

基于 Yolov8-SCG 神经网络的电动车头盔佩戴检测算法

杨琚钱, 胡平, 戴家树

安徽工程大学 计算机与信息技术学院, 安徽 芜湖 241000

摘要:目的 针对行人与电动车驾驶人员共用道路通行情况下, 电动车骑行人员的头盔检测问题, 提出一种基于 Yolov8n 的电动车头盔佩戴检测改进算法。方法 首先, 为提升模型对于低分辨率图像及小目标检测的精度, 引入 SPDConv 替换模型普通卷积与下采样算子; 其次, 为提升模型对于背景与检测目标相似情况下的辨识能力, 引入 CG block 模块, 与原模型 C2f 模块融合, 创建 C2f-CG 模块, 替换原有 C2f 模块, 提升上下文特征提取能力; 最后, 为降低模型的计算量, 保持模型轻量化, 将原模型 Head 层普通卷积替换为组卷积。结果 经实验检测, 改进模型较 Yolov8n 原模型 mAP 精度提升 4.2%, 计算量降低 15%, 对于低分辨率图像及小目标检测精度均有上升。结论 改进模型适用于复杂情况下电动车头盔的实时检测, 可以作为应用领域的解决方法。

关键词: 电动车头盔检测; YOLOv8n; SPDConv; CG block; GroupConv

中图分类号: TP391.41; TP183 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2026.0002.013

Electric Vehicle Helmet Wearing Detection Algorithm Based on Yolov8-SCG Neural Network

YANG Juqian, HU Ping, DAI Jiashu

School of Computer and Information, Anhui Polytechnic University, Wuhu 241000, Anhui, China

Abstract: Objective In the scenario where pedestrians and electric vehicle drivers share the road, an improved electric vehicle helmet-wearing detection algorithm based on Yolov8n is proposed to address the helmet detection of electric vehicle riders. **Methods** First, to improve the model's accuracy in detecting low-resolution images and small targets, SPDConv was introduced to replace the ordinary convolution and down-sampling operators in the model. Second, to enhance the model's ability to distinguish objects when the background was similar to the detection target, the CG block module was introduced and integrated with the original C2f module to create the C2f-CG module, which replaced the original C2f module to boost the context feature extraction capability. Finally, to reduce the computational volume of the model and keep the model lightweight, the ordinary convolution in the Head layer of the original model was replaced with group convolution. **Results** After experimental testing, the enhanced model proposed in this paper demonstrated an improvement in mAP accuracy of 4.2% and a reduction in computation of 15% in comparison to the Yolov8n original model. The detection accuracy for low-resolution images and small targets had also increased. **Conclusion** The improved model is suitable for electric vehicle helmet detection in complex situations and can be used as a solution in practical fields.

Keywords: electric vehicle helmet detection; YOLOv8n; SPDConv; CG block; GroupConv

收稿日期: 2024-05-14 **修回日期:** 2024-08-28 **文章编号:** 1672-058X(2026)02-0101-07

基金项目: 国家自然科学基金项目资助(62302011); 安徽省教育厅高校科学研究重点项目资助(2023AH050899, KJ2020A0362); 安徽工程大学企业委托研发项目资助(HX-2023-02-019, HX-2022-09-038)。

作者简介: 杨琚钱(2000—), 男, 安徽芜湖人, 硕士研究生, 从事计算机视觉研究。

通信作者: 胡平(1979—), 男, 安徽芜湖人, 副教授, 从事智能软件和云计算研究。Email: huping@ahpu.edu.cn。

引用格式: 杨琚钱, 胡平, 戴家树. 基于 Yolov8-scG 神经网络的电动车头盔佩戴检测算法[J]. 重庆工商大学学报(自然科学版), 2026, 43(2): 101-107.

YANG Juqian, HU Ping, DAI Jiashu. Electric vehicle helmet wearing detection algorithm based on Yolov8-SCG neural network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 101-107.

伴随着科学技术的进步,城市内的交通拥堵问题愈发严重。而二轮电动车作为日常代步交通工具,能够有效减少交通堵塞带来的城市交通压力,所以电动车在人们日常生活中占据越来越重要的地位。

中华人民共和国工业和信息化部发表声明,自 2023 年 7 月 1 日,摩托车、电动自行车驾乘人员头盔实施新标准,要求骑行人员必须佩戴头盔。在某些复杂场景下,如图像检测分辨率较低,行人对电动车骑行人员存在遮挡关系,现有目标算法无法做到准确且快速的检测,这便需要对现有算法进行改进。

现阶段目标检测算法根据特征提取方式与算法流程可以分为一阶段目标检测算法与二阶段目标检测算法。一阶段目标检测算法具有运算效率高,实时性强的优势。现有的一阶段目标检测算法有 YOLO 系列^[1-3]、SSD^[4]、RetinaNet^[5]等,这类算法能够大幅减少运算时间,使得模型具备实时性高的优势。而二阶段目标检测算法则与一阶段目标检测算法相反,检测准确度更高,但检测时间会增加,大多无法直接应用于实时检测项目。其代表算法有 Faster-RCNN^[6]、Cascade-RCNN^[7]、Mask-RCNN^[8]等。

目标检测算法在多个领域已有应用先例^[9],对电动车骑行人员头盔佩戴情况进行检测也有众多研究人员提出了创新思路。Macalisang 等^[10]通过对 YOLOv3 参数微调来改善模型对于电动车头盔的检测精度,但因为数据集容量较少,使得模型泛化性能较差;Bouhayane 等^[11]采用 Swin Transformer 作为模型主干,使用 FPN 架构作为颈部网络处理多尺度特征,最后使用 Cascade-RCNN 检测多尺度特征图并输出,模型较主流算法有较大提升,但模型复杂程度高,计算周期长,在实际使用中无法达到实时性要求;Jia 等^[12]通过将三重注意力^[13]添加到骨干网络的最后一层,引入 Soft-NMS 替换 NMS,改善了模型对于头盔的检测能力,但对于多目标

的检测效果不佳。在国内,李世聪^[14]基于实际部署需求,使用 YOLOv3-tiny 作为基底模型,引入深度可分离卷积替换原有卷积模块,减小模型参数量,同时,为了保证模型精度,将原有特征融合模块扩充,但模型在背景与特征相似时存在误检情况;胡光喆^[15]在 YOLOv5 模型中使用 Ca 注意力机制增强模型对于头盔的检测精度,使用 Ghost 模块替换原有的 C3 模块,降低了模型计算量,但因为数据集数量不够导致模型泛化性能不够;陈扬等^[16]通过修改 YOLOv5 原损失函数 CIOU 为 GIOU,在原本 FPN+PAN 结构的颈部网络中加入跳层连接与注意力机制,改善了 YOLOv5 对于头盔检测的精度,但模型对于复杂场景的实际效果检测较差;王雅妮等^[17]将 FPN 网络结构加入 RetinaNet 网络中,提升了对电动车头盔的检测能力,但对于有遮挡的头盔检测效果不佳;张碧川等^[18]对 YOLOv8 进行剪枝轻量化处理,但实际精度并没有显著提升。

本文针对检测过程中低分辨率图像及小目标检测困难,背景与检测目标相似,模型参数量较大等问题,改进 YOLOv8n 模型,命名为 YOLOv8-SCG,具体改进如下:

引入 SPDConv 模块替换原模型的普通卷积模块,提升模型对于低分辨率图像的辨识能力;引入 CG block 模块,与原模型 C2f 模块相融合,成为 C2f-CG 模块,通过局部特征提取与全局特征提取改善模型对于检测目标与背景相似时出现的错检误检问题;针对原模型参数量较大的问题,替换 Head 层的普通卷积为组卷积,有效降低模型参数,提升模型的训练速度。

1 YOLOv8n 模型结构及其改进

1.1 YOLOv8n 模型结构

YOLOv8 模型作为 YOLO 系列模型的最新成果,较之前的 YOLO 系列模型具有极大的提升,其自身性能已经足以作为目标检测领域的 Sota 模型,其结构如图 1 所示。

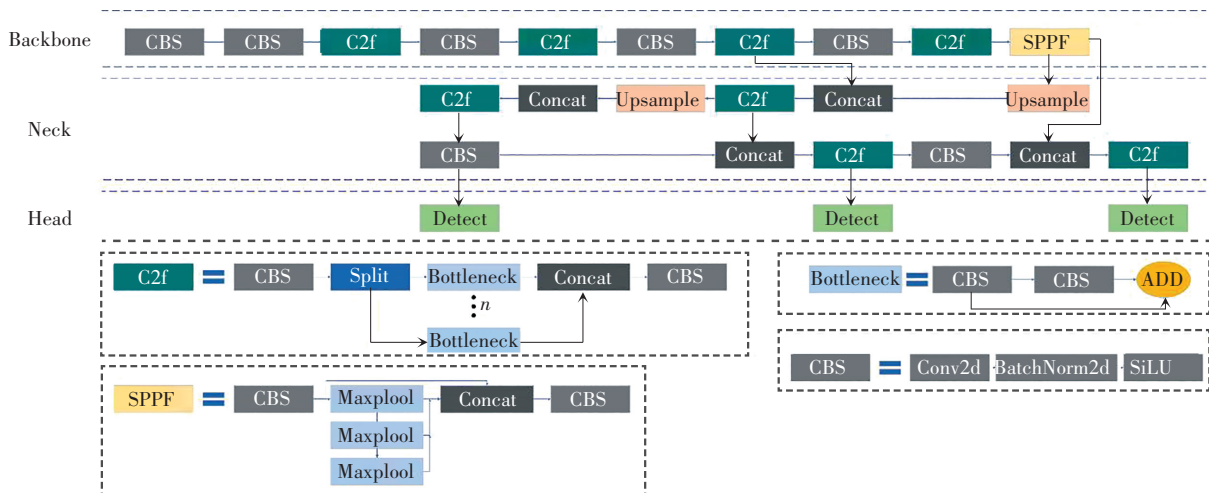


图 1 YOLOv8n 网络结构

Fig. 1 YOLOv8n network structure

Yolov8n 模型主要分为 3 部分,分别是 Backbone 层,Neck 层与 Head 层。Backbone 层较 Yolov5 结构没有发生变化,只改变组成 Backbone 的模块。其中,在主干网络中,以一系列的卷积模块开始。卷积模块由卷积核、BN 层与激活函数组成,对预处理之后的图像进行初步特征提取,提取到图像的细节信息,Yolov8 卷积核由 Yolov5 的 $6 * 6$ 大小,进一步减小到 $3 * 3$ 大小,这样处理有助于减小模型的整体参数量。每通过若干个卷积模块,便接续通过 C2f 模块,这是由 Yolov5 的 C3 模块,通过借鉴 Yolov7 的 Elen 模块后提出的优化模块。其主要原理是将输入的特征图分为两部分,分别进行不同的卷积层变换后合并输出。与 Yolov5 相比,其加入了更多的跨层结合,能进一步提升模型对于特征提取的准确度。模型的 Backbone 层最后通过 SPPF 模块。Yolov8 的 SPPF 模块与 Yolov5 模型的 SPPF 模

块相似,只是将 $5 * 5, 9 * 9$ 与 $13 * 13$ 的最大池化层全部替换为 $5 * 5$ 的最大池化层,并通过跨层连接提升模型的检测精度。Neck 层与 Yolov5 相比,基本没有发生变化,依旧采用 FPN+PAN 结构,多次对特征图上采样、下采样加融合,以保证特征提取的精度。而 Head 层则采用与 Yolov5 的耦合头(Coupled-Head)不同的解耦头(Decoupled-Head)充当输出,将检测头与目标识别分类分离,更加有效地识别目标类别,同时,由于 Yolov5 的 Anchor-based 检测方法转换为 Anchor-free,减少了 Anchor box 的生成,降低了计算量,避免了不合理 Anchor box 带来的误检与漏检问题。

本文针对检测低分辨率图像及小目标时精度较低,分辨背景与相似特征较困难及原模型参数量较大的问题提出改进。改进后的 Yolov8-SCG 图像如图 2 所示。

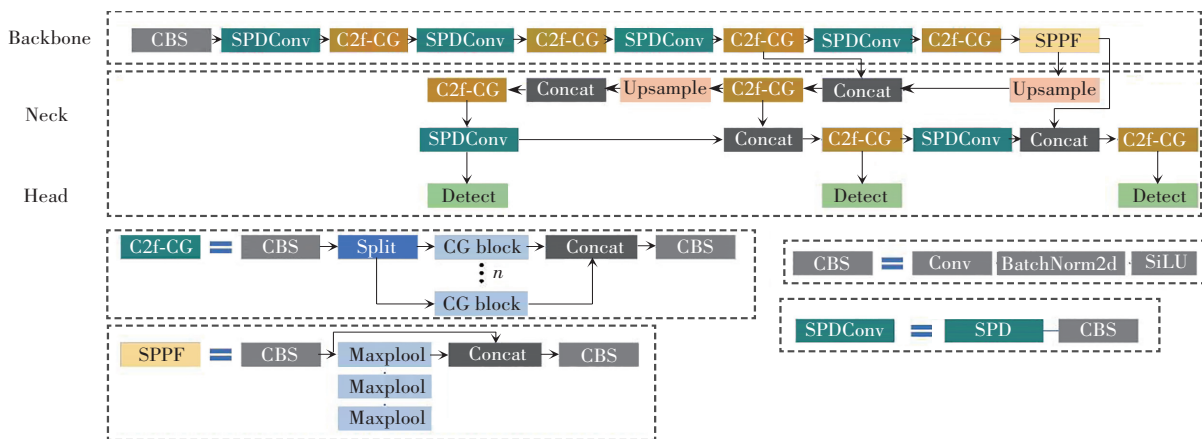


图 2 Yolov8-SCG 模型结构图

Fig. 2 Yolov8-SCG model structure

1.2 SPDCConv^[19]

Yolo 系列作为卷积神经网络模型,其自身拥有 CNN 目标检测模型共同的缺点,即使用了卷积步长(Strided Convolution)与池化层(Pooling Layers),对于检测不同细粒度的目标信息可能会产生丢失现象,这导致模型对于目标特征检测可能会不完备。自 Yolo 系列创始以来,科研工作者对于这种现象不断提出改进方法。Yolov8 通过增加小目标检测层,提升对于小目标检测的精度,但这样处理对于小目标检测的效果提升有限。SPDCConv 构建一种新的模块,较原有卷积模块相比,对于小目标检测精度更优,其具体结构如图 3 所示。




图 3 SPDCConv 结构图

Fig. 3 SPDCConv structure

SPDCConv 由 SPD 模块与基本卷积构成。SPD 模块将输入特征图通过间隔采样的方式,四分为通道数相等的特征图,即传输进入的特征图通道数为 $H * W * C$,而四等分后的特征图通道数为 $H/2 * W/2 * C$;之后通过 Concat 模块对于四分特征图进行拼接,得到 $H/2 * W/2 * 4C$ 的特征图像;之后通过 $1 * 1$ 卷积(因为采用任意步长大于 1 的卷积会导致信息的固定缺失)降低整个模型的检测精度。

将以上所提及模块应用在 Yolov8 中,可有效改善模型对于低分辨率图像及图像中较小目标检测的精度。具体改进为保留第 0 层的卷积模块,之后替换 Backbone 层所有步长为 2 的卷积模块,对于 Neck 层,替换下采样的两个卷积模块。

1.3 C2f-CG block

为了提升模型轻量化功能,削减模型参数与计算量,同时加强模型对于上下文的特征把握,降低复杂背景对于待检测目标的干扰,本文引入 CGNET 网络结构中的 CG block^[20] 模块。CG block 模块启发于自然感官系统,其具体结构如图 4 所示。




图 4 CG block 结构图

Fig. 4 CG block structure

CG block 结构可以分为 4 部分,输入图像首先经过 $1 * 1$ 卷积,之后进入平行分支处理,分别是局部特征提取(f_{loc})与周围上下文特征提取(f_{sur}),在代码中具现为 Conv 模块与 DConv 模块。局部特征提取主要通过使用标准卷积学习输入图像中的局部特征,而周围上下文特征提取则是采用扩展卷积来扩大感受野范围,即从局部特征周围扩大感受野范围,从更大的视野中推理目标的范围与类别,提升模型的检测精度。在经过分支处理后,将不同分支提取到的特征输入联合特征提取器(f_{joi}),将不同尺度的特征图在通道维度上进行拼接,以提高目标检测的精度,在代码中具现为 Concat 模块。之后通过批量归一化(Batch Normalization, BN)和参数化的线性单元(Parametric ReLU, PReLU),进一步提升特征的提取能力。最后,将特征图输入进全局上下文提取器(f_{glo}),通过检索输入图像的全局信息,来提取特征,在代码中具现为多个模块,首先是全局平均池化(GAP),来提取全图的特征信息,之后通过两个全连接层(FC),这样可以保证获取信息的全面性,避免信息的丢失与缺损。为保证模型的结构性,可以将 CG block 与原模型的 C2f 模块相融合,可以得到 C2f_CG block 模块,其结构如图 5 所示。




图 5 C2f_CG block 结构图

Fig. 5 C2f_CG block structure

将原本 C2f 模块中的 BottleNeck 层全部替换为 CG block 模块,能有效减小模型参数量,提升模型对于图像的整体特征提取,减少卷积对于图像造成的信息缺失。

1.4 Head 层输出改进

Yolov8 的 Head 层采用解耦头的输出思路,较 Yolov5 的耦合头,可以有效减少计算量与参数量,同

时,目标检测算法也从 Yolov5 的 Anchor-based 转变为 Anchor-free,再次减少了计算量与参数量。为了能进一步减少参数量,本文引入组卷积模块(Group Conv)^[21],Yolo 原模型卷积模块与组卷积模块结构图如图 6、图 7 所示。




图 6 普通卷积结构图

Fig. 6 Structure diagram of ordinary convolution




图 7 组卷积结构图

Fig. 7 Structure diagram of group convolution

一般卷积进行卷积操作,其卷积核大小通道数与输入图像通道数一致,共经过 C' 个卷积核,最终得到输出通道为 C' 的输出特征。其需要的计算参数量如下: $w * h * C * C'$ 。

而组卷积则采用将输入图片通道数分为 n 组,之后分别进入 n 个相同通道数的卷积核,在得到输出数据后,再使用 Concat 模块将 n 个输出进行特征融合,得到最终的输出。这样做的目的是大幅减少参数,其需要的计算参数量如下: $w * h * C/n + C'/n * 2$ 。

对比可以看出,将一般卷积替换为组卷积,可以减少参数量到 $1/n$ (n 为分类的组数),减少模型过拟合风险,提升模型的计算效率。

2 仿真实验与结果分析

2.1 数据集创建与预处理

现行对于电动车头盔的开源数据集较少,且大多种类较为单一,行人以及电动车并行的图像资源基本不会收录到数据集中,这会导致模型的泛化性能下降。为了避免这种问题的出现,本文采用的数据集通过在校园场景内架设摄像头采集行人、电动车驾驶人员及二者同时出现时的图像,共采集 3 821 张图像,之后通过人工标注形式,以矩形框标注完成后进行模型训练。本次所采用的数据集按照 8 : 1 : 1 划分为训练集、验证集和测试集。

2.2 实验环境

本次实验所采用的硬件环境分别为 Cpu: Intel Core i7-12700K, Gpu: Nvidia Geforce RTX 4090 (24g), 内存 32 G, 硬盘为 1 T 固态硬盘。

软件环境分别为操作系统 Ubuntu 20.02, Cuda 版本为 12.2, Pytorch 版本为 1.13.1, Python 版本为 3.9.16。

2.3 评价指标

为了展示模型改进的优劣性,一般采用客观评价指标来权衡模型的精度与计算量。本文采用目标检测算法通用的指标,即平均精度均值 (mAP@50:95),下文以 f_{mAP} 代指。该指标通过对精确率 (P) 与召回率 (R) 两类指标的复合运算,得到检测模型的检测精度,对于模型的准确性有着较为精准的衡量。而对于模型的计算复杂程度,多数模型采用模型的参数量 (Parameters) 与模型的计算量 (GFLOPs) 来衡量,以下是对模型精度与计算量衡量指标的详细介绍:

(1) 精确率与召回率。对于模型的精确率与召回率是通过另外两种定义计算出来的,即正例 (Positive) 与负例 (Negative)。正例为模型需要检测出的目标,本文指电动车骑行人员的头盔;而负例则相反,指任何不为头盔的目标。通过这两种定义,可以将本文的检测结果分为以下 4 个部分:

True Positives (TP)。图像中电动车骑行人员正确佩戴头盔,同时被模型分类为佩戴头盔的检测结果。下文以 N_{TP} 代指。

False Positives (FP)。图像中电动车骑行人员未佩戴头盔,却被模型分类为检测到佩戴头盔的检测结果。下文以 N_{FP} 代指。

False Negatives (FN)。图像中电动车骑行人员正确佩戴头盔,却被模型分类为未佩戴头盔的检测结果。下文以 N_{FN} 代指。

True Negatives (TN)。图像中电动车骑行人员未佩戴头盔,被模型分类为未佩戴头盔的检测结果。下文以 N_{TN} 代指。

在本文中,精确率为图像中电动车驾驶人员正确佩戴头盔与模型检测到佩戴头盔(即正确检测到佩戴头盔与错误检测到佩戴头盔之和)的比例,其计算如下:

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (1)$$

在本文中,召回率为图像中电动车骑行人员正确佩戴头盔,且模型检测正确占所有模型检测正确(即正确检测佩戴头盔与正确检测未佩戴头盔之和)的比例,其计算如下:

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (2)$$

(2) 平均精度均值 (mAP)。 f_{mAP} 值通过 PR 曲线图作

积分运算得到, $f_{\text{mAP}@50:95}$ 是以步长为 0.05, 计算 f_{mAP} 值平均到各个分类类别的值,其具体计算如式(3):

$$f_{\text{mAP}} = \frac{1}{C} \sum_{i=1}^c f_i^{\text{AP}} \quad (3)$$

其中, C 为具体的分类类别数目,在本文中, $C=2$ 。

(3) 模型大小评估指标。模型大小通常通过参数量 (Parameters) 大小与计算量 (GFLOPs) 大小来评估。这二者与模型的大小成正比,即参数量越大,计算量越大,模型大小越大,实地部署需要更多资源。

(4) 模型实时性评估指标。在实际部署到硬件中,需要考虑模型实时性的性能,是模型在实际硬件中的运行速度,一般使用 FPS (Frames Per Second) 来表示,即模型每秒可以处理的图像数量。

2.4 实验结果及分析

2.4.1 消融实验对比

为确保本文实验的真实有效性,验证改良算法的优越性,采用消融实验,与基础 Yolov8n 算法模型相比较。依次为 Yolov8n 原模型, Yolov8n 模型与 SPDCConv 模块相结合 (Yolov8-SPD), Yolov8n 模型与 CG block 相结合 (Yolov8n-CG), Yolov8 模型与 SPDCConv 模块、CG block 模块相结合 (Yolov8n-SC), Yolov8 模型与 SPDCConv 模块、CG block 模块、组卷积模块相结合 (Yolov8n-SCG) 模型,基本对比参数如表 1 所示。

表 1 消融实验对比

Table 1 Comparison of ablation experiments

模 型	f_{mAP}	P	R	参数量/M	GFLOPs
Yolov8n	0.659	0.852	0.918	3.3	8.2
Yolov8-SPD	0.707	0.846	0.943	4.7	11.6
Yolov8n-CG	0.662	0.872	0.904	2.2	6.6
Yolov8n-SC	0.699	0.879	0.94	3.8	9.4
Yolov8n-SCG	0.701	0.909	0.939	3.2	6.9

从表 1 中的数据可以得出,本文所提出的改进模型在各个消融实验中能够达到准确度与计算量的次优,达到平衡准确度与计算量的最优解,在保证模型检测精度的同时,保持了原模型轻量化的优势。添加 SPDCConv 模块后,较原模型 f_{mAP} 上涨 7%,但计算量上涨 41.5%,这会导致 Yolov8 的轻量化性能得不到体现;在添加 CG block 模块后,模型计算量下降 20%,准确率没有得到提升;在添加 SPDCConv 模块、CG block 模块,及替换 Head 层普通卷积为组卷积后,模型计算量下降 16%, f_{mAP} 提升 6%,在提升准确率的同时保持了模型轻量化的优势,为后续改进提供先决条件;在添加所有改进模块后,改进算法能够达到准确度及计算量的次优值,能够达到综合性能最优。

2.4.2 对比实验

在多个改进点互相对比后,将改进模型与主流算法进行对比,表 2 展示了改进模型与主流的二阶段目

标检测算法与一阶段检测算法的对比。

表 2 不同模型实验对比

模型	f_{mAP}	P	R	参数量/M	GFLOPs	FPS
Faster-RCNN	0.672	—	—	41.13	206.67	30.30
Cascade-RCNN	0.669	—	—	68.93	234.47	22.95
Yolov5	0.662	0.853	0.964	7.02	16.0	66.22
Yolov7	0.632	0.838	0.891	37.20	105.1	66.22
Yolov8n-SCG	0.701	0.909	0.939	3.2	6.9	104.10

从表 2 中数据对比可知,本文所提出的改进算法在主流一阶段算法与二阶段算法中能够取得最优的效

果,在准确度、计算量与实时性 3 种衡量标准中取得了最优表现。较二阶段算法 Faster-RCNN 与 Cascade-RCNN 相比, f_{mAP} 分别上涨了 4.2% 与 4.6%,计算量降至二阶段算法的 5% 以下;与一阶段主流算法 Yolov5 与 Yolov7 相比, f_{mAP} 分别上涨了 5.5% 与 10%,计算量下降了 50% 与 95%。同时,本文提出的改进模型在实时性上达到了最优,能够满足实地部署实时监测的需求。综上所述,本文提出的算法在众多算法中综合性能最优。

2.5 实际场景应用对比

为了验证本文中提出的改进模型与原模型在实际场景中的检测精度是否提高,采用实地采集数据验证集进行验证,对比结果如图 8 所示。

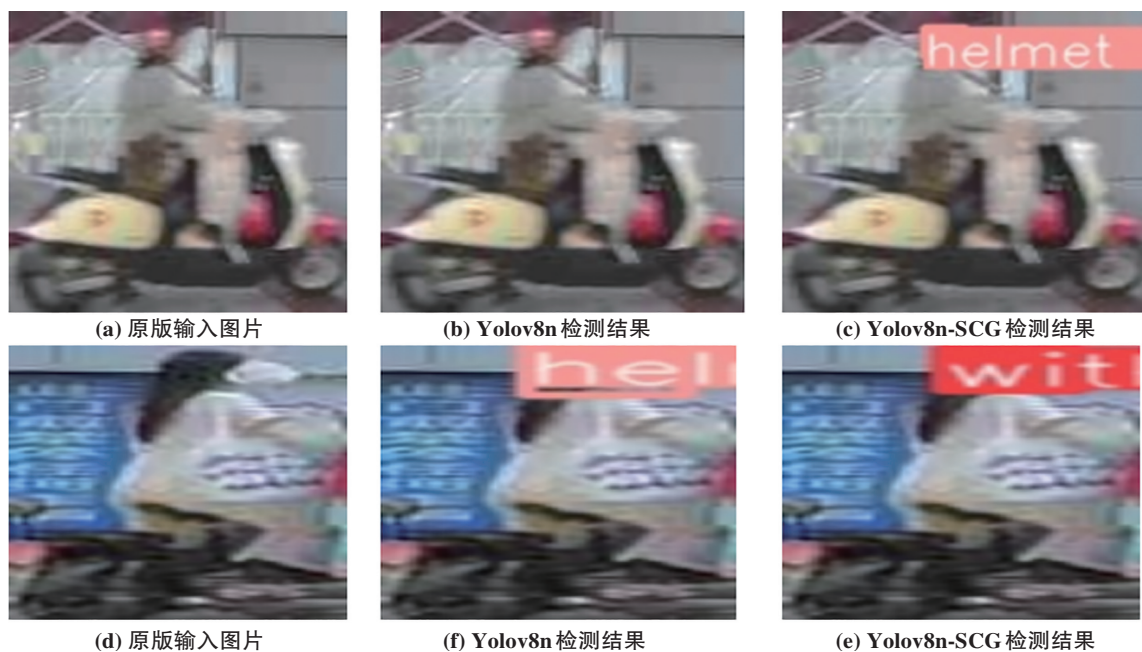


图 8 Yolov8n 原模型与改进模型对比

Fig. 8 Comparison between the Yolov8n original model and the improved model

图 8 共分为 3 列,从左往右分别是原始输入图片、Yolov8n 原始模型检测输出图片与改进模型检测输出图片。第一行图片检测可以看出,在分辨率较低时,原版检测效果不佳,而改进模型由于加入了 SPDCConv 模块,提升了对低分辨率图像及小目标的检测精度,所以可以检测出头盔佩戴;第二行骑行人员的防晒帽与后半部分头发和头盔形象较为接近,原模型无法分辨其中的差距,导致漏检,而改进模型加入了 CG block 模块,通过对上下文特征提取,能够从较大视野中更加精准地识别图片中的头盔特征。

3 结论与讨论

本文提出 Yolov8-SCG 算法,在原有 Yolov8n 算法的基础上,引入 SPDCConv 模块,替换原模型中的普通卷积及下采样算子,提升了模型对于自主采集训练集中分辨率较低图像的辨识精度,改善了原有模型对于小目标检测精度较差的问题;融合 CG block 模块与原模

型的 C2f 模块,提出 C2f-CG block 模块,提供上下文特征提取与全文特征提取,优化了模型对于局部背景的筛选能力与全局信息的把握能力,防止与目标特征相似的背景提供错误的检测项;针对 SPDCConv 带来的计算量上升问题,替换 SPPF 模块中的普通卷积为组卷积,降低了整体模型的计算量,保持了模型轻量化的优势。

通过与多种主流算法的对比,验证出本文所提出的算法在准确度与计算量上达到了最优解,能够为实际场景电动车骑行人员头盔佩戴检测任务提供良好的解决方案。但其对于特定场景,如强光环境下会出现一定的检测误差。在后续的研究中,会着眼于多种实际场景下的应用,提升模型的泛化性。

参考文献(References):

- [1] 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. Piscataway: IEEE Press, 2016: 779-788.
- [2] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 6517-6525.
- [3] WANG C Y, BOCHKOVSKIY A, LIAO H M. Scaled-YOLOv4: Scaling cross stage partial network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 13029-13038.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [5] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 2999-3007.
- [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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] CAI Z, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 6154-6162.
- [8] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 2980-2988.
- [9] 聂壮壮,汪军,黄翔翔.基于改进 YOLOv5 的护目镜佩戴检测算法[J].重庆工商大学学报(自然科学版),2025,42(1):48-56.
NIE Zhuang-zhuang, WANG Jun, HUANG Xiang-xiang. Based on the improved YOLOv5 goggle wearing detection algorithm[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2025, 42(1):48-56.
- [10] MACALISANG J R, ALON A S, JARDINIANO M F, et al. Drive-awake: A YOLOv3 machine vision inference approach of eyes closure for drowsy driving detection[C]//Proceedings of the IEEE International Conference on Artificial Intelligence in Engineering and Technology. Piscataway: IEEE Press, 2021: 1-5.
- [11] BOUHAYANE A, CHAROUH Z, GHOGHO M, et al. A swin transformer-based approach for motorcycle helmet detection[J]. IEEE Access, 2023, 11: 74410-74419.
- [12] JIA W, XU S, LIANG Z, et al. Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector[J]. IET Image Processing, 2021, 15(14): 3139-3148.
- [13] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: convolutional triplet attention module[C]//Proceedings of the IEEE Winter Conference on Applications of Computer Vision. Piscataway: IEEE Press, 2021: 3138-3147.
- [14] 李世聪.基于深度学习的二轮车头盔检测算法研究[D].赣州:江西理工大学,2022:1-72.
LI Shi-cong. Research on Two-wheeler helmet detection algorithm based on deep learning[D]. Ganzhou: Jiangxi University of Science and Technology, 2022: 1-72.
- [15] 胡光喆.基于深度学习的道路安全头盔佩戴检测算法研究[D].徐州:中国矿业大学,2022:1-90.
HU Guang-zhe. Research on detection algorithm of road safety helmet wearing based on deep learning[D]. Xuzhou: China University of Mining and Technology, 2022: 1-90.
- [16] 陈扬,吕艳辉.基于改进 YOLOv5s 的头盔佩戴检测算法[J].沈阳理工大学学报,2023,42(5):11-17.
CHEN Yang, LYU Yan-hui. Algorithm of helmet wearing detection based on improved YOLOv5s[J]. Journal of Shenyang Ligong University, 2023, 42(5): 11-17.
- [17] 王雅妮,汤天培,刘希文,等.基于 RetinaNet 的电动自行车骑乘人员安全头盔佩戴行为检测模型[J].交通运输研究,2023,9(1):115-126.
WANG Ya-ni, TANG Tian-pei, LIU Xi-wen, et al. Detection model on electrical bike riders' safety helmet wearing based on RetinaNet[J]. Transport Research, 2023, 9(1): 115-126.
- [18] 张碧川,刘卫东,米浩,等.基于轻量化 YOLOv8 的安全帽检测[J].电脑与电信,2024(1):35-39.
ZHANG Bi-chuan, LIU Wei-dong, MI Hao, et al. Safety helmet detection based on lightweight YOLOv8[J]. Computer & Telecommunication, 2024(1): 35-39.
- [18] 张碧川,刘卫东,米浩,等.基于轻量化 YOLOv8 的安全帽检测[J].电脑与电信,2024(1):35-39.
ZHANG Bi-chuan, LIU Wei-dong, MI Hao, et al. Safety helmet detection based on lightweight YOLOv8[J]. Computer & Telecommunication, 2024(1): 35-39.
- [19] SUNKARA R, LUO T. No more strided convolutions or Pooling: a new CNN building block for Low-Resolution images and Small objects[C]//Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2023: 443-459.
- [20] WU T, TANG S, ZHANG R, et al. CGNet: A light-weight context guided network for semantic segmentation[J]. IEEE Trans Image Process, 2021, 30: 1169-1179.
- [21] IOANNOU Y, ROBERTSON D, CIPOLLA R, et al. Deep roots: improving CNN efficiency with hierarchical filter groups[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 1231-1240.

责任编辑:李翠薇