

文章编号: 2095-2163(2023)10-0029-06

中图分类号: TP391

文献标志码: A

基于改进 Yolov5 算法的地铁车辆轴箱盖螺栓定位方法研究

朱久牛¹, 李立明^{1,2}, 柴晓冬^{1,2}, 郑树彬^{1,2}, 彭乐乐^{1,2}, 吕 晟³

(1 上海工程技术大学 城市轨道交通学院, 上海 201620; 2 上海工程技术大学 上海市轨道交通振动与噪声控制技术工程研究中心, 上海 201620; 3 上海地铁维护保障有限公司, 上海 200031)

摘要: 针对传统算法在地铁车辆轴箱盖螺栓检测任务中出现模型体积和模型参数较大的问题, 本文提出了一种改进 Yolov5s 算法, 采用 GhostNet 残差结构思想和挤压激励, 构建一个 GGS 模型结构作为主干, 在多尺度融合时使用深度可分离卷积进行降维和降采样的轻量化的目标检测网络算法。实验结果表明, 本文基于改进 Yolov5 网络在螺栓定位平均精确度达到了 72%, Yolov5 网络提升了 2.8%, 网络模型尺寸更是减少到 5.6 m, 相比于 Yolov5s 网络模型降低了 62.2%, 相对 Yolov5s 网络精度无损失的情况下, 本文的网络的模型尺寸和模型参数大幅度下降。

关键词: GhostNet 残差结构; 挤压激励; 深度可分离卷积; 螺栓定位

Research on localization method of axle box cover bolts of subway vehicles based on improved Yolov5 algorithm

ZHU Jiuniu¹, LI Liming^{1,2}, CHAI Xiaodong^{1,2}, ZHENG Shubin^{1,2}, PENG Lele^{1,2}, LV Sheng³

(1 School of Urban Railway Transportation, Shanghai University of Engineering Science, Shanghai 201620, China; 2 Shanghai Engineering Research Centre of Vibration and Noise Control Technologies for Rail Transit, Shanghai University of Engineering Science, Shanghai 201620, China; 3 Shanghai Metro Maintenance Guarantee Co., Ltd., Shanghai 200031, China)

[Abstract] To address the problem of large model volume and model parameters in the traditional algorithm for subway vehicle axle box cover bolt detection tasks, an improved Yolov5s algorithm is proposed. Our method uses the GhostNet residual structure idea and squeeze excitation to construct a GGS model structure as the backbone. The model uses depthwise separable convolution for feature down-sample during the process of multi-scale feature fusion. Experimental results show that the algorithm achieves an average precision of 72% in locating the bolts (a 2.8% improvement over the original network) with the network model size reduced to 5.6 m (a 62.2% reduction compared to the Yolov5s network model). With no loss of accuracy compared to the Yolov5s algorithm, a significant reduction in model size and model parameters is achieved in this paper.

[Key words] GhostNet residual structure; squeeze excitation; depthwise separable convolution; Locating bolts

0 引言

中国城市快速建设, 城市轨道交通飞速发展, 其数量每一年都在急速增加, 也带来了诸多挑战^[1]。截至 2021 年末, 上海城轨交通数量超 7 000 辆, 其中 9 号线车辆数量达到 600 多辆, 约占上海城轨交通数量的 8.57%。维修车辆是轨道交通基础设施维护的重要措施, 从而使列车检测尤其重要^[2]。比如地铁车辆轴箱螺栓的检修和维护, 地铁车辆轮与侧架连接在一起的装置是轴箱, 承受车辆重量、传递各方作用力的作用^[3]。螺栓用来链接轴箱体和轴箱前盖, 螺栓预紧力过大将导致轴箱体螺纹孔损坏和

轴箱前盖发生塑性变形甚至断裂, 螺栓预紧力过小则导致车辆运行过程中轴承窜动而损坏^[4]。在传统轴盖螺栓检测有两种方法: 停车列检和定期段检。中国拥有庞大的地铁车辆, 在车辆的检修与维护过程中, 带来了人员配置的巨大压力和高成本。在对螺栓检测的方法中, 李静等^[5]对转向架心盘螺栓图像进行了区域分割和特征提取, 然后用分类器训练, 定位螺栓, 以此来判别螺栓故障状态; 陈燕等^[6]利用数字图像的检测技术和 Hough 变化检测螺栓缺失时边缘特征, 从而判别螺栓缺失故障。以上研究是利用传统方法识别螺栓的缺失故障, 精度较低, 误检率较高。近年来, 卷积神经网络在计算机视觉领域的图像

基金项目: 国家自然科学基金(51975347, 51907117); 上海市科技计划项目(22010501600)。

作者简介: 朱久牛(1997-), 男, 硕士研究生, 主要研究方向: 交通通信与智能信息处理; 李立明(1982-), 男, 博士, 高级实验师, 硕士生导师, 主要研究方向: 轨道检测、图像处理、深度学习。

收稿日期: 2022-10-22

处理方法中流行,王振等^[7]以 YOLOv3 网络为基础,检测出图像序列中的螺栓组件目标位置;陈健雄等^[8]利用 YOLOv2 网络寻找连接板的位置信息,实现螺钉头部与连接板边缘的分割,从而判别螺钉状态。以上研

究模型检测的精度得到提升,但网络模型复杂,不够轻量化。因此,本文在不损失精度情况下,针对网络模型的轻量化,提出一种基于改进 YOLOv5s 算法的车辆轴箱盖螺栓定位模型,如图 1 所示。

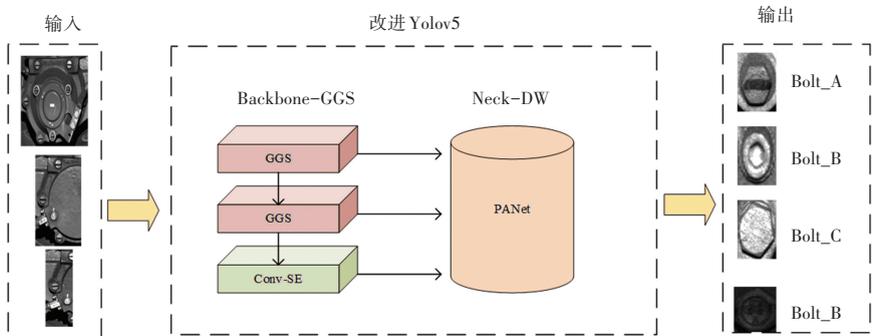


图 1 基于改进 YOLOv5s 算法的车辆轴箱盖螺栓定位模型

Fig. 1 Vehicle axle box cover bolt localization model based on improved YOLOv5s algorithm

1 网络模型

YOLOv5s 网络利用 CSPNet (Cross Stage Partial Network) 结构构建两种不同的结构,实现特征提取和特征融合,导致网络深度较复杂,模型体积较大。本文采用 GhostNet 残差结构和挤压激励 (Squeeze Excitation, SE) 模块构建 GGS (Ghost-Ghost-SE) 模型应用在原 YOLOv5s 主干网络中的 8 倍、16 倍下采样和特征提取,并在 32 倍下采样和空间池化操作 (Spatial Pyramid Pooling, SPP) 后增加一个 SE 模块。在 PANet (Path Aggregation Network) 结构中使用步长为 1 的 Ghost 瓶

颈结构、 1×1 和 3×3 的深度可分离卷积构建一个自下而上的路径多尺度融合框架;在 32 倍降采样特征进行特征融合、降维、上采样操作,然后与 16 倍降采样特征进行特征拼接,得到的拼接特征进行降采样,再按照相同的操作与 8 倍下采样特征进行特征拼接、降维;降维时产生的特征分别是 p_1 、 p_2 、 p_3 ,尺寸分别是 13×13 、 26×26 、 52×52 ; p_3 经过特征融合得到 P_3 , P_3 降采样得到的特征与 p_2 拼接,得到的尺寸进行特征融合得到 P_2 , P_2 降采样得到的尺寸与 p_1 拼接,得到的尺寸进行特征融合得到 P_1 , P_1 、 P_2 和 P_3 卷积生成大小尺寸为 $13 \times 13 \times 30$ 、 $26 \times 26 \times 30$ 、 $52 \times 52 \times 30$,网络结构如图 2 所示。

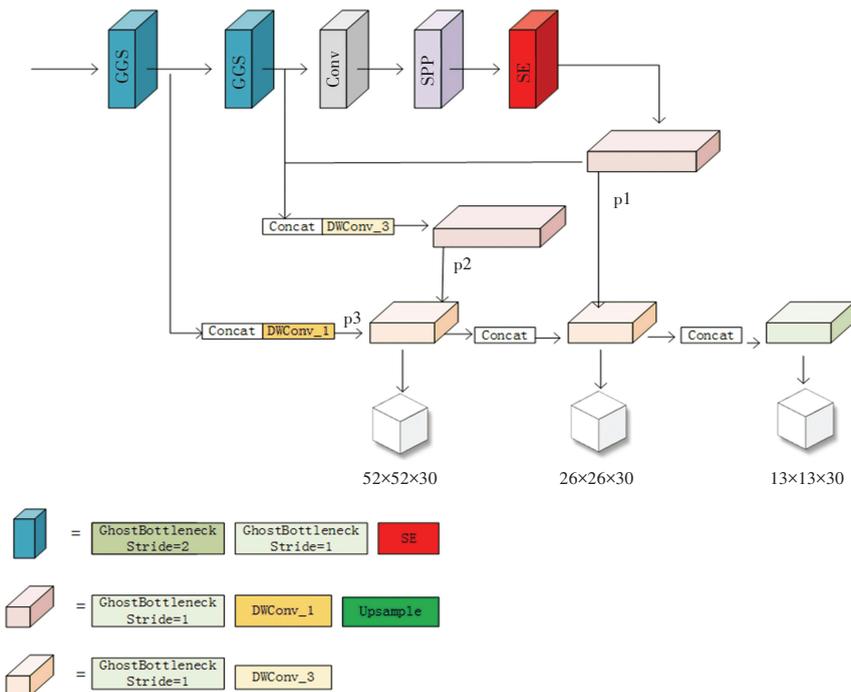


图 2 改进 YOLOv5 网络结构

Fig. 2 Improved YOLOv5 network structure

1.1 GGS 模型

Ghost 残差结构是将特征经过一次普通卷积生成部分特征,生成的部分特征再进行廉价的线性变化,生成另一部分特征,两部分特征叠加得到新的特征^[9]。为了充分利用特征通道中包含的重要信息,

引入了 SE 模块。先用 2 个 Ghost 模块、步长为 2 的深度可分离卷积和短接组成一个步长为 2 的 Ghost 瓶颈,再用 2 个 Ghost 模型和短接组合一个步长是 1 的 Ghost 瓶颈,最后与 SE 模块连接。Ghost 模型和 GGS 模型结构,如图 3 所示。

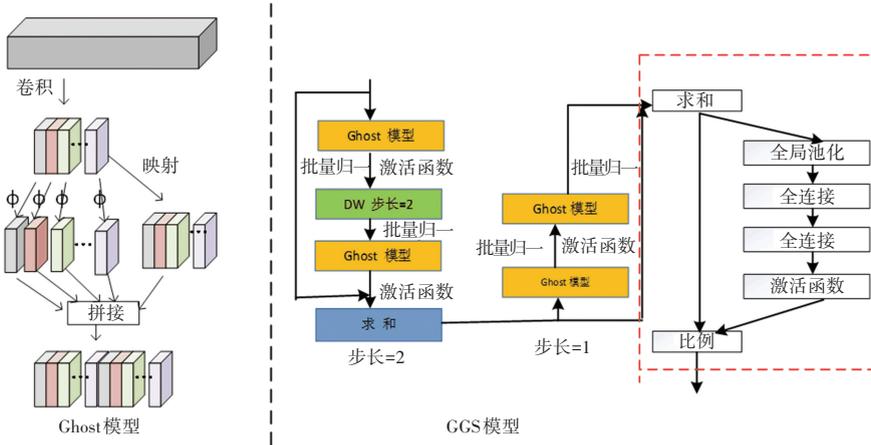


图 3 Ghost 模型和 GGS 模型结构图

Fig. 3 Structure diagram of Ghost model and GGS model

在 GGS 模型中,输入特征先进行步长为 2 的 Ghost 瓶颈降采样,再进行步长为 1 的 Ghost 瓶颈特征提取;经过全局池化得到挤压特征,使之具有全局感受野、降维,经过全连接 (Fully Connection, FC)、全连接、通过 Sigmoid 激活函数将权重归一化;最后进行比例操作对特征进行权值评估,以便更加集中

重要的特征表达。

利用构建轻量高效的 GGS 模型替换原 Yolov5s 网络的主干网络的部分卷积和 CSPNet 结构,使其能够更好地表达特征和聚合感受野的特征,改进后网络的主干网络结构如图 4 所示([3,2]表示卷积核尺寸大小为 3,步长为 2),虚框为 GGS 模型结构。

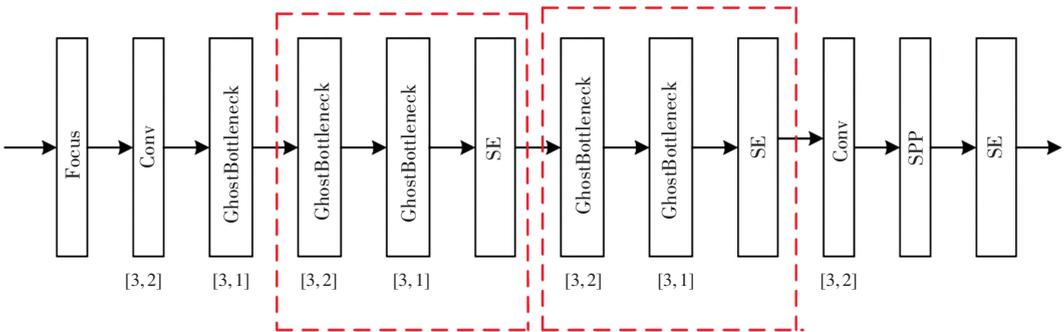


图 4 改进网络的主干网络结构

Fig. 4 Backbone network structure of the improved network

本文网络和原网络的主干网络结构的参数对比见表 1,使用 GGS 模型结构作为改进网络的主干网

络,实现了参数量大幅度的降低。

表1 改进前后主干网络模型参数对比

Tab. 1 Comparison of backbone parameters before and after improvement

主干网络(前)	步长	参数量	主干网络(后)	步长	参数量	参数减少/%
Conv	3	73,984	GhostBottleneck	2	18,784	74.61
CSP		161,152	GhostBottleneck	1	32,928	79.57
			SE		2,048	-
Conv	3	295,424	GhostBottleneck	2	66,240	77.58
CSP		641,792	GhostBottleneck	1	115,008	82.08
			SE		8,192	--
Conv	3	1,180,672	Conv	3	1,180,672	-
SPP		656,896	SPP		656,896	-
			SE		32,768	--
total		3,009,920	total		2,113,536	29.78

1.2 深度可分离卷积

原 YOLOv5s 网络在 PANet 结构中使用普通卷积进行降维和降采样,导致其结构模型参数较多、计算量较大。为了不降低网络检测精度,本文引用深度

可分离卷积替代普通卷积,降低网络参数数量和计算量,将输入特征先进行深度卷积 (Depthwise Convolution, DW),得到的特征在进行逐点卷积,输出最终结果。深度可分离卷积结构如图 5 所示。

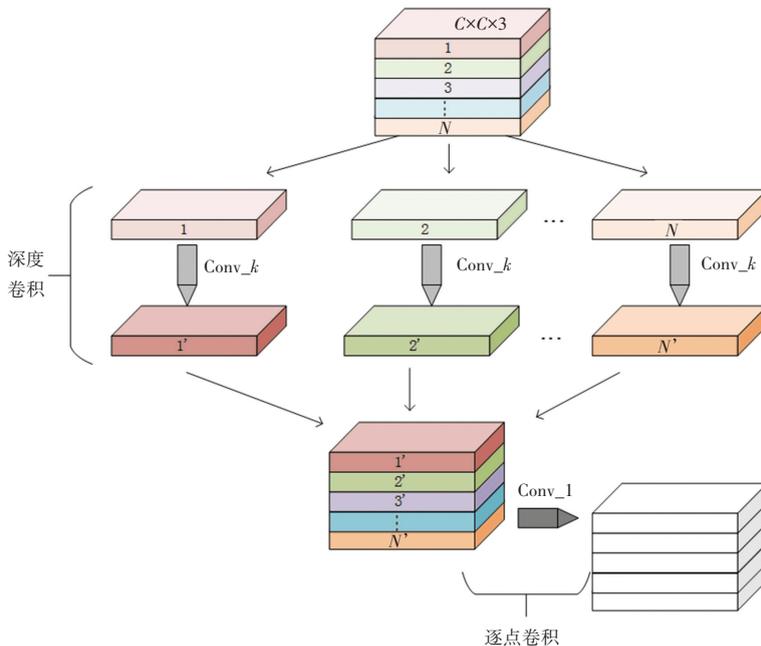


图5 深度可分离卷积结构

Fig. 5 Depthwise separable convolution structure

普通卷积的计算量,式(1):

$$n_{std} = C \times C \times 3 \times k \times k \times N \quad (1)$$

深度可分离卷积的计算量,式(2):

$$n_{dsc} = (k \times k + 1 \times 1 \times N) \times C \times C \times 3 \quad (2)$$

其中, C 表示输入特征的尺寸; k 表示卷积核的尺寸; N 表示输入特征的通道数量。

深度可分离卷积和普通卷积计算量之比,式(3):

$$F = \frac{n_{dsc}}{n_{std}} = \frac{1}{N} + \frac{1}{k^2} \quad (3)$$

一般情况下, N 值很大, k 值设置为 3, 所以深度可分离卷积和普通卷积计算量之比约为 1/9。

在改进网络的 PANet 中,用步长是 1 的 Ghost 瓶颈结构、 1×1 和 3×3 的深度可分离卷积进行特征融合、通道维度变换、降采样。前后 PANet 网络结构参数量对比见表 2。可见改进的 PANet 模型结构每一行的参数量相对原算法的 PANet 结构都有实质性的大幅度的降低,改进的模型参数量的总和是原算法参数量总和的 1/9 左右。

表 2 改进前后 PANet 结构模型参数对比

Tab. 2 Comparison of model parameters in PANet before and after improvement

PANet 结构(前)	参数量	PANet 结构(后)	步长	参数量	参数减少/%
CSP	1,248,768	GhostBottleneck	1	142,208	88.61
Conv	131,584	DWConv	1	1,024	99.22
		DWConv	3	5,120	-
CSP	378,624	GhostBottleneck	1	38,336	89.88
Conv	33,024	DWConv	1	512	98.45
		DWConv	1	512	--
CSP	95,104	GhostBottleneck	1	10,976	88.46
Conv	147,712	DWConv	3	31,360	78.77
CSP	313,088	GhostBottleneck	1	38,336	87.75
Conv	590,336	DWConv	3	62,720	89.37
CSP	1,248,768	GhostBottleneck	1	142,208	88.61
total	4,187,008	total		473,312	88.69

2 实验结果与分析

2.1 数据集的建立

本文试验使用的数据集是利用 360° 动态图像检测系统采集上海 9 号线地铁车辆轴箱盖图像, 一共采集 370 张具有轴箱盖的图像。按照比例 8:1:1 的方式, 训练集有 296 张, 验证集有 37 张, 测试集有 37 张。由于螺栓样本数据较少, 因此在训练时采用 Mosaic 数据增强方式, 丰富数据集的同时极大的提升网络的训练的速度, 提高最终的检测效果, 降低模型的内存需求, 有效抑制模型过拟合程度。

2.2 评价指标

本文模型性能评估指标为精度 (P), 平均精度 (Average Precision, AP), 平均精度均值 (mean Average Precision, mAP)。精度的计算, 式(4):

$$P = \frac{TP}{TP + FP} \quad (4)$$

其中, TP 表示真阳率, FP 表示假阳率。

平均精度为不同召回率下精确率的平均值。平均精度均值是不同类别平均精度的平均值, 用来评价某一类的检测精度, 评价网络模型的整体性能, 式(5):

$$mAP = \frac{\sum_{i=0}^n AP(i)}{n} \quad (5)$$

其中, n 为检测目标类别数, $AP(i)$ 为某一类的检测精度。

本文使用 $mAP@0.5$, 即设置 IoU 阈值为 0.5 得到的 mAP 。

2.3 实验结果

分别使用 Yolov5s 算法、Yolov5-ghost 算法和 Yolov5-GGS-DW (本文) 算法定位螺栓, 各算法的模

型参数和模型尺寸如图 6 所示, 可见算法模型参数量和模型尺寸越来越小, 以及本文网络模型参数量是 Yolov5s 网络模型参数量的 1/3 左右, 模型尺寸比 Yolov5s 网络模型尺寸的一半还要小。3 种算法的损失函数曲线如图 7 所示, 训练网络时设置 IoU 的阈值为 0.5, 每一种算法训练 500 次。由图 7 可见, 在训练次数到达 200 次, 算法的损失函数值的收敛值趋于 0。

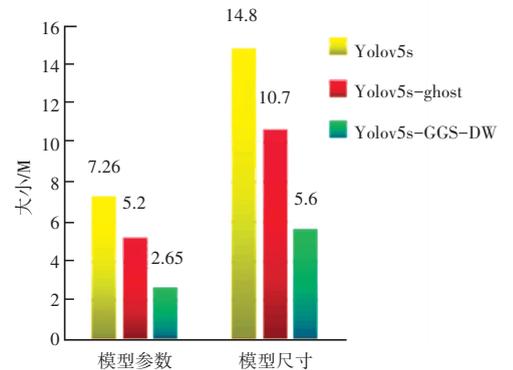


图 6 3 种算法模型参数和模型尺寸的对比

Fig. 6 Comparison of model parameters and model size of three algorithms

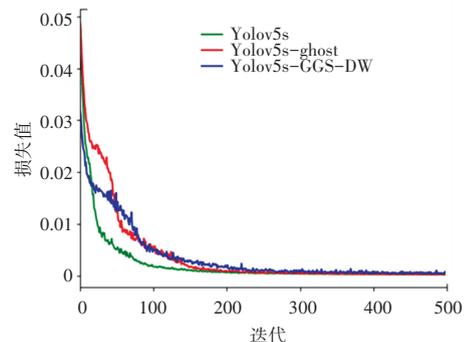


图 7 3 种算法的损失函数曲线

Fig. 7 Loss curves of three algorithms

使用不同算法各种类螺栓的平均精度见表3, 本文算法中的螺栓种类 Bolt_A 的平均精度比其他两种算法高, Bolt_B 的平均精度与 YOLOv5s 算法一致, 螺栓种类 Bolt_C 和 Bolt_D 的平均精度相对较低, 本文算法的平均精确度值为98.6%, 相对于另外两种算法的平均精度均值基本没有什么损失。

表3 YOLOv5s 算法、YOLOv5s-ghost 算法和 YOLOv5s-GGS-DW 算法各种类检测平均精度对比

Tab. 3 Comparison of the average accuracy of YOLOv5s, YOLOv5s-ghost and YOLOv5s-GGS-DW

网络模型	Bolt_A	Bolt_B	Bolt_C	Bolt_D
YOLOv5s	99.5	97.8	99.6	99.5
YOLOv5s-ghost	99.7	96.1	99.6	99.5
YOLOv5s-GGS-DW	99.7	97.8	98.6	98.3

使用本文算法对城市轨道交通车辆的轴箱盖螺栓定位检测, 如图8所示, 每一种类别的螺栓的定位框的置信度大部分在80%以上, 可以用来判断螺栓是否存在。

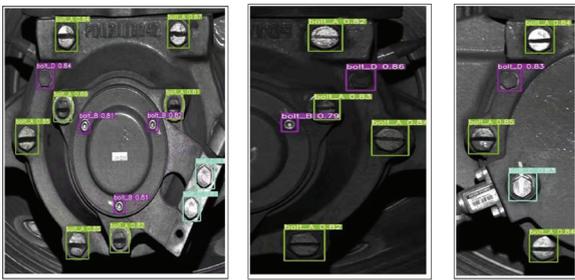


图8 螺栓定位

Fig. 8 Bolt location

本文运用了精度 (P)、浮点运算 (giga floating point operations persecond, gflops)、 $mAP50$ 的数值进行模型性能指标对比, 见表4。

表4 3种算法的性能指标对比

Tab. 4 Comparison of the performance metrics of the three algorithms

网络模型	$P/\%$	gflops	$mAP50/\%$
YOLOv5s	99.3	16.8	99.1
YOLOv5s-ghost	99.5	10.6	98.7
YOLOv5s-GGS-DW	99.6	5.8	98.6

从表4可知, 本文算法的精度高达99.6%, 相比 YOLOv5s 网络提升了0.3%, 而且 $mAP50$ 也高达98.6%, 相比较原 YOLOv5s 网络下降了0.5%。从浮点运算可以看出, 在无损精度的状态下, 本文的网络计算量是原网络计算量的1/3, 实现了压缩模型的体积, 使网络模型更加轻量化。

3 结束语

本文将 GhostNet 残差结构和 SE 模块的性质组合 GGS 模型代替 YOLOv5 的主干网络中的特征提取层, 在 PANet 结构中使用深度可分离卷积和步长是1的 Ghost 瓶颈结构进行特征降采样, 减小模型尺寸, 改进 YOLOv5s 轻量级网络检测效果与 YOLOv5s 检测精度, 模型尺寸却只有原 YOLOv5s 的37.8%。

参考文献

- [1] 李义岭, 喻彦喆, 姚克民. 城市轨道交通智能化及可持续发展现状分析与展望[J]. 现代城市轨道交通, 2021(11): 90-94.
- [2] 汪永元. 城市轨道交通大型检测与维修车辆资源共享方案研究[J]. 都市轨道交通, 2020, 33(5): 58-64.
- [3] 严隽毫, 傅茂海. 车辆工程[M]. 3版. 北京: 中国铁道出版社, 2011: 50-58.
- [4] 李维岗, 刘卫, 白文虽. 一种基于 VDI2230 的轨道车辆轴箱螺栓联接强度评估方法[J]. 机械工程师, 2020, 349(7): 126-129.
- [5] 李静, 高晓蓉, 杨凯. 基于 HOG 特征及 SVM 的机车车底螺栓检测方法[J]. 信息技术, 2016(3): 125-127, 135.
- [6] 陈燕, 郭锋. TFDS 系统心盘螺栓丢失故障的自动识别检测技术[J]. 郑州轻工业学院学报(自然科学版), 2010, 25(3): 90-94.
- [7] 王振, 邓三鹏, 祁宇明, 等. 基于 YOLO v3 的钢轨螺栓组件故障检测方法[J]. 机器人技术与应用, 2021, 199(1): 34-36.
- [8] 陈健雄, 宁航. 基于 YOLO v2 与 OTSU 的中低速磁浮接触轨连接板螺钉松动识别[J]. 计算机与现代化, 2019, 289(9): 118-121, 126.
- [9] HAN K, WANG Y, TIAN Q, et al. GhostNet: More Features From Cheap Operations[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 1577-1586