



Deep Features para sistemas de identificação de plantas

Luciano A. D. Filho¹, Rodrigo T. Calumby¹

¹Universidade Estadual de Feira de Santana – Feira de Santana – BA – Brazil

lucianoadfilho@ecomp.uefs.br, rtcalumby@uefs.br

Abstract. *The selection of a Deep Convolutional Neural Network (DCNN) architecture is a decisive task. In this paper we propose to evaluate the generalization power of Deep Features extracted from a broad set of DCNNs without fine-tuning for plant species recognition from images using a multi-organ dataset. The conventional Softmax classification approach and an alternative based on SVM and feature selection are compared. The experimental validation allowed to identify the most promising methods, with Softmax and SVM reaching 0.76 and 0.82 of Micro-F1, respectively.*

Resumo. *A seleção de uma arquitetura de Rede Neural Convolutacional Profunda (RNCP) é uma tarefa decisiva. Neste trabalho avaliamos o poder de generalização de Deep Features extraídas à partir de um amplo conjunto de RNCPs sem fine-tuning para classificação de espécies de plantas em imagens, utilizando um conjunto de dados de imagens multi-órgão. São comparadas as abordagens de classificação convencional com Softmax e uma alternativa baseada em SVM e seleção de features. A validação experimental permitiu identificar os métodos mais promissores, com o métodos baseados em Softmax e SVM alcançando 0.76 e 0.82 de Micro-F1, respectivamente.*

1. Introdução

A indústria agrícola ao redor do globo tem lidado cada vez mais com os desafios oriundos da necessidade de sustentabilidade à medida que a população mundial cresce. Com isso, a otimização dos resultados tem desempenhado um papel crucial, objetivando maximização da produção com menor uso de área possível. Nesse sentido, diversas tecnologias têm sido empregadas, não apenas no desenvolvimento de novos modelos de produção, mas buscando a melhoria da precisão em várias tarefas [Shi et al. 2015, Meng et al. 2015], bem como a automação de muitas delas, por exemplo, por meio de tecnologias de reconhecimento de padrões. Neste contexto, diversos trabalhos têm proposto a utilização de RNCPs para realização de tarefas relacionadas à identificação automática de doenças

em plantas [Khan et al. 2018, Brahimi et al. 2018], identificação de espécies invasivas [V. Sivakumar et al. 2020], , entre outros. De modo geral, esses estudos demonstram o desenvolvimento de ferramentas auxiliares nas tarefas de monitoramento e administração do campo, principalmente relacionadas à identificação automática de plantas. Isso possibilita também a implementação de sistemas que auxiliem na tomada de decisões, contribuindo para maior eficácia no controle de situações adversas que impactem a produção.

Neste contexto, a seleção de arquiteturas de RNCPs adequadas é uma tarefa decisiva [Maeda-Gutiérrez et al. 2020], ainda mais se tratando do domínio de plantas, com um vasto número de espécies e cenários de classificação com alta heterogeneidade visual nas imagens. Considerando a diversidade de aplicações de RNCPs relacionadas a plantas na agricultura, este trabalho tem por objetivo avaliar experimentalmente a eficácia de RNCPs para classificação sobre um conjunto de dados de propósito geral voltado para identificação multi-órgão de espécies de plantas. Para isso, realiza-se uma análise considerando a abordagem convencional de classificadores neurais com ativação *Softmax*, além da extração e seleção explícita de *Deep Features* e classificação com o algoritmo *Support Vector Machines* (SVM).

2. Trabalhos Correlatos

Diversos trabalhos propõem a utilização de RNCP para extração de *Deep Features* e identificação de plantas com classificadores tradicionais. Em [Khan et al. 2018], foi proposto o uso de *Deep Features* e classificadores tradicionais (*e.g.*, *Decision Trees* e *SVM*) para segmentação e identificação de doenças em frutas. Similarmente, em [Khan et al. 2020], também é proposta a detecção e identificação de doenças em imagens de folhas de pepino. Foram utilizadas as arquiteturas VGG-19 e o VGG-M pré-treinadas para extração de *Deep Features*, além um método para seleção de características. Para identificar doenças em imagens de folhas de plantas, em [Li et al. 2020] avaliou-se o uso de classificadores (*Random Forests* e *SVM*) e *Deep Features*, com objetivo de compará-los com as RNCP. Além de reportar a superioridade dos métodos tradicionais, os autores demonstraram aspectos positivos da seleção de *features*, principalmente em relação à redução da complexidade computacional. Especificamente para a tarefa de identificação de espécies de plantas, em [Feitoza et al. 2019] os autores demonstraram resultados promissores com extração de *features* usando as redes InceptionV3, VGG-16 e VGG-19 e o classificador SVM. Contudo, não foram considerados procedimentos de otimização dos classificadores.

Diferentemente dos trabalhos descritos, este trabalho propõe avaliar um amplo conjunto de arquiteturas de RNCP, para a tarefa de reconhecimento de espécies de plantas sobre dados de maior complexidade em termos de heterogeneidade visual, número de amostras, classes e múltiplos órgãos. Além disso, estende-se significativamente o trabalho de [Feitoza et al. 2019] considerando o dobro das arquiteturas de RNCP e otimizações de hiperparâmetros, analisando-se a estabilidade dos modelos, além de compararmos os resultados obtidos com as arquiteturas treinadas à partir da abordagem de classificação convencional (classificador neural com ativação *Softmax*).

3. Metodologia

Esse trabalho utilizou o conjunto de dados do PlantCLEF 2013, com 26,077 imagens de 250 espécies de plantas, incluindo imagens de órgãos individuais *e.g.*, fruta, flor, ga-

a)			b)		
Protocolo	Parâmetros	Configuração	Protocolo	Parâmetros	Configuração
10-Folds Estratificado	Batch size	16	10-Folds Estratificado	Cost	0.01
		32			0.1
		64			1
	N. épocas	20			10
		40			0.0001
		60		0.001	
	Learning rate	1×10^{-4}		0.01	
		5×10^{-4}		“auto”	
		1×10^{-3}			
		5×10^{-3}			

Figura 1. Configurações de otimização de hiperparâmetros *Grid Search*.

lhos, tronco, além da planta inteira. Considerando um cenário de classificação de mundo real, os experimentos foram realizados de maneira agnóstica em relação aos tipos de imagem. Na primeira etapa treinamos as redes VGG-16, VGG19, InceptionV3 (GoogLeNet), NasNET-A (NasNETLarge), ResNet50 e ResNet152_V2 com otimização de hiperparâmetros via *Grid Search* (Figura 1-a). As redes foram inicializadas com pesos pré-treinados sobre a base ImageNet, havendo otimização apenas no componente de classificação. Para isso, consideramos a função de custo *Categorical Crossentropy* e otimizador *Adam* com as configurações padrão propostas pelos autores. As redes pré-treinadas foram utilizadas para a extração de *Deep Features*, com posterior aplicação de PCA com 90% de variância junto com o classificador SVM com configurações de Kernel: *Linear, Sigmoid, Polynomial* e método de composição *One-vs-Rest*. Nesta etapa realizou-se também otimização de hiperparâmetros (Figura 1-b). Para avaliação da eficácia, as médias das medidas Micro-F1 foram calculadas para considerar o desbalanceamento de classes. Utilizou-se protocolo de validação cruzada com *k folds*, sendo, em cada rodada, 9 *folds* usados para treino e 1 para teste. Para análise de estabilidade e significância estatística, são apresentados intervalos de confiança de 95%.

4. Resultados e Discussão

A Figura 2 apresenta os resultados de Micro-F1 para as melhores configurações obtidas com a otimização de hiperparâmetros. Na Figura 2-c apresentamos um comparativo dos resultados entre Softmax e SVM. De modo geral, os resultados com SVM foram superiores aos com o classificador baseado em *Softmax*. Nos casos em que a média de Micro-F1 do Softmax foi maior, os resultados podem ser considerados equivalentes quando analisados os intervalos de confiança. Além disso, o tamanho dos intervalos de confiança para as redes treinadas com o *Softmax* foram muito maiores, indicando menor estabilidade dos métodos para diferentes amostras de treino e teste.

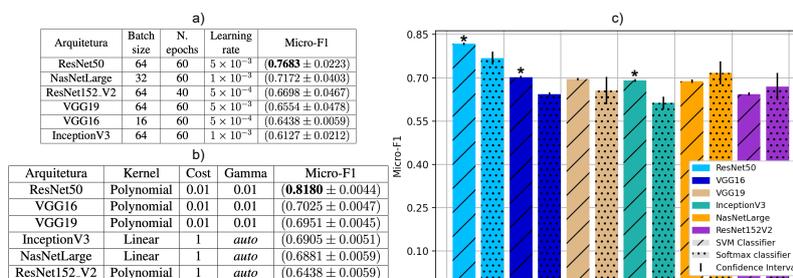


Figura 2. Resultados dos modelos otimizados: a) Softmax; b) SVM; c) Comparativo de Softmax e SVM com *deep features* e intervalos de confiança. (*) Significância em relação ao Softmax.

5. Conclusões

Os resultados possibilitaram identificar as arquiteturas de RNCP mais eficazes para extração de *features* de plantas, com destaque para a ResNet50, que com a utilização de PCA e do SVM alcançou Micro-F1=0.82. Além disso, os resultados evidenciaram que apesar do tipo de classificador ter desempenhado um papel significativo sobre a eficácia e precisão dos modelos, podemos observar que estatisticamente não houve diferença significativa na ordem de eficácia das arquiteturas para os diferentes classificadores. Isso sugere a consistência dos resultados em relação à eficácia das redes avaliadas. Por fim, estes resultados contribuem diretamente para o desenvolvimento de sistemas de identificação automática de plantas e tarefas relacionadas à aplicação de RNCP para classificação de órgãos de plantas e as inúmeras aplicações no contexto da agricultura e biodiversidade.

Referências

- Brahimi, M., Arsenovic, M., Laraba, S., Sladojevic, S., Boukhalfa, K., e Moussaoui, A. (2018). *Deep Learning for Plant Diseases: Detection and Saliency Map Visualisation*, pages 93–117. Springer International Publishing, Cham.
- Feitoza, M. C., da Silva, W. B., e Calumby, R. T. (2019). Exploring deep features and transfer learning for plant species recognition. In *Proceedings of the XV Brazilian Symposium on Information Systems*, pages 1–8.
- Khan, M. A., Akram, T., Sharif, M., Awais, M., Javed, K., Ali, H., e Saba, T. (2018). Ccdf: Automatic system for segmentation and recognition of fruit crops diseases based on correlation coefficient and deep cnn features. *Computers and electronics in agriculture*, 155:220–236.
- Khan, M. A., Akram, T., Sharif, M., Javed, K., Raza, M., e Saba, T. (2020). An automated system for cucumber leaf diseased spot detection and classification using improved saliency method and deep features selection. *Multimedia Tools and Applications*, pages 1–30.
- Li, Y., Nie, J., e Chao, X. (2020). Do we really need deep cnn for plant diseases identification? *Computers and Electronics in Agriculture*, 178:105803.
- Maeda-Gutiérrez, V., Galván Tejada, C., Zanella Calzada, L., Celaya Padilla, J., Galván Tejada, J., Gamboa-Rosales, H., Luna-Garcia, H., Magallanes-Quintanar, R., Carlos, G.-M., e Olvera-Olvera, C. (2020). Comparison of convolutional neural network architectures for classification of tomato plant diseases. *Applied Sciences*, 10:1245.
- Meng, Q., Qiu, R., He, J., Zhang, M., Ma, X., e Liu, G. (2015). Development of agricultural implement system based on machine vision and fuzzy control. *Computers and Electronics in Agriculture*, 112:128–138. Precision Agriculture.
- Shi, Y., Wang, N., Taylor, R., e Raun, W. (2015). Improvement of a ground-lidar-based corn plant population and spacing measurement system. *Computers and Electronics in Agriculture*, 112:92–101. Precision Agriculture.
- V. Sivakumar, A. N., Li, J., Scott, S., Psota, E., Jhala, A. J., Luck, J. D., e Shi, Y. (2020). Comparison of object detection and patch-based classification deep learning models on mid- to late-season weed detection in uav imagery. *Remote Sensing*, 12(13).