

DOI:10.19651/j.cnki.emt.2209364

基于 SlimYOLO 的控制箱零件检测方法^{*}

冯晨光 魏巍 陈灯 张彦铎 刘玮 栗娟

(武汉工程大学智能机器人湖北省重点实验室 武汉 430205)

摘要: 控制箱零件检测是控制箱生产过程中的重要环节。采用机器视觉方法可自动识别控制箱内零件的类别及安装位置,及时检测控制箱装配缺陷。然而现有目标检测深度学习模型时效性较低,难以满足控制箱零件在线实时检测需求。本文对 YOLOv4 目标检测模型进行剪枝和优化,提出了轻量级的目标检测模型 SlimYOLO。SlimYOLO 改进了特征提取网络结构,压缩了冗余特征层,提高了模型推理速度。同时采用 Kmeans++ 聚类算法对模型 anchor 框参数进行聚类分析,提升了模型对控制箱的检测效果。基于自主构建的控制箱零件数据集开展了多项对比实验研究, SlimYOLO 的平均检测精度为 98.08%,较 YOLOv4 提升 0.58%,模型体积缩小 9.8%,参数量减少了 700 万,推理速度提升了 10%,为实际工业场景中控制箱零件的快速智能化检测奠定了基础。

关键词: 装配缺陷检测;控制箱;基于视觉的缺陷检测;目标检测;YOLOv4

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.20

Detection method of electrical cabinet parts based on SlimYOLO

Feng Chenguang Wei Wei Chen Deng Zhang Yanduo Liu Wei Li Juan

(Hubei Provincial Key Laboratory of Intelligent Robot, Wuhan Institute of Technology, Wuhan 430205, China)

Abstract: The detection of electrical cabinet parts is an important part of the production of electrical cabinets. Machine vision is used to automatically identify the type and installation location of parts in the electrical cabinet, and to detect the assembly defects of the electrical cabinet in time. However, the existing object detection in-depth learning model has low timeliness, which makes it difficult to meet the online detection requirements of electrical cabinet parts. In this paper, the YOLOv4 object detection model is pruned and optimized, and a lightweight object detection model SlimYOLO is proposed. SlimYOLO improves the feature extraction network structure, compresses the redundant feature layer, and improves the detection speed of the model. At the same time, the Kmeans++ clustering algorithm is used to cluster anchor box parameters, which improves the detection effect of the model for electrical cabinet parts. Based on the self-built data set of electrical cabinet parts, an experimental study was carried out. The average detection accuracy of SlimYOLO is 98.08%, which is 0.58% higher than YOLOv4, the model volume is reduced by 9.8%, the parameter is reduced by about 7 million, and the detection speed is increased by 10%, which lays a foundation for the fast and intelligent detection of electrical cabinet parts in the actual industrial scene.

Keywords: assembly defect detection; electrical cabinet; visual-based defect detection; object detection; YOLOv4

0 引言

控制箱是一种常见的工业部件,广泛应用于电力以及电气等领域。其通常安装有开关设备、测量仪表以及保护电器等种类繁多零部件。这些零部件装配过程需要遵循电气图纸,在位置上满足正常运行、便于检修和安全稳定等严格要求。同时装配过程还涉及复杂的电气连接关系,极易出现装配错误。随着人力成本的急剧上升,采用机器视

觉技术对控制箱装配质量进行检测,自动发现装配缺陷成为工业界的一项重要现实需求。

目标检测是机器视觉领域的一项常见的任务,主要包括基于传统图像处理的方法和基于深度学习的方法^[1]。例如:袁纵青等^[2]提出基于阈值分割的零件检测方法。该方法通过人工设定的灰度阈值可将待检测的零件从背景中分离出来。杨宏贤等^[3]提出基于模板匹配的零件检测方法,该方法对待检测零件设计匹配模板,采用逐点扫描进行零

收稿日期:2022-03-22

^{*} 基金项目:国家自然科学基金(62171328,62102292)项目资助

件检测。然而,上述基于传统图像处理的方法对工作场景具有较高要求,难以在实际开放工业场景下获得鲁棒的效果。例如:上述基于阈值分割的方法要求图像背景与工业零件具有明显灰度值差异;基于模板匹配的方法需要辅助照明光源并且拍照角度需要满足特定的条件。近年来,基于深度学习的目标检测方法以鲁棒性的优势在各类机器视觉应用中取得了巨大成功^[4-6],并且出现了 SSD^[7]、YOLO^[8]和 Centernet^[9]等一系列优秀的模型为此,余永维等^[10]提出了基于 Inception-SSD 的零件检测方法。方法通过一组不同尺度卷积层构成的特征金字塔可检测各种大小的目标。然而,自底向上的特征提取结构导致浅层缺乏语义信息,深层缺乏位置信息,限制了其对小目标的检测能力。张静等^[11]提出基于改进 YOLOv3 的家具装配检测方法。其在 YOLOv3^[12]的基础上,优化了主干网络 Darknet-53^[13],增强了网络的特征提取能力,对装配零件的检测精度达到了 93%。然而,为了提高目标检测精度,这类目标检测模型在设计上通常采用增加深度的方法提高模型的复杂度,从而导致深度学习模型具有较高的时间复杂度和空间复杂度^[14]。例如:YOLOv3 大小为 235 MB,具有 7 000 万左右的参数,在检测分辨率为 416×416 的图像时需要超过 30 B 的浮点运算(FLOPs)。为此,已有的目标检测深度学习模型难以在资源有限的嵌入式工业设备上部署,无法满足高实时性自动化工业产线的要求。

本文针对目标检测深度学习模型在工业视觉检测应用中存在的问题展开研究,基于 YOLOv4^[15]目标检测模型进行剪枝和优化,提出了适用于控制箱零件检测的轻量级模型 SlimYOLO。SlimYOLO 采用层级剪枝优化方法对 YOLOv4 进行了优化,移除 YOLOv4 颈部的 SPP(space pyramid pool)^[16]模块,将主干网络的最后一级输出与 PAN(path

aggregation network)^[17]连接,大幅压缩了模型的参数量,提升了模型的推理速度。为了在模型复杂度降低的情况下保证目标检测精度,采用 K-means++ 算法对自主构建的控制箱零件数据集进行了聚类分析,提升了 anchor 框与目标边框重合度。提出的 SlimYOLO 模型通过剪枝策略降低了复杂度,同时面向控制箱零件检测进行了 anchor 框优化,在检测精度和时空效率上进行均衡和优化,可有效推动目标检测深度学习方法在实际工业场景中的应用。

基于自主构建的控制箱零件数据集开展了实验研究。结果表明,提出的方法可获得 98.08% 平均检测精度,略高于 YOLOv4 模型 97.50% 的平均检测精度。并且 SlimYOLO 模型体积缩小 9%,推理速度提升了 10%,为实际工业场景中控制箱零件的快速智能化检测奠定了基础。

1 控制箱零件检测方法

1.1 总体框架

如图 1 所示,为了实现工业场景下控制箱零件的高效检测,基于 YOLOv4 提出了轻量级目标检测深度学习模型 SlimYOLO。SlimYOLO 采用层级剪枝技术对冗余的特征层进行了压缩并且优化了模型结构,降低了模型复杂度和参数。此外,基于自主构建的控制箱零件图像数据集,采用 K-means++ 算法进行聚类分析,对模型 anchor 框参数进行优化,提高模型检测零件的精度。采用迁移学习策略对模型进行训练,以数据集 VOC_2007 上预训练获得的主干网络参数为基础,结合自主构建的数据集对模型参数调优。经过充分训练的 SlimYOLO 模型在复杂度和检测精度上进行均衡和优化,可在保障检测精度的同时减少模型的体积,提升模型的推理速度,为工业场景下控制箱零件的快速视觉检测提供了支撑。

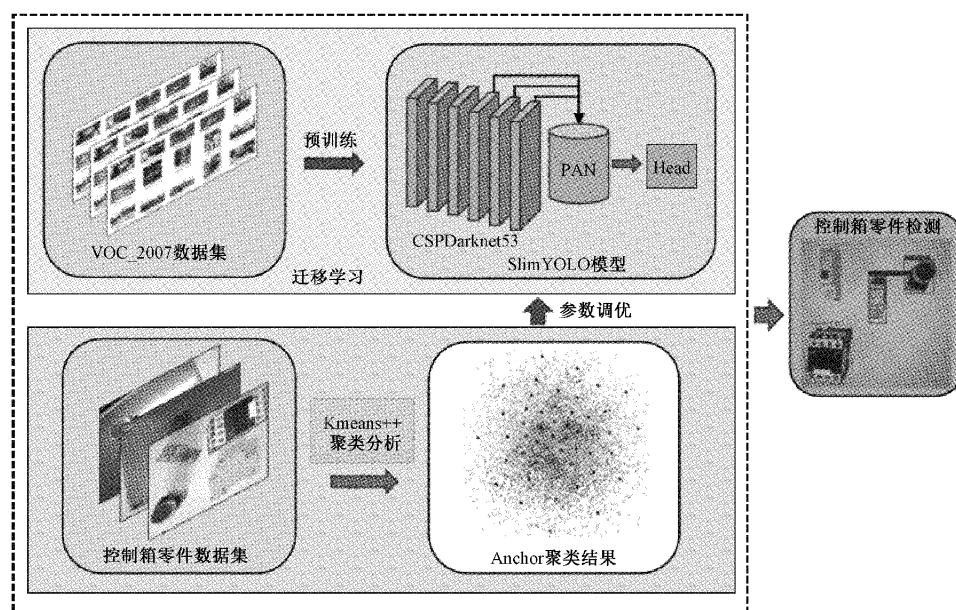


图 1 控制箱零件检测总体框架

1.2 控制箱零件检测模型

如图 2 所示, SlimYOLO 以 YOLOv4 目标检测模型为基础, 包括主干网络 CSPDarknet53, 由特征金字塔 (FPN) 和路径聚合网络 (PAN) 构成的颈部以及作为头部的分类预测网络。

1) 主干网络 CSPDarknet53 提取图像特征并输出 3 个尺度依次递减、维度递增的特征层 C0 (19×19×1 024)、C1 (38×38×512) 和 C2 (76×76×256);

2) FPN 与 CSPDarknet53 连接, C0 层经过多次卷积处理后, 跳过 SPP 模块, 直接传入 F0 层, F0 特征层进行上采

样操作后与 C1 层进行拼接, 形成 F1 (38×38), F1 进行上采样操作后与 C2 拼接形成 F2 (76×76);

3) PAN 在 FPN 的自下向上的路径之后又添加了一个自上向下的融合路径, P2 由 F2 多次卷积后产生, P2 降采样与 F1 进行融合生成 P0, 再次降采样后与 F0 融合后得到 P0。

4) 最后 Head 部分负责最终的目标预测, 特征层 H0 (19×19)、H1 (38×38)、H2 (76×76) 分别由 P0、P1、P2 经过多轮卷积和归一化处理生成, 实现对不同尺寸的控制箱零件的检测。

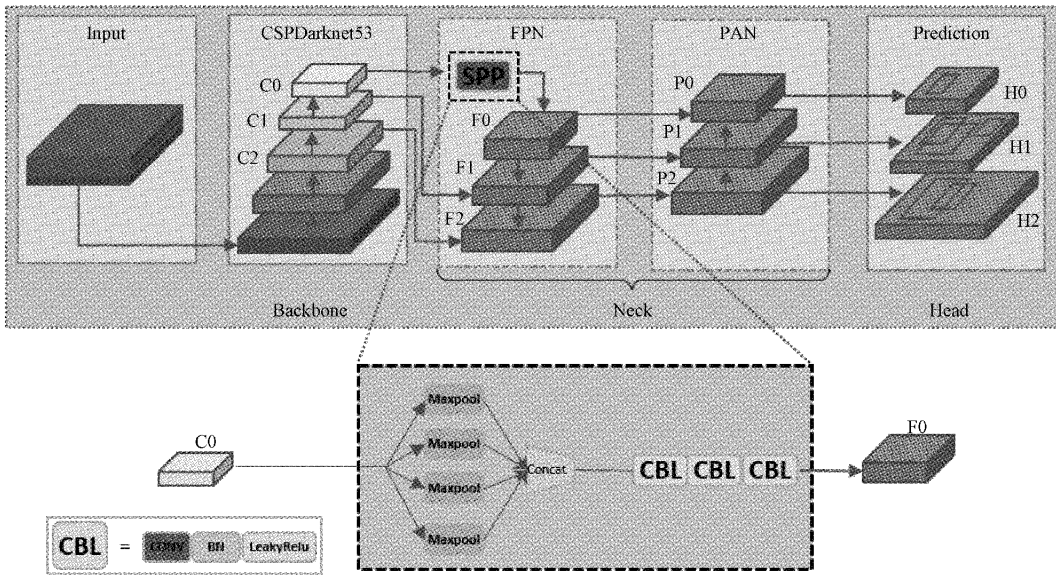


图 2 SlimYOLO 网络框架

SlimYOLO 对模型颈部结构进行了大幅度剪枝。YOLOv4 中, 为解决输入目标尺度不统一的问题, 采用空间金字塔池化模块 (SPP) 进行特征提取。SPP 模块对主干网络 CSPDarknet53 的 C0 层 (19×19×1 024) 分别进行 1×1、5×5、9×9、13×13 的最大池化, 并将池化后得到的 4 个特征图 (19×19×512) 拼接为 1 个特征图 (19×19×2 048), 最后经过多个 CBL 单元 (由 1×1 卷积、BN 层、LeakyRelu 激活函数构成) 进行维度下降, 输出特征层通道数下降至 512 后传入 F0 层。SPP 模块利用不同尺寸的池化层增强网络的感受野, 适用于待检测图像分辨率不统一和同类目标尺寸差异大的情况。在控制箱零件检测任务中, 视觉传感器的输出图像为固定尺寸, 且拍摄方位和距离固定不变, 不存在同型号零件图像目标尺度不一致的问题。因此, SlimYOLO 在颈部结构中移除 SPP 模块并将主干网络输出特征层 C0 传入颈部的 FPN 模块中进行特征融合。由于移除 SPP 模块所包含的多个池化层和相邻的卷积, SlimYOLO 的模型体积得到了有效控制, 使其更加便于在资源有限的嵌入式控制设备上部署。

1.3 Anchor 框参数聚类

图 3 展示了基于 anchor box 的预测框生成过程。

SlimYOLO 沿用 anchor box 机制, 其根据 anchor 框参数在网格点 $A(c_x, c_y)$ 处生成 anchor 框 (虚线框)。模型在对图像进行检测时, 生成 anchor 框校正量, 根据校正量计算, 实




图 3 预测框生成过程

现 anchor 框向预测框(实线框)的校正。该校正过程主要分为两部分,中心的偏移校正、边框的缩放校正,具体计算过程如下公式所示。

中心的偏移校正:

$$b_x = \sigma(t_x) + c_x \quad (1)$$

$$b_y = \sigma(t_y) + c_y \quad (2)$$

$$\sigma(x) = 1/(1 + e^{-x}) \quad (3)$$

边框的缩放校正:

$$b_w = p_w e^{t_w} \quad (4)$$

$$b_h = p_h e^{t_h} \quad (5)$$

其中, t_x 、 t_y 、 t_w 和 t_h 是模型预测时产生校正量, e 为自然底数。

中心的偏移校正: c_x 和 c_y 表示 anchor 框的中心, 式(3)为便于回归计算的 Sigmoid 函数, 通过 Sigmoid 函数计算 anchor 框中心点向预测框中心点的偏移量 $\sigma(t_x)$ 和 $\sigma(t_y)$, 并通过式(1)和(2)分别计算预测框的中心点 b_x 和 b_y 。

边框的缩放校正: p_w 和 p_h 表示 anchor 框的宽和高, 根据式(4)和(5), p_w 和 p_h 将被分别缩放为预测框的宽和高, 即 b_w 和 b_h 。

基于上述公式及相关参数, 图 4 中的 anchor 框对中心点 A 和边框宽高进行校正后, 完成 anchor 框向预测框的转换。

选取合适的 anchor 框参数, 能减少预测过程中的校正, 实现进行更精确的预测^[18]。因此本文对控制箱零件目标大小进行聚类分析, 获取合适的 anchor 框参数。

本文采用 K-means++ 算法对训练数据进行 anchor 框聚类分析。K-means++ 算法聚类步骤如下:

1) 从控制箱零件数据集中剥离数据中所有目标的宽高信息构造聚类算法的输入集合 $D = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m\}$, \bar{x}_i 为二维数据, SlimYOLO 的检测部分含有 3 个 Head 模块, 每个 Head 需要 3 个 anchor 框, 即设定聚类簇数 K 为 9;

2) 聚类中心初始化, 从集合 D 中选取聚类所需的 9 个初始样本数据集 $U = \{\bar{O}_1, \bar{O}_2, \dots, \bar{O}_9\}$, 具体步骤:

(1) 从集合 D 中随机选取 \bar{x}_i 作为初始聚类中心 \bar{O}_1 ;

(2) 计算集合 D 中每个样本 \bar{x}_j 与当前已有聚类中心 \bar{O}_i 之间的最短距离 $L(\bar{x}_j) = \min\{d^2(\bar{O}_i, \bar{x}_j)\}$, 其中, $d^2(\bar{O}_i, \bar{x}_j)$ 表示样本 \bar{x}_j 与聚类中心 \bar{O}_i 的平方欧式距离;

(3) 将 $L(\bar{x}_j)$ 值最大的样本 \bar{x}_j 添加至集合 U, 作为下一个聚类中心;

(4) 重复步骤 2), 直至集合 U 内聚类中心达到 9 个。

3) 然后对输入数据中的每个样本 \bar{x}_i 分别计算它到 9 个聚类中心的距离并将其划分至距离最小的聚类中心所对应的类中;

4) 对所有样本都完成一轮分类后, 重新计算每个类别的聚类中心 $\bar{O}'_i = \frac{1}{|C_i|} \sum_{x \in C_i} x$, 即属于该簇类所有样本

的质心;

5) 重复步骤 3) 和 4), 直至聚类中心不在发生变化, 终止迭代计算, 输出 SlimYOLO 模型所需的 9 个 anchor 框参数。

将聚类分析后得到 9 个的 anchor 框参数按照宽度从小到大进行排序, 分别分配给 SlimYOLO 的头部 3 个特征图 H1(76×76)、H2(38×38)、H3(19×19), 实现对不同大小的控制箱零件检测。

2 实 验

2.1 实验数据集

控制箱零件类别众多, 本文选取其中具有代表性的零件(断路器、按钮、继电器、接触器)进行数据集制作, 共获取控制箱零件图像 2 042 张。实验采用镜像翻转对数据集进行数据增强, 将样本数量扩增 4 倍, 有效增加数据样本的多样性, 防止训练过程中的过拟合现象。对控制箱零件进行数据增强后的效果如图 4 所示。




图 4 增强数据集部分样本

采用 Labelimg 软件对增强后的工机具图像进行人工标注。然后, 将控制箱零件数据集按照 6 : 2 : 2 的比例划分为训练集、验证集和测试集, 用于控制箱零件检测模型的训练。

2.2 实验配置及参数设置

实验在一台显卡服务器上进行, 操作系统为: Ubuntu20.04LTS, 处理器型号为: Intel® Core™ i7-8700 CPU@3.20 GHz, 显卡型号为: NVIDIA GeForce GTX-1080TI11G, 采用 NVIDIA CUDA10.0 加速工具箱, 编译环境为: Python3.6.0, Pytorch1.2.0。实验参数如表 1 所示。

实验采用 K-means++ 聚类算法计算 Anchor 框参数, 最终参数取值为 (45, 100), (59, 156), (71, 75), (83, 192), (99, 112), (129, 181), (145, 99), (184, 218), (201, 143)。

表 1 实验参数设置

参数	值
数据批量	16
输入尺寸	416×416
学习率	0.000 01
迭代次数	100

2.3 评价指标

实验选取平均准确率(mean average precision, mAP)作为 SlimYOLO 模型检测效果的评价指标。AP(average precision)是 Precision-Recall 曲线与横轴合围的面积, mAP 即为模型对数据集中所有类别的 AP 平均值, 计算公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$AP = \sum_{k=1}^N \max_{\tilde{k} \geq k} P(\tilde{k}) \Delta r(k) \quad (8)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (9)$$

式中: TP 表示正样本被模型预测为正样本的数量; TN 表示负样本被模型预测为负样本的数量; FP 表示正样本被模型预测为负样本的数量; FN 表示负样本被模型预测为正样本的数量; N 表示置信度级别值的个数; $P(\tilde{k})$ 表示每一级别对应的最大 Precision 值; $\Delta r(k)$ 表示级别数从 $k-1$ 变化到 k 时, 召回率 Recall 值变化的差值; n 表示控制箱零件的类别数。

表 2 控制箱零件检测结果对比

类别	检测精度			
	SlimYOLO/%	YOLOv4/%	SSD/%	CenterNet/%
按钮	100.00	99.67	97.06	91.01
断路器	95.77	95.99	85.48	83.91
继电器	98.32	99.28	97.63	90.69
接触器	98.32	95.14	95.43	87.02
平均检测精度(mAP)	98.08	97.50	93.90	88.16

由表 2 可以看出, SlimYOLO 对所有检测类别的 AP 精度均在 90% 以上, 最高为 100%。SlimYOLO 的 mAP 为 98.08%, 与 YOLOv4、SSD 和 CenterNet 相比, 分别提高了 0.58%、4.18% 和 9.92%。

上述结果表明, SlimYOLO 虽然采用剪枝策略压缩了模型的体积, 但是在 Anchor 框参数优化等方法的作用下, 模型依然保持了较高的检测精度。

2.6 模型推理速度对比分析

为验证 SlimYOLO 算法在推理速度上的优化效果, 本文用工业相机(IMX686)分别采集了 60 s 480 P、720 P、

2.4 模型训练

实验基于 Pytorch 框架进行 SlimYOLO 模型的训练, 模型采用迁移学习策略进行训练, 主干网络初始权重通过在 VOC_2007 数据集上进行预训练获得。通过加载预训练权重后, 在自主构建的控制箱零件数据集上进行进一步训练, 优化 SlimYOLO 模型参数。

图 5 展示了 SlimYOLO 模型训练过程中损失变化曲线, 横坐标为训练迭代次数, 纵坐标为模型 Loss 值。由图 5 可知, 经过 100 轮迭代训练后, Loss 值不再下降, 模型参数收敛到稳定数值。




图 5 SlimYOLO 模型训练过程 Loss 图

2.5 模型检测精度对比分析

为验证本文方法可靠性, 采用训练好的 SlimYOLO 模型对自主构建的控制箱零件数据中的测试集图像进行图像检测, 设定 IOU 阈值为 0.85, 并与 YOLOv4、SSD、CenterNet 进行对比, 综合评估 SlimYOLO 模型在控制箱零件检测任务中的性能。表 2 分别展示了各类算法对控制箱零件的检测精度。

1 080 P 的控制箱零件视频数据, 分别采用 SlimYOLO 和 YOLOv4 进行视频检测, 通过帧率进行对比分析, 评估 SlimYOLO 的推理效率, 结果如表 3 所示。

表 3 SlimYOLO 推理速度结果对比

视频分辨率	推理速度/(f · s ⁻¹)	
	SlimYOLO	YOLOv4
720×480	29	27
1 080×720	23	21
1 920×1 080	15	14

由表 3 可以看出, SlimYOLO 在进行视频检测的推理速度明显优于 YOLOv4, 其中对分辨率为 $1\ 080 \times 720$ 的视频进行检测时, SlimYOLO 模型的帧率较 YOLOv4 提升了 10%。

2.7 基于 SlimYOLO 的控制箱零件装配缺陷检测应用分析

控制箱零件装配过程要求零件按照规范安装到固定的位置或者保持特定的相对位置关系。如图 6 所示, 本文采用 SlimYOLO 算法自动检测安装在控制箱中的各个零件, 获取零件类别和位置信息, 然后通过位置关系推理实现了多种不合格控制箱零件装配问题的快速检测, 基本满足工业检测场景精度和效率需求。




图 6 控制箱零件检测效果图

上述实验结果表明, SlimYOLO 模型在保证检测精度的前提下大幅缩减了模型体积, 降低了推理预测的运算量, 更适于在资源有限的边缘计算平台上部署。

3 结 论

控制箱零件缺陷检测是智能制造的重要组成部分, 为提高的控制箱零件检测效率, 本文提出了一种基于 SlimYOLO 的控制箱零件检测算法。采用层级剪枝对目标检测模型进行优化, 在保证检测效果的基础上, 大幅降低模型参数。同时, 采用 K-means++ 聚类算法对数据样本的目标尺寸进行分析, 获取针对控制箱零件数据集的 anchor 框参数, 用于目标检测模型的训练与检测。本文将 SlimYOLO 与 YOLOv4 的结果进行对比, SlimYOLO 在检测速度和检测精度上取得了更好的平衡, 更适合部署在工业场景中的设备。本文主要采用剪枝的策略优化模型的体积和时间性能, 在后续研究中将尝试采用 ShuffleNet^[19]、MobileNet^[20]、GhostNet^[21] 等轻量级网络作为 SlimYOLO 模型的主干, 进一步提升模型的效果。

参考文献

[1] 张培培, 王昭, 王菲. 基于深度学习的图像目标检测

算法研究[J]. 国外电子测量技术, 2020, 39(8): 34-39.

- [2] 袁纵青, 徐惠钢, 谢启. 基于机器视觉的汽车零部件检测系统设计[J]. 仪表技术与传感器, 2020(8):57-60,76.
- [3] 杨宏贤, 朱世根, 白云峰, 等. 基于机器视觉的扁平细长带钩零件检测系统研发[J]. 仪表技术与传感器, 2021(5):117-121.
- [4] 杨琳, 陈赛旋, 崔国华, 等. 基于改进 YOLOv4 算法的零件识别与定位[J]. 组合机床与自动化加工技术, 2021(10):28-32,37, DOI:10.13462/j.cnki.mmtamt.2021.10.007.
- [5] 臧春华, 周介祺, 刘桂雄. 基于 Mask R-CNN 实例分割的机械零件识别方法研究[J]. 电子测量技术, 2021, 44(22):32-36.
- [6] 沈新峰, 姜平, 周根荣. 改进 SSD 算法在零部件检测中的应用研究[J]. 计算机工程与应用, 2021, 57(7): 257-262.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [8] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [9] DUAN K, BAI S, XIE L, et al. Centernet: Keypoint triplets for object detection [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6569-6578.
- [10] 余永维, 韩鑫, 杜柳青. 基于 Inception-SSD 算法的零件识别[J]. 光学精密工程, 2020, 28(8):1799-1809.
- [11] 张静, 刘凤连, 汪日伟. 智能装配中基于 YOLO v3 的工业零件识别算法研究[J]. 光电子. 激光, 2020, 31(10):1054-1061.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [13] REDMON J, FARHADI A. Yolov3: An incremental improvement [J]. ArXiv Preprint, 2018, ArXiv: 1804.02767.
- [14] 张明路, 郭策, 吕晓玲, 等. 改进的轻量化 YOLOv4 用于电子元器件检测[J]. 电子测量与仪器学报, 2021, 35(10):17-23.
- [15] WANG C Y, LIAO H, WU Y H, et al. CSPNet: A new backbone that can Enhance Learning Capability of CNN [C]. 2020 IEEE/CVF Conference on Computer

- Vision and Pattern Recognition Workshops (CVPRW), IEEE, 2020.
- [16] HE K, ZHANG X, REN S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9): 1904-1916.
- [17] LIU S, QI L, QIN H, et al. Path Aggregation Network for Instance Segmentation[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2018,8759-8768.
- [18] 刘艳菊, 王秋霖, 赵开峰, 等. 基于卷积神经网络的热轧钢条表面实时缺陷检测[J]. 仪器仪表学报, 2021, 42(12):211-219.
- [19] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018; 6848-6856.
- [20] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2018.
- [21] LYU M, WANG W, WANG H, et al. Deep-learning-based ghost imaging [J]. Scientific reports, 2017, 7(1): 1-6.

作者简介

冯晨光, 硕士研究生, 主要研究方向为图像处理、深度学习、目标检测与识别。

E-mail: 781800634@qq.com

魏巍, 博士, 教授, 主要研究方向为机器人及其自动化。

E-mail: 18933757@qq.com

陈灯(通信作者), 博士, 副教授, 主要研究方向为工业机器人智能化、多媒体数据处理。

E-mail: dchen@wit.edu.cn

张彦锋, 博士, 教授, 博士生导师, 主要研究方向为智能计算(优化)、机器人路径规划、多机器人协作等。

E-mail: zhangyanduo@hotmail.com

刘玮, 博士, 教授, 硕士生导师, 主要研究方向为智能软件工程、服务计算、语义计算等方向的研究。

E-mail: liuwei@wit.edu.cn

栗娟, 博士, 讲师, 主要研究方向为云计算、移动边缘计算、边缘计算、边云协同环境下的资源调度优化策略和任务—资源协同算法研究。

E-mail: juanli2018@wit.edu.cn