

Universidade de Pernambuco
Programa de Pós-Graduação em Engenharia da
Computação (PPGEC)

Proposta de Tese de Doutorado

Área: Computação Inteligente

Título: Aprendizagem com poucos exemplos para inspeção em ambiente industrial

Orientador – Bruno José Torres Fernandes (bjtf@ecomp.poli.br)

Descrição – Atualmente, métodos baseados em deep learning [1] tem apresentados resultados satisfatórios em várias áreas da visão computacional, como categorização de objetos [2], reconhecimento de postura [3] e reconhecimento de gestos [4]. Entretanto, quando a quantidade de informações sobre o problema alvo não é tão vasta, digamos com somente algumas centenas de imagens rotuladas, a performance do sistema pode ficar abaixo do esperado.

Algumas alternativas podem ser empregadas para contornar o problema da ausência de uma quantidade expressiva de dados rotulados. Dentre elas, podemos citar:

- *Transfer learning* [5]: abordagem por meio de qual um modelo já treinado em um problema análogo pode ter seu conhecimento transferido para o novo problema;
- *Few-shot learning* [6]: onde o aprendizado é feito a partir de várias tarefas relacionadas com pequenas bases de dados com o objetivo de que a solução do problema de interesse seja alcançada;
- *Conhecimento do especialista* [7]: nessa abordagem, o especialista se envolve mais com a construção da solução para o problema específico inserindo seus conhecimentos existentes como regras dentro do modelo;
- *Data augmentation* [8]: onde bases são expandidas através de técnicas diversas.

A resolução do problema de aprendizado com poucas imagens rotuladas é particularmente útil no ambiente industrial, onde muitas vezes as ocorrências dos defeitos embora sejam registradas acontecem em baixo volume, mas com consequências que podem ser catastróficas. Dessa forma, é necessário a construção de um modelo que possa generalizar o aprendizado a respeito de defeitos já conhecidos.

Esse projeto se propõe então a investigação das técnicas já existentes para aprendizado com poucos dados expandindo o conhecimento existente na literatura para construção de um modelo genérico para detecção de defeitos na produção em ambientes industriais. Este projeto de doutorado está dentro do escopo do projeto de inovação “Inspeção em linha de produção automotiva utilizando visão computacional e deep learning” apoiado pela FACEPE (processo nº APQ-0441-1.03/18), que conta com o interesse da FCA Fiat Chrysler Brasil Automóveis LTDA.

Referências Bibliográficas

1. LECUN, YANN, Yoshua Bengio, e Geoffrey Hinton. Deep learning. Nature 521, no. 7553 (2015): 436-444.
2. HE, KAIMING, Xiangyu Zhang, Shaoqing Ren e Jian Sun. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition (2016).
3. CAO, ZHE, Tomas Simon, Shih-En Wei e Yaser Sheikh. Realtime Multi-Person

- 2D Pose Estimation using Part Affinity Fields. IEEE Conference on Computer Vision and Pattern Recognition (2017).
4. CARREIRA, JOAO e Andrew Zisserman. Quo Vadis, Action Recognition? A New Model and the Kinetics Dataset. IEEE Conference on Computer Vision and Pattern Recognition (2017).
 5. YOSINSKI, JASON, Jeff Clune, Yoshua Bengio e Hod Lipson. How transferable are features in deep neural networks? Advances in neural information processing systems. pp. 3320–3328 (2014).
 6. WANG, YAQING, Quanming Yao, James Kwok e Lionel M. Ni. Generalizing from a Few Examples: A Survey on Few-Shot Learning. CoRR, abs/1904.05046 (2019).
 7. ZARE, MOHAMMAD REZA, David Olayemi Alebiosu e Sheng Long Lee. Comparison of Handcrafted Features and Deep Learning in Classification of Medical X-ray Images. International Conference on Information Retrieval and Knowledge Management (2018).
 8. FERREIRA, JANDERSON R. B. C., Milla S. A. Ferro, Bruno J. T. Fernandes e Meuser J. S. Valença. Extreme Learning Machine Autoencoder for Data Augmentation. IEEE Latin American Conference on Computational Intelligence (2017).