

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.ssilva@upe.br)

Resumo

A detecção de objetos consiste em localizar e classificar múltiplos objetos presentes em uma imagem, sendo uma tarefa central em visão computacional [1]. Embora os modelos baseados em aprendizagem profunda representem o estado da arte, seu desempenho depende da disponibilidade de bases de dados bem distribuídas entre classes. Nesse cenário, a Inteligência Artificial Centrada em Dados (*Data-Centric AI*) tem ganhado destaque ao priorizar técnicas de construção, curadoria e otimização de conjuntos de dados como meio para elevar o desempenho de sistemas de aprendizagem profunda [2].

Um dos desafios recorrentes em detecção de objetos é o desequilíbrio entre classes e a baixa separabilidade interclasse, especialmente em bases de dados com *long-tail distribution*. Estudos mostram que quanto maior a distinção entre classes, mais simples tende a ser o processo de aprendizado e mais robusto o classificador resultante [3]. Guan et al. [3] introduzem o *Distance-based Separability Index* (DSI), uma métrica para avaliar formalmente a separabilidade das classes, revelando seu impacto direto na dificuldade do problema de classificação.

Nesse contexto, reorganizar as classes de um conjunto de dados pode ser um mecanismo eficiente de correção de vieses introduzidos por assimetrias entre classes. Junior et al. [4] demonstram isso empiricamente ao redefinir a taxonomia original da base FICS-PCB, criando a FICS PCB REMAP por meio de métricas de variabilidade intra e interclasse. A redistribuição manual das classes resultou em um ganho expressivo de 22,02% em mAP usando YOLOv5, reforçando que a estrutura taxonômica dos dados pode ser tão determinante quanto o modelo empregado.

Além disso, pesquisas recentes reforçam que o próprio processo de treinamento de detectores é altamente sensível à distribuição das classes. Aziz et al. [5], por exemplo, mostram que a qualidade dos pseudo-rótulos em pipelines de *self-training* é diretamente afetada pela predominância de classes majoritárias. Para mitigar esse efeito, propõem o método SALB, que integra balanceamento de classes via *data augmentation (copy-paste)* e estratégias de *labeling* de alta precisão, obtendo um incremento de 8,7% no mAP no *dataset* Waymo usando apenas 10% dos dados rotulados. O trabalho evidencia que estratégias explícitas de balanceamento de classes têm impacto mensurável mesmo em cenários modernos de aprendizagem semissupervisionada.

Da mesma forma, Duan et al. [6] argumentam que *long-tailed distributions* afetam até o processo de pré-treinamento de detectores, propondo o 2DRCL — um framework que realiza reamostragem dinâmica de instâncias sub-representadas durante o *pretraining*. Seus resultados em COCO e LVIS mostraram aumentos significativos na AP de classes raras, reforçando que a distribuição das classes deve ser tratada de maneira adaptativa em múltiplos estágios do pipeline de detecção.

Outras abordagens, como o framework *Balanced Classification* (BACL) de Qi et al. [7], sugerem mecanismos para corrigir o viés competitivo entre classes majoritárias e minoritárias durante a otimização. O método emprega uma perda de classificação balanceada e um módulo de geração de amostras sintéticas (feature *hallucination*), resultando em ganhos de até 16,1% AP em classes raras no benchmark LVIS. Estes estudos, em conjunto, consolidam a ideia de que redistribuir, reamostrar ou reorganizar classes é uma estratégia crítica e ainda pouco explorada na detecção de objetos, especialmente em cenários industriais ou com bases de dados pequenas.

Diante desse panorama, **o presente trabalho propõe investigar algoritmos capazes de sugerir redistribuições automáticas de classes em bases de dados de detecção de objetos**. O objetivo central é maximizar a separabilidade interclasse e minimizar a variância intraclasse, de forma a mitigar os efeitos do desbalanceamento e da redundância semântica observada em diversas bases reais. Espera-se que, ao permitir que o próprio algoritmo proponha reorganizações sinérgicas com o modelo — ao invés de depender exclusivamente de decisões manuais — seja possível obter ganhos robustos de desempenho, estabilidade e generalização em modelos de detecção de objetos baseados em redes neurais profundas.

Referências Bibliográficas

- [1] Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. “Object Detection with Deep Learning: A Review”, IEEE Transactions on Neural Networks and Learning Systems, 30(11), 3212–3232, 2019.
- [2] Motamedi, M., Sakharnykh, N., & Kaldewey, T. “A Data-Centric Approach for Training Deep Neural Networks with Less Data”, NeurIPS 2021.
- [3] Guan, S., Loew, M., & Ko, H. “Data Separability for Neural Network Classifiers and the Development of a Separability Index”, arXiv:2005.13120, 2022.
- [4] Junior, A. A. F., Silva, L. H. D. S., Fernandes, B. J. T., Azevedo, G. O. A., & Oliveira, S. C. “Learning from pseudo-labels: Self-training Electronic Components Detector for Waste Printed Circuit Boards”, SIBGRAPI 2022.
- [5] Aziz, Z., Urmonov, O., Sajid, S., & Kim, H. “Improving Object Detection of Intelligent Vehicles Through Self-Training with Accurate Labeling and Class Balancing”, IEEE Transactions on Intelligent Vehicles, 2025.
- [6] Duan, C.-L., Li, Y., Wei, X.-S., & Zhao, L. “Long-tailed Object Detection Pretraining: Dynamic Rebalancing Contrastive Learning with Dual Reconstruction”, NeurIPS 2024.
- [7] Qi, T., Xie, H., Li, P., Ge, J., & Zhang, Y. “Balanced Classification: A Unified Framework for Long-Tailed Object Detection”, IEEE Transactions on Multimedia, 26, 3088–3101, 2024.