

DOI:10.16515/j.cnki.32-1722/n.2022.01.002

一种基于改进 YOLOv5s 的电动车头盔佩戴检测方法

徐 栋¹, 陈正宇^{2*}

(1. 南京邮电大学电子与光学工程学院, 江苏 南京 210023; 2. 金陵科技学院电子信息工程学院, 江苏 南京 211169)

摘要:为了解决电动车驾乘人员头盔佩戴检测问题,提出了一种基于改进 YOLOv5s 模型的电动车头盔佩戴检测方法。该方法以 YOLOv5s 模型为基础,首先使用 GhostBottleneck 模块替换 YOLOv5s 中的卷积模块以减少参数量;其次设计了 GhostCSP-Bottleneck 来优化特征提取结构;最后在主干网络增加注意力机制提升检测精度。实验结果表明,改进后的模型平均准确率均值为 84.2%,较 YOLOv5s 提升了 1.3 个百分点;模型参数量和体积分别压缩为原来的 51.39% 和 47.95%,在小目标和密集目标场景下具有较好的泛化性;将模型移植到 NVIDIA Jetson Xavier NX 开发板上,检测速度达到 28.2 FPS,满足检测的实时性和准确性要求。

关键词:电动车头盔; YOLOv5s; GhostCSP-Bottleneck; 注意力机制

中图分类号: TP391.4

文献标识码: A

文章编号: 1672-755X(2022)01-0007-08

An Electric Vehicle Helmet Wearing Detection Method Based on Improved YOLOv5s

XU Dong¹, CHEN Zheng-yu^{2*}

(1. Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

2. Jinling Institute of Technology, Nanjing 211169, China)

Abstract: Aiming at solving the problem of wearing helmet detection of electric vehicle drivers and passengers, a wearing detection method of electric vehicle helmet based on improved YOLOv5s model is proposed. Based on YOLOv5s model, firstly, the network structure replaces convolution module in YOLOv5s with GhostBottleneck module to reduce the amount of parameters. Secondly, the GhostCSP-Bottleneck structure is designed to optimize feature extraction. Finally, attention mechanism is added in the backbone network to improve the detection accuracy. Experimental results show that the mean average precision of the improved model is 84.2%, which is 1.3 percent points higher than that of YOLOv5s. The parameters and weight of the model are compressed to 51.39% and 47.95%, which makes the model show good generalization in the scene of small targets and dense targets. The model is transplanted to the development board NVIDIA Jetson Xavier NX, and can achieve a detection speed of 28.2 FPS, which is able to meet the detection requirement of real-time and accuracy.

Key words: electric vehicle helmet; YOLOv5s; GhostCSP-Bottleneck; attention mechanism

驾驶电动车时佩戴安全头盔可在事故发生时缓冲头部撞击,保护生命安全。电动车驾乘人员佩戴头

收稿日期: 2022-01-14

基金项目: 教育部人文社会科学研究青年基金项目(21YJCZH108)

作者简介: 徐栋(1996—),男,江苏徐州人,硕士研究生,主要从事计算机视觉研究。

通信作者: 陈正宇(1978—),男,江苏淮安人,教授,博士,主要从事物联网和人工智能研究。

盔成为保障道路安全的一项重要工作。通过人工智能算法构建电动车驾乘人员佩戴安全头盔的检测系统对促进道路安全具有重要意义,也是迈向交通智能化的关键一步。

目前,针对道路场景下电动车头盔佩戴检测的研究较少,不少研究是针对工地安全帽的佩戴检测,二者检测方法存在相似之处,但是道路场景下电动车头盔佩戴检测对检测速度的要求更高。传统的安全头盔检测方法如使用支持向量机作为分类器、通过梯度直方图进行特征提取等,存在主观性强、特征提取困难、泛化性差等问题,需要进一步改进^[1]。深度学习卷积神经网络在提取图像特征时不需要手动设计特征,给安全头盔的佩戴检测提供了一个新的方向。目前主流的基于深度学习的头盔佩戴检测算法分为两类:一类是以 Fast R-CNN^[2]和 Faster R-CNN^[3]为代表的双阶段检测算法;另一类是以 SSD^[4]、YOLO^[5]为代表的单阶段检测算法。双阶段算法模型体积较大,训练时间长,检测速度不高,不利于模型部署;单阶段算法的泛化能力较弱,对小目标的检测性能有待提升。此外,上述基于深度学习的研究大多数是基于 GPU 工作站,缺乏对部署嵌入式平台的考虑,难以满足道路场景下电动车骑行者头盔佩戴的检测要求。

因此,本文通过降低卷积参数、改进特征提取结构、加入注意力机制对 YOLOv5s 模型进行优化,提出了一种基于改进 YOLOv5s 模型的电动车头盔佩戴检测方法,以期对小目标和遮挡目标有较好的检测效果,在 NVIDIA Jetson Xavier NX 开发板上具有较高的检测速度。

1 YOLOv5s 模型

YOLOv5 是在 YOLOv3、YOLOv4 模型基础上不断创新的模型,该模型的特点是适用于移动端、模型小、速度快。YOLOv5 包括 YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x 四个模型。YOLOv5s 是其中网络深度最浅、特征图宽度最小的模型,体积只有 14 M,非常适合嵌入式设备的部署,因此本文选用 YOLOv5s 模型作为基准模型。

YOLOv5s 模型结构如图 1 所示,主要由主干网络(backbone)和头部(head)两部分构成。backbone 包含 Focus 结构、SPP^[6]结构和参照 CSP^[7]结构设计的 C3 结构,head 部分使用了 PANet^[8]结构。

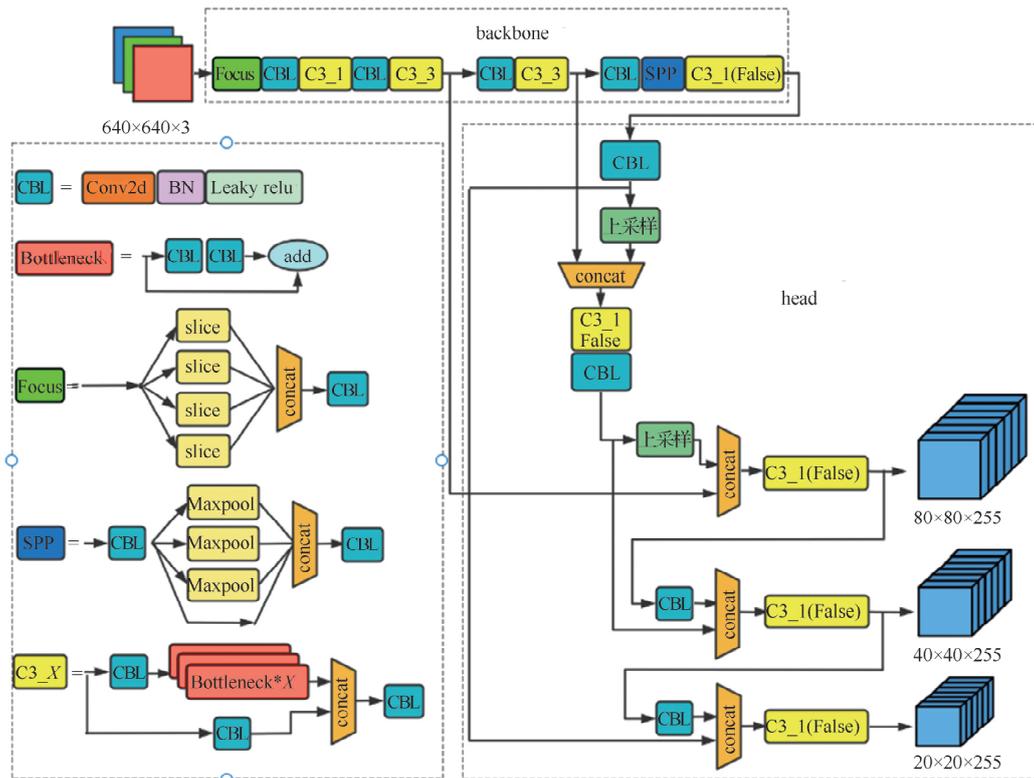


图 1 YOLOv5s 模型结构

YOLOv5s 创造性地采用了 Focus 结构,先通过间隔采样对输入图像进行四倍通道扩充,再经过卷积操作得到无特征信息损失的二倍下采样特征图。Focus 模块对普通卷积操作进行了优化,以更少的计算成本实现下采样并增加通道维度,降低了参数量并提升了速度。

YOLOv5s 根据跨阶段合并策略设计了 C3 模块,该模块是对残差特征进行学习的主要模块。C3 模块根据堆叠的 Bottleneck^[9]有无侧向连接设计了两种 CSP 模块,分别是 C3_X(True)和 C3_X(False),X 是 Bottleneck 的堆叠数量。前者用于 backbone 部分的特征提取,后者用于 head 部分的特征融合。

PANet 是在特征金字塔网络(FPN)^[10]的基础上加上一个自底向上的特征传递路径,然后将不同深度的特征进行融合。该结构使得顶层特征图也可以有效利用底层特征丰富的位置信息,从而提升了多尺度目标的检测效果。

2 改进的 YOLOv5s 模型

YOLOv5s 模型对目标检测中常见的问题都做了一定的优化改进,在性能上同时兼顾检测速度和检测精度,具有较好的工程实用性,但在一些实际场景下仍有待提升。为了满足电动车驾乘人员头盔佩戴检测需要,本文从模型计算量、体积、精确度出发,将 YOLOv5s 模型进一步优化,以提升检测精度。

2.1 GhostCSP-Bottleneck 的设计

YOLOv5s 模型中,C3 模块使用了较多的标准卷积,带来了计算量大的问题。因此,本文引入 Ghost 模块,该模块能够通过高效操作以更少的参数量和计算量生成特征图^[11]。Ghost 模块的实现分为两部分,一部分是普通卷积,另一部分是更为高效的线性操作。先通过普通卷积得到一组特征图,再将得到的特征图通过线性操作生成另一组特征图,最后把两组特征图拼接起来。

为了更高效地提取特征,本文使用 GhostNet^[11]中的 GhostBottleneck 结构代替 YOLOv5s 主干网络的标准卷积,结构如图 2(a)所示。该结构在两个 Ghost 模块之间通过一个步长(stride)为 2 的深度卷积(DWConv)进行向下采样连接,最后将这两个 Ghost 模块的输入和输出合并。第一个 Ghost 模块用于增加通道数,第二个 Ghost 模块用于压缩通道数,这构成了逆残差结构,使得信息损失更少,结构表征能力更强。根据 MobileNetV2 的思想,将通道压缩后,不使用 ReLU 函数激活可以避免特征信息丢失^[12]。因此,除了最后一个 Ghost 模块不使用 ReLU 函数外,在每一层后均通过批标准化(BN)和 ReLU 函数进行非线性激活。将该结构替换 YOLOv5s 中 backbone 部分的 CBL 卷积结构,减少了模型的参数量和计算量。

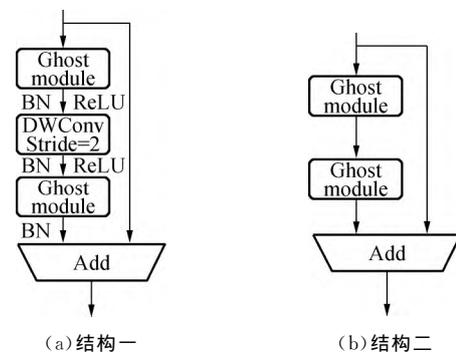


图 2 GhostBottleneck 结构

假设输入特征图的通道数、高度和宽度分别为 c 、 h 和 w ,输出特征图的通道数、高度和宽度分别为 n 、 h' 和 w' ,普通卷积中卷积核的大小为 $k \times k$ 。Ghost 模块中通过普通卷积生成的特征图数量为 m ,每个线性运算的平均内核大小为 $d \times d$ 。根据文献^[11],GhostBottleneck 模块的计算量可表示为 $2[mh'w'ckk + ddh'w'(n-m)]$ 。根据图 1,Bottleneck 模块的计算量可表示为 $2nh'w'ckk$ 。因此 Bottleneck 模块与 GhostBottleneck 模块的计算量之比可表示为:

$$r = \frac{2nh'w'ckk}{2[mh'w'ckk + ddh'w'(n-m)]} = \frac{ckk}{\frac{m}{n}ckk + dd \frac{n-m}{n}} \approx \frac{n}{m + \frac{n-m}{c}} = \frac{n}{m} \quad (1)$$

其中, k 和 d 的大小相同, $m < n$,且 $n-m \ll c$ 。得到 Bottleneck 模块的计算量约为 GhostBottleneck 模块的 r 倍。由于 Bottleneck 中使用了较多 3×3 标准卷积,因此用该结构替换 C3 模块中的 Bottleneck 模块能够将模型的体积和计算量进一步压缩。用图 2(b)的 GhostBottleneck 结构替换 YOLOv5s 中 C3 的 Bottleneck 模块得到新的 GhostCSP-Bottleneck 结构,如图 3 所示。GhostCSP-Bottleneck 结构可以减少模型的计算量并压缩体积。

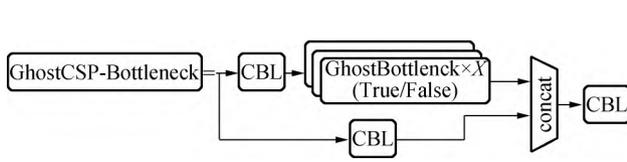


图 3 GhostCSP-Bottleneck 结构

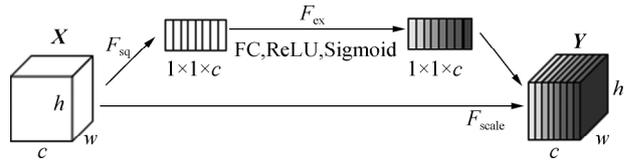


图 4 SE 注意力模块示意图

2.2 SE(squeeze and excitation)注意力模块

虽然 GhostBottleneck 模块能够大幅压缩 YOLOv5s 模型的参数量和计算量,但不可避免地导致检测精度小幅度下降。为了提升检测精度,本文在主干网络部分引入 SE^[13] 注意力模块(图 4),该模块能够解决卷积池化过程中由于特征图不同、通道占比不同带来的损失问题。SE 注意力模块首先是挤压操作 F_{sq} ,将输入特征图 X 进行全局池化,生成 $1 \times 1 \times c$ 的一维矩阵,该矩阵具有全局大小的感受野;然后是激励操作 F_{ex} ,通过两个全连接层(FC),利用非线性操作拟合通道之间的相关性,在第一个全连接层后加入 ReLU 函数增加通道间的非线性,在第二个全连接层后加入 Sigmoid 函数进行权值归一化操作,得到附带通道权值的 $1 \times 1 \times c$ 矩阵;最后是缩放操作 F_{scale} ,将得到的 $1 \times 1 \times c$ 特征图与输入特征图做全乘操作,将权重加权到输入特征图上,这样就得到了附带不同通道权重的特征图 Y 。

SE 注意力模块为即插即用模块,通常用在卷积模块之后^[14]。因此本文在 YOLOv5s 主干网络的第二个和第三个 C3 模块后加入 SE 注意力模块,为不同尺度的特征层赋予更高的权重;再在 SPP 层后加入 SE 注意力模块,强化融合后的局部特征和全局特征,丰富特征图的表达能力。在主干网络加入 SE 注意力模块后参数量增加了 43 008,仅占 YOLOv5s 模型总参数量的 0.61%;学习到的特征信息被进一步优化,赋予通道小目标的权值比重,能大幅提升模型精度。

2.3 改进的 YOLOv5s 模型

改进的 YOLOv5s 模型网络结构如图 5 所示。

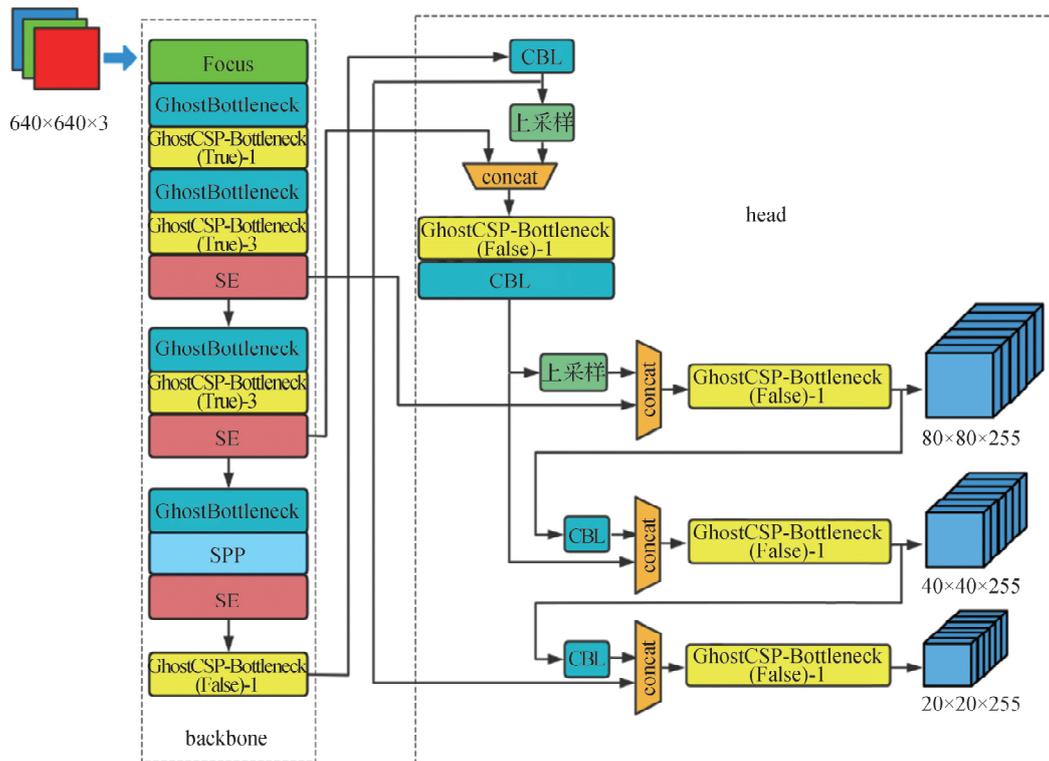


图 5 改进的 YOLOv5s 模型结构

GhostCSP-Bottleneck 模块的 True 和 False 表示有无残差边,后面的数字(YOLOv5s 中是 1 和 3)代表 GhostBottleneck 的堆叠次数。经计算,改进前后的 YOLOv5s 模型参数如表 1 所示。

表 1 改进前后 YOLOv5s 模型参数对比

模型	params/M	FLOPs/G	weight/MB
YOLOv5s	7.2	17.1	14.4
改进的 YOLOv5s	3.7	8.2	7.6

从表 1 可以看出,改进的 YOLOv5s 模型参数量(params)为 3.7 M,每秒浮点运算次数(FLOPs)为 8.2 G,模型体积(weight)为 7.6 MB,三者分别为原始 YOLOv5s 模型的 51.39%、47.95%和 52.78%,实现了较大幅度的压缩。

3 实验结果与分析

3.1 数据集及实验环境

由于所需的检测类别没有公开的数据集,所以自行制作了包含 5 000 张图片的原始数据集。数据集图片来源包括两部分:一是利用 Python 网络爬虫从百度图片获取,二是从金陵科技学院的道路监控缓存视频截取图片。为了提高模型的泛化性能,使用随机缩放、裁剪、翻转、旋转等方式来增加原始数据集的多样性。

本实验的数据集由 motorcycle、helmet、person 三个类别构成,分别对应电动车目标、头盔目标和未佩戴头盔的人脸目标,其中 helmet 和 person 为两种对立的状态。先使用标注工具将图片中出现的三类目标进行标注,生成 YOLOv5s 模型训练格式的标签,最后按照 7:2:1 的比例划分训练集、验证集和测试集,完成数据集的构建。

3.2 实验平台和模型训练配置

实验所使用的设备是云服务器平台,操作系统为 Ubuntu 18.04,GPU 为 GeForce RTX 2080Ti,搭配 CUDA10.2 和 CUDNN7.6 加速工作站。训练完成后将模型移植到嵌入式平台 NVIDIA Jetson Xavier NX 上进行部署。实验使用的深度学习框架为 Pytorch 1.8.0,对应的 torchvision 版本为 1.9.0。训练时设置初始学习率为 0.01,动量设置为 0.937,衰减系数为 0.000 5,epoch 为 300,batchsize 为 32。

3.3 评价指标

为了定量评价实验结果,使用准确率(precision)、召回率(recall)、平均准确率均值(mAP)作为指标,如式(2)~式(5)所示。此外还采用模型体积、参数量、每秒浮点运算次数(FLOPs)、检测速度(单位为 FPS)作为衡量模型大小、计算量、推理速度的指标。

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{AP} = \int_0^1 P dR \quad (4)$$

$$\text{mAP} = \frac{\sum_{i=1}^n \text{AP}_i}{n} \quad (5)$$

式中,TP 表示被正确分类的正样本,FP 表示被错误分类的正样本,FN 表示被错误分类的负样本, n 表示总类别数。

3.4 消融实验

在验证改进后的完整模型之前,通过消融实验探究改进方法对于 YOLOv5s 的影响。消融实验以 YOLOv5s 模型为基础,按照 2.1 节和 2.2 节所述的改进方法将 GhostBottleneck(以下简称 GBk)模块、GhostCSP-Bottleneck(以下简称 GhostCSP)模块、SE 注意力模块加入到 YOLOv5s 模型中,得到的结果如表 2 所示,图片输入尺寸为 640×640。

表 2 以 YOLOv5s 为基础的消融实验结果

模型	mAP(0.5)/%	recall/%	FLOPs/G	weight/MB
YOLOv5s	82.9	78.7	17.1	14.4
YOLOv5s+SE	85.3	76.9	17.1	14.5
YOLOv5s+GhostCSP	82.5	76.5	10.5	10.1
YOLOv5s+GBk+GhostCSP	82.1	75.8	8.2	7.5
YOLOv5s+SE+GBk+GhostCSP	84.2	75.4	8.2	7.6

由表 2 可知,加入 SE 注意力模块后模型精度有较大的提升,比原 YOLOv5s 模型 mAP 提升了 2.4 个百分点,且计算量几乎没有增加,但是召回率有所下降。在模型中同时加入 GBk 模块和 GhostCSP 模块后,计算量减少了 52.0%,mAP 下降了 0.8 个百分点,因此 GBk 和 GhostCSP 能够以更少的计算量提取特征信息。

根据消融实验可以发现,在主干网络不同尺度特征层加入 SE 注意力模块,能够为不同通道赋予权重信息,而且在后续的特征融合中可以将权重信息继续传递,最终以少许计算量为代价显著提高检测精度;GBk 模块由于以更高效的方式提取特征,对计算量和模型体积有较明显的压缩;GhostCSP 模块减少了特征信息的损失,以少量准确率为代价将模型的计算量和参数量进一步压缩。可见,SE 注意力模块、GBk 模块和 GhostCSP 模块对于模型整体性能提升十分必要。

3.5 不同模型在数据集上的对比实验

为了验证改进后模型的效果,选用同类型轻量级模型 YOLOv4-tiny 和 MobilenetV3-YOLOv5s 进行对比实验,后者是由 MobilenetV3 的 backbone 部分替换掉 YOLOv5s 的 backbone 得到。将模型按照 3.2 节的配置进行训练,将训练好的模型放在测试集上测试模型的性能,测试集包含 500 张图片,测试结果如表 3 所示。

表 3 不同模型的检测性能

模型	size	mAP(0.5)/%	recall/%	params/M	FLOPs/G	weight/MB
YOLOv5s	640	82.9	78.7	7.2	17.1	14.4
改进的 YOLOv5s	640	84.2	75.4	3.7	8.2	7.6
YOLOv4-tiny	640	83.5	81.9	6.4	21.8	12.3
MobilenetV3-YOLOv5s	640	82.1	73.6	3.5	6.3	7.4

从表 1 和表 3 可以看出,改进后模型的 mAP 为 84.2%,在四种模型中最高,较改进前提升了 1.3 个百分点,但是召回率下降了 3.3 个百分点。虽然改进后的模型在参数量、计算量、体积上稍逊色于 MobilenetV3-YOLOv5s,但是 mAP 比 MobilenetV3-YOLOv5s 高 2.1 个百分点。实验结果表明,相较于 YOLOv5s,本文所提方法在大幅度减小参数量和计算量的同时提高了检测精度。

将训练好的模型部署到 NVIDIA Jetson Xavier NX 开发板上,比较不同模型的检测速度。由表 4 可知,在 640×640 的图像输入尺寸下,由于嵌入式设备性能限制,YOLOv5s 的检测速度仅有 20.2 FPS,实时性不佳。本文提出的模型的检测速度达到 28.6 FPS,较改进前提升了 8.4 FPS,可以满足实时性的检测需求。在 512×512 的图像输入尺寸下,改进后模型的检测速度达到了 36.3 FPS,比 YOLOv4-tiny 略快。结果表明,本文提出的模型在电动车驾乘人员头盔佩戴检测方面更有优势。

表 4 不同模型在不同尺寸下的检测速度

模型	FPS	
	640×640	512×512
YOLOv5s	20.2	28.6
改进的 YOLOv5s	28.6	36.3
YOLOv4-tiny	26.1	32.4
MobilenetV3-YOLOv5s	21.8	27.8

3.6 不同模型在实际道路上的对比实验

除了在数据集上验证模型的性能外,还从实际道路采集图像以直接检验模型的检测效果。图 6—图 8 是改进前后模型的部分检测结果,(a) 图为原始 YOLOv5s 模型的检测结果,(b) 图为改进后模型的检测结果。从图 6 可以看出,在场景良好的情况下改进前后的模型都能将电动车驾驶人员的头盔佩戴情况检测出来,即二者均满足检测需求。在图 7 中,YOLOv5s 模型没能检测出图片左下方被遮挡的电动车目标和右上角远处模糊的电动车目标,而改进的模型能够将这两个目标检测出来,说明改进的模型对遮挡目标和小目标有更好的检测效果。在图 8(为了便于观察做了标签隐藏处理)中,左侧的自行车目标(蓝色框标出)和右侧的电动车目标在特征上有较高的相似度,原始 YOLOv5s 模型没能将二者区分开来,将自行车错误地识别为电动车目标,而改进后的模型成功地区分出了这两个相似的目标。由此得出,改进后的模型不但在常规场景下可以成功识别出电动车驾乘人员的头盔佩戴情况,而且对遮挡目标、小目标和相似度较高的目标也有较好的检测效果。

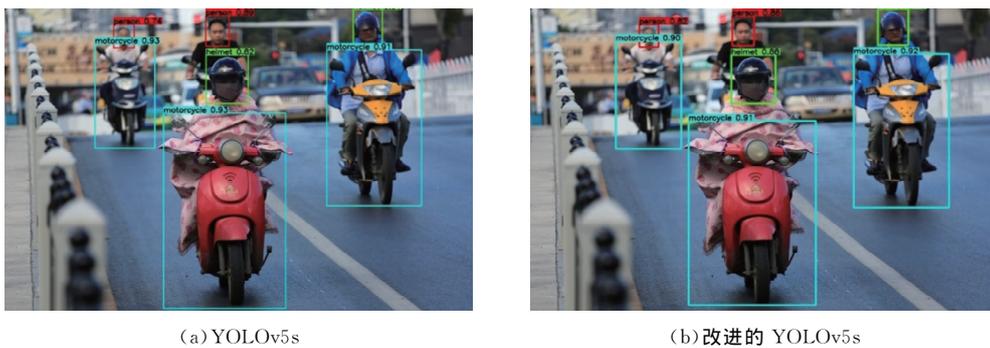


图 6 场景良好时的检测结果



图 7 存在小目标和遮挡目标时的检测结果

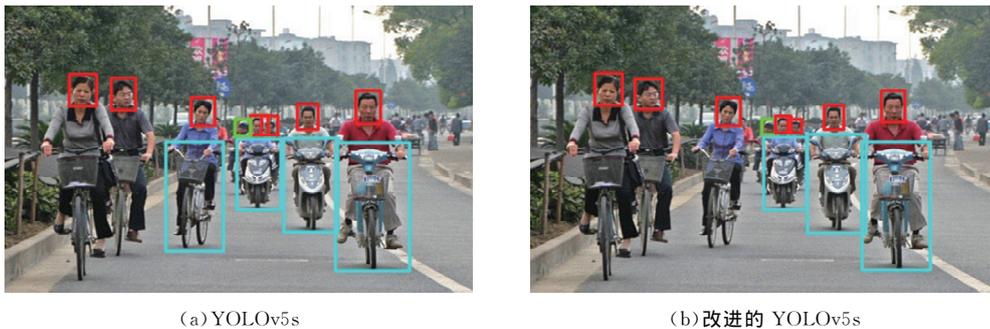


图 8 存在自行车干扰目标时的检测结果

4 结 语

本文针对电动车驾乘人员头盔佩戴检测任务,以YOLOv5s模型为基础,引入GhostBottleneck优化网络结构,设计GhostCSP-Bottleneck模块替换C3模块,并在主干网络加入SE注意力模块,形成了一种适用于嵌入式平台的轻量化电动车驾乘人员头盔佩戴检测方法。实验结果表明,改进的模型在精度上稍高于原模型,且具有更少的计算量、更小的模型体积和更快的检测速度。在 640×640 的图像输入尺寸下,平均准确率均值mAP为84.2%,在四种模型中最高,比YOLOv5s提高了1.3个百分点;在嵌入式平台NVIDIA Jetson Xavier NX上的检测速度可以达到28.6 FPS,比YOLOv5s提高了8.4 FPS,可以很好地满足实时性的检测需求。本文提出的模型在精度上和检测速度上取得了良好的平衡,适合嵌入式平台的部署检测。下一步工作目标是丰富检测场景,提升模型在夜晚、雾天、雨雪天等环境下的检测效果。

参考文献:

- [1] 蒋润熙,阿里甫·库尔班,耿丽婷.面向轻量化网络的安全帽检测算法[J].计算机工程与应用,2021,57(20):263-270
- [2] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, Santiago: IEEE, 2015: 1440-1448
- [3] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[J]. CoRR, 2015, abs/1512.02325
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas: IEEE, 2016: 779-788
- [6] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916
- [7] WANG C Y, LIAO H Y, 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). Seattle: IEEE, 2020: 1571-1580
- [8] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City: IEEE, 2018: 8759-8768
- [9] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas: IEEE, 2016: 770-778
- [10] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu: IEEE, 2017: 936-944
- [11] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 1577-1586
- [12] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City: IEEE, 2018: 4510-4520
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City: IEEE, 2018: 7132-7141
- [14] 邹梓吟,盖绍彦,达飞鹏,等.基于注意力机制的遮挡行人检测算法[J].光学学报,2021,41(15):157-165

(责任编辑:湛 江)