

# 基于改进 YOLOv5 的行车目标检测与分割研究

巫少方<sup>1</sup> 陈朝大<sup>1\*</sup> 陈浩霖<sup>1</sup>

(1. 广州航海学院 船舶与海洋工程学院 广东广州 510725)

**摘要:** 行车道路目标检测与分割是计算机视觉领域的重要研究课题。为更准确且快速的检测汽车、车道线等目标,本文提出了一种基于改进 YOLOv5 算法的目标检测模型进行道路目标检测与语义分割的方法。在 YOLOv5 模型中利用全卷积神经网络(Fully Convolutional Networks, FCN)进行道路目标的检测及语义分割。实验结果显示对道路的目标特征的预测精度达 88%,召回率达 99%,实现了快速准确的道路目标的检测与分割,有效提高了行车目标检测效果。

**关键词:** 行车道路、目标检测、语义分割、YOLOv5

## 0 引言

随着自动驾驶技术的快速发展,对道路上行人、车辆和其他对象的准确检测和分割变得尤为关键<sup>[1]</sup>。目前汽车在行驶过程中对车道路的特征检测与分割,主要通过摄像头采集视频图像数据,将图像数据进行不同方式的处理,进而获得检测目标在图像中的位置信息<sup>[2]</sup>。

张凯祥等<sup>[3]</sup>提出使用 YOLOv5 作为骨干网络及目标检测分支,结合实时语义分割网络 ENet 进行车道线检测和可行驶区域分割,且采用  $\alpha$ -IoU 计算损失来提高回归精度,实现了多特征体的检测与分割。

杨奎河等<sup>[4]</sup>提出了一种联合训练目标检测和语义分割的 YOLOSeg 算法,利用 PANet 多尺度融合不同尺度的特征图,加强对小物体的细节特征和语义信息的学习,在不同尺度的特征图上完成目标检测任务。

王军等<sup>[5]</sup>提出了一种改进 YOLOv5s 的交通信号灯检测算法。通过构建一种特征金字塔模块 RSN-BiFPN 与融合不同尺度的交通信号灯特征,且采用 EIoU 函数优化损失,提高了对小目标的检测能力与检测速度。

彭瑾等<sup>[6]</sup>提出一种基于 YOLOv5s 的交通标志检测算法,通过在骨干网络设计带有通道和空间注意力机制的 C3CBAM 卷积模块,从通道和空间域上增加对包含交通标志信息的特征图的关注度并在模型骨干网络和颈部增加跨层连接结构来融合更多的语义特征。

刘晓萌等<sup>[7]</sup>针对场景复杂、目标尺度差异大导致误检和漏检的问题,提出一种基于 YOLOv5s 的改进车辆检测算法。先增加检测层以更好地学习车辆的多级特征,再将原 YOLOv5s 算法的空间金字塔池化(SPP)模块替换为 Atrous 空间金字塔池化(ASPP)模块,以增加不同大小图像的感受野,提取多尺度上下文信息。

目前的方法存在许多挑战,如复杂的场景、准确性问题和实时性要求等。针对实际车辆行驶场景复杂多变的问题。为了提高道路目标特征的识别准确率和多场景适应程度,本文提出一种基于改进 yolov5 模型的方法,以实现行车道路的目标特征检测与分割,从而提高模型对目标检测的准确率以及模型的多场景适应形。

## 1 YOLO 算法原理

YOLO 是目前常用的目标检测与图像分割算法。YOLO 框架主要以 Backbone 和 Head 两个部分组成<sup>[8]</sup>。

### 1.1 Backbone 主干网络

Backbone 主干网络用于提取图像特征,供后续网络层使用<sup>[9]</sup>。YOLOv5 在主干网络中使用了 Focus 结构,而且提出了两种 CSP 结构。

#### 1.1.1 Focus 结构

YOLOv5 的 Focus 结构是主干网络第一层,通过通道拼接和切片操作将高分辨率图像信息转变到通道维度上,同时减小输入尺寸以提高网络训练和推理速度。

#### 1.1.2 CSP 模块<sup>[9]</sup>

为解决梯度重复计算问题带来的巨大计算负担,YOLOv5 主干网络采纳了 CSP 结构。在 YOLOv5 中,引入了两种不同的 CSP 模块,CSP1\_X 用于主干网络,而 CSP2\_X 用于 Neck 网络。主干网络中,CSP 结构集成了带有残差组件的设计,而 Neck 部分则用卷积操作替代残差组件。CSP 结构的主要目标在于将特征图分为两部分,其中一部分继续卷积以获取更深刻的特征信息,而另一部分则与前一部分卷积后的特征图合并。引入 CSP 模块的优势在于增强网络的学习能力、提高准确率、减少计算负担,同时也提升了推理速度。

### 1.2 改进主干网络<sup>[10-11]</sup>

首先,将 Focus 模块替换为了便于模型部署的  $6 \times 6$  卷积层;其次,用 C3 模块代替了 CSP 模块,将主干网络的最后一个 C3 模块引入了残差组件;此外,SPPF 模块取代了 SPP 模块,置于主干网络中;最后,在主干网络 P3 层中减少了 C3 模块的重复次数,以提高反映速度。这些改进不仅使 SPPF 结构发挥了与 SPP 结构相同的效果,而且还降低了模型的计算量,提高了效率。SPP 模块将特征图并行输入,再将 4 个感受野不同的特征图拼接到一起,而 SPPF 模块则是将特征图串行输入,然后进行特征融合。

## 2 YOLOv5 模型

### (1) 置信度

$$Confidence = P_r(Object) * IoU_{pred}^{truth} \quad (1)$$

对象存在时,Pr(Object)为 1,否则为 0;其中,IoU 为真实框与预测框的交并比。

### (2) 损失函数

IoU 是在目标检测中根据预测框与真实框的重叠程度来判断预测框的准确程度,其计算过程如下。

$$IoU = |A \cap B| / |A \cup B| \quad (2)$$

$$L_{IoU} = 1 - IoU \quad (3)$$

其中, A 代表真实框, B 代表预测框。

当真实框和预测框不重叠时, IoU 恒为零, 但这不能反映二者的位置距离, 也不能表达在 IoU 值相等时存在重叠的情况。因此, 提出 GIoU 损失:

$$GIoU = IoU - |C/(A \cup B)|/|C| \quad (4)$$

其中, C 代表真实框和预测框的最小闭包区域面积。

DIoU 损失在 IoU 损失的基础上做了改进, 考虑了真实框和预测框中心点的距离、重合程度和两个框的尺寸<sup>[10]</sup>。在  $L_{IoU}$  的基础上加上  $\rho^2(b, b^g)/c^2$ 。

其中,  $\rho$  为欧式距离函数,  $b$ 、 $b^g$  分别为预测框和真实框的中心点,  $c$  为预测框和真实框最小闭包区域的对角线距离。由于 DIoU 损失将两个框之间的距离最小化了, 因此加快了收敛速度。

### (3) 混淆矩阵

混淆矩阵在图像精度评价中, 可把分类结果的精度可视化在一个混淆矩阵里面, 如表 1 所示<sup>[7]</sup>。

表 1 混淆矩阵

		Prediction (预测)	
		Positive	Negative
Actual (实际)	True	TP	FN
	False	FP	TN

其中, T/F:表示预测的对错; P/N:表示预测的结果。

$$precision = TP/(TP + FP) \quad (5)$$

$$recall = TP/(TP + FN) \quad (6)$$

精度 Precision 表示评估预测的精确度, 召回率 Recall 表示评估预测的完整度。TP 表示真正类。样本的真实类别是正类, 并且模型识别的结果也是正类。FN 表示假负类。样本的真实类别是正类, 但是模型将其识别为负类。FP 表示假正类。样本的真实类别是负类, 但是模型将其识别为正类。TN 表示真负类。样本的真实类别是负类, 并且模型将其识别为负类。

## 3 实验结果与分析

### 3.1 数据集构建

为了更好、更完整的实现道路特征的检测, 本文采用了伯克利大学 AI 实验室 (BAIR) 发布的驾驶数据集 BDD100K, 包含晴天、阴天、雪天、雨天、多云、有雾 6 种不同天气, 以及城市道路、隧道、高速公路、住宅、停车场、加油站 6 种不同场景。

(1) 对数据集进行了预处理<sup>[12]</sup>, 将数据集按 3:1 的比例划分为训练集、测试集;

(2) 对图片数据进行筛选, 提高数据集与实验的匹配性;

(3) 对图片上目标特征进行分割标注。如图 1 所示。



图 1 特征标注图

### 3.2 模型训练

将训练步数设置为 300 步。利用 YOLOv5-seg 实例分割模型进行训练获得训练权重文件。观察在训练完生成的数据文件中预测精度曲线以及查看训练的测试集的识别准确度。若预测精度在 90%以上证明训练成功。

训练得到训练集与测试集损失参数曲线图, 如图 2 所示。

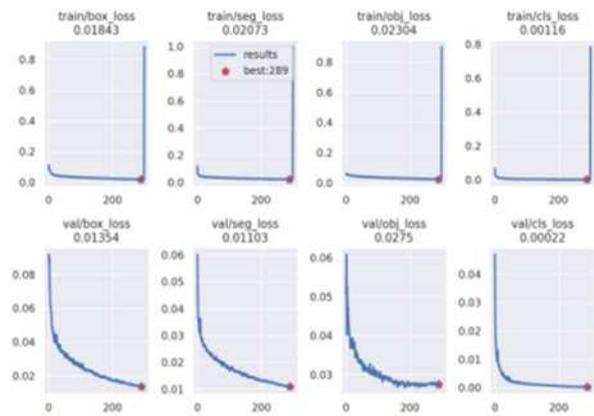


图 2 损失参数曲线

同时, 得到目标预测精度 (查准率 Precision) 及目标预测完整度 (召回率 Recall) 指标曲线图, 如图 3 所示。

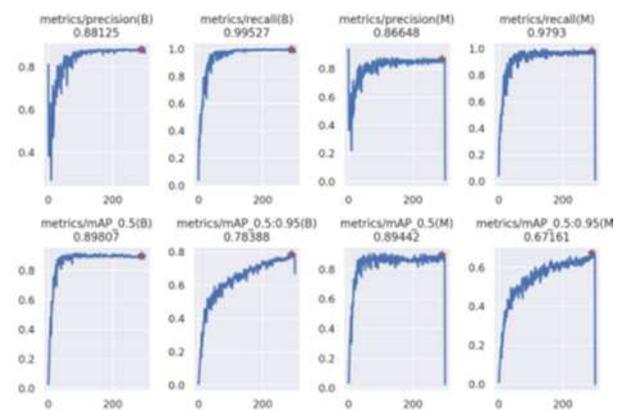


图 3 预测精度与完整度指标曲线

测试集训练的预测结果如图 4 所示, 检测结果中对于道路目标特征分割检测及分类准确, 且目标框和实际的目标特征区域能够准确选中并覆盖, 对于有车辆遮挡的不明显的车道线也能进行检测, 对于车辆行驶道路中的目标特征的预测能力大大提升。



图 4 YOLOv5-seg 训练结果

### 3.3 目标检测与分割结果

利用训练所得的权重文件实现对图片、视频和摄像头数据进行检测,结果如图5所示。

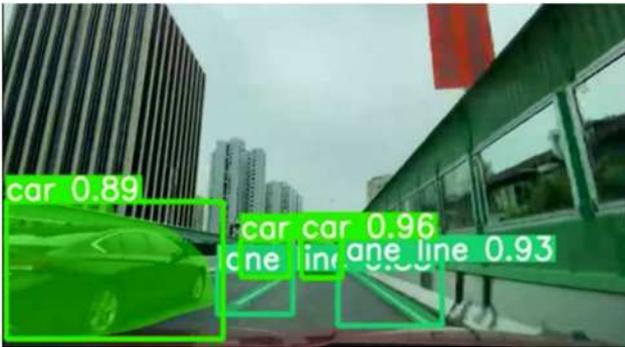


图5 实际检测与分割结果

通过多次试验,数据显示,该算法的目标检测分割准确度达到88%,召回率达到99%,实现了快速准确的道路目标的检测与分割效果。

## 4 结论

本文基于YOLOv5算法提出了一种改进的行车道路目标检测和分割方法。实验和分析结果显示,采用改进后的YOLOv5算法在行车道路目标检测和分割方面表现出良好的效果。算法整体架构和训练模型的改进提高了目标检测和分割准确性,并选择合适的Backbone主干网络进一步提升了性能。这一改进的基于YOLOv5的行车道路目标检测和分割方法具有广泛的应用前景,特别适用于交通安全和智能交通系统。在对不同场景下的视频序列进行测试时,实验结果表明对道路目标特征的预测精度达到了88%,召回率达到了99%,验证了该算法的有效性。

未来的研究可以考虑引入更先进的深度学习模型以应对复杂场景和目标遮挡的问题,以提高行车道路目标检测、分割和跟踪的准确性和效率。此外,结合传感器融合等技术,还有进一步完善行车道路目标感知系统的潜力。

### 参考文献:

[1]赵麒博,王梦梅,潘海英,李晨欢,吴祥龙,郭晨阳. 基于改进YOLOv5和DeepSort的车道线检测方法[J]. 信息技术与信息化,2023,(07):217-220.

ZHAO Qibo, WANG Mengmei, Pan Haiying, Li Chenhuan, WU Xianglong, Guo Chenyang. Lane detection Method based on improved YOLOv5 and DeepSort [J]. Information Technology and Informatization,2023,(07):217-220.

[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]. 计算机应用,1-12.

Deng Yaping, Li Yingjiang. YOLO Algorithm and its Application to target Detection in Autonomous Driving Scenarios [J]. Computer Applications :1-12.

[3]张凯祥,朱明. 基于YOLOv5的多任务自动驾驶环境感知算法[J]. 计算机系统应用,2022,31(09):226-232.

Zhang Kaixiang, Zhu Ming. Environment Awareness Algorithm for

Multi-Task Automatic Driving Based on YOLOv5 [J]. Computer System Applications, 2002,31(09):226-232.

[4]杨奎河,张宇. 交通场景下基于YOLOv5的目标检测与分割算法[J]. 长江信息通信,2023,36(04):48-50.

Yang Kuihe, ZHANG Yu. Object Detection and Segmentation Algorithm Based on YOLOv5 in Traffic Scenario [J]. Changjiang Information and Communication, 2019,36(04):48-50.

[5]王军,葛宝康,程勇. 基于改进YOLOv5s算法的交通信号灯检测[J]. 计算机系统应用:1-10.

Wang Jun, GE Bao-Kang, CHENG Yong. Traffic light Detection Based on improved YOLOv5s algorithm [J]. Computer System Applications :1-10.

[6]彭瑾,桑正霄,李木易. 一种基于YOLOv5s的交通标志检测算法[J]. 自动化技术与应用,2023,42(09):53-57.

Peng Jin, SANG Zhengxiao, LI Muye. A Traffic sign detection Algorithm based on YOLOv5s [J]. Automation Technology and Application, 2019,42(09):53-57.

[7]L. Xiaomeng, F. Jun and C. Peng. Vehicle Detection in Traffic Monitoring Scenes Based on Improved YOLOv5s. 2022 International Conference on Computer Engineering and Artificial Intelligence (ICCEAI), Shijiazhuang, China, 2022, pp. 467-471.

[8]X. Zhang, H. Song, F. Wan and X. Yang. A Pedestrian Detection Method Based on Improved YOLOv5s. 2022 International Conference on Cloud Computing, Big Data Applications and Software Engineering (CBASE), Suzhou, China, 2022, pp. 197-201.

[9]B. Xiao, J. Guo and Z. He. Real-Time Object Detection Algorithm of Autonomous Vehicles Based on Improved YOLOv5s. 2021 5th CAA International Conference on Vehicular Control and Intelligence (CVCI), Tianjin, China, 2021, pp. 1-6.

[10]宁俊彦. 自动驾驶复杂场景下目标检测研究[D].西安工业大学,2023.

Ning Junyan. Research on Object Detection in Complex Autonomous Driving Scenarios [D]. Xi'an Technological University,2023.

[11]刘昌华. 复杂交通场景下自动驾驶道路目标检测[D].大连理工大学,2022.

Liu Changhua. Automatic Driving Road Object Detection in Complex Traffic Scenarios [D]. Dalian University of Technology,2022.

[12]Z. Lu, L. Ding, Z. Wang, L. Dong and Z. Guo. Road Condition Detection Based on Deep Learning YOLOv5 Network. 2023 IEEE 3rd International Conference on Electronic Technology, Communication and Information (ICETCI), Changchun, China, 2023, pp. 497-501.