

DOI: 10.13382/j.jemi.B2104174

改进的轻量化 YOLOv4 用于电子元器件检测*

张明路 郭 策 吕晓玲 张 艳
(河北工业大学 机械工程学院 300132)

摘 要:针对电子行业制造机器人对电子元器件检测精度低和速度慢的问题,提出基于改进 YOLOv4 的电子元器件检测方法。对网络结构进行改进,利用深度可分离卷积代替 PAN 网络中的传统卷积,提高检测速度;利用一种具有线性瓶颈的逆残差结构代替 CSP darknet53 主干网络,降低模型参数,进一步提高检测效率;在检测网络 YOLO head 前添加注意力机制,提高检测精度。模拟工业传送带环境建立了电子元器件数据集并进行数据增强,相较于原算法,精度(mAP)提高了 1.31%,速度提高了 16.34 fps,权重大小从 245 下降到 41.20 MB。研究可为相关电子行业制造机器人的研制提供技术参考。

关键词:目标检测;深度学习;可分离卷积;注意力机制;电子元器件

中图分类号: TP391.41;TN609 **文献标识码:** A **国家标准学科分类代码:** 520.20

Improved lightweight YOLOv4 for electronic components detection

Zhang Minglu Guo Ce Lv Xiaoling Zhang Yan
(School of Mechanical Engineering, Hebei University of Technology, Tianjin 300132, China)

Abstract: Aiming at the problem of low accuracy and slow speed of electronic components detection by manufacturing robots in the electronics industry, an electronic component detection method based on improved YOLOv4 is proposed. The network structure was improved by using depth-separable convolution instead of the traditional convolution in PAN networks to improve the detection speed. An inverse residual structure with a linear bottleneck was used instead of the CSP darknet53 backbone network to reduce the model parameters and further improve the detection efficiency. An attention mechanism was added before the YOLO head of the detection network to improve the detection accuracy. A data set of electronic components was established to simulate the industrial environment with conveyor belt and the data was enhanced. Compared with the original algorithm, the accuracy (mAP) is increased by 1.31%, the speed is increased by 16.34 fps, and the weight size is reduced from 245 to 41.20 MB. The research can provide technical reference for the development of manufacturing robots in the electronics industry.

Keywords: object detection; deep learning; separable convolution; attention mechanism; electronic components

0 引 言

电子产品需求的持续增长推动了电子制造行业的迅猛发展。但是,电子元器件的分拣和集成工作很大程度依靠人工。实现电子产业的自动化需要对电子元器件进行实时、精准的检测。现有的关于电子行业检测的研究大多依赖传统算法,Hagi 等^[1]利用支持向量机(SVM)进行电路板检测,张永宏等^[2]使用 SIFT 匹配算法进行 PCB

板检测,文献[3]采用图像分割、形态学处理和轮廓拟合等算法进行电子元器件管脚定位。

深度学习算法相比于传统算法具有高效、准确的优势,已逐渐替代传统算法。基于深度学习的目标检测算法可大致分为以 YOLO^[4]和 SSD^[5]为代表的单阶段算法和以 Faster RCNN^[6]为代表的两阶段算法。单阶段算法在牺牲少量精度的前提下取得了较高的检测速度,被广泛应用在工业场景中。文献[7]采用 YOLO 方法对列车轮踏面损伤进行检测,文献[8]对 SSD 算法进行改进来

计算量。因此,引入具有线性瓶颈的逆残差结构代替原有残差块来提高检测效率。

图 2(a) 所示为 CSP darknet53 中的残差块,直接使用两次 3×3 和 1×1 的传统卷积,然后增加一个残差通道使用 Concat 函数按通道方向组合。图 2(b) 所示为改进后的残差块,增加了 1×1 卷积进行升降维操作,构成了线性瓶颈结构,文献[22]表明,瓶颈结构可以有效减少计算量,加深神经网络,有效、直观地进行网络训练及特征提取。由式(2)和(4)可知,在通道数较多时,可分离卷积可以更好地减少参数量,因此将降维后的传统卷积替换成深度可分离卷积。




图 2 主干特征提取网络的改进

Fig. 2 Improvement of backbone feature extraction network

2.3 对检测器的改进

特征融合网络获得的卷积层经多次融合后通道数最多可达 1 792 个,不加区分地送入检测器,容易造成信息冗余,重要信息无法得到充分训练。因此,需要使用注意力机制学习不同通道的重要性,为不同通道添加动态权重。




图 3 注意力模块

Fig. 3 Attention module

在每个检测层前都添加了图 3 所示的注意力模块,对输入大小为 $W \times H \times N$ 的特征层,首先利用全局平均池化对进行压缩,如式(5)所示。

$$Z_N = F_{sq}(U_N) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H U_N(i, j) \quad (5)$$

式中: U_N 表示第 N 个通道的大小为 $W \times H$ 的矩阵,对每个通道所对应的二维矩阵都进行全局平均池化,可得到大小为 $1 \times 1 \times C$ 的矩阵,对应每个通道上的全局信息。

然后,利用激活操作获得各通道之间的相关性,如式(6)所示。

$$S_N = F_{ex}(Z, W) = \sigma(W_2 \delta(W_1 Z)) \quad (6)$$

式中: W_1 和 W_2 分别表示一个全连接的操作,来实现各通道特征信息的映射; σ 和 δ 分别表示 Sigmoid 和 Relu 激活函数。这样最终得到了各通道之间的权重 S ,与输入特征层 U 相乘得到最终输出 X ,每个通道计算如式(7)所示。

$$X_N = F_{scale}(U_N, S_N) = S_N \times U_N \quad (7)$$

3 实验与分析

3.1 数据集的建立

目前尚无较为完备的公开电子元器件数据集,因此,模拟电子制造工业环境,搭建了如图所示的电子元器件视觉检测平台。将电阻、发光二极管等 14 种零件置于运动的传送带上进行图像采集,共得到了 6 326 张图片。深度学习的成功依赖于庞大的数据规模,数据量越大模型泛化能力越强。采集到的数据很难覆盖到电子元器件检测的全部场景,如元器件角度位置的变化、运动模糊、光照条件、噪声影响等。

文献[23]指出,庞大的图像数据库有利于深度学习方法的发展。因此,在建立电子元器件数据集时,提出了一种适合于电子元器件检测的数据增强方法,来扩充数据集,提高模型泛化能力。数据增强方法如图 4 所示,为了适应电子元器件角度位置的变化,进行了图 4(b)~(d)所示的旋转和翻转操作。对部分图像添加了如图 4(e)所示高斯噪声来适应噪声影响,添加了图 4(f)所示的模糊处理来适应运动模糊现象。最后,考虑到不同光照度的影响,进行图 4(g)、4(h)所示的光照度变换。最终扩充至 12 652 张图片。




图 4 数据增强方法

Fig. 4 Data enhancement method

3.2 实验设置

所用计算机硬件系统由 Intel Core i7-8700 CPU, NVIDIA TITAN Xp GPU, 32 GB RAM 组成。使用的操作系统为 Windows10, 编译环境为 tensorflow1. 13. 1 以及 keras2. 1. 5 深度学习环境。

模型输入分辨率将统一转换成 (608, 608, 3), 学习率采用余弦退火衰减方式, 初始学习率设置为 $1 \times e^{-4}$, 最低衰减学习率为 $1 \times e^{-6}$ 。考虑到显卡计算能力, 冻结主干提取特征层训练 50 代, 对应的训练批次大小为 16。然后解封训练 50 代, 对应批次大小为 8。为了改善随机初始化时聚类结果不稳定的问题^[24], 对电子元器件数据集进行了 Kmeans++ 聚类分析, 最终得到预设锚点框为 (10, 14)、(23, 27)、(37, 58)、(81, 82)、(135, 169)、(344, 319)。YOLOv4 损失函数由分类损失、置信度损失、位置损失三部分组成, 实验采用原算法的损失函数。

3.3 评价指标

采用目标检测常用的准确率 (precision)、召回率 (recall)、精准率和召回率的调和平均数 F1、平均精度 (mean average precision, mAP)、每秒检测图片数量评价所提方法。

准确率和召回率的计算如下:

$$precision = \frac{TP}{TP + FP} \tag{8}$$

$$recall = \frac{TP}{TP + FN} \tag{9}$$

式中: TP (true positive) 代表模型预测为正样本且实际预测正确; FP (false positive) 代表模型预测为负样本且检测正确; FN (false negative) 代表模型预测为负样本且检测错误。因此, 准确率代表模型判断的所有正样本中正确预测的比例, 召回率代表实际正样本中模型检测正确预测的比例。

平均精度被定义为准确率与召回率曲线相对于坐标轴的面积。F1 表示精准率和召回率的调和平均数, 公式如下:

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \tag{10}$$

3.4 结果与分析

将所提方法与原 YOLOv4 算法与 YOLOv4 算法的轻量化版本 YOLOv4 Tiny 在电子元器件数据集上进行了精度对比, 结果统计如表 1 所示。由表 1 可知, 所提算法与 YOLOv4 相比准确率下降了 2. 26%, 但召回率提升较大, 提高了 13. 93%。相比于 YOLOv4 在 F1 和 mAP 分别提升了 5. 84% 和 1. 31%, 总体性能更好。而 YOLOv4 的 Tiny 版本精度下降明显, mAP 下降了 6. 94%。

参数量和权重大小与检测速度如表 2 所示。从表 2

表 1 算法精度对比

Table 1 Algorithm accuracy comparison (%)				
方法	Precision	Recall	F1	mAP
YOLOv4	84. 44	71. 70	78. 07	88. 25
YOLOv4 Tiny	72. 05	79. 71	75. 88	81. 29
本文	82. 18	85. 63	83. 91	89. 56

可看出, 所提算法参数量约为原算法的 1/6, 权重大小从 245 减少到 41. 20 MB, 因此速度有较大的提升, 从 24. 86 提高到了 41. 20 fps。而 YOLOv4 的 Tiny 版本由于网络更为精简, 参数量和权重大小最小, FPS 相对于所提算法高出 3. 86。但其精度下降明显, 因此并不适合电子元器件检测任务。

表 2 算法计算效率对比

Table 2 Algorithm calculation efficiency comparison			
方法	Parameters	Weight/MB	速度/fps
YOLOv4	64, 429, 405	245	24. 86
YOLOv4 Tiny	6, 943, 389	22. 6	45. 06
本文	10, 872, 893	40. 9	41. 20

为了验证不同改进方法的有效性, 共进行了四组消融实验, 实验结果统计在表 3 中。可以看出, 第 2 组实验中利用线性瓶颈结构对主干网络进行改进, 在 mAP 仅有 1. 68% 下降的情况下, 速度从 24. 86 提高到了 30. 45 fps, 提高了计算效率。而第 3 组实验中, 对特征融合网络用可分离卷积代替原有卷积, 从 30. 45 提升到 42. 21 fps, 在几组实验中速度最高, 但精度从 88. 25% 下降到 84. 20%。

为了弥补效率提升带来的精度下降问题, 在第 4 组实验中对检测器进行了改进, 引入了注意力模块, 虽然速度从 42. 21 下降为 41. 20 fps, 但精度提高到了 89. 56%, 达到了速度和精度的平衡。这一结果更适合电子行业机器人对电子元器件的检测。

表 3 消融实验结果

Table 3 Results of ablation experiments					
NET	CSP darknet53	PANet	YOLO Head	mAP/%	速度/fps
1	×	×	×	88. 25	24. 86
2	√	×	×	86. 57	30. 45
3	√	√	×	84. 20	42. 21
4	√	√	√	89. 56	41. 20

为了验证所提方法的有效性, 与其他先进算法及其他改进 YOLOv4 算法进行了对比, 结果如表 4 所示。从表 4 可以看出, Faster RCNN 等双阶段算法精度较高, 相比于 SSD300 精度高出了 4. 98%。但双阶段算法效率严重不足, FPS 仅为 5. 52, 无法满足实时应用。从表 4 中可以看出, YOLOv4 框架更适合电子元器件检测。所提算

法相比于目前其他先进算法在精度和效率上都取得了优秀的表现。文献[11]所提方法在部署到电子元器件数据集时,剪枝算法起到了较大幅度减少模型参数的作用,速度有了明显提升。由于专用领域不同,检测精度还需进一步优化。文献[12]所提方法在电子元器件数据集上保证了精度,检测速度还需进一步优化。文献[13]所提方法在检测速度上取得了一定提升,检测精度仍需根据不同专用任务进一步优化。相比上述方法,本文所提方法在电子元器件检测任务上更趋于速度和精度的平衡,更适用于电子行业机器人的视觉检测任务。

表 4 与其他先进算法对比结果

方法	mAP/%	速度/fps
Faster RCNN	81.54	5.52
SSD300	74.52	14.56
RefineDet	79.35	16.78
EffientDet-D0	85.69	21.56
Centernet	82.45	11.24
文献[11]	85.35	46.35
文献[12]	88.34	26.59
文献[13]	84.59	28.25
本文	89.56	41.20

为了验证所提算法的有效性,在目前已经公开的COCO数据集上进行了测试。COCO数据集是当前评价目标检测性能的常用数据集,由微软公司制作,包含80个类别的物体,共有超过11万张图片。将所提算法和原算法分别在COCO2017训练集上进行了训练,将IOU阈值设为0.5,保持实验环境不变进行了实验。在COCO2017测试集上进行测试,结果如表5所示。从表5可以看出,在公开的通用数据集上,所提方法仍起到了减小参数,提高模型效率的作用。权重大小由247减少到了43.2 MB,速度从20.39提高到了40.59 fps。但是相比于专用电子元器件数据集,注意力机制的作用有所减弱,精度有4.15%的下降。

表 5 在 COCO 数据集上的对比

方法	Weight/MB	mAP/%	速度/fps
YOLOv4	247	70.5	20.39
本文	43.2	66.35	40.59

测试集中的部分检测效果如图5所示,本文所提算法在运动模糊、噪声影响等复杂场景下均检测出了电子元器件,取得了较好表现。




图 5 测试集测试结果

Fig. 5 The test set tests the results

4 结 论

本文利用 YOLOv4 算法代替传统算法实现了电子行业机器人对电子零部件的检测。通过引入深度可分离卷积减少了参数,简化了神经网络的计算,较大幅度提高了效率。在主干网络增加了1×1卷积的升降维操作构成瓶颈结构,用3×3的深度可分离卷积替代原有卷积,进一步减少了网络运算量。通过引入注意力机制对检测器进行改进,来改善参数减少带来的精度下降,实现精度和速度的平衡。通过实验对比发现,相比于原算法,在电子元器件数据集上取得了更优秀的表现。研究可为相关电子行业机器人的研制提供技术参考。在后续研究中,将进一步探索损失函数对于模型精度的影响,进一步提高检测效果。

参考文献

[1] HAGI H, IWAHORI Y, FUKUI S, et al. Defect classification of electronic circuit board using SVM based on random sampling[J]. Procedia Computer Science, 2014, 35: 1210-1218.

[2] 张永宏, 黄晓华. 基于 SIFT 匹配算法的 PCB 板缺陷检测[J]. 计算机测量与控制, 2012, 20(9):2328-2330.

ZHANG Y H, HUANG X H. PCB board defect detection based on SIFT matching algorithm [J]. Computer Measurement and Control, 2012, 20(9):2328-2330.

[3] 王越. 基于机器视觉的异型电子元器件插装技术研究及实现[D]. 北京: 机械科学研究总院, 2016: 27-46.

WANG Y. Research and implementation of special-shaped electronic component plug-in technology based on machine vision [D]. Beijing: Central Academy of Mechanical Sciences, 2016: 27-46.

- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision, Springer, 2016: 21-37.
- [6] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] 何静, 余昊宇, 张昌凡, 等. 基于 Canny-YOLOv3 的列车轮对踏面损伤检测[J]. 电子测量与仪器学报, 2019, 33(12): 25-30.
- HE J, YU H Y, ZHANG CH F, et al. Detection of train wheel tread damage based on canny-Yolov3 [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 25-30.
- [8] 张业宝, 徐晓龙. 基于改进 SSD 的安全帽佩戴检测方法[J]. 电子测量技术, 2020, 43(19): 80-84.
- ZHANG Y B, XU X L. A safety helmet wearing detection method based on improved SSD[J]. Electronic Measurement Technology, 2020, 43(19): 80-84.
- [9] 韩航迪, 徐亦睿, 孙博, 等. 基于改进 Tiny-YOLOv3 网络的航天电子焊点缺陷主动红外检测研究[J]. 仪器仪表学报, 2020, 41(11): 42-49.
- HAN H D, XU Y R, SUN B, et al. Research on active infrared detection of solder joint defects in aerospace electronics based on improved Tiny-YOLOv3 network[J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 42-49.
- [10] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection [J/OL]. [2020-04-24]. <https://arxiv.org/abs/2004.10934>.
- [11] YU Z W, SHEN Y G, SHEN C H. A real-time detection approach for bridge cracks based on YOLOv4-FPM[J]. Automation in Construction, 2021, 122: 103514.
- [12] CHEN W, LU S, LIU B, et al. Detecting citrus in orchard environment by using improved YOLOv4[J/OL]. Scientific Programming: 1-13 [2020-11-25]. <https://www.hindawi.com/journals/sp/2020/8859237/>.
- [13] WU L, MA J, ZHAO Y, et al. Apple detection in complex scene using the improved YOLOv4 model[J]. Agronomy. 2021, 11(3): 476.
- [14] 高伟, 周宸, 郭谋发. 基于改进 YOLOv4 及 SR-GAN 的绝缘子缺陷辨识研究[J/OL]. 电机与控制学报: 1-11 [2021-05-19]. <http://kns.cnki.net/kcms/detail/23.1408.TM.20210518.1550.014.html>.
- GAO W, ZHOU CH, GUO M F. Research on insulator defect identification based on improved YOLOV4 and SR-GAN [J/OL]. Journal of electrical and control: 1-11 [2021-05-19]. <http://kns.cnki.net/kcms/detail/23.1408.TM.20210518.1550.014.html>.
- [15] 邱志斌, 朱轩, 廖才波, 等. 基于目标检测的电网涉鸟故障相关鸟种智能识别[J/OL]. 电网技术: 1-9 [2021-05-19]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0133>.
- QIU ZH B, ZHU X, LIAO C B, et al. Power grid based on target detection wading bird fault related intelligent recognition [J/OL]. Grid technology: 1-9 [2021-05-19]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0133>.
- [16] ZHANG S, WEN L, BIAN X, et al. Single-shot refinement neural network for object detection[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018.
- [17] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] 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.
- [19] 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.
- [20] REDMON J, FARHADI A. YOLOv3: An incremental improvement[C]. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2018: 2767-2773.
- [21] 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), 2018: 4510-4520.
- [22] HE K M, ZHANGX Y, REN S Q, et al. Deep residual learning for image recognition[J]. Computer Vision and Pattern Recognition, 2016: 770-778.
- [23] LIU X, CHEN B M. An approach to synthesize diverse underwater image dataset [J]. Instrumentation, 2019, 6(3): 67-75.
- [24] 解尧婷, 张丕状. 基于改进的 YOLOv4 输电线路小目标检测[J]. 国外电子测量技术, 2021, 40(2): 47-51.
- XIE Y T, ZHANG P ZH. Small target detection based on improved YOLOv4 transmission line[J]. Foreign Electronic Measurement Technology, 2021, 40(2): 47-51.

作者简介



张明路, 1985 年于河北工业大学获得学士学位, 1988 年于河北工业大学获得硕士学位, 1997 年于天津大学获得博士学位, 现为河北工业大学教授, 主要研究方向为机器视觉、特种机器人技术。

E-mail: zhangml@hebut.edu.cn

Zhang Minglu received his B. Sc. degree from Hebei University of Technology in 1985, M. Sc. degree from Hebei University of Technology in 1988, and Ph. D. degree from Tianjin University in 1997. Now he is a professor at Hebei University of Technology. His main research interests include machine vision and special robotics.



吕晓玲 (通信作者), 2004 年于河北工业大学获得学士学位, 2007 年于河北工业大学获得硕士学位, 2010 年于河北工业大学获得博士学位, 现为河北工业大学讲师, 主要研究方向为计算机视觉、智能机器人。

E-mail: lxl000418@163.com

Lv Xiaoling (Corresponding author) received her B. Sc. degree from Hebei University of Technology in 2004, M. Sc. degree from Hebei University of Technology in 2007, and Ph. D. degree from Hebei University of Technology in 2010. Now she is a lecturer at Hebei University of Technology. Her main research interests include computer vision and intelligent robotics.