

金瑞颖, 施卫, 宋子杨. 基于改进 YOLOv7 的自动驾驶道路场景目标检测算法[J]. 智能计算机与应用, 2026, 16(4): 68-75.
DOI: 10.20169/j.issn.2095-2163.24062201

基于改进 YOLOv7 的自动驾驶道路场景目标检测算法

金瑞颖, 施卫, 宋子杨

(江苏理工学院 机械工程学院, 江苏 常州 213001)

摘要: 目标检测是自动驾驶技术的重要一环。然而现存在车辆行人等目标分布密集、互相遮挡的情况导致识别不精, 造成漏检、误检等问题。本文提出了一种基于改进 YOLOv7 的自动驾驶道路场景目标检测算法。采用轻量化网络 ShuffleNetv2 替换原始主干网络, 减少模型参数量和复杂度, 提高模型训练速度。在颈部网络(Neck 层)加入 Coordinate Attention(CA)注意力模块, 增强模型对通道关系的学习, 提高多通道输入数据的建模能力。然后, 在 Neck 层和 Head 层引入多尺度特征融合网络结构, 加深特征图的感受野, 改善小目标漏检误检的情况。最后, 引入 Focal-EIoU 损失函数, 加速模型收敛并提高回归精度。在 KITTI 数据集进行的训练检测实验结果表明, mAP@0.5 达到 91.6%, 相较原模型提高了 2.5%, 模型参数量和计算量分别降低了 36.2% 和 38.2%, 提升了检测精度和速度。

关键词: 目标检测; 自动驾驶; 轻量化网络; 注意力机制; 特征融合

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2026)04-0068-08

Object detection algorithm for autonomous driving road scenes based on improved YOLOv7

JIN Ruiying, SHI Wei, SONG Ziyang

(School of Mechanical Engineering Jiangsu University of Technology, Changzhou 213001, Jiangsu, China)

Abstract: Object detection is an important part of automatic driving technology. However, there exist problems such as inaccurate recognition, missed detections, and false positives caused by the dense distribution and mutual occlusion of targets like vehicles and pedestrians. This paper proposes an object detection algorithm for autonomous driving road scenes based on improved YOLOv7. It uses a lightweight network, ShuffleNetv2, to replace the original backbone network, which reduces the number of model parameters and complexity and improves the model training speed. The Coordinate Attention (CA) attention module is added to the neck network (Neck layer) to enhance the model's learning of channel relationships and improve the modeling ability for multi-channel input data. Then, a multi-scale feature fusion network structure is introduced in the Neck and Head layers to deepen the sensory field of the feature maps and improve the miss-detection and misdetection of small objects. Finally, the Focal-EIoU loss function is introduced to accelerate model convergence and improve regression accuracy. The training and detection experiments conducted on the KITTI dataset showed that, mAP@0.5 reached 91.6%, an increase of 2.5% compared to the original model, with a reduction of 36.2% and 38.2% in model parameters and computational complexity, respectively, improving detection accuracy and speed.

Key words: object detection; autonomous driving; lightweight network; attention mechanism; feature fusion

0 引言

随着经济的高速发展和人们生活品质的不断提高, 汽车保有量显著增加, 导致道路交通愈发拥挤, 交通事故发生率也逐年递增。自动驾驶技术能够辅助驾驶员控制车辆安全运行, 缓解和改善道路拥堵

状况, 减少交通事故发生, 是未来汽车行业的发展趋势。该技术通过先进的传感器和算法, 实时感知分析其周边环境, 预测理解道路上车辆和行人行为的动态变化。其中, 目标识别与检测的准确性、实时性, 直接影响着自动驾驶系统的性能和安全性。

目标检测的主要作用是识别理解道路上的各种

作者简介: 金瑞颖(2000—), 女, 硕士研究生, 主要研究方向: 新能源汽车控制与运用; 宋子杨(1998—), 男, 硕士研究生, 主要研究方向: 新能源汽车控制与运用。

通信作者: 施卫(1974—), 男, 硕士, 高级实验师, 硕士生导师, 主要研究方向: 汽车控制技术, 汽车智能网联, 汽车故障诊断技术等。Email: 66084561@qq.com。

收稿日期: 2024-06-22

物体,包括车辆、行人、交通标志等。目前目标检测算法主要分为传统视觉算法和基于深度学习的算法,传统算法的效率低、速度慢、精度低等,难以满足自动驾驶汽车实时性和安全性的需求。基于深度学习的目标检测算法^[1]凭借智能高效,高检测精度的优势,成为目标检测应用的主流算法,其主要分为 RCNN 系列的两阶段(two-stage)算法和 YOLO^[2-4]系列的单阶段(one-stage)检测算法。如李学军等^[5]基于 Faster-RCNN 改进的交通标志检测算法,添加了 scSE 注意力机制和 GSConv 卷积结构,提高了恶劣天气环境中的交通标志检测精度,但该算法实时性和检测速度相比 YOLO 较差。针对行人检测问题,徐芳芯等^[6]提出基于 YOLOv7 的 DETR^[7]算法,引入注意力机制提取小目标特征,并使用 Smooth 与 GIoU 结合的损失函数来加速收敛。针对交通标志检测问题,韩岩江等^[8]以 YOLOv5s 为模型,融合坐标注意力和 BiFPN^[9],使用 SIoU 损失函数^[10],改善对小目标交通标志的检测能力。针对复杂道路场景的目标检测问题,冉险生等^[11]基于 YOLOv5 算法,引入特征融合因子^[12],增加浅层特征检测层,并在特征融合网络中加入注意力机制,一定程度上解决了目标密集遮挡、漏检误检问题。

上述方案对于道路复杂情况的目标检测仍存在不足,主要有以下几点:

- (1) 目标状态的复杂性,其中行人检测的难点在于小目标密集遮挡以及存在各种复杂的背景;
- (2) 在实际路况中,行人到大型车辆都可能存在,目标大小各异,需要目标检测算法具备多尺度特征提取和处理能力;
- (3) 在远距离或特定视角下,目标存在显示模糊的情况,只能提供较少的有效特征信息,增加了目标检测的难度。

此外,当前模型还存在三方面缺陷:

- (1) 原始模型的参数量大,设备检测效率低;
- (2) 检测目标的位置信息不准确,存在只关注局部特征的问题;
- (3) 对目标的有效感受野感知不足,特征提取能力较差。

为解决上述问题,本文提出了一种改进 YOLOv7 的自动驾驶道路场景目标检测算法^[13],方案改进如下:

- (1) 更换主干网络为轻量化网络 ShuffleNetv2^[14],减少模型参数量和复杂度来提高模型训练速度。
- (2) 在 Neck 层加入 Coordinate Attention(CA)注

意力模块^[15],增加模型检测精度。

(3) 在 Neck 层和 Head 层引入多尺度特征融合网络结构^[16],通过加权双向特征融合 BiFPN 和小目标检测层 P2,加深特征图的感受野,改善小目标漏检误检的情况。

(4) 使用 Focal-ElIoU 损失函数^[17]代替原模型中损失函数 CIoU,提升模型收敛速度和精度。

1 YOLOv7 网络模型结构

YOLOv7 网络模型由 4 部分组成:输入(Input)、主干部分(backbone)、颈部网络(neck)和多尺度检测头(Head),结构如图 1 所示。主干部分由 CBS 卷积模块、ELAN 模块、MPCoV 模块组成。卷积模块 CBS 选用 SiLU 作为激活函数,SiLU^[18]可将输入映射到(0,1)区间上,有助于减少梯度消失问题,增强网络的表征能力。ELAN 模块由不同的卷积融合而成,通过注意力机制对特征图进行加权,使模型能够更好地关注重要的特征。MPCoV 模块上层分支执行 MaxPool 最大池化操作^[19],下层分支的两次卷积分别将通道数减半和特征图尺寸的长宽减半。最终上下分支合并输出尺寸减半、输入输出通道相等的特征图,降低特征图维度的同时,更高效地提取图像特征。加强特征提取部分引入主干部分中间层到底层的 3 个有效特征层作为输入,利用 SPPCSPC 处理来自主干网络的特征图,通过自下而上和自上而下的路径,实现不同层次特征的高效集成。最后通过 RepConv 对 3 个尺度的特征图进行通道数调整再送入检测头并输出。

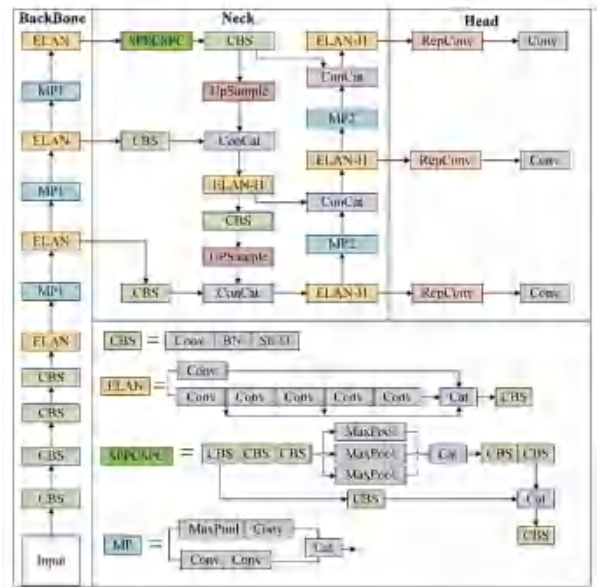


图 1 YOLOv7 网络结构图

Fig. 1 YOLOv7 network structure diagram

带来的精度损失;二是降低训练时间的同时提高训练效率。

传统注意力机制主要采用 SE 模块和 CBAM 模块,前者的弊端在于只考虑通道间的信息而忽略了位置信息。后者尝试通过降低通道数再提取位置注意力信息,但卷积只能捕获局部关系,无法获得长距离全局关系的充分提取。本文引入注意力机制(CA),结构如图 5 所示。CA 分别在 X 和 Y 方向分别进行全局平均池化,得到两个单独方向的特征图后进行融合卷积,通过归一化和线性回归操作将特征图分为两个单独方向的特征图,再次卷积并通过激活函数分配权重,获得最后的输出值。其不仅能够自适应选择和调整不同通道地特征权重,还能抑制不重要的通道,提高模型对关键特征的关注度。

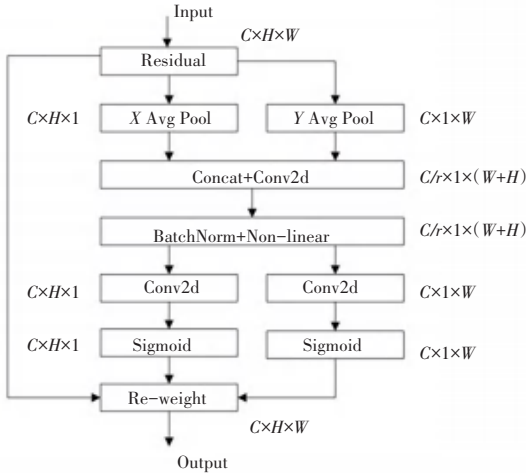


图 5 CA 注意力机制结构图


Fig. 5 CA attention mechanism structure diagram

ELAN_H_CA 模块是将 CA 模块添加至 ELAN_H 模块结构内部的最后,本文没有选择在 Neck 层直接加入 CA 模块,而是在不改变 Neck 层主体架构的情况下加入 CA 注意力模块,保持整体网络结构的轻量级和高效,如图 6(a) 所示。图 6(b) 相当于在 Neck 层完整地插入一个新的层作为额外的组件,导致整个网络结构发生了改变,不仅增加了 Concat 模块接受信息的负担,而且网络结构变得更加复杂和庞大,也增加了计算和内存开销。

2.3 多尺度特征融合方式改进

与常规目标相比,小目标通常在图像中占据较小的空间且容易被较大背景物体所包围或置于复杂背景中。本文设计了一种多尺度特征融合的优化方式:借鉴加权双向特征金字塔 BiFPN,有效融合来自不同网络层的多尺度特征;增加一个 160×160 小目

标检测层,特别针对小目标的检测。



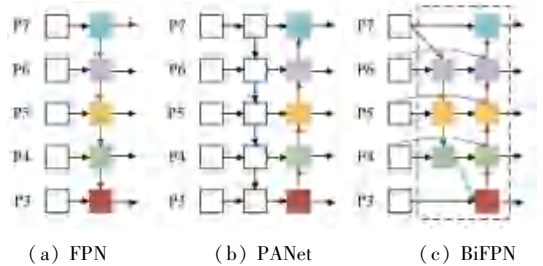
(a) 本文方案 (b) 对比方案

图 6 CA 添加位置对比图

Fig. 6 CA add location comparison chart

2.3.1 加权双向特征金字塔 BiFPN

传统特征融合方式 FPN 采用从上到下的信息融合,受到单向信息流的限制,如图 7(a) 所示。PANet 基于 FPN 额外添加了一个自下向上的路径聚合网络,但忽略了输入特征之间分辨率及贡献值的不同,如图 7(b) 所示。BiFPN 在传统特征融合方式的基础上引入了双向连接与自适应特征融合,改变过去对不同分辨率特征图叠加的融合操作。双向连接指从高层到低层和从低层到高层,使特征信息可以在不同层级之间自由传递和交换,有助于更好地融合全局和局部信息;自适应特征融合指根据不同层级特征的重要性动态地调整不同层级之间的融合权重,保证网络在融合特征时更加灵活和准确,如图 7(c) 所示。



(a) FPN (b) PANet (c) BiFPN

图 7 不同特征金字塔结构图

Fig. 7 Diagram of the structure of the pyramid of different features

BiFPN 对每个输入添加一个额外的权重,利用加速归一化加权融合式(1)来约束每个权重的大小,利用学习率 ε 保证数值的有效性,提高了 GPU 的运行效率。

$$O_i = \sum_i \frac{\omega_i}{\sum_j \omega_j + \varepsilon} \times I_i \quad (1)$$

式中: O_i 为第 i 层特征输出值, I_i 为第 i 层特征输出值, ω_i 为第 i 层输入特征图权重。

2.3.2 160×160 尺度小目标检测层

原始 YOLOv7 算法的 Head 层输出 3 个不同尺度的特征层, 分别为 20×20、40×40 和 80×80, 负责预测的目标尺寸由大到小, 深度由深层的语义特征到浅层的表征特征。由于浅层特征图的感受野小, 获取信息能力弱, 因此提出增加一个 160×160 的检测层来提高小尺度特征图的表达能力, 即由原来的 3 个输出端改为 4 个, 如图 8 所示。




图 8 增加 160×160 层多尺度检测

Fig. 8 Addition of 160×160 layers for multi-scale testing

2.4 Focal-EIoU 损失函数

YOLOv7 损失函数分为分类损失、目标置信度损失和定位损失。其中定位损失采用基于 IoU 函数的 Clou 损失函数, 计算公式如(2)~(4)式, 参数 ν 用来度量边界框的纵横比差异, 更准确地衡量预测框与真实框之间的相似度。但参数 ν 的计算复杂且预测框的宽高分别与真实框之间的差异的问题仍然存在, 这些因素都会阻碍模型对相似度的有效优化。

$$L_{Clou} = 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha\nu \quad (2)$$

$$\nu = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \left(\frac{w}{h} \right) \right)^2 \quad (3)$$

$$\alpha = \frac{\nu}{1 - \text{IoU} + \nu} \quad (4)$$

式中: ρ 为真实框与预测框中心点的距离, b 和 b^{gt} 为预测框和真实框, c 为真实框与预测框最小外接矩形的对角线距离, α 为一个正权衡参数, ν 为度量宽高比的一致性, w^{gt} 、 h^{gt} 、 w 和 h 为真实框和预测框的宽度和高度。

因此引入 Focal-EIoU 损失函数作为 YOLOv7 算法的定位损失函数, 分为 3 个部分: IoU 损失、距离损失与位置损失, 具体改进方案如下: (1) 将纵横比的损失项拆分成预测框与真实框的高度差和宽度差, 帮助模型更加专注于优化宽高比的不同方面, 从而提高定位的准确性。(2) 引入了 Focal Loss 优化样本不平衡的问题, 即减少对与目标框重叠较少部分的大量预测, 使回归过程专注于高质量预测框。

计算公式如下式:

$$L_{EIoU} = 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{(c_w)^2 + (c_h)^2} + \frac{\rho^2(w, w^{gt})}{(c_w)^2} + \frac{\rho^2(h, h^{gt})}{(c_h)^2} \quad (5)$$

$$L_{\text{Focal-EIoU}} = \text{IoU}^\vartheta \times L_{EIoU} \quad (6)$$

式中: ϑ 为控制异常值抑制程度参数值, c_w 为预测框与真实框最小外接矩形的宽度, c_h 为预测框与真实框最小外接矩形的高度。

3 实验环境与结果分析

实验环境配置基于 win 11 操作系统, GPU 显卡为 Nvidia GeForce RTX 4060 Ti, CPU 处理器为 13th Gen Intel(R) Core(TM) i7-13620H 2.40 GHz, 编程语言为 Python3.10, 加速环境为 CUDA12.2, 深度学习网络框架为 Pytorch2.1.0, 代码运行软件为 Pycharm。整个训练过程设置初始学习率为 0.01, 权重衰减系数为 0.0001, Batch Size 为 8, epoch 为 200, 图像输入尺寸统一为 640×640 数据集。

3.1 数据集选择与预处理

本文选用 KITTI-2D 数据集^[20]训练和验证改进后的算法, 将数据集图片的标签转换为 YOLOv7 训练所需的 yolo 格式(即 txt 格式), 标签文件中包含了图片的坐标位置信息并与图片相互对应。

KITTI-2D 原数据集包括 Car、Van、Truck、Pedestrian、Pedestrian-sitting、Cyclist、Tram 和 Misc 共 8 种类别, 总共包含 7 481 张图片; 去除 Misc 类, 将 Car、Van、Truck、Tram 合并为 Car 类, 将 Pedestrian 和 Pedestrian-sitting 合并为 Pedestrian 类; 处理过后包含 Car、Pedestrian、Cyclist 3 种类别作为实验数据, 并将图片按照 8:1:1 的比例划分为训练集、验证集和测试集的图片数据集。

3.2 评价指标

本文的评价指标分别为平均准确率均值(mAP@0.5)、准确率(Precision, P)、浮点计算量(FLOPs)、召回率(Recall, R)、参数量(Parameters)。计算公式如下:

$$\text{mAP} = \frac{\sum_{i=1}^k \text{AP}_i}{k} \quad (7)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

式中: AP_i 表示每一类的准确率, k 表示类别数量,

TP 表示预测为正的正样本, FP 表示预测为正的负样本, FN 表示预测为负的正样本。

3.3 结果与分析

3.3.1 YOLOv7 不同主干网络的对比实验

对 YOLOv7 的 3 种不同主干网络进行对比试验, 验证采用 ShuffleNetv2_2.0 给模型带来的网络轻量化效果。首先采用 ShuffleNetv2 替换原始网络结构, 由表 1 可知, 模型的 Params 和 FLOPs 分别减少了 35.5% 和 40.0%, 但 mAP@0.5 (%) 值却降低了 1.4%, 表明轻量化主干网络以牺牲精度来提升运行速度, 导致对深层次目标特征提取能力减弱。然后根据这一结果对 ShuffleNetv2 进行改进提出 ShuffleNetv2_2.0, 由表 1 可知, ShuffleNetv2_2.0 在参数量和计算量几乎不变的情况下将 mAP@0.5 (%) 值的差距缩小至 1.1%, 有效弥补了轻量化网络带来的精度损失。

表 1 不同主干网络对比实验结果

主干网络	mAP@0.5/%	P	R	Params/M	FLOPs/G
ELAN	89.1	90.4	85.5	37.21	104.3
ShuffleNetv2	87.7	87.2	81.9	24.01	62.6
ShuffleNetv2_2.0	88.0	89.3	82.5	24.05	62.8

表 3 消融和对比实验结果

Table 3 Ablation and comparison experiment results

序号	ShuffleNetv2_2.0	Focal-EIoU	ELAN_H_CA	BiFPN	P2	mAP@0.5 (%)			P	R	Params/M	FLOPs/G
						行人	车辆	all				
1						81.3	95.9	89.1	90.4	85.5	37.21	104.3
2	✓					79.5	95.5	88.0	89.3	82.5	24.05	63.8
3	✓	✓				79.7	95.7	88.3	88.1	83.4	24.05	63.8
4	✓	✓	✓			80.2	96.1	88.9	87.6	84.7	24.15	64.2
5	✓	✓	✓	✓		81.8	96.3	90.6	91.0	85.6	23.21	64.1
6	✓	✓	✓	✓	✓	83.1	96.4	91.1	91.5	86.9	23.74	64.4

由 3.3.1 可知, 虽然将主干网络改进为 ShuffleNetv2_2.0 导致精度值有所降低, 但模型的参数量和计算量大幅降低。由表 3 可知, 采用 Focal-EIoU 损失函数, 在不增加 FLOPs 的情况下, 使 mAP@0.5 较第 2 组增加了 0.3%; 采用 ELAN_CA 注意力机制 mAP@0.5 较第 3 组增加了 0.6% 且车辆目标增加了 0.4%; 采用加权双向特征融合 BiFPN, 使 mAP@0.5 较第 3 组增加了 1.7%, 并且参数量还有所降低; 采用一个 160×160 检测头, mAP@0.5 较第 5 组提升了 0.5%, 并且行人目标的 mAP@0.5 增加了 1.3%, 效果显著, 说明小尺度检测头能有效提高对小目标的检测能力。

3.3.2 不同注意力结构对比实验

为验证 CA 注意力机制在本文模型上的效果, 在同样位置添加 SE、CBAM 主流注意力机制进行对比, 根据表 2 所示, 在运行速度几乎相同的情况下, 本文所选用的 CA 注意力在 mAP@0.5 上表现更优, 并且在原有的 ELAN 模块中加入 CA 的方法比直接加入效果更佳, mAP@0.5 可以达到 88.9%。

表 2 不同注意力结构对比实验结果

Table 2 Comparison results of different attention structures

注意力机制	mAP@0.5 (%)	FLOPs/G
SE	84.8	68.5
CBAM	85.3	68.6
CA	86.2	68.5
ELAN_CA	88.9	64.2

3.3.3 ShuffleNetv2_2.0 网络模型的消融实验

由上述分析可知, 仅靠改进主干网络内部结构仍无法完全弥补轻量化导致的精度损失, 因此, 为提升网络的检测能力, 在改进主干网络的基础上依次加入 Focal-EIoU 损失函数、ELAN_H_CA 注意力机制、BiFPN 特征融合结构、P2 检测头 4 种改进方法, 并开展了 6 组消融实验, 其中 ✓ 代表选择对应的改进方法进行实验、消融, 对比实验结果见表 3。

总体看来, 改进后的算法可有效提高道路场景中行人、车辆的目标检测精度和速度, 与原始 YOLOv7 算法比较 mAP 值、Precision 和 Recall 分别提高了 2.0%、1.1%、1.4%, Params 和 FLOPs 分别下降了 36.2% 和 38.3%。

3.3.4 KITTI 数据集检测效果比较分析

为分析改进 YOLOv7 对道路场景目标的检测能力, 本文选取 3 种复杂背景典型样本, 即强光、背光、密集遮挡的检测效果, 如图 9 所示。

由图 9(a) 所示, 拥堵是城市道路常见的现象, 密集遮挡现象造成检测目标仅保留部分特征, 加大网络特征提取的难度, 容易导致漏检误检问题, 改进

YOLOv7 通过多尺度特征提取模块增强了模型对关键点的特征提取能力。如图 9(b)所示,在强光环境中受强光照射的物体会导致颜色淡化、特征信息减弱,改进 YOLOv7 通过添加注意力加强对特征信息

提取的能力。如图 9(c)所示,在背光环境下的物体颜色呈灰暗状态,尤其是深色物体与背景相似,物体清晰度大大降低,改进 YOLOv7 加强了对目标识别的关注度、敏感度及抗干扰能力。



(a) 密集遮挡



(b) 强光环境



(c) 背光环境

图 9 实际检测效果对比

Fig. 9 Comparison of actual detection effect

4 结束语

本文提出了基于改进 YOLOv7 的自动驾驶道路场景目标检测模型,为了解决城市交通中行人车辆等目标分布密集、互相遮挡导致识别不精、漏检误检等问题,从主干网络、注意力机制、多尺度特征融合、损失函数 4 个方面对 YOLOv7 模型进行改进。首先对比分析不同轻量化主干网络的算法检测性能,展开消融实验研究,验证了轻量化设计对模型减少复

杂度和提升检测速度的有效性;其次对比不同注意力机制的性能,验证在 ELAN 模块中加入 CA 注意力机制,提升模型对感兴趣区域的获取能力;然后采用多尺度特征融合,分别引入 BiFPN 和小目标检测头,提升网络的特征融合能力和小尺度目标的表达能力;最后采用 Focal-EIoU 损失函数替换原损失函数 CIoU,加速收敛并提高精度。在 KITTI 数据集上进行模型的消融实验,并对比了 YOLOv7 和改进算法在不同场景下的检测性能。实验结果表明,改进

后的算法较原始算法在目标检测精度和速度上均有明显提升,对于城市道路场景中车辆行人等目标具有良好的检测效果。

参考文献

- [1] 谷永立,宗欣欣. 基于深度学习的目标检测研究综述[J]. 现代信息科技,2022,6(11):76-81.
- [2] 邓亚平,李迎江. YOLO算法及其在自动驾驶场景中目标检测研究综述[J]. 计算机工程与应用,2023,59(12):1-18.
- [3] WU D, LIAO M, ZHANG W, et al. YOLOP: You only look once for panoptic driving perception [J]. Machine Intelligence Research,2022,19(6):550-562.
- [4] 杨伟,杜学峰,张勇,等. 基于深度学习的车辆目标检测算法综述[J]. 汽车实用技术,2022,47(2):24-26. DOI:10.16638/j.cnki.1671-7988.2022.002.006.
- [5] 李学军,权林霏,刘冬梅,等. 基于Faster-RCNN改进的交通标志检测算法[J]. 吉林大学学报(工学版),2024,54(3):120-128.
- [6] 徐芳芯,樊嵘,马小陆. 面向拥挤行人检测的改进YOLOv7算法[J]. 计算机工程,2024,50(3):250-258. DOI:10.19678/j.issn.1000-3428.0067741.
- [7] JUN L, XUE M, DANIL P, et al. Deep neural network for structural prediction and lanedetection in traffic scene [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017,28(3):690-703.
- [8] 韩岩江,王伟,王峰萍. 融合坐标注意力和BiFPN的YOLOv5s交通标志检测方法[J]. 国外电子测量技术,2022,41(11):170-179. DOI:10.19652/j.cnki.femt.2204271.
- [9] 李英群,李亚菲,裴雷,等. 基于YOLOv5-ECA-BiFPN的学术论文期刊文献图表识别与提取方法研究[J]. 数据分析与知识发现,2023,7(11):158-171.
- [10] ZHOU D, FANG J, SONG X, et al. IoU Loss for 2D/3D object detection. [J]. arXiv preprint arXiv, 1908.03851, 2019. <http://arxiv.org/abs/1908.03851>.
- [11] 冉焱生,苏山杰,陈俊豪,等. 自适应特征融合的复杂道路场景目标检测算法[J]. 计算机工程与应用,2023,59(24):216-226.
- [12] SONG G, LIU Y, WANG X. Revisiting the sibling head in object detector [C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ:IEEE, 2020:11560-11569.
- [13] 胡森,姜麟,陶友凤,等. 改进YOLOv7的自动驾驶目标检测算法[J]. 计算机工程与应用,2024,45(4):1-11.
- [14] 兰红,王惠钊. 结合轻量化与多尺度融合的交通标志检测算法[J]. 计算机工程,2024,50(2):23-29.
- [15] 杨飞帆,李军. 面向自动驾驶的YOLO目标检测算法研究综述[J]. 汽车工程师,2023(11):1-11. DOI:10.20104/j.cnki.1674-6546.20230095.
- [16] 李成豪,张静,胡莉,等. 基于多尺度感受野融合的小目标检测算法[J]. 计算机工程与应用,2022,58(12):177-182.
- [17] 井方科,任红格,李松. 基于多尺度特征融合的小目标交通标志检测[J]. 激光与光电子学进展,2024,61(6):1-13.
- [18] 赵宏,冯宇博. 基于CGS-GhostYOLO的交通标志检测研究[J]. 计算机工程,2023,49(12):194-204. DOI:10.19678/j.issn.1000-3428.0066520.
- [19] 彭育辉,郑玮鸿,张剑锋. 基于深度学习的道路障碍物检测方法[J]. 计算机应用,2020,40(8):2428-2433.
- [20] GEIGER A, LENZ P, STILLER C, et al. Vision meets robotics: The kitti dataset [J]. The International Journal of Robotics Research, 2013, 32(11):1231-1237.