

Universidade de Pernambuco

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

Proposta de Dissertação de Mestrado

Área: **Computação Inteligente**

Título: **Redistribuição Automática de Classes em Bases de Dados para Aumentar o Desempenho de Modelos de Detecção de Objetos**

Orientador – Leandro Honorato de Souza Silva (leandro.silva@ifpb.edu.br / leandro.silva@poli.br)

Resumo

A detecção de objetos envolve localizar e classificar múltiplos objetos em uma mesma imagem, sendo uma das principais tarefas da visão computacional [1]. Atualmente, os modelos baseados em aprendizagem profunda constituem o estado da arte e são comumente treinados usando o paradigma da aprendizagem supervisionada [1].

Uma das principais dificuldades enfrentadas nessa área é a aquisição de bases de dados adequadas para o treinamento eficaz de modelos de aprendizagem profunda. Nesse contexto, a Inteligência Artificial Centrada em Dados (*Data-Centric AI*) se dedica ao estudo da construção e otimização de bases de dados, visando maximizar a eficiência no treinamento de redes neurais profundas [2].

É sabido que quanto maior a distinção entre as classes de um conjunto de dados, mais simples e eficiente tende a ser o treinamento de classificadores [3]. Guan et al. [3] propuseram a métrica *Distance-based Separability Index* (DSI) para mensurar a separabilidade entre classes em uma base de dados. Além disso, abordagens hierárquicas que agrupam classes semelhantes demonstram potencial para aumentar o desempenho de detectores de objetos [4].

No trabalho de Junior et al. [5], uma nova distribuição de classes foi proposta para a base de dados FICS PCB, composta por imagens de placas de circuito impresso. Originalmente, as classes eram: capacitor, resistor, indutor, transistor e diodo. Usando métricas de variabilidade intra e interclasse, os autores propuseram uma redistribuição manual das classes, criando a FICS PCB REMAP, que incluía as classes: capacitor cerâmico, capacitor tântalo, capacitor eletrolítico, resistor, circuito integrado, indutor, diodo LED e diodo. Essa nova distribuição resultou em um aumento de 22,02% no mAP do modelo YOLOv5 em relação à distribuição original.

O presente trabalho tem como objetivo explorar e avaliar algoritmos de aprendizado de máquina capazes de propor redistribuições automáticas de classes para bases de dados de detecção de objetos, maximizando a variância interclasse e minimizando a variância intraclasse. Espera-se, assim, melhorar o desempenho de modelos de detecção de objetos baseados em redes neurais profundas.

Referências Bibliográficas

- [1] Z. Q. Zhao, P. Zheng, S. T. Xu, e X. Wu, “Object Detection with Deep Learning: A Review”, *IEEE Trans Neural Netw Learn Syst*, vol. 30, no 11, p. 3212–3232, 2019, doi: 10.1109/TNNLS.2018.2876865.
- [2] M. Motamedi, N. Sakharaykh, e T. Kaldewey, “A Data-Centric Approach for Training Deep Neural Networks with Less Data”, no *NeurIPS*, p. 3–7, 2021, [Online]. Disponível em: <http://arxiv.org/abs/2110.03613>
- [3] S. Guan, M. Loew, e H. Ko, “Data Separability for Neural Network Classifiers and the Development of a Separability Index”, 2022, doi: <https://doi.org/10.48550/arXiv.2005.13120>.

- [4] C.-W. Kuo, J. D. Ashmore, D. Huggins, e Z. Kira, “Data-Efficient Graph Embedding Learning for PCB Component Detection”, em *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, IEEE, jan. 2019, p. 551–560. doi: 10.1109/WACV.2019.00064.
- [5] A. A. F. Junior, L. H. D. S. Silva, B. J. T. Fernandes, G. O. A. Azevedo, e S. C. Oliveira, “Learning from pseudo-labels: Self-training Electronic Components Detector for Waste Printed Circuit Boards”, em *Proceedings - 2022 35th Conference on Graphics, Patterns, and Images, SIBGRAPI 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, p. 252–257. doi: 10.1109/SIBGRAPI55357.2022.9991743.