

## 基于改进YOLOv5的电动车头盔佩戴检测算法

谢溥轩, 崔金荣, 赵敏

引用本文

谢溥轩, 崔金荣, 赵敏. 基于改进YOLOv5的电动车头盔佩戴检测算法[J]. 计算机科学, 2023, 50(6A): 220500005-6.

XIE Puxuan, CUI Jinrong, ZHAO Min. Electric Bike Helment Wearing Detection Alogrithm Based on Improved YOLOv5 [J]. Computer Science, 2023, 50(6A): 220500005-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

[基于多特征融合的GRU-LSTM大学生就业动态预测](#)

College Students Employment Dynamic Prediction of Multi-feature Fusion Based on GRU-LSTM  
计算机科学, 2023, 50(6A): 220500056-6. <https://doi.org/10.11896/jsjx.220500056>

[基于深度学习的超高频标签识别系统](#)

Tag Identification for UHF RFID Systems Based on Deep Learning

计算机科学, 2023, 50(6A): 220200151-6. <https://doi.org/10.11896/jsjx.220200151>

[CT影像阶段化目标检测方法研究](#)

Study on Phased Target Detection in CT Image

计算机科学, 2023, 50(6A): 220200063-10. <https://doi.org/10.11896/jsjx.220200063>

[基于深度学习的摩托车车道实时检测](#)

Real-time Detection of Motorcycle Lanes Based on Deep Learning

计算机科学, 2023, 50(6A): 220200066-5. <https://doi.org/10.11896/jsjx.220200066>

[基于多尺度注意力机制的两阶段文物图像修复方法](#)

Two-stage Method for Restoration of Heritage Images Based on Muti-scale Attention Mechanism

计算机科学, 2023, 50(6A): 220600129-8. <https://doi.org/10.11896/jsjx.220600129>

# 基于改进 YOLOv5 的电动车头盔佩戴检测算法

谢溥轩<sup>1,2</sup> 崔金荣<sup>1,2</sup> 赵敏<sup>3</sup>

1 华南农业大学数学与信息学院 广州 510642

2 广州市智慧农业重点实验室 广州 510642

3 深圳市人工智能与机器人研究院 广东 深圳 518129

(312154302@qq.com)

**摘要** 在电动车交通事故中,颅脑损伤致死是电动车骑行人员死亡的主要原因,而大多数电动车骑行人员很少佩戴头盔,因此通过将目标检测算法与道路摄像头结合起来监管电动车骑行者头盔佩戴情况具有很强的现实意义。针对目前电动车头盔佩戴检测存在着目标相互遮挡漏检率较高、较小目标漏检率较高的问题,文中提出了一种改进的 YOLOv5 目标检测算法,用于实现对电动车头盔佩戴情况的检测。该方法首先在 YOLOv5 网络中添加通道注意力机制 ECA-Net,使得模型能够更快地检测到目标特征,从而提高模型的检测性能;其次,使用 Bi-FPN 加权双向特征金字塔模块,实现对不同层级特征重要性的平衡,有利于改进小目标漏检问题;最后,使用 Alpha-CIoU Loss 的损失函数,提高模型定位的准确性。实验结果表明,该方法在 3 种场景下对电动车骑行人员头盔佩戴情况的检测精度均高于其他模型,平均精度达到 95.8%,相比原网络检测精度有所提升,实现了电动车头盔佩戴情况的高精度检测。

**关键词** 深度学习;头盔佩戴检测;YOLOv5;Bi-FPN;ECA-Net;Alpha-CIoU

**中图分类号** TP391

## Electric Bike Helment Wearing Detection Algorithm Based on Improved YOLOv5

XIE Puxuan<sup>1,2</sup>, CUI Jinrong<sup>1,2</sup> and ZHAO Min<sup>3</sup>

1 College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2 Guangzhou Key Laboratory of Intelligent Agriculture, Guangzhou 510642, China

3 Shenzhen Institute of Artificial Intelligence and Robotics, Shenzhen, Guangdong 518129, China

**Abstract** In electric vehicle traffic accidents, craniocerebral injury is the main cause of death of electric vehicle riders, and most electric vehicle riders rarely wear helmets. Therefore, it is of strong practical significance to supervise the helmet wearing situation of electric vehicle riders by combining the target detection algorithm with road cameras. For the current problems of electric vehicle helmet wearing detection: the high leakage rate of targets blocking each other, and the high leakage rate of smaller targets, this paper proposes an improved YOLOv5 target detection algorithm to achieve the detection of electric vehicle helmet wearing. The method first adds the channel attention mechanism ECA-Net to the YOLOv5 network, so that the model can detect the target features, thus improving the model detection performance; the Bi-FPN weighted bidirectional feature pyramid module is used to achieve a balance of the importance of features at different levels, which is conducive to improving the small target miss detection problem; the loss function of Alpha-CIoU Loss is used to improve the accuracy of model localization. Experimental results show that the detection accuracy of the method is higher than other models for the helmet wearing situation of electric vehicle riders in all three scenarios, with an average accuracy of 95.8%, which is higher than the original network detection accuracy, and achieves high accuracy detection of electric vehicle helmet wearing situation.

**Keywords** Deep learning, Helmet wearing detection, YOLOv5, Bi-FPN, ECA-Net, Alpha-CIoU

## 1 引言

近年来电动自行车行业的快速发展,给人们的出行带来了极大的便利,也在一定程度上解决了人们出行“最后一公里”的问题,但由于电动自行车驾驶员没有经过系统的考核及培训,驾驶员的交通安全意识、规则意识普遍不高,因此直接

导致逐年攀升、居高不下的交通事故发生率和伤亡率。据统计,近 80% 的电动自行车事故死亡原因为颅脑损伤<sup>[1]</sup>,而较低的头盔佩戴率则正是伤亡率较高的重要原因之一。若电动车骑行人员能正确佩戴头盔,能够将交通事故死亡风险降低 60%~70%<sup>[1]</sup>,对保护人们的生命安全有着至关重要的作用。因此,将深度学习和目标检测算法应用于道路交通监管中来

基金项目:国家重点研发计划(2019YFB1310402);国家自然科学基金面上项目(1,62172285)

This work was supported by the National Key R&D Program of China(2019YFB1310402) and National Natural Science Foundation of China(1,62172285).

通信作者:崔金荣(tweety1028@163.com)

检测电动车骑行人员是否佩戴安全头盔具有很强的现实意义。

电动车头盔佩戴检测算法也是目标检测算法中的一类,随着“一盔一带”主题教育活动的开展,已经有许多国内学者对电动车头盔佩戴的检测展开了研究。如 Liu 等<sup>[2]</sup>将视觉机制引入 SSD 网络中,并利用其实现对摩托车头盔佩戴的检测;Ding 等<sup>[3]</sup>提出在 YOLOv3 中衔接特征融合结构,以此加强 YOLOv3 在检测头盔这一小目标时的检测效果;Jia 等<sup>[4]</sup>依托可变形部件模型,使用弹簧形变模型表征目标部件的空间位置关系,解决了目标部分遮挡和微小形变的问题,从而提高模型进行头盔佩戴检测时的检测率;Chen 等<sup>[5]</sup>先基于 HOG 获取图像特征值,再通过随机森林以及决策树算法实现头盔佩戴检测,为密集场景下的头盔佩戴检测提供了新思路。

目标检测算法主要分为两类:1)传统目标检测算法;2)基于深度学习的目标检测算法。而目前应用较为广泛的是基于深度学习的目标检测算法。基于深度学习的目标检测算法又分为 One-Stage 和 Two-Stage 算法,One-Stage 算法(如 YOLO<sup>[6]</sup>, SSD<sup>[7]</sup>)有着更快的检测速度,而 Two-Stage 算法(如 Fast R-CNN<sup>[8]</sup>)则有着更高的检测精度。由于本文所进行的头盔佩戴检测对实时性有着较高的要求,因此本文选择了检测速度较快的 YOLOv5 算法。

YOLOv5 作为 One-Stage 算法的代表,有着推理速度较快、结构简单等优势,但也存在着小目标检测效果较差的缺陷。此外,目前的电动车头盔佩戴检测算法还存在因目标相互遮挡而漏检率较高、算法模型规模较大等问题。

为了解决上述问题,优化模型对于电动车头盔佩戴检测的性能,本文提出了基于 YOLOv5 的电动车头盔佩戴检测算法。

本文的主要工作如下:

(1)提出了基于 YOLOv5 的电动车头盔佩戴检测算法。使用 Bi-FPN<sup>[9]</sup>加权双向特征金字塔网络改进检测模型的网络结构,增加了模型对不同层级特征重要性的平衡,提高了特征融合的效率,对小目标漏检问题进行了改进。

(2)使用 Alpha-CIoU Loss<sup>[10]</sup>代替 Ciou Loss 作为损失函数,以此提高模型定位的准确性。

(3)将通道注意力模块 ECA-Net<sup>[11]</sup>嵌入模型中,该模块通过自适应计算一维卷积以及参数共享的方式可实现性能的提升。

## 2 YOLOv5 算法原理

YOLOv5 是一种检测速度较快的 One-Stage 目标检测算法,由输入 input、主干网络 backbone、颈部 neck 以及输出 output 组成,而 backbone 和 neck 则是 YOLOv5 中的主要结构,具体网络结构如图 1 所示。输入图片在经过多个 Conv 和 C3 模块处理后将得到多个不同尺度的特征图,并将特征图送入 SPPF 模块中,SPPF 利用不同大小的池化核进行池化,池化后进行堆叠,并将输出结果输入到 neck 层。

为了能够提升模型提取融合特征的能力,在 backbone 和输出层中插入 neck 层,YOLOv5 中的 neck 层采用了 FPN<sup>[12]</sup>+PAN<sup>[13]</sup>的结构。FPN 主要是通过上采样的方法来使得高层特征图能够与低层特征图相融合,即实现多层特征信息的

融合,加强网络特征融合的能力,从而提升对不同尺度目标的检测。FPN 完成自顶向下的语义特征传递后,并没有实现对定位特征的传递,因此 YOLOv5 在 FPN 之后引入了 PAN 结构,PAN 通过下采样使低层特征图与高层特征图融合,实现自底向上的定位特征传递,融合了低层的位置信息,从而加强网络的特征融合。最后,将 PANet 处理过的特征图通过分类器进行分类,使用回归器对预测框进行修正微调,并通过 nms 非极大值抑制筛选出正确的预测框,最终实现对结果的预测。

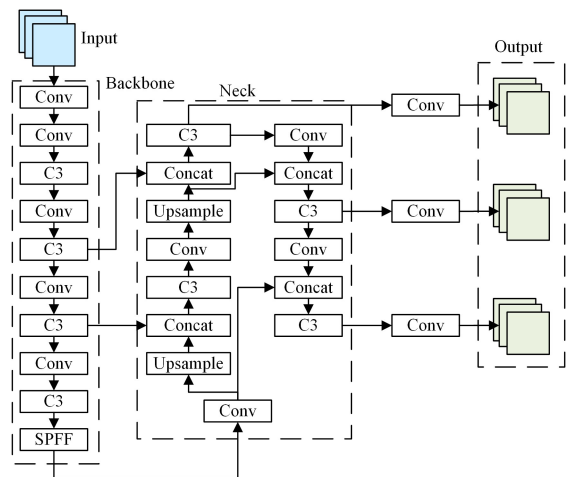


图 1 YOLOv5 的整体网络结构

Fig. 1 Overall network structure of YOLOv5

## 3 基于改进的 YOLOv5 头盔佩戴检测方法

为解决 YOLOv5 在小目标检测上的缺陷并提高模型性能,本文将从特征金字塔、损失函数以及通道注意力机制方面实现对 YOLOv5 的改进。

### 3.1 特征金字塔网络优化

随着神经网络层次的不加深,各个网络层级上所产生的特征也存在着比较明显的差异。为了能够在高层级特征中获取更多细节信息,从而提高模型对小目标检测的准确性,本文将 Bi-FPN 结构添加到 YOLOv5 模型中。

Bi-FPN 是由 Google 公司提出的一种加权双向特征金字塔网络,很好地平衡了不同层级特征值的重要性。Bi-FPN 不仅规模小并且效率高,在 COCO 数据集上实现了当前最高的平均精度,且相比 PANet 有着更少的参数和更小的计算量。PANet 在 FPN 的基础上添加了自底向上的一条线路,结构如图 2(a)所示,而 Bi-FPN 主要是通过删除 PANet 中一些对融合特征贡献较小的节点,同时在同尺度的输入输出节点中添加一个跳跃连接,结构如图 2(b)所示。通过这种优化后的结构既在一定程度上实现了简化网络结构,又能融合更多的特征。

此外,谷歌公司为了实现 Bi-FPN 中的加权特征融合,尝试了 3 种不同的融合方式:1)无界融合;2)基于 Softmax 的融合;3)快速归一化融合。无界融合对权重并没有限制,可能会引起训练的不稳定。基于 Softmax 的融合存在着导致 GPU 硬件发生显著减速的缺陷,而快速归一化融合策略不仅能获得与 Softmax 同等的准确性,而且具有速度更快的优点,因此本文采用快速归一化融合。基于 Softmax 的融合以及快速归一化融合的计算式分别如式(1)、式(2)所示:



## 4 实验设置

### 4.1 实验平台

为验证本文方法的有效性,本文搭建了相关实验平台,使用 ubuntu18.04 作为操作系统,PyTorch 作为深度学习框架对模型进行训练和测试,具体实验环境配置如表 1 所列。

表 1 实验环境

Table 1 Experimental environment

| 环境项    | 环境规格                 |
|--------|----------------------|
| 操作系统   | ubuntu18.04          |
| 集成开发环境 | Pycharm 社区版 2021.2.3 |
| 编程语言   | Python3.8            |
| 深度学习框架 | PyTorch1.8.0         |
| CPU    | Intel Xeon Gold 5218 |
| GPU    | GeForce RTX 2080 Ti  |

### 4.2 数据集构建

由于目前关于电动车骑行人员图像的数据集较少,因此本文使用了 kaggle 大赛公开的数据集中的部分图像,并通过爬虫方式从百度图库中收集相关图像,使用 LabelImg 对图像进行标注,最终形成了电动车骑行人员数据集和头盔佩戴数据集。该数据集包含了各个场景下的电动车骑行人员以及头盔佩戴的图像,两个数据集图像的数量分别为 9 687 张和 9 029 张。部分图像如图 5 所示,图 5(a)给出了电动车骑行人员数据集实例,图 5(b)给出了头盔佩戴数据集实例。



(a) 骑行人员数据集实例

(b) 头盔佩戴数据集实例

图 5 数据集实例

Fig. 5 Data set example

### 4.3 模型训练

在进行模型训练之前,需要对模型配置文件的参数进行修改,使其能够符合本文数据集的训练要求,模型训练参数设置如表 2 所列。

表 2 模型训练参数

Table 2 Training parameters of model

| 参数项    | 数值         |
|--------|------------|
| 预训练模型  | YOLOv5m_pt |
| 训练迭代次数 | 200        |
| 批大小    | 8          |
| 统一图片尺寸 | 640        |
| 学习率    | 0.0001     |

## 5 实验结果和分析

利用电动车骑行者数据集中所划分的测试集对本文提出的改进后的 YOLOv5 算法进行性能测试,并分别以 YOLOv5, SSD 以及 Faster RCNN<sup>[15]</sup> 算法进行对比实验,从而验证本文改进后的 YOLOv5 算法在电动车骑行人员头盔佩戴检测上的性能。实验主要由 4 个部分组成:1) 基于测试集的对比实验;2) 在密集场景下的对比实验;3) 对于后座乘车

人员头盔佩戴情况检测的对比实验;4) 针对小目标检测的对比实验。

### 5.1 基于测试集的算法检测结果对比

以相同的训练集、验证集以及 epoch 对上述算法进行训练后,以相同测试集对上述算法进行测试,并以平均准确率均值(mean Average Precision, m-AP)和每秒传输帧数(Frames Per Second, FPS)为评价指标,以此评价各种算法在测试集上的检测性能。评价指标的意义如下:

(1) 平均准确率均值(mAP): 衡量模型检测精度的指标, 即:

$$mAP = \frac{\sum AP}{N} \quad (8)$$

其中, AP 为某一检测类别的平均精度, N 是检测类别总数。

(2) 每秒传输帧数(FPS): 用于评价模型的检测速度, 即:

$$FPS = \frac{Num}{Time} \quad (9)$$

其中, Num 是固定时间间隔内检测的总帧数, Time 是固定的时间间隔长度。

测试后的实验结果如表 3 所列。

表 3 测试集上各模型的检测效果

Table 3 Detection effect of each model in test set

| 算法          | mAP/% | FPS |
|-------------|-------|-----|
| SSD         | 84.7  | 38  |
| Faster RCNN | 90.3  | 11  |
| YOLOv5      | 94.7  | 67  |
| 改进后 YOLOv5  | 95.8  | 50  |

从表中可以看出,本文改进后的 YOLOv5 模型在测试数据集上的 mAP 最高,相比原有的 YOLOv5 模型提高了 1.1%,而 SSD 和 Faster RCNN 在测试数据集上的 mAP 则相对较低。由于本文改进后的 YOLOv5 在网络结构上有所变化,例如添加了通道注意力机制 ECA-Net 以及对损失函数进行了优化,相应地增加了网络计算量,使得整体模型在推理预测时的速度较慢,因此 FPS 相对改进前的模型有所下降。

### 5.2 密集场景下算法检测结果对比

我国电动车种类繁多、数量大,因此模型在实际检测时在背景中往往会有大量的电动车,而电动车之间的相互遮挡和覆盖无疑会使模型检测的困难程度增加,因此设计一组实验来评估模型在多目标复杂背景条件下的检测性能,设计的实验方案如下。

使用 300 张包含多个检测目标(大于 5 个检测目标)的图片进行检测,并在相同的实验条件下,使用 SSD、Faster RCNN、YOLOv5 以及本文所构建的改进后的 YOLOv5 模型进行检测,检测结果如表 4 所列。

表 4 密集背景下各模型的检测效果

Table 4 Detection effect of each model in dense background

| 目标数量 | 模型          | 漏检数 | 漏检率/% | 错检数 | 准确率/% |
|------|-------------|-----|-------|-----|-------|
| 2490 | SSD         | 571 | 22.93 | 178 | 69.92 |
|      | Faster-RCNN | 515 | 20.68 | 162 | 72.81 |
|      | YOLOv5      | 433 | 17.39 | 173 | 75.66 |
|      | 本文方法        | 412 | 16.54 | 149 | 77.47 |

从表中可以看出,4 种模型受骑行人员的距离、重叠程度的影响比较严重,尤其是在密集背景下的检测效果都受到了一定程度的影响。但在此条件下,本文改进后的 YOLOv5 模型仍然比原 YOLOv5、SSD 以及 Faster-RCNN 模型的检测

效果都好,因此可以看出经过改进后的模型在密集背景下的检测效果有一定的提升。

为了能进一步凸显出各个模型之间在此场景下的性能差异,选取同一张图片作为测试图片,对 4 个模型的测试效果进行对比,4 种模型的检测效果如图 6 所示。



(a)SSD 检测效果 (b)Faster RCNN 检测效果 (c)YOLOv5 检测效果 (d)改进 YOLOv5 检测效果

图 6 密集背景情况下各模型的检测效果图

Fig. 6 Detection effect diagram of each model in dense background

从检测效果图中可以看出,本文模型在测试图中只出现了一名骑行人员头盔佩戴情况的漏检,没有出现错检,YOLOv5 也出现了一个漏检,而 SSD 和 Faster RCNN 则出现了较多的错检和漏检。

### 5.3 后座乘车人员检测结果的对比

由于在现实情况中,电动车往往会乘载 2~3 名骑行者,因此模型还需要对电动车后座上的乘坐人员进行头盔佩戴检测。因此,设计了一组实验来评估模型在电动车存在后座人员情况下检测时的性能,设计的实验方案如下。

使用 300 张电动车存在后座乘车人员的图片进行检测,并在相同的实验条件下,使用 SSD、Faster RCNN、YOLOv5 和本文所构建的改进后的 YOLOv5 模型进行检测,检测结果如表 5 所列。


表 5 后座存在乘车人员条件下各模型的检测效果

Table 5 Detection effect of each model with passengers in back seat

| 目标数量 | 模型          | 漏检数 | 漏检率 / % | 错检数 | 准确率 / % |
|------|-------------|-----|---------|-----|---------|
| 425  | SSD         | 84  | 19.76   | 35  | 72.00   |
|      | Faster-RCNN | 28  | 6.59    | 20  | 88.71   |
|      | YOLOv5      | 33  | 7.76    | 13  | 89.18   |
|      | 本文方法        | 26  | 6.12    | 12  | 91.06   |

从表中可以看出,本文改进后的 YOLOv5 在漏检和错检数量上都是最少的,准确率也是 4 个模型中最高的,因此可以看出经过改进后的 YOLOv5 在当前场景下的改进效果的有效性。

为了能进一步凸显各个模型之间在此场景下的性能差异,选取同一张测试图片进行对比,4 种模型的检测效果如图 7 所示。



(a)SSD 检测效果 (b)Faster RCNN 检测效果 (c)YOLOv5 检测效果 (d)改进 YOLOv5 检测效果

图 7 后座存在乘车人员情况下各模型的检测效果图

Fig. 7 Detection effect diagram of each model with passengers in back seat

从图中可以看出,Faster RCNN 和 YOLOv5 以及本文模型均正确检测出后座乘车人员的头盔佩戴情况,而 SSD 模型则未能检测出后座乘车人员的头盔佩戴情况。

### 5.4 针对小目标检测结果的对比

在头盔佩戴检测的实际运用场景中,往往会存在许多距离摄像头较远的小目标。其中,在实际运用中对小目标的定义如下:

$$Small_{target} : \sqrt{\frac{w_{img} \cdot h_{img}}{w_{pre} \cdot h_{pre}}} < 3\% \quad (10)$$

其中, $w_{img}$ 和 $h_{img}$ 分别表示完整图像的宽和高, $w_{pre}$ 和 $h_{pre}$ 分别表示预测框的宽和高。

虽然当前基于深度学习的目标检测算法已经获得高于传统目标检测算法的检测精度和鲁棒性,但对于小目标检测仍然存在较高的漏检率。因此,本文进行了针对小目标的模型优化,并设计了一组实验来评估模型在骑行人员佩戴不同头盔情况下的检测效果,设计的实验方案如下。

使用 300 张包含小目标的图片进行检测,并在相同的实验条件下,使用 SSD、Faster RCNN、YOLOv5 以及本文所构建的改进后的 YOLOv5 模型进行检测,检测结果如表 6 所列。


表 6 小目标条件下各模型的检测效果

Table 6 Detection effect of each model for small target conditions

| 目标数量 | 模型          | 漏检数 | 漏检率 / % | 错检数 | 准确率 / % |
|------|-------------|-----|---------|-----|---------|
| 360  | SSD         | 83  | 23.06   | 26  | 69.72   |
|      | Faster-RCNN | 79  | 21.94   | 22  | 71.94   |
|      | YOLOv5      | 67  | 18.62   | 14  | 77.50   |
|      | 本文方法        | 59  | 16.39   | 18  | 78.61   |

从表中可以看出,本文模型在针对小目标检测的准确率最高,但是 4 个模型在此条件下的检测准确率都不高,经过对测试结果的研究发现,针对小目标图像的检测,往往会受到图像质量的限制。图像分辨率较低时,模型检测的效果较差。

为了能进一步凸显出各个模型之间在此场景下的性能差异,选取同一张图片作为测试图片,对 4 个模型的测试效果进行对比,4 种模型的检测效果如图 8 所示。从图中可以看出,本文模型出现了一个漏检,YOLOv5 模型出现了 4 个漏检,而 SSD 和 Faster RCNN 均出现了较多的错检和漏检,因此本文方法在针对小目标检测条件下进行的改进是有效的。



(a)SSD 检测效果 (b)Faster RCNN 检测效果 (c)YOLOv5 检测效果 (d)改进 YOLOv5 检测效果

图 8 针对小目标条件下各模型的检测效果图

Fig. 8 Detection effect of each model for small target conditions

**结束语** 为了利用深度学习算法规范电动车骑行人员佩戴头盔,同时提高目标检测算法在此过程中的检测准确度,本文提出了一种改进 YOLOv5 的电动车头盔佩戴检测算法。

本文提出的检测算法在相同实验条件下,比 YOLOv5,SSD 以及 Faster RCNN 有着更高的检测精度,在测试集上 mAP 达到了最佳的 95.8%,同时速度达到了 50FPS,基本满足实时检测的要求。此外,通过实验证明,该算法在复杂场景下也有较高的检测精度和鲁棒性,能够

适用于现实场景中的检测。值得说明的是,由于距离、严重遮挡以及光线等原因,本文算法在密集场景以及小目标检测条件下的检测精度还有很大的提升空间,在后续的工作中将对此进行进一步的深入研究。

### 参 考 文 献

- [1] The Ministry of Public Security Traffic Management Bureau deployed to carry out the “one helmet and one belt” safety guarding action [J]. Road Traffic Management, 2020, 35(5): 9-10.
- [2] LIU C, WANG J T, WANG M Y. Application of SSD network with introduced visual mechanism in motorcycle helmet wearing detection[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 144-151.
- [3] DING M D, LI Y X. Design and implementation of helmet wearing recognition system for cyclists based on YOLOv3[J]. China New Communication, 2021, 23(13): 44-45.
- [4] JIA J S, BAO Q J, TANG H M. Safety helmet wearing detection based on deformable component model[J]. Computer Application Research, 2016, 33(3): 953-956.
- [5] CHENG C C, HU S F. Research on intelligent detection of helmet wearing in intensive scenes[J]. Intelligent Computers and Applications, 2020, 10(9): 223-224.
- [6] 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.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector [C] // Computer Vision-ECCV 2016: 14th European Conference. Springer International Publishing, 2016: 21-37.
- [8] GIRSHICK R. Fast R-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision. 2015: 1440-1448.
- [9] TAN M, PANG R, LE Q V. EfficientDet: Scalable and Efficient Object Detection [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [10] HE J, ERFANI S, MA X, et al. Alpha-IOU: A Family of Power Intersection over Union Losses for Bounding Box Regression [J]. Advances in Neural Information Processing Systems, 2021, 34: 20230-20242.
- [11] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [12] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature Pyramid Networks for Object Detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2117-2125.
- [13] LI H, XIONG P, AN J, et al. Pyramid Attention Network for Semantic Segmentation [J]. arXiv: 1805. 10180, 2018.
- [14] JIE H, LI S, GANG S, et al. Squeeze-and-Excitation Networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.
- [15] 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.



**XIE Puxuan**, born in 2000, undergraduate. His main research interests include machine learning and image processing.



**CUI Jinrong**, born in , Ph.D, lecture, is a member of China Computer Federation. Her main research interests include face recognition, image processing and pattern recognition, machine learning etc.