

基于改进 YOLOv10n 的电动车头盔佩戴检测算法^{*}

周翔¹ 王可庆² 周新翔¹ 韩基泰²

(1. 南京信息工程大学自动化学院 南京 210044; 2. 无锡学院自动化学院 无锡 214105)

摘要: 针对电动车头盔佩戴检测方法存在着复杂路况下头盔小目标检测精度较低、目标相互遮挡漏检率较高、检测模型大运算复杂等问题。本研究提出一种基于改进 YOLOv10n 的目标检测算法,以解决在实际应用中的这些问题。首先,在 MAFPN 的基础上融合了 BiFPN 的优点,创新性地提出了 BIMAFPN 结构,提高了模型在复杂路况场景下的检测性能。其次,构建 Inner-Wise-MPDIoU 损失函数以替代传统的 CIoU 损失函数,在提高网络的检测精度的同时,还加速了模型的收敛过程。最后,引入 LSCD 检测头进一步减少模型参数量并提升检测性能。实验结果表明,改进模型相比于原模型在 mAP@0.5 精度上提升了 2.7%,同时参数量降低了 25%,模型大小减少了 35%。本研究使用的检测方法不仅显著提高了复杂路况下的头盔检测精度,同时在兼顾轻量化的基础上保持了良好的实时性,便于将模型部署于小型嵌入式交通设备中。

关键词: YOLOv10n; 头盔佩戴检测; BIMAFPN; 损失函数; LSCD; 模型轻量化

中图分类号: TP391.4; TN06 文献标识码: A 国家标准学科分类代码: 520.6040

Electric bike helmet wearing detection algorithm based on improved YOLOv10n

Zhou Xiang¹ Wang Keqing² Zhou Xinxiang¹ Han Jitai²

(1. College of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;

2. College of Automation, Wuxi University, Wuxi 214105, China)

Abstract: For the electric vehicle helmet wearing detection method exists in complex road conditions helmet small target detection accuracy is low, the target mutual occlusion leakage rate is high, detection model large arithmetic complexity and other problems. This question proposes a target detection algorithm based on improved YOLOv10n to solve these problems in practical applications. Firstly, the advantages of BiFPN are integrated on the basis of MAFPN, and the BIMAFPN structure is innovatively proposed, which improves the detection performance of the model in complex road scenarios. Secondly, the Inner-Wise-MPDIoU loss function is constructed to replace the traditional CIoU loss function, which improves the detection accuracy of the network while accelerating the convergence process of the model. Finally, the LSCD detection head is introduced to further reduce the number of model parameters and improve the detection performance. Experimental results show that compared with the original model, the improved model improves the accuracy of mAP@0.5 by 2.7%, the number of parameters is reduced by 25%, and the model size is reduced by 35%. The detection method used in this paper not only significantly improves the accuracy of helmet detection under complex road conditions, but also maintains good real-time performance while taking into account lightweight, which makes it easy to deploy the model in small embedded transport devices.

Keywords: YOLOv10n; helmet wearing detection; BIMAFPN; loss function; LSCD; model lightweighting

0 引言

近些年,我国城市交通中的电动自行车数量不断上升,为保障电动车骑行人的道路安全,国家交管部门强制性规定骑行时需佩戴头盔。因此,将目标检测算法与道路摄像

头相结合,运用于电动车骑行人头盔佩戴识别场景中,发挥着至关重要的作用。

目前,主流的深度学习目标检测算法分为双阶段检测算法和单阶段检测算法。双阶段检测算法的典型代表为 R-CNN^[1](region-based convolutional neural networks, R-

CNN) 系列, 如 Fast R-CNN^[2] 和 Faster R-CNN^[3] 算法等, 由于该类方法需要进行候选区域生成和特征分类两阶段处理, 模型结构复杂, 计算复杂度高, 实时性较差。Dahiya 等^[4] 和 Vishnu 等^[5] 采用 Fast R-CNN 目标检测算法, 分别实现了对自行车和摩托车骑乘人员安全头盔佩戴行为的自动检测, 但算法在应对复杂应用场景时检测效率较低。王雅妮等^[6] 使用特征金字塔网络 (feature pyramid networks, FPN) 结构改进 Fast R-CNN 模型, 提高了电动车头盔检测在不同角度和光线下检测效果的稳定性。但此类模型参数量较大, 不适合在低算力嵌入式设备上部署。

单阶段检测算法的典型代表为 SSD^[7] (single shot multibox detector, SSD) 和 YOLO (you only look once, YOLO) 系列算法。YOLO 算法将检测和分类任务合并处理, 模型结构简单, 可以实现更高的实时检测性能。YOLO 算法设计了输入端、骨干网络、颈部网络、输出端等模块。从 YOLOv1 到 YOLOv10 多个改进版本, 已被广泛应用于交通、工业、农业等众多领域。王新等^[8] 提出了 EfficientNetV2-SSD 算法, 通过使用轻量级 EfficientNetV2 网络和 FPN 金字塔结构改进了 SSD 中的部分结构, 提高了头盔小目标的检测准确率, 但是相对于 YOLO 系列算法来讲, 模型尺寸较大, 处理速度也相对较慢。朱周华等^[9] 针对 YOLOv5 模型, 通过引入 CBAM 和 CA 注意力模块, 结合改进的 DIoU-NMS 算法, 并增加多尺度特征融合, 提升了头盔小目标的检测效果。谢溥轩等^[10] 则在 YOLOv5 中添加高效通道 ECA 注意力机制和 Bi-FPN 模块, 并引入 Alpha-CIOU Loss, 进一步平衡了不同层级特征的重要性并增强定位性能, 同样在小目标检测上取得了显著提升。但上述改进在目标相互遮挡的情况下仍有较高的漏检率。Mu 等^[11] 通过深化网络结构、加入加权连接和引入轻量级卷积模块改进了 YOLOv8n, 显著提升了小目标识别的精度, 并有效减少了模型参数。周顺勇等^[12] 通过引入渐进式特征金字塔网络结构, 设计 PCAHead 检测头和 HelmetIoU 损失函数, 对 YOLOv8n 进行了改进, 从而在目标相互遮挡的检测场景中有效降低了漏检率。但上述方法在复杂路况场景下的检测能力较弱, 准确性有所下降。高立鹏等^[13] 提出了一种基于 REIW-YOLOv10n 的安全帽检测算法, 通过设计 RepNMSC 结构并在颈部引入 ERepGFPN 结构, 同时替换了原有的损失函数, 有效提高了在复杂环境中对安全帽佩戴情况的检测精度。然而, 该模型的检测速度为 75 fps, 实时性相对较差, 可能影响实际检测进程。Du 等^[14] 通过调整主干通道参数并引入 BiFormer 模块, 同时细化 Neck 结构并采用 Power-IoU 损失函数对 YOLOv10n 进行改进, 结合稀疏注意机制和低频增强滤波器优化特征提取与图像处理, 从而有效提升了模型在复杂应用场景下的检测精度。然而, 这些改进也导致了模型参数量和计算量的增加。

上述改进算法在电动车头盔佩戴检测方面具有一定的

贡献, 但现有的大多数方法仍然存在着在复杂路况下头盔小目标检测精度较低、目标相互遮挡漏检率较高、检测模型大运算复杂的问题, 这对它们的广泛采用构成了很大的障碍, 特别是在资源受限的嵌入式设备上。为了解决这些问题, 本研究提出了一种基于改进 YOLOv10n 的电动车头盔佩戴检测算法。本文的主要改进方法总结如下: 通过在多分支辅助特征金字塔网络^[15] (multi-branch auxiliary FPN, MAFPN) 的基础上融合了加权双向金字塔 (bidirectional FPN, BiFPN)^[16] 的优点, 提出了 BIMAFPN 结构, 提升了在复杂路况下的检测性能; 使用 Inner-Wise-MPDIoU 替代传统的 CIOU 损失函数, 利用缩放因子和梯度增益策略, 在提高网络检测精度的同时还加速了模型的收敛; 引入轻量级共享卷积检测头 (lightweight shared convolutional detection head, LSCL) 进一步减少模型参数量并提升模型检测性能。

1 YOLOv10n 算法原理

YOLOv10 是该系列模型的迭代版本之一, 它继承了前几代 YOLO 模型的优点, 并进行了一些新的改进, 进一步提升了目标检测的性能, 具体网络结构如图 1 所示。YOLOv10 提出一致的双分配策略^[17], 消除 YOLO 系列的非极大值抑制训练依赖, 并采用了整体效率和准确性驱动的模型设计策略, 显著提高了其性能和效率。YOLOv10 的模型结构由 3 大部分组成: 主干网络 (Backbone)、特征融合模块 (Neck) 和检测头 (Detection Head)。在主干网络中, 其继承了 YOLOv8 的 C2f 和 SPPF 结构, 并引入了 SCDown、C2fUIB 和部分自注意力机制 (position-wise spatial attention, PSA) 3 个新的模块。SCDown 通过将点卷积与深度卷积串联, 实现空间与通道的分离下采样。C2fUIB 是 YOLOv10 的核心构建模块, 采用紧凑的倒置块结构, 利用高效的深度卷积进行空间信息的混合, 并通过低成本的点卷积完成通道间的融合操作。此外, YOLOv10 提出了高效的 PSA, 解决了传统自注意力机制计算复杂度过高的问题。在特征融合部分, YOLOv10 采用了路径聚合网络 (path aggregation network, PANet)^[18] 层, 有效融合多尺度特征, 从而提升模型在不同大小目标检测上的性能。在检测头部分, YOLOv10 使用了 One-to-one Head 和 One-to-many Head 两种轻量级检测头, 进一步优化了训练效率和检测精度。

YOLOv10 在小目标图像数据集上效果很好, 尤其是在复杂背景下头盔这种容易被遮挡的小目标能够更好地被检测到, 同时兼顾模型轻量化方便嵌入式设备部署。YOLOv10 系列具体分为 YOLOv10n、YOLOv10s、YOLOv10m、YOLOv10b、YOLOv10l 和 YOLOv10x 共 6 个模型。考虑到道路工作面应用场景边缘设备部署时需做到模型高效且轻量的要求, 本研究选择 YOLOv10n 作为基准模型, 进行电动车头盔佩戴目标检测任务的研究。

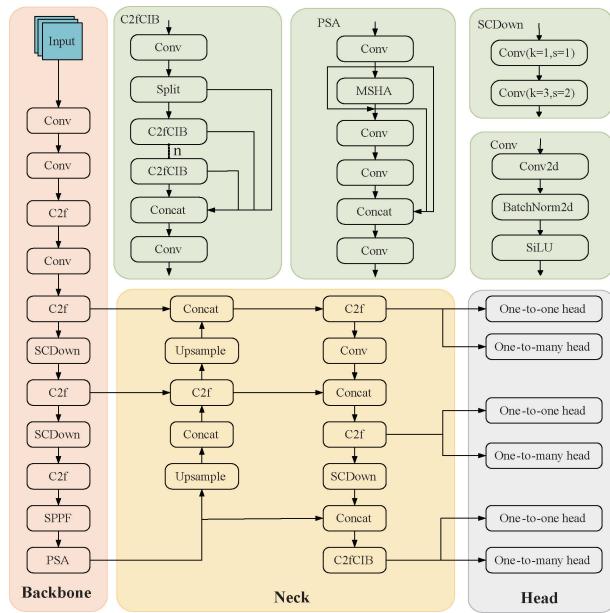


图 1 YOLOv10 网络结构示意图

Fig. 1 Structure diagram of YOLOv10 network

2 算法的创新与改进

为了进一步优化 YOLOv10n 在电动车头盔佩戴检测方面的综合性能,解决提出的一些实际应用场景遇到的问题,本研究将从特征融合模块、损失函数以及检测头方面实现对 YOLOv10n 的改进,结构如图 2 所示。

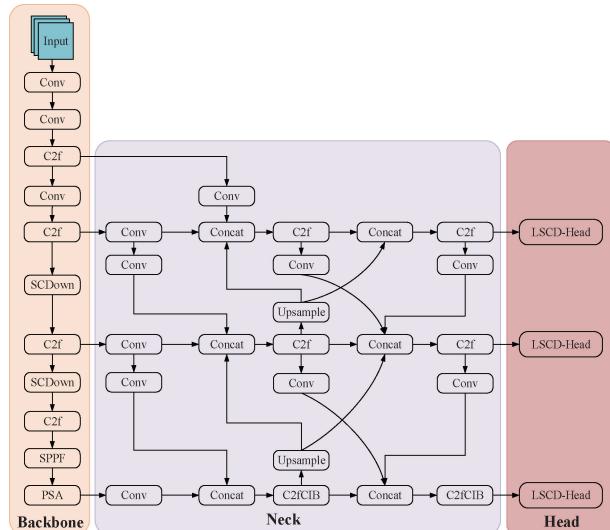


图 2 改进的 YOLOv10 网络结构

Fig. 2 Structure diagram of improved YOLOv10 network

2.1 BIMAFPN 特征金字塔网络结构

随着神经网络层次的不断加深,各个网络层级上所产生的特征也存在着比较明显的差异。YOLOv10 的多尺度特征融合模块采用了基于 PANet 的结构,其中上采样和下采样操作之间的信息流为单向传递。这种设计在训练过程

中对于头盔等小目标的特征信息融合效果不佳,单个节点获取的信息有限,同时增加了模型的参数量。针对以上问题,本研究为颈部设计了 BIMAFPN 结构,该结构在 MAFPN 的基础上融合了 BiFPN 的优点,结构如图 3 所示。

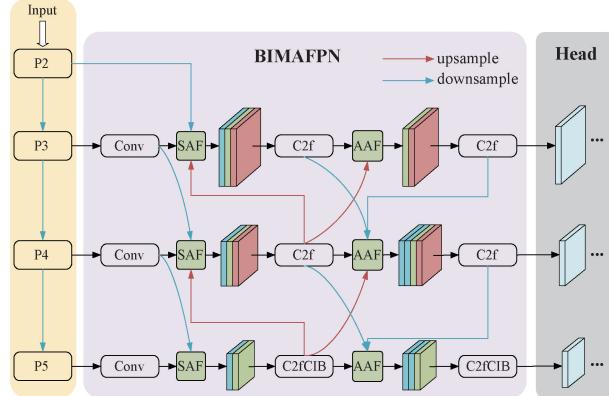


图 3 BIMAFPN 网络结构

Fig. 3 Structure of BIMAFPN network

在改进模型中,输入图像首先通过主干网络的 4 个阶段:P2、P3、P4 和 P5,逐步提取特征。接着引入 BiFPN 结构的部分思想,在空间注意力融合之前,在不同层次上执行卷积操作,每个卷积层负责对输入特征图进行进一步的卷积处理,从而提取到更加丰富和细致的特征,以增强特征图的多尺度表示能力。在第一个自下而上的路径中,空间注意力融合(superficial assisted fusion, SAF)模块负责从主干网络中提取多尺度特征,并在颈部的浅层实现初步的辅助融合,增强低层次特征的表征能力。与此同时,自适应注意力融合(advanced assisted fusion, AAF)模块通过更密集的连接在第 2 个自上而下的路径中收集每 1 层的梯度信息,进一步优化特征传递过程。这种结构不仅有效整合了不同层次的特征,还为检测头提供丰富的上下文信息,同时在结构设计上还简化了模型的复杂度,更加有利于模型的轻量化。

在主干网络中保留浅层的空间信息对于增强小目标的检测能力至关重要。网络结构中的 SAF 的主要目标是将深层信息与主干网络中相同层级的特征以及高分辨率的浅层特征进行整合,旨在保留丰富的定位细节,增强网络的空间表征能力,模块原理图如图 4 所示。利用 1×1 卷积来控制浅层信息的通道数,确保在进行拼接操作时,它占据较小的比例,从而不影响后续的学习过程。其中 P_{n-1} 、 P_n 和 P_{n+1} 分别表示不同分辨率下的特征图, P_n 、 P'_n 和 P''_n 表示主干网络的特征层和 MAFPN 的路径, up 表示上采样操作, Down 表示带有批归一化层的 3×3 下采样卷积, C 表示用于控制通道数的 1×1 卷积。

为了进一步增强特征层信息的交互利用,本研究在 MAFPN 的深层中引入了 AAF 模块进行多尺度信息整合,

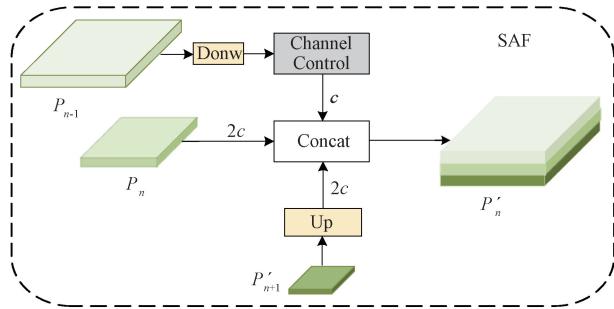


图 4 空间注意力融合结构

Fig. 4 The architecture of superficial assisted fusion

模块原理图如图 5 所示。具体来说,图 5 展示了 P''_{n-1} 中的AAF 连接,涉及浅层高分辨率特征层 P'_{n+1} 、浅层低分辨率特征层 P'_{n-1} 、同级浅层特征层 P'_n 以及上一层 P''_{n-1} 的信息聚合。此时,最终的输出层能够同时融合来自不同层的信息,从而显著提升对大小目标的检测性能。AAF 同样采用 1×1 卷积控制通道数,以调节每一层对输出结果的影响。借鉴传统 FPN 的单路径结构,本研究将每一层的通道数设为相同,以确保模型能够获得多样化的输出。

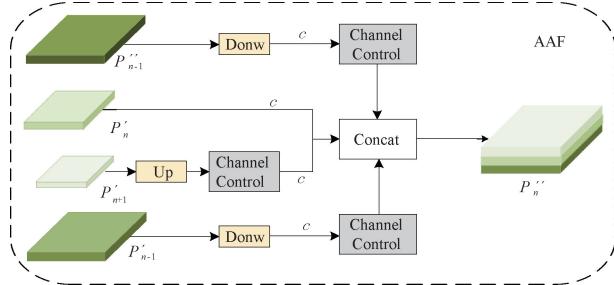


图 5 自适应注意力融合结构

Fig. 5 The architecture of advanced assisted fusion

2.2 Inner-Wise-MPDIoU 损失函数

YOLOv10n 损失函数由偏移量位置损失、类别分类损失以及预测框的回归损失组成。其中,预测框回归损失用于衡量预测框和真实框的位置差异,YOLOv10n 采用 CIoU 损失函数进行计算。在使用 CIoU 损失函数时,当真实框与预测框具有相同的宽高时,宽高比的惩罚项 $v=0$,惩罚项失去作用,CIoU 损失函数失去有效性,导致模型的收敛速度与精度受限。为解决上述问题,本文引入一种新的边界框回归的损失函数 MPDIoU^[19] 替换 CIoU。

MPDIoU 的核心公式为:

$$MPDIoU = IoU - \frac{d_1^2 + d_2^2}{h^2 + w^2} \quad (1)$$

MPDIoU Loss:

$$L_{MPDIoU} = 1 - MPDIoU \quad (2)$$

其中, d_1 和 d_2 分别代表预测边界框与真实边界框的对角线之间的欧式距离。 h 和 w 分别是边界框的高度和宽度, IoU 表示预测边界框和真实边界框之间的交并比。

通过这种设计,MPDIoU 不仅考虑了边界框的重叠程度,还考虑了它们之间的相对位置和形状,从而在保持 CIoU 损失函数优点的同时,增加了对边界框对齐精度的考量。这使得 MPDIoU 在目标检测和实例分割等任务中,相比于传统的损失函数,能够更准确地评估和优化边界框的预测结果。

为提高 MPDIoU 的收敛速度,引入了 Inner-IoU^[20] 的辅助边界框概念和 Wise-IoU^[21] 的动态聚焦机制对 MPDIoU 进行改进,即 Inner-Wise-MPDIoU。这种损失函数旨在通过辅助边界框来改善边界框的初始定位,利用 Wise-IoU 的动态聚焦提高对中质量样本的关注,同时通过 MPDIoU 优化边界框的精确对齐。

基于 Inner-IoU 的思想,使用辅助边界框来改进损失函数对于不同质量样本的处理,尤其是在边界框大小和形状极度不一致的情况下。采用 Wise-IoU 的动态非单调聚焦系数,根据样本的质量动态调整损失函数的权重,优化模型对不同质量样本的学习。通过 MPDIoU 计算边界框之间的距离,以提高边界框对齐的精度,特别是重叠或部分重叠的边界框。

Inner-Wise-MPDIoU 核心公式为:

$$L_{Inner-Wise-MPDIoU} = r \times L_{MPDIoU} + IoU - IoU_{Inner} \quad (3)$$

其中, r 为 Wise-IoU 中的动态聚焦系数, L_{MPDIoU} 为 MPDIoU Loss, IoU 为预测边界框和真实边界框之间的交并比, IoU_{Inner} 为 Inner-IoU 中辅助框的预测边界框和真实边界框之间的交并比。

这种损失函数融合了上述 3 种损失函数的优势,将其各个的核心功能串联到了一起。在电动车头盔检测数据集上有着十分优异的表现,具有更快的收敛速度,更小的损失函数值,并且改进了损失函数的同时不会给网络结构带来任何计算负荷,完全是无任何损失的提升。

2.3 LSCD 检测头

YOLOv10 的原始检测头包含多个检测层,每个检测层都有自己独立的卷积运算,用于处理输入的特征图并生成最终的检测结果,由于每个检测层的独立卷积运算,导致产生了大量的参数,浪费计算资源。针对上述问题,本研究引入了一种 LSCD 检测头,其结构如图 6 所示。

该结构接收 P3、P4、P5 层级输入特征,首先使用卷积核为 1×1 的共享卷积处理,增加通道维度的信息交换;其次,使用两个 3×3 卷积核的共享卷积进行信息聚合,减少冗余信息,增加相邻特征信息的学习概率;最后,将共享卷积提取的信息输入到分类和回归头中,并通过 Scale 层进行特征缩放,增强多尺度特征的保留能力。在卷积模块部分,共享卷积模块是由 CBS 卷积模块中的批量归一化 (batch normalization, BN) 层替换为组归一化 (group normalization, GN) 层。BN 层的归一化计算依赖于批次大小,批次变小时均值和方差计算不稳定,导致小批次时误差增大。为了解决这一问题,提出了 GN 层,它通过将特征通

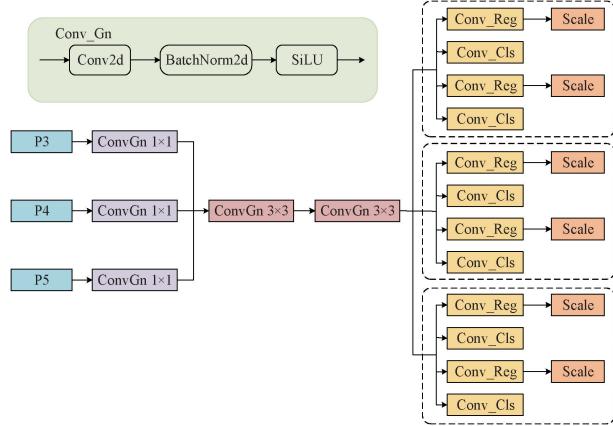


图 6 LSCD 检测头网络结构

Fig. 6 LSCD detection head network structure

道分组,并在组内计算均值和方差进行归一化,避免了对批次大小的依赖,确保在不同批次大小下精度稳定。

共享卷积检测头的设计可以有效的减少参数量和计算量,提升模型的运行速度,同时处理不同尺度的特征,捕获图像中各尺寸的信息,有助于模型更好地理解图像中物体之间的关系。将轻量化共享卷积检测头 LSCD 运用于电动车头盔佩戴检测中,提高了模型的推理速度和适用性,同时也有助于降低在目标相互遮挡情况下头盔的漏检率。

3 实验结果和分析

3.1 实验环境配置

本实验用的操作系统为 Windows 10 64 位, GPU 为 NVIDIA GeForce GTX 4060,CPU 为 13th Gen Intel(R) Core(TM) i5-13490F,CUDA 版本为 12.1,深度学习框架使用 PyTorch 搭建,PyTorch 版本为 2.2.2,Python 版本为 3.10.14。

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,使其能够符合本研究数据集的训练要求,模型训练参数设置如表 1 所示。

表 1 模型训练参数

Table 1 Model training parameters

参数项	数值
图片尺寸	640×640
训练迭代次数	200
批大小	32
学习率	0.01
线程数	8

3.2 数据集构建

随着国家惩治行车不戴头盔违法行为的力度不断加大,电动车头盔检测任务也越来越重要。由于目前关于电动车骑行人员图像的数据集较少,因此本文使用了双轮车

佩戴头盔检测数据集 (two wheeler helmet dataset, TWHD),并通过爬虫方式从百度图库中收集相关图像,按照双轮车与驾乘人员整体、未戴头盔的人头、戴头盔的人头进行定位与分类标注,最终形成了电动车骑行人员头盔佩戴数据集,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。

数据集总共包括 6 085 幅图像,标注共 3 个类别,这些图像以 8:1:1 的比例被随机分为训练集、验证集和测试集。其中,训练集由 4 868 张图像组成,验证集由 608 张图像组成,测试集由 609 张图像组成。

3.3 评估指标

为了验证模型对电动车头盔佩戴的检测性能,本研究选取了精确度 (precision, P)、召回率 (recall, R)、平均精度 (average presion, AP)、平均精度均值 (mean average presion, mAP)、浮点运算量 (floating-point operations per second, FLOPs)、参数量 (parameters)、帧率 (frames persecond, FPS)、模型大小作为评价指标。

其中,精度用于描述检测到的目标中正样本所占比例,计算公式如式(4)所示。其中 T_p 表示佩戴安全帽且预测为已佩戴安全帽的目标数量; F_p 表示未佩戴头盔但预测为已佩戴头盔的目标数量。

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (4)$$

召回率用于描述检测到的正样本占所有正样本的比例,计算公式如式(5)所示。其中 F_n 表示佩戴头盔但预测为未佩戴头盔的目标数量。

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (5)$$

所有类别的平均精度(AP)为平均精度均值(mAP),计算公式如式(6)、(7)所示。其中 T_n 表示未佩戴头盔且预测为未佩戴头盔的目标数量。

$$AP = \frac{T_p + T_n}{T_p + F_p + T_n + F_n} \times 100\% \quad (6)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n A_{p_i} \quad (7)$$

FPS 表示在 1 s 内可以处理和输出多少帧图像,FPS 越大,模型对图片处理速度越快,计算公式如式(8)所示。 t_1 是图像预处理时间, t_2 是图像推理时间, t_3 是后处理时间。

$$FPS = \frac{1000 \text{ ms}}{t_1 + t_2 + t_3} \quad (8)$$

3.4 不同损失函数分析对比

不同回归损失函数的设计,对目标检测的性能有重要影响。为了研究不同的损失函数对模型检测精度的影响,实验将分别使用 CIoU、EIoU、DIOU、GIoU、SIOU、ShapeIoU、MPDIoU 等 7 种常见的损失函数在本文数据集上进行对比实验,实验结果如表 2 所示。

表 2 不同损失函数对比

Table 2 Comparison of different loss functions

损失函数	mAP@0.5/%	Parameters/M	FLOPs/M
CIoU(原模型)	81.7	2.26	6.5
EIoU	81.9	2.26	6.5
DIoU	82.1	2.26	6.5
GIoU	81.7	2.26	6.5
SIoU	81.7	2.26	6.5
ShapeIoU	82.1	2.26	6.5
MPDIoU	82.3	2.26	6.5

由表 2 可知,在相同实验条件下,更换不同的回归损失函数对模型的精度有不同的影响。使用 MPDIoU 作为损失函数对模型的检测精度提升最大,且不影响模型的参数量和计算量。因此,为了使模型达到更好的检测效果,本研究采用 MPDIoU 作为回归损失函数。此外,为提高 MPDIoU 的收敛速度,引入了 Inner-IoU 的辅助边界框概念和 Wise-IoU 的动态聚焦机制对 MPDIoU 进行改进,即 Inner-Wise-MPDIoU。本研究将各个对损失函数的改进进行组合实验,实验结果如表 3 所示。

通过将 MPDIoU 损失函数与 Inner-IoU 辅助边界框概念结合进行实验,结果表明,改进后的方法相比于单独使用 MPDIoU,精度提升了 0.2%,同时参数量和计算量保持不变。另通过将 MPDIoU 损失函数与 Wise-IoU 的动态聚焦机制结合进行实验,精度较 MPDIoU 提高了 0.1%,同样在参数量和计算量上未发生变化。进一步将 Inner-IoU 辅助边界框概念与 Wise-IoU 动态聚焦机制结合,提出了 Inner-Wise-MPDIoU,实验结果显示该方法的精度优于前两组组合实验,较 MPDIoU 提升了 0.3%。由此可见,结合这两种

对 MPDIoU 的改进方式,在电动车头盔佩戴检测中能达到最佳效果。

表 3 MPDIoU 损失函数改进系列对比

Table 3 Comparison of MPDIoU loss function improvement series

损失函数	mAP@0.5/%	Parameters/M	FLOPs/M
MPDIoU	82.3	2.26	6.5
Inner-MPDIoU	82.5	2.26	6.5
Wise-MPDIoU	82.4	2.26	6.5
Inner-Wise-MPDIoU	82.6	2.26	6.5

3.5 消融实验

为了进一步的直观评估各模块对 YOLOv10n 网络结构的增益效果,设置了多组消融实验,实验结果如表 4 所示,各改进模型与原始模型 YOLOv10n 相比,使用 BIMAFPN 结构优化特征融合模块使得 mAP@0.5 提高了 1.1%,且其参数量和模型大小都有较明显的下降,改进模块不仅显著提高了检测精度,同时还使模型更加轻量化。尽管引入 Inner-Wise-MPDIoU 损失函数导致检测速度有所下降,但在采用 BIMAFPN 结构的基础上,mAP@0.5 进一步提升了 1.3%。在此基础上,用 LSCD 检测头模块替换原检测头,不但参数量和计算量有所下降,mAP@0.5 还额外提升了 0.3%。与原模型相比,本模型虽然检测速度有所下降,但仍能够达到 179 fps,能够满足便携式嵌入式交通设备的实时检测需求。同时,检测精度整体提升了 2.7%,模型参数量减少了 25%,综合性能得到显著提升,验证了 YOLOv10n 算法改进的结构和模块具备有效性。

表 4 模型消融实验结果

Table 4 Results of model ablation experiment

模型	BIMAFPN	损失函数	LSCD	mAP@0.5/%	Parameters/M	FLOPs/M	FPS
YOLOv10n	—	—	—	81.7	2.26	6.5	230
模型 2	√	—	—	82.8	1.87	6.3	192
模型 3	—	√	—	82.6	2.26	6.5	259
模型 4	—	—	√	82.0	1.94	6.2	255
模型 5	—	√	√	83.1	1.94	6.2	233
模型 6	√	—	√	83.6	1.70	6.2	177
模型 7	√	√	—	84.1	1.87	6.3	188
本文方法	√	√	√	84.4	1.70	6.2	179

3.6 对比实验

为综合验证本文改进模型的有效性,在实验环境和数据集不变的情况下,将该模型与主流目标检测算法进行对比实验,具体包括 YOLOv5n、YOLOv7-tiny^[22]、YOLOv8n、YOLOv8s、YOLOv10n、文献[12]、文献[13],

以及经典算法 Faster-RCNN 和 SSD。评价指标采用精确度、召回率、平均精度均值、参数量、运算量、帧率,同时为测试不同模型训练后的内存占用情况,增加模型大小(model size)指标。实验结果如表 5 所示。

由实验结果可知,针对电动车头盔佩戴检测,YOLO

系列算法整体优于经典算法 Faster-RCNN 和 SSD, 在运算量和精度方面均表现出色。从 mAP@0.5 方面对比, 本研究改进模型在 10 种模型中最高, 相较于 YOLOv8n、YOLOv10n、文献[12]和文献[13]分别高出 4.1%、2.7%、0.9% 和 0.6%, 表明本文改进模型在检测精确性上表现最好。从模型复杂程度方面对比, 本研究改进模型的参数量和计算量在对比模型里面均为最小, 并且权重文件占据空

间是所有模型中最低。较低的复杂度与权重文件大小的同时又有较好的精度, 适用道路场景下的电动车头盔佩戴检测任务。本研究改进的模型在检测速度上尽管有所下降, 但相较于文献[13]的模型, 其检测精度较高且能够满足便携式嵌入式交通设备的实时检测需求。实验结果证明, 改进后的模型在精度与轻量化的综合评估中, 相较于原模型及其他模型具有显著优势。

表 5 不同检测模型对比实验

Table 5 Comparative experiment of different detection models

模型	mAP@0.5/%	Precision	Recall	Parameters/M	FLOPs/M	Model Size/M	FPS
Faster-RCNN	71.9	70.6	67.4	136.2	360.0	105.9	25
SSD	69.7	68.2	66.1	25.4	131.7	87.2	51
YOLOv5n	75.9	80.5	68.7	2.2	6.4	4.9	179
YOLOv7-tiny	73.8	75.2	67.9	6.1	11.2	11.7	145
YOLOv8n	80.3	80.8	75.3	3.0	8.1	6.0	311
YOLOv8s	82.5	82.6	77.4	11.1	28.4	21.5	201
YOLOv10n	81.7	81.0	76.0	2.3	6.5	5.5	230
文献[12]	83.5	85.0	76.9	3.3	9.7	7.0	165
文献[13]	83.8	84.9	77.8	2.7	7.8	6.4	75
本文方法	84.4	83.7	78.4	1.7	6.2	3.6	179

3.7 可视化分析

为了更直观地比较本文算法与基准模型 YOLOv10n 算法的检测效果, 使用同样的测试集对两种算法进行测试, 并选取了其中具有代表性的图片进行可视化分析, 其对比可视化结果如图 7 所示。

从图 7(a)的检测结果可以看出, 与原模型相比, 改进后的算法在复杂路况场景中能更有效地区分背景信息, 显

著提高了头盔的检测精度; 图 7(b)中可以看出, 在密集小目标场景下, 改进算法能够准确检测所有电动车头盔的佩戴情况, 具备在此类场景中应用的能力; 图 7(c)则展示了在目标间相互遮挡的情况下, 改进算法仍能准确识别电动车头盔的佩戴状态。综上所述, 该改进算法不仅有效提高了复杂路况下的头盔检测精度, 还显著降低了在目标遮挡场景中的漏检率, 满足了实际应用的需求。





图 7 模型检测效果对比

Fig. 7 Comparison of helmet and license plate detection performance

4 结 论

为了解决电动车头盔佩戴检测在复杂路况下精度较低、目标遮挡导致漏检率较高、以及检测模型大计算复杂等问题,本研究提出了一种基于 YOLOv10 的改进算法。该算法在 MAFPN 的基础上融合了 BiFPN 的优势,创新性地提出了 BIMAFPN 结构,以提升模型在复杂路况下的检测表现。其次,本研究通过引入 Inner-IoU 和 Wise-IoU 的思想,优化了 MPDIoU 损失函数,用 Inner-Wise-MPDIoU 替代了传统的 CIoU 损失函数,不仅提升了检测精度,还加速了模型的收敛。最后,通过引入 LSCD 检测头,进一步减少了模型的参数量,并提升了检测性能。改进后的算法在本研究电动车头盔佩戴检测数据集上 mAP@0.5 精度上提升了 2.7%,同时在参数量、计算量和模型大小方面也

实现了优化,呈现出性能与效率的双重提升。未来将继续丰富数据集,加入在各种天气条件下拍摄的图像,并研究在各种天气条件下的整体性能,提高算法的检测精度的同时提升泛化能力。

参考文献

- [1] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [2] GIRSHICK R. Fast R-CNN [J]. ArXiv preprint arXiv:1504.08083, 2015.
- [3] REN SH 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, 2016, 39(6): 1137-1149.
- [4] DAHIYA K, SINGH D, MOHAN C K. Automatic detection of bike-riders without helmet using surveillance videos in real-time[C]. 2016 International Joint Conference on Neural Networks (IJCNN). IEEE, 2016: 3046-3051.
- [5] VISHNU C, SINGH D, MOHAN C K, et al. Detection of motorcyclists without helmet in videos using convolutional neural network [C]. 2017 International Joint Conference on Neural Networks (IJCNN). IEEE, 2017: 3036-3041.
- [6] 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 Y N, TANG T P, LIU X W, et al. Detection model on electrical bike riders' safety helmet wearing based on retinaNet[J]. Transport Research, 2023, 9(1): 115-126.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Computer Vision-ECCV 2016: 14th European Conference, 2016: 21-37.
- [8] 王新, 冯艺楠. 基于改进 SSD 的骑行人员佩戴头盔检测[J]. 电子测量技术, 2022, 45(21): 90-97.
- WANG X, FENG Y N. Helmet wearing detection for cyclists based on improved SSD [J]. Electronic Measurement Technology, 2022, 45(21): 90-97.
- [9] 朱周华, 齐琦. 基于改进 YOLOv5s 电动车头盔的自动检测与识别[J]. 计算机应用, 2023, 43(4): 1291-1296.
- ZHU ZH H, QI Q. Automatic detection and recognition of electric vehicle helmet based on improved YOLOv5s [J]. Journal of Computer Applications, 2023, 43(4): 1291-1296.
- [10] 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(S1): 420-425.
- XIE P X, CUI J R, ZHAO M. Electric bike helmet wearing detection algorithm based on improved YOLOv5 [J]. Computer Science, 2023, 50 (S1): 420-425.
- [11] MU Q Y, YU Q CH, ZHOU CH CH, et al. Improved YOLOv8n model for detecting helmets and license plates on electric bicycles [J]. Computers, Materials & Continua, 2024, 80(1): 449-466.
- [12] 周顺勇, 彭梓洋, 张航领, 等. Helmet-YOLO: 一种更高精度的道路安全头盔检测算法[J]. 计算机工程与应用, 2025, 61(2): 135-144.
- ZHOU SH Y, PENG Z Y, ZHANG H L, et al. Helmet-YOLO: A higher-accuracy road safety helmet detection algorithm [J]. Computer Engineering and Applications, 2025, 61(2): 135-144.
- [13] 高立鹏, 周孟然, 胡锋, 等. 基于 REIW-YOLOv10n 的井下安全帽小目标检测算法[J/OL]. 煤炭科学技术, 1-13 [2024-11-05]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.
- GAO L P, ZHOU M R, HU F, et al. Small target detection algorithm for underground helmet based on REIW-YOLOv10n [J/OL]. Coal Science and Technology, 1-13 [2024-11-05]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.
- [14] DU Q, ZHANG SH H, YANG SH J. BLP-YOLOv10: Efficient safety helmet detection for low-light mining [J]. Journal of Real-Time Image Processing, 2025, 22(1): 10.
- [15] YANG ZH Q, GUAN Q, ZHAO K ER, et al. Multi-branch auxiliary fusion YOLO with re-parameterization heterogeneous convolutional for accurate object detection[C]. Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Singapore: Springer Nature Singapore, 2024: 492-505.
- [16] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [17] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [18] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [19] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [20] MA S L, XU Y. MPDIoU: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv:2307.07662, 2023.
- [21] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.

- [22] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

作者简介

周翔,硕士研究生,主要研究方向为深度学习、图像处理。

E-mail: 18796585418@163.com

王可庆(通信作者),教授,硕士生导师,主要研究方向为机器人工程、模式识别与智能系统。

E-mail: 860020@cwxu.edu.cn

周新翔,硕士研究生,主要研究方向为目标检测、图像处理。

E-mail: zhou_xxsc@163.com