na classificação individual foi o crivado com um “F1-score” de 1,00, seguido da classificação de pêsegos com oídio com uma classificação de 0,96. A classe de pêsegos saudáveis teve uma classificação “F1-score” de 0,98. O desempenho total do modelo alcançou uma pontuação da macro média “F1-score” de 0,98. Estes resultados vêm realçar o potencial do uso de CNN de classificação de doenças do fruto com pequenas quantidades de dados para o treino da rede. Este tipo de técnicas de inteligência artificial baseadas em visão computacional, incorporadas em robôs autônomos, terrestres ou aéreos, podem permitir detetar precocemente o surgimento de doenças, possibilitando ao fruticultor tomar medidas que restrinjam os efeitos negativos que possam acarretar à produção ou à qualidade final dos produtos.

Agradecimentos

Este estudo faz parte das atividades do projeto PrunusBot - Sistema robótico aéreo autônomo de pulverização controlada e previsão de produção frutícola, operação n.º PDR2020-101-031358 (líder), consórcio n.º 340, iniciativa n.º 140 promovida por PDR2020 e cofinanciada pela FEADER no âmbito da iniciativa Portugal 2020.

Os autores agradecem a oportunidade e o apoio financeiro para levar a cabo este projeto à Fundação para a Ciência e Tecnologia (FCT) e à Unidade de I&d "Centro de Ciências e Tecnologias Mecânicas e Aeroespaciais" (C-MAST), no âmbito do projeto UIDB / 00151 /2020.

Referências

Abirami, S., & Thilagavathi, M. (2019). Classification of fruit diseases using feed forward back propagation neural network. *2019 International Conference on Communication and Signal Processing (ICCSP)*, 0765–0768. <https://doi.org/10.1109/ICCSP.2019.8698071>



Behera, S. K., Jena, L., Rath, A. K., & Sethy, P. K. (2018). Disease classification and grading of orange using machine learning and fuzzy logic. *2018 International Conference on Communication and Signal Processing (ICCSP)*, December, 0678– 0682. <https://doi.org/10.1109/ICCSP.2018.8524415>

Collins, M. (n.d.). *Feedforward Neural Networks*. Retrieved November 29, 2020, from <http://www.cs.columbia.edu/~mcollins/ff.pdf>

Dubey, S. R., & Jalal, A. S. (2012). Adapted approach for fruit disease identification using images. *International Journal of Computer Vision and Image Processing*, 2(3), 44–58. <https://doi.org/10.4018/ijcvip.2012070104>

El-gayar, M. M., Soliman, H., & Meko, N. (2013). A comparative study of image low level feature extraction algorithms. *Egyptian Informatics Journal*, 14(2), 175–181. <https://doi.org/10.1016/j.eij.2013.06.003>

Forestry Images: Forest Health, Natural Resources, Fire, Trees, Wildlife, Silviculture Photos. (n.d.). Retrieved November 29, 2020, from <https://www.forestryimages.org/>

Deng, J., Dong, W., Socher, R., Li, L., Li, K. & Fei-Fei, L. (2009). ImageNet: A large- scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 2009, pp. 248-255, doi: 10.1109/CVPR.2009.5206848

Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image- based plant disease detection. *Frontiers in Plant Science*, 7(September). <https://doi.org/10.3389/fpls.2016.01419>

Oquab, M., Bottou, L., Laptev, I., & Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 1717–1724. <https://doi.org/10.1109/CVPR.2014.222>

Peach/Nectarine Insects and Diseases | USU. (n.d.). Retrieved November 29, 2020, from https://extension.usu.edu/pests/ipm/notes_ag/fruit-list-peach

Peach | Diseases and Pests, Description, Uses, Propagation. (n.d.). Retrieved November 29, 2020, from <https://plantvillage.psu.edu/topics/peach/infos>

Peach Disease - Anthracnose. (n.d.). Retrieved November 29, 2020, from <https://extension.psu.edu/peach-disease-anthracnose>

Peach Scab - Story - News & Events | College of Agricultural & Environmental Sciences. (n.d.). Retrieved November 29, 2020, from <https://www.caes.uga.edu/news-events/news/story.html?storyid=5097&story=Peach-Scab>

Samajpati, B. J., & Degadwala, S. D. (2016). Hybrid approach for apple fruit diseases detection and classification using random forest classifier. *2016 International Conference on Communication and Signal Processing (ICCSP)*, 1015–1019. <https://doi.org/10.1109/ICCSP.2016.7754302>

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *ArXiv*, 4510–4520.

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019- 0197-0>



Walnut-Codling moth / Pacific Northwest Pest Management Handbooks. (n.d.). Retrieved November 29, 2020, from <https://pnwhandbooks.org/>

Quadro 1 - Aumento de dados.

Transformação	Valores
Rotação	40
Mudança de largura	0,15
Mudança de altura	0,15
Zoom	0,2
Flip-horizontal	Verdadeiro

Quadro 2 - Estrutura do MobileNetV2 (Cada linha descreve uma sequência de uma ou mais camadas iguais, representadas em “*n*”. Todas as camadas na mesma linha têm o mesmo número “*c*” de canais de saída. A primeira camada de cada sequência tem um passo “*s*” e todas as outras usam o passo 1. O fator de expansão aplicado à entrada é “*t*”).

Entrada	Operador	<i>t</i>	<i>c</i>	<i>n</i>	<i>s</i>
$224^2 \times 3$	Conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	Conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	Avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	Conv2d 1x1	-	k	-	-

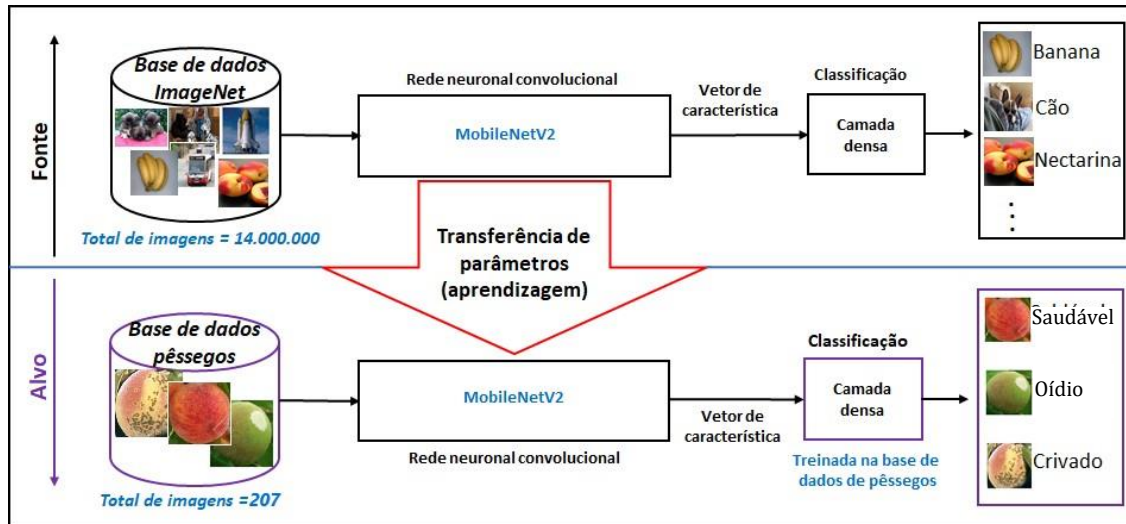


Figura 1 – Modelo proposto com base na rede MobileNetV2: O modelo já foi treinado anteriormente no conjunto de dados ImageNet (fonte). Os parâmetros pré-treinados são transferidos para o alvo (classificação de doenças de frutas). Além disso, uma camada totalmente conectada é treinada no conjunto de dados de doenças do pêsego para compensar a diferença entre as imagens de dados de origem e de destino.





Figura 2 - Exemplos de imagens utilizadas da base de dados do tipo: (a) pêssegos saudáveis; (b) pêssegos com oídio; (c) pêssegos com crivado.



(a) Precisão do treino e validação. (b) Custos no treino e validação. (c) Matriz de resultados.

Figura 3 - Resultados do processo de treino e validação da CNN.