

祝磊, 欧阳万棋, 敖思铭. 基于 YOLOv5s 轻量化改进的车尾灯语检测[J]. 智能计算机与应用, 2025, 15(9): 56-63. DOI: 10.20169/j. issn. 2095-2163. 250909

## 基于 YOLOv5s 轻量化改进的车尾灯语检测

祝磊, 欧阳万棋, 敖思铭

(武汉科技大学 机械自动化学院, 武汉 430081)

**摘要:** 为准确检测车辆尾灯灯语, 实现模型轻量化, 提出一种轻量化改进 YOLOv5s 网络模型。首先利用轻量级 EfficientNet 网络替换原主干网络, 再将 VoV-GSCSP 模块替换颈部网络内 C3 模块, 并在 VoV-GSCSP 模块后添加 NAM 注意力机制。针对上述 3 处改进, 采用消融试验验证模型优化效果, 模型训练采用车辆尾灯灯语检测专用的 VLS 数据集。实验结果表明, 轻量化改进后模型相较于原 YOLOv5s, 参数量减少了 41%、计算量减少了 50% 以及模型文件大小减少了 39%, 同时平均准确率精度 (mAP@0.5) 增加 0.9%, 证明改进后模型具有较好车辆尾灯灯语检测性能。

**关键词:** 车尾灯语检测; YOLOv5s; EfficientNet; VoV-GSCSP; NAM 注意力机制

**中图分类号:** TP391

**文献标志码:** A

**文章编号:** 2095-2163(2025)09-0056-08

## Vehicle tail light signal detection based on YOLOv5s lightweight improvement

ZHU Lei, OUYANG Wanqi, AO Siming

(College of Machinery and Automation, Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract:** In order to accurately detect vehicle tail light signals and realize model lightweight, an improved lightweight YOLOv5s network model is proposed. Firstly, the lightweight EfficientNet network is used to replace the original backbone network, then the VoV-GSCSP module is used to replace the C3 module in the neck network, and the NAM attention mechanism is added after the VoV-GSCSP module. In view of the above three improvements, ablation test is used to verify the optimization effect of the model, and the VLS data set dedicated to vehicle tail light signal detection is used for model training. The experimental results show that compared with the original YOLOv5s, the number of parameters, calculation amount and model file size of the improved lightweight model are reduced by 41%, 50% and 39%. Meanwhile, the average accuracy (mAP@0.5) is increased by 0.9%, which proves that the improved model has better tail light signal detection performance.

**Key words:** tail light detection; YOLOv5s; EfficientNet; VoV-GSCSP; NAM attention mechanism

## 0 引言

车辆尾灯灯语可表达车辆的行驶状态、行车意图等有用信息, 因此研究如何快速准确检测识别到前方各台车辆的尾灯灯语具有重要意义。当前对于车辆尾灯灯语检测的研究包括以下 3 类方法。第一类是针对车灯的颜色特征, 用传统方法检测。田强等学者<sup>[1]</sup>提出参数优化的最小二乘支持向量机 (LS-SVM) 对尾灯状态进行分类, 结合状态历史信息判断灯语。Cui 等学者<sup>[2]</sup>先用可变形部件模型检测车辆后采取 HSV 对尾灯配对, 再用稀疏字典学习方法对灯语分类。Wang 等学者<sup>[3]</sup>用高动态范围

(HDR) 相机分别在亮通道和暗通道进行车辆检测和信号灯灯语识别。第二类是基于深度学习的方法。Chang 等学者<sup>[4]</sup>提出基于 YOLOv4 并结合高级语义和低级特征的前车尾灯检测算法, 利用 BiFPN 模型进行多尺度特征融合来提高检测精度。Song 等学者<sup>[5]</sup>在车辆检测基础上提出动作状态联合学习的方法, 应用 CNN-LSTM 模型同时识别刹车灯和转向灯信号的动作特征。Tong 等学者<sup>[6]</sup>基于 YOLOv4-tiny 采用空间金字塔池快速 (SPPF) 模块和利用路径聚合网络 (PANet) 构建具有特征链接的特征金字塔, 大大提高了检测精度。Zhang 等学者<sup>[7]</sup>在 YOLOv5s 骨干网络插入 CA 注意力机制, 利

**基金项目:** 湖北省重点研发计划项目 (2021BAA180)。

**作者简介:** 祝磊 (1996—), 男, 硕士研究生, 主要研究方向: 机器视觉, 目标检测。Email: 384862019@qq.com; 欧阳万棋 (1998—), 男, 硕士研究生, 主要研究方向: 图像处理; 敖思铭 (1996—), 男, 硕士研究生, 主要研究方向: 目标检测。

**收稿日期:** 2023-12-19

用 EIoU-Loss 和 EIoU-NMS 来解决类不平衡以及锚盒误差抑制,改进后模型 mAP@ 0.5 提高了 9.2%。第三类则是结合前 2 种方法的检测方法。Nava 等学者<sup>[8]</sup>结合车道检测算法和 YOLO 模型检测到车辆后使用 SVM 识别刹车灯。Shi 等学者<sup>[9]</sup>采用 YOLOv4 检测车辆后,再基于自适应阈值的 HSV 空间分割出尾灯,最后建立深度神经网络模型对数据训练,根据像素信息对灯语分类。

以上方法虽然在检测精度方面有所提升,但是在模型的轻量化方面仍存在不足,体现在不易于部署在车载设备当中,本文针对以上问题在 YOLOv5s 模型基础上进行了优化:

(1)用 EfficientNet<sup>[10]</sup> 轻量化网络替换原模型主干网络,减少模型参数和计算量。

(2)颈部网络内 C3 模块改为 VoV-GSCSP<sup>[11]</sup>,

进一步轻量化模型。

(3)在 VoV-GSCSP 后添加 NAM 注意力机制<sup>[12]</sup>提升检测精度。

1 YOLOv5s 网络简介

YOLO 系列以其优异的识别精度和速度成为车辆检测中被广泛应用的目标检测算法,其中较为成熟的 YOLOv5 为本文首要选择的目标检测模型。在 YOLOv5 中包含 5 个具有不同特征图深度和宽度的模型,但结构均相同,分别是 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。YOLOv5x 模型识别精度高,但计算损失大,无法满足检测实时性要求,YOLOv5n 模型参数量少,但模型精度较差。YOLOv5s 同时具备两者优点,故作为本文所用的基础模型,其网络结构如图 1 所示。

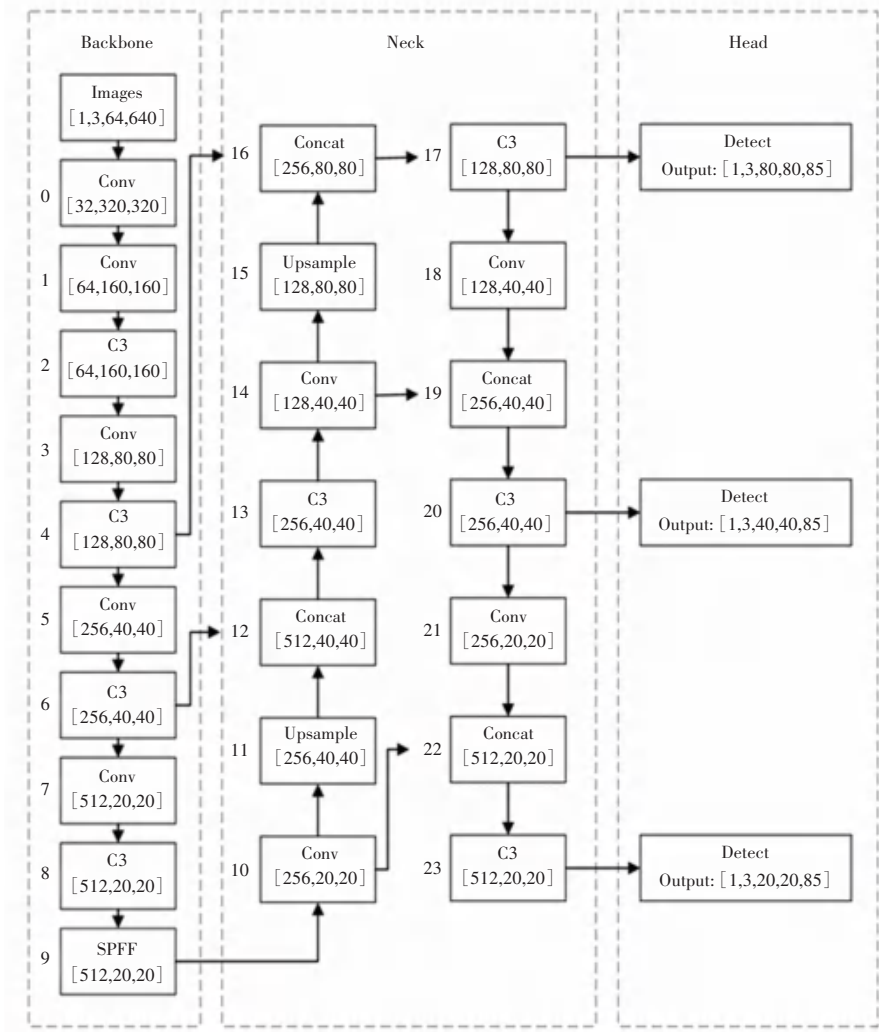


图 1 YOLOv5s 网络结构图  
Fig. 1 Network structure of YOLOv5s

图 1 模型结构由 3 部分组成,可分为主干网络 (Backbone)、颈部网络 (Neck) 以及头部网络 (Head)。主干网络提取图像特征信息;颈部网络将经过自上而下和自下而上的特征提取过后进行相应融合,凸显 Backbone 所提取的特征,提高模型鲁棒性;头部网络获取网络的输出,通过非极大值抑制来筛选多目标框,将置信度最高的作为输出结果。

2 模型轻量化改进

2.1 EfficientNet 网络

Tan 等学者<sup>[10]</sup>在 2019 年基于对轻量化卷积神经网络的研究提出 EfficientNet 网络,可提高模型特征提取能力,避免梯度消失以及减少计算量,相比于现有的轻量级网络,其在平衡训练时间和精度方面更具优势。

深度学习架构旨在用更简单的网络结构,展示出更高效的性能。与其他先进的模型不同,EfficientNet 网络在缩小模型的同时,通过均匀地缩放深度、宽度和分辨率来获得更有效的结果,该网络结构分为 B0~B8 共 9 个版本,模型参数量随版本上升而增加。出于轻量化考量,因 B0 参数量最少,故本文选用 EfficientNet-B0 替换 YOLOv5s 的 BackBone 以提升模

型运行速度,EfficientNet-B0 网络结构见表 1。

表 1 EfficientNet-B0 结构  
Table 1 EfficientNet-B0 structure

阶段	层名	分辨率	通道数	层数
1	Conv3×3	224×224	32	1
2	MBConv1, $k3 \times 3$	112×112	16	1
3	MBConv6, $k3 \times 3$	112×112	24	2
4	MBConv6, $k5 \times 5$	56×56	40	2
5	MBConv6, $k3 \times 3$	28×28	80	3
6	MBConv6, $k5 \times 5$	28×28	112	2
7	MBConv6, $k5 \times 5$	14×14	192	4
8	MBConv6, $k3 \times 3$	7×7	320	1
9	Conv1×1& 池化 & 全连接	7×7	1 280	1

由表 1 可知,EfficientNet 网络主要模块是倒置瓶颈 MBConv<sup>[10]</sup>,引入深度可分离卷积层,与传统层相比,可大大减少计算量,增加卷积层感受野,提升特征提取能力。其结构由 2 个 Conv 1×1、1 个 Depthwise  $k \times k$  (有 3×3 和 5×5 两种)、压缩-激励 (SE) 模块和 Dropout 层组成,其中前后 2 个 Conv 1×1 为网络进行升维和降维,SE 作为通道注意模块,其作用包括压缩和激励,否定信息更少的特征通道。MBConv 的具体结构如图 2 所示。




图 2 MBConv 模块结构  
Fig. 2 Structure of the MBConv module

2.2 VoV-GSCSP 模块

VoV-GSCSP 模块最初和 GSConv<sup>[11]</sup>相结合在 Slim-neck 结构<sup>[11]</sup>中实现减小中间层通道数,进而起到参数量减少的作用,但在实际训练中发现 GSConv 代替 Conv 后存在模型检测精度降低的情况,而在单独使用 VoV-GSCSP 后未出现检测精度降低,故本文引入了 VoV-GSCSP 模块替换颈部网络内 C3 模块,其结构如图 3 所示。

VoV-GSCSP 模块由多个卷积滤波器和 GSbottleneck 构成,其将前后层的特征图进行拼接再卷积,此操作有效避免残差块中出现信息丢失和梯度消失问题。GSbottleneck 结构类似于残差结构,区别在于主路的卷积层被 GSConv 代替,GSConv 具体结构如图 4 所示。首先将输入进行 1×1 卷积核滤波,再将输出进行深度可分离卷积,下一步将深度可分离卷积与 1×1 卷积的输出沿通道数融合特征信

息,最后通过 Shuffle 重组输出特征结果。相较于传统 3×3 卷积核,GSConv 不仅降低了参数量,还提升了检测效率。综上所述,用 VoV-GSCSP 模块替换颈部网络中的 C3 模块,既可保证模型检测精度,而且进一步降低模型参数和计算量。

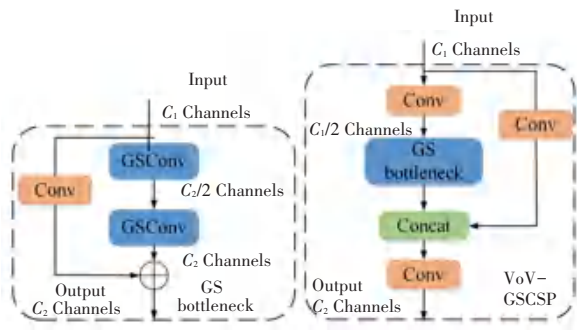


图 3 VoV-GSCSP 模块结构  
Fig. 3 Structure of the VoV-GSCSP module

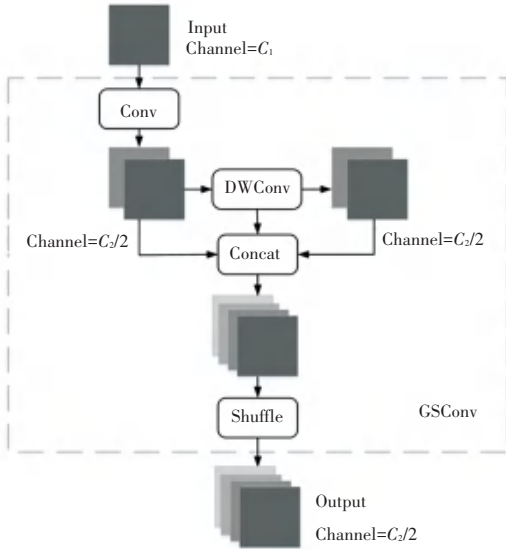


图 4 GSConv 结构

Fig. 4 GSConv structure

### 2.3 NAM 注意力机制

注意力机制因有利于神经网络在通道和空间中抑制不太突出的特征,而被广泛应用于目标检测网络。许多研究集中在如何通过注意力机制算子获取显著特征上,如 CBAM 注意力机制<sup>[13]</sup>、SE 注意力机制<sup>[14]</sup>等,这些方法利用了不同维度特征的相互信息,却忽略了通过训练模型调整权重信息。NAM 注意力机制则利用训练模型权值的方差来度量显著特征,利用权重贡献因子增强注意效果,同时使用批处理归一化比例因子和标准差表现权重重要性,如此可避免添加多余的全连接层和卷积层。

NAM 通过矩阵乘法和元素操作计算通道和空间的注意力权重,然后将其特征映射。通过在批处理归一化中计算缩放因子,反映出每个通道变化的大小,通道变化越剧烈,其提供的信息按比例更丰富,比例系数越大。对通道注意子模块使用批归一化中的比例因子,计算公式如下:

$$B_{out} = BN(B_{in}) = \gamma \frac{B_{in} - \mu_{\omega}}{\sqrt{\sigma_{\omega}^2 + \epsilon}} + \beta \quad (1)$$

其中,  $\mu_{\omega}$  和  $\sigma_{\omega}$  分别表示小批次样本  $\omega$  的均值和标准差;  $\gamma$  和  $\beta$  分别表示可训练的仿射变换参数。

比例因子衡量通道的方差以表示通道的重要性,在模型训练过程中方差越大表示通道中包含的特征信息越丰富,说明该区域更值得被关注。

通道注意子模块如图 5 所示。研究推得的公式如下:

$$M_c = \text{Sigmoid}(W_{\gamma}(\text{BN}(F_1))) \quad (2)$$

其中,  $M_c$  表示输出特征;  $\gamma$  表示各通道的标度

因子;  $W_{\gamma}$  表示权重。进一步推得公式如下:

$$W_{\gamma} = \gamma_i / \sum_{j=0} \gamma_j$$

NAM 用空间维度应用缩放因子 BN 来衡量像素的重要性,称为像素归一化。对应的空间注意模块如图 6 所示。对此计算过程可以表示为:

$$W_{\lambda} = \lambda_i / \sum_{j=0} \lambda_j$$

(3)

$$M_s = \text{Sigmoid}(W_{\lambda}(\text{BN}_s(F_1)))$$

其中,  $M_s$  表示输出,  $\lambda$  表示比例因子。




图 5 通道注意子模块

Fig. 5 Channel Attention Module




图 6 空间注意子模块

Fig. 6 Spatial Attention Module

为了抑制不太显著的权重,其在损失函数中加入了一个正则化项,具体公式如下:

$$\text{Loss} = \sum_{(x,y)} l(f(x, W), y) + p \sum g(\gamma) + p \sum g(\lambda) \quad (4)$$

其中,  $x$  表示输入;  $y$  表示输出;  $W$  表示网络权值;  $l(\cdot)$  表示损失函数;  $g(\cdot)$  表示  $l_1$  范数惩罚函数;  $p$  表示平衡  $g(\gamma)$  和  $g(\lambda)$  的惩罚。

综上所述,一方面, NAM 注意力机制可有效减少跨维度交互的信息损失和放大大局跨维度交互;另一方面,鉴于其轻量化和高效等特性,本文在 VoV-GSCSP 模块替换掉颈部网络中 C3 模块的同时又在每一层 VoV-GSCSP 模块后添加 NAM。网络中 NAM 注意力机制主要通过关注待检测车辆尾部灯语的重要特征来获取更多信息,将有限的信息分配到更重要的部分,在增加少量参数的同时提高检测精度。



3 实验与结果分析

3.1 数据集来源

当前车辆尾灯灯语检测的数据集较少,大部分常用公开交通道路数据集均针对车辆、行人、交通信号灯、交通指示牌等目标,如需检测车辆尾灯灯语还需人工手动标注符合要求的灯语图像,存在较大工作量。在 2022 年 Lai 等学者<sup>[15]</sup>为实现道路车辆尾灯状态检测提出了 VLS(Vehicle Tail Light Signal)数据集,以后车视角在白天黑夜一共采集了 7 720 张不同道路场景下具备车辆尾灯状态的照片,依据不同的车辆尾部状态将灯语分为了 8 个类别,分别是:白天无车尾灯信号(day-no)、白天刹车信号(day-on)、白天右转信号(day-right)、白天左转信号(day-left)、夜间无车尾灯信号(night-no)、夜间刹车信号(night-on)、夜间右转信号(night-right)、夜间左转信号(night-left)。由于该数据集符合本文实验的要求,故将 VLS 数据集按 9:1 的比例划分为训练集共 6 948 张和验证集共 772 张。

3.2 实验环境与参数设置

本次实验所使用的环境配置见表 2。模型训练参数设置如下:训练轮数(epoch)设为 150;批处理参数(Batch Size)设为 100;转载数据时 CPU 需用线程数(Workers)设为 64;输入图像大小设为 640×640;实验需用到 2 个显卡,故在 device 中设置“default=‘0,1’”;学习率为 0.01;weights 为模型自训练权重;数据增强参数采用 hyp. scrach-low. yaml,其中由于图像的左右翻转会混淆数据集中左右转向灯灯语的标签定义,故将代表图像左右翻转的 flip\_lr 设置为 0。

表 2 实验环境配置表

Table 2 Experimental environment configuration table	
名称	型号
CPU	Intel(R)Xeon(R)Platinum 88352V CPU @2.10 GHz
内存	180 GB(90 GB×2)
显卡	RTX 4090 24 G(×2)
操作系统	Ubuntu20.04
编程语言	Python 3.8
深度学习框架	PyTorch 1.11.0

3.3 模型评价指标

本文针对 YOLOv5s 进行了轻量化改进,对模型的评价指标具体如下:即平均准确率均值 mAP@0.5(mean Average Precision)、参数量(Parameters)、计算量(GFLOPS)和模型文件大小。

(1)mAP@0.5。代表模型检测性能,其值越大代表模型检测效果越好,推得的公式具体如下;

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i$$

(5)

其中,平均精度(AP)可由下式计算求得:

$$AP = \int_0^1 P(R) dR$$

(6)

其中,P、R 分别表示目标检测模型的一般评价指标:测准率(Precision)和召回率(Recall),其数学定义公式见如下:

$$Precision = \frac{TP}{TP + FP}$$

(7)

$$Recall = \frac{TP}{TP + FN}$$

(8)

其中,TP、FN、FP 表示依据实验结果样本所划分类的数量,其在分类结果混淆矩阵详见表 3。

表 3 分类结果混淆矩阵

Table 3 Confusion matrix of classification results		
真实情况	模型预测结果	
	正例	反例
正例	真正例(TP)	假反例(FN)
反例	假正例(FP)	真反例(TN)

(2)Parameter。表示模型参数量大小,其数值影响模型内存占用、初始化快慢及模型文件大小。

(3)GFLOPS。是以 10 秒亿次为单位来计算的浮点运算数,其计算量的大小关乎硬件设备所需算力,GFLOPS 越高、算力要求越高;模型文件所占内存大小,单位为 MB,内存越小、对硬件磁盘空间要求更低。

3.4 轻量化模型消融试验及分析

根据本文 2 节中 3 处对模型的轻量化改进方法进行消融试验,最后依照各类评价指标来对各个方法改进前后模型轻量化的效果加以验证。实验过程是依次把 EfficientNet 网络、VoV-GSCSP 模块及 NAM 注意力机制在 YOLOv5s 原网络上进行添加改进,并按顺序以及组合改进来进行试验。轻量化模型消融试验结果见表 4。表 4 中替换主干网络 EfficientNet 定义为“①”,将颈部 C3 替换成 VoV-GSCSP 定义为“②”,将添加 NAM 注意力机制定义为“③”。

在表 4 模型消融试验结果中,表明了各轻量化改进后模型指标变化细节以及各项指标数据对比。从前 4 组试验可以看出,EfficientNet 在替换 YOLOv5s 的主干网络后其模型参数量、计算量、文件所占内存

明显下降的同时,平均准确率均值仍稍有提高;在试验 5、6、7 中进一步体现了轻量化组合改进方法在各项评价指标中的优异性, EfficientNet 替换主干网络和 VoV-GSCSP 替换颈部 C3 能够大幅减少原模型的参数量、计算量和内存;轻量化的 NAM 注意力机制则侧

重于提升 mAP;将第 8 组实验结果相较于其他,可发现本文所提改进方法使得模型检测效果达到最优,对比 YOLOv5s 原模型其参数量减少了  $2.89 \times 10^6$  M, GFLOPs 计算量减少了 8.1,模型内存减少 5.7 MB,同时平均准确率均值 mAP(@ 0.5%)也提高了 0.9%。

表 4 轻量化模型消融试验结果  
Table 4 Ablation results of lightweight model


试验组数	模型	参数量 Parameters/ $\times 10^6$ M	计算量 GFLOPs	平均准确率均值 mAP@ 0.5/%	模型大小/MB
1	YOLOv5s	7.04	16.0	92.1	14.5
2	YOLOv5s+①	4.88	10.1	92.4	10.3
3	YOLOv5s+②	7.19	14.3	92.6	14.9
4	YOLOv5s+③	7.03	15.8	92.6	14.5
5	YOLOv5s+①②	4.14	7.9	92.5	8.8
6	YOLOv5s+①③	4.88	10.1	92.8	10.3
7	YOLOv5s+②③	7.56	15.0	92.8	15.6
8	YOLOv5s+①②③	4.15	7.9	93.0	8.8

3.5 训练结果与分析

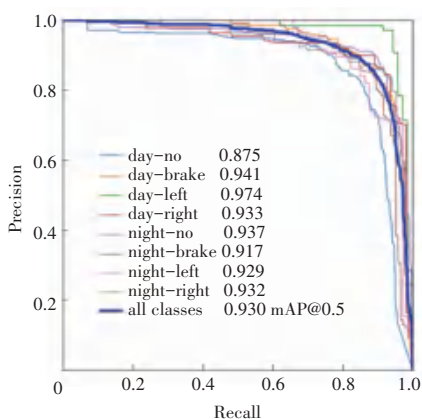
3.5.1 P-R 曲线

本文的 P-R 曲线图同时将 8 个不同车辆尾灯语检测类别以各自的召回率 (Recall) 作为横坐标,精准率 (Precision) 作为纵坐标绘制,同时 P-R 图的右上角展示出了 8 类车尾灯语标签分别对应的

mAP@0.5 值,如图 7 所示。模型改进前后的各类 mAP@0.5 值变化如下: day-no (+1%)、day-brake (-0.2%)、day-left (-0.2%)、day-righth (+1.8%)、night-no (+0.7%)、night-brake (+0.7%)、night-left (+3.3%)、night-right (+0%)、all classes(+0.9%)。



(a) 改进前



(b) 改进后

图 7 模型改进前后 P-R 曲线图

Fig. 7 P-R curves before and after model improvement

3.5.2 评价指标图

轻量化改进模型训练后各项评价指标以及各类损失函数随迭代变化曲线如图 8 所示,实验证明,训练集和验证集的位置损失函数 (box\_loss)、目标损失函数 (obj\_loss) 以及类别损失 (cls\_loss) 值越小分别代表标定框大小、目标检测和分类越准,且图 8 中损失函数曲线均平滑下降,各类验证损失函数均达到最优拟合结果。在模型训练 150 次后, Precision

和 Recall 趋于稳定, mAP@0.5 维持在 0.93,说明改进后模型具有较好的拟合性能和较为准确的检测能力。

3.5.3 模型检测结果图

将轻量化改进后模型所训练出来的 best 模型用在测试集中进行测试,得到的部分检测结果如图 9 所示。实验表明,模型能较为准确地对灯语进行检测。

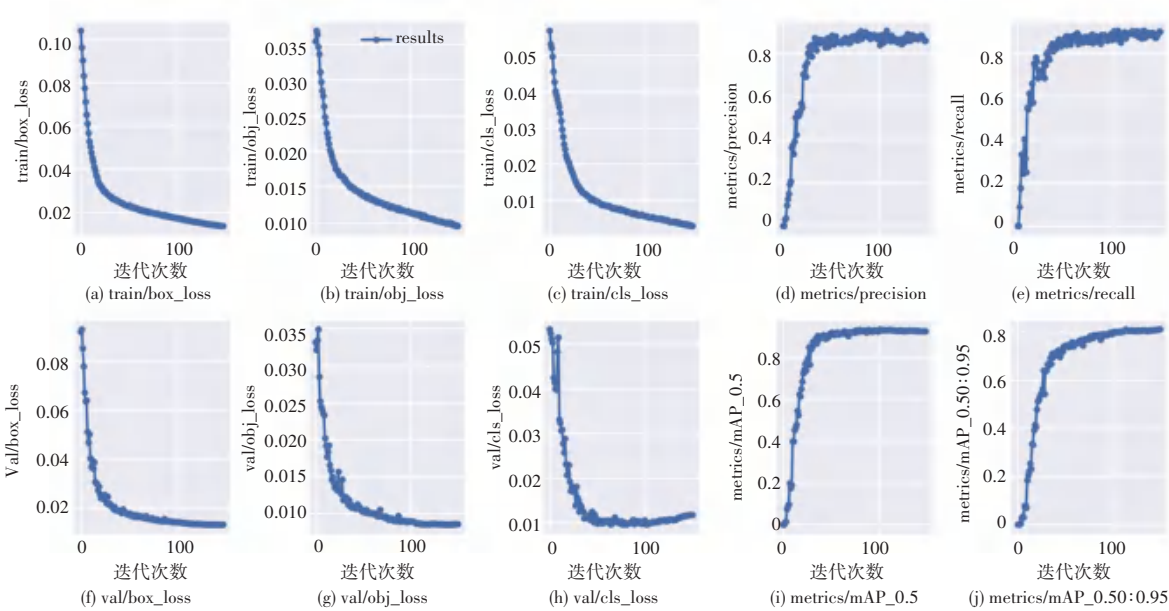


图 8 模型各项评价指标图

Fig. 8 Evaluation indicators of the model



图 9 模型检测部分结果图

Fig. 9 Model testing partial results graph

4 结束语

本文针对交通道路场景下的车辆尾灯灯语的检测问题,提出了一种轻量化改进的 YOLOv5s 模型,在标记了 8 种灯语类别的 VLS 数据集上训练了模型。该模型在 YOLOv5s 网络结构上进行了 3 处改进,分别是用 EfficientNet 网络替换了原主干网络大幅降低模型的参数量、计算量和内存;将颈部网络内 C3 模块用 VoV-GSCSP 模块替换,进一步轻量化模型;在每个 VoV-GSCSP 模块后增加轻量且高效的

NAM 注意力机制,增加模型检测准确性。模型消融实验表明,相较于原 YOLOv5s,参数量减少 41%,计算量减少 50%以及模型文件内存减少 39%,同时平均准确率精度 (mAP@0.5) 增加 0.9%。综上所述,本文所提模型对于车辆尾灯灯语检测具有实际应用意义。

参考文献

[1] 田强,孔斌,孙翠敏,等. 车辆尾灯灯语的检测与识别[J]. 计算机系统应用,2015,24(11):213-218.

- [2] CUI Zhiyong, YANG Shaowen, TSAIH M. A vision - based hierarchical framework for autonomous front - vehicle taillights detection and signal recognition[C] //Proceedings of 2015 IEEE 18<sup>th</sup> International Conference on Intelligent Transportation Systems. Piscataway,NJ;IEEE, 2015;931-937.
- [3] WANG Jiangang, ZHOU Lubing, SONG Zhiwei, et al. Real-time vehicle signal lights recognition with HDR camera [C]//Proceedings of 2016 IEEE International Conference on Internet of Things ( iThings ) and IEEE Green Computing and Communications ( GreenCom ) and IEEE Cyber, Physical and Social Computing ( CPSCom ) and IEEE Smart Data ( SmartData ). Piscataway,NJ;IEEE, 2016; 355-358.
- [4] CHANG Le, ZHANG Chongyang. Vehicle taillight detection based on semantic information fusion[M]//MANTORO T, LEE M, AYU M A, et al. Neural Information Processing. ICONIP 2021. Communications in Computer and Information Science. Cham;Springer, 2021,1517: 528-536.
- [5] SONG W, LIU S, ZHANG T, et al. Action-state joint learning-based vehicle taillight recognition in diverse actual traffic scenes [ J ]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18088-18099.
- [6] TONG B, CHEN W, LI C, et al. An improved approach for real-time taillight intention detection by intelligent vehicles [ J ]. Machines, 2022, 10(8): 626.
- [7] ZHANG Zhizheng, LAN Cuiling, ZENG Wenjun, et al. Relation-aware global attention for person re - identification [ C ]//Proceedings of the IEEE/CVF Conference onComputer Vision and Pattern Recognition. Piscataway,NJ;IEEE, 2020;3186-3195.
- [8] NAVA D, PANZANI G, SAVARESI S M. A collision warning oriented brake lights detection and classification algorithm based on a mono camera sensor[C]//Proceedings of 2019 IEEE Intelligent Transportation Systems Conference ( ITSC ). Piscataway, NJ; IEEE, 2019; 319-324.
- [9] SHI Peicheng, QI Heng, LIU Zhiqiang, et al. Research on intelligent vehicle lamp signal recognition in traffic scene[J]. SN Applied Sciences, 2022, 4(12): 327.
- [10] TAN Mingxing, LE Q V. Efficientnet; Rethinking model scaling for convolutional neural networks [ C ]//Proceedings of the International Conference on Machine Learning. PMLR, 2019; 6105-6114.
- [11] LI Hulin, LI Jun, WEI Hanbing, et al. Slim-neck by GSConv: A better design paradigm of detector architectures for autonomous vehicles[J]. arXiv preprint arXiv,2206.02424, 2022.
- [12] LIU Yichao, SHAO Zongru, TENG Yueyang, et al. NAM: Normalization-based attention module[J]. arXiv preprint arXiv, 2111.12419, 2021.
- [13] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham;Springer,2018; 3-19.
- [14] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ; IEEE, 2018; 7132-7141.
- [15] LAI Ruili, WEN Chumei, XU Jingmei, et al. VLS: Vehicle tail light signal detection benchmark [ C ]//Proceedings of 2022 5<sup>th</sup> International Conference on Algorithms, Computing and Artificial Intelligence. New York;ACM,2022;110.