

基于 SC-YOLOv8 的交通标志检测算法研究

闫世洋 罗素云

(上海工程技术大学机械与汽车工程学院 上海 201600)

摘要: 为了解决交通标志检测中所存在的准确率低、参数量大等问题,本文提出了一种基于 YOLOv8s 改进的 SC-YOLOv8 交通标志检测算法。该算法使用下采样 Adown 模块替换普通下采样 Conv,提升模型对目标的感知能力;使用 SCConv 模块替换 C2f 中的 Bottleneck,设计全新的 C2f-SC 模块,大幅减少模型参数;通过增加 160×160 尺度的检测头去除 20×20 尺度的检测头来改进目标检测层,有效的提高了检测精度;最后使用 WIoU 损失函数的思想改进 MPDIoU,以 Wise-MPDIoU 替换原 CIoU 损失函数,缓解了正负样本不平衡的问题。该算法在 TT100K 交通标志数据集上进行验证,与原模型 YOLOv8s 进行比较,精确率 P 提升了 4.8%,召回率 R 提升了 6.7%,mAP50 提升了 6.6%,参数量 Params 下降了 61.5%。证明了所做改进的有效性。

关键词: YOLOv8s; Wise-MPDIoU; 交通标志检测; SCConv

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 410.8012

Research on traffic sign detection algorithm based on SC-YOLOv8

Yan Shiyang Luo Suyun

(College of Mechanical and Automotive Engineering, Shanghai University of Engineering and Technology, Shanghai 201600, China)

Abstract: In order to solve the problems of low accuracy and large number of parameters in traffic sign detection, this paper proposes an improved SC-YOLOv8 traffic sign detection algorithm based on YOLOv8s. This algorithm uses the downsampling Adown module to replace the ordinary downsampling Conv, improving the model's perception ability of the target; replace the Bottleneck in C2f with the SCConv module and design a brand new C2f-SC module, significantly reducing model parameters; adding a 160×160 scale detection head and removing a 20×20 scale detection head, effectively improving detection accuracy; finally, the idea of using WIoU loss function is used to improve MPDIoU, replacing the original CIoU loss function with Wise-MPDIoU, alleviating the problem of imbalanced positive and negative samples. The algorithm was validated on the TT100K traffic sign dataset, and compared with the original model YOLOv8s, the accuracy P increased by 4.8%, the recall R increased by 6.7%, the mAP50 increased by 6.6%, and the parameter count Params decreased by 61.5%. Proved the effectiveness of the improvements made.

Keywords: YOLOv8s; Wise-MPDIoU; traffic sign detection; SCConv

0 引言

交通标志检测是自动驾驶汽车环境感知中不可或缺的重要组成部分,随着城市交通流量的不断增加,交通标识的错检、漏检等问题时常发生,极大的影响了交通安全。因此,对于交通标志目标检测的研究具有十分重要的意义^[1]。

目前,深度学习方法是国内外交通标志检测研究的主流方向,尤其是基于卷积神经网络的目标检测算法在该领域取得了显著进展^[2]。该检测算法主要分为两类:以区域建议卷积神经网络(region with convolutional neural networks feature, R-CNN)系列^[3]为主要代表的双阶段检

测算法和以单次多框检测器(single shot multibox detector, SSD)^[4]、你只看一次(you only look once, YOLO)系列为主要代表的单阶段检测算法。R-CNN 系列通过生成候选区域的方法有效提高了检测精度,但存在模型参数量大以及检测速度慢等问题;SSD 算法通过多尺度特征图处理不同大小的物体有效提升了检测速度,但对于小目标的检测效果仍然较差;YOLO 系列采用端到端训练能够实现快速实时检测,但相比双阶段算法检测精度略低。

近年来的深度学习交通标志检测研究中,江金洪等^[5]将深度可分离卷积和改进的损失函数引入到 YOLOv3^[6]算法中,计算效率显著提高,但模型的复杂度和训练难度仍然

较高。Jiang 等^[7]提出使用平衡特征金字塔网络加入通道注意力^[8]的方法来提升 YOLOv5^[9]对小目标的检测效果,但改进后的模型参数量较大。这两项研究分别从模型结构和注意力机制两个角度对 YOLO 系列算法进行了改进,均取得了一定的成果。深度可分离卷积和平衡特征金字塔网络都在一定程度上提升了检测准确率,但模型轻量化与检测精度之间的平衡依然是一个重要问题,可以进一步探索高效的卷积结构和特征提取方法,以提升交通标志的检测性能。

综上所述,本文针对交通标志检测中所存在的错检、漏检等问题提出了一种基于选择性卷积 YOLOv8 (selective convolution YOLOv8, SC-YOLOv8) 的交通标志检测算法,该算法在模型参数以及检测精度方面达到了良好的平衡,主要方法如下: 1) 使用下采样 Adown 模块替换普通下采样 Conv, 提升了目标的检测精度; 2) 提出全新的 C2f_SC

模块,使用选择性卷积(selective convolution, CConv)替换 C2f 中的 Bottleneck,同时考虑了空间和通道维度的信息,减少了特征冗余; 3) 增加 160×160 尺度的检测头去除 20×20 尺度的检测头,有效的改善了对小目标的检测能力; 4) 使用 Wise-MPDIoU 替换原 CIoU 损失函数,缓解了正负样本不平衡的问题。

本文的 SC-YOLOv8 算法以提高交通标志的检测准确率和降低模型参数量为目标,能够有效改善交通标志的错检、漏检问题,以减少交通事故的发生率,从而显著提升自动驾驶系统的性能和安全性。

1 YOLOv8s 算法原理

YOLOv8s 模型结构如图 1 所示,主要分为 4 个部分: 输入端(Input)、骨干网络(Backbone)、融合层(Neck)和检测头(Head)。

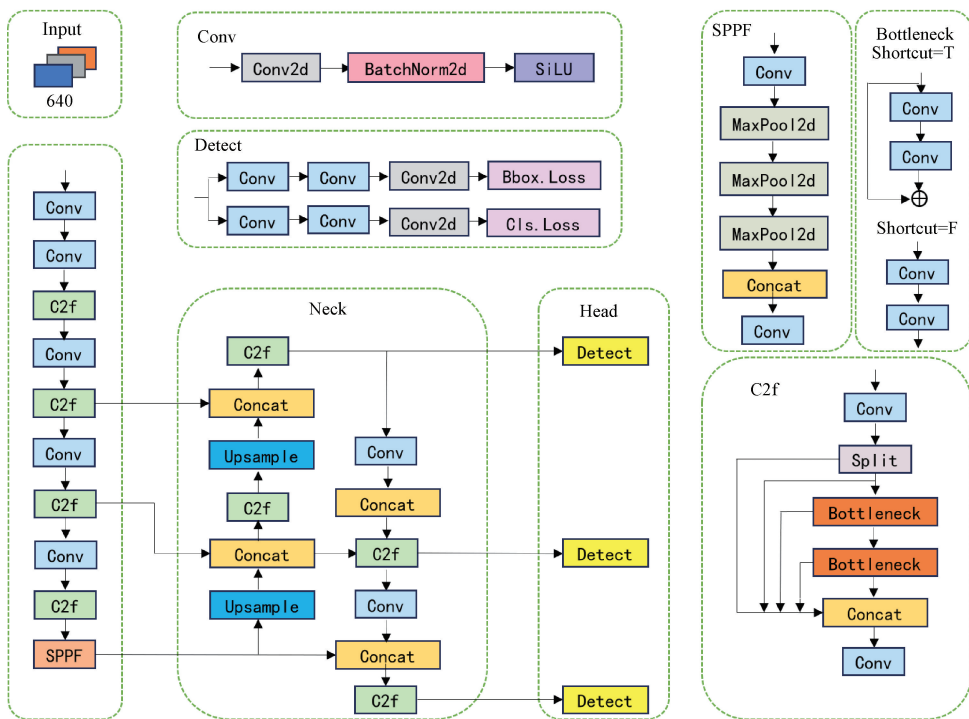


图 1 YOLOv8s 模型结构

Fig. 1 YOLOv8s model structure

输入端进行 Mosaic 数据增强,对四张图片进行随机的缩放、裁剪和排列,在最后 10 个 epoch 将其关闭;骨干网络由 Conv、C2f 和快速空间金字塔池化(spatial pyramid pooling-fast, SPPF)等模块构成。Conv 模块主要对特征图进行卷积操作;C2f 模块借鉴了 YOLOv5 中的 C3 模块和 YOLOv7 中的高效层聚合网络(efficient layer aggregation networks, ELAN)模块,通过多分支进行跨层连接,获得更加丰富的梯度流信息;SPPF 模块用于提取不同感受野特征,使得网络更好的适应不同尺度的目标。

融合层主要由特征金字塔网络^[10]和路径聚合网络^[11]

结构组成,将高层与低层的特征信息进行融合和增强,以进一步优化特征图的表示能力。检测头部分,YOLOv8 采用解耦头操作,将目标位置信息和类别信息分别提取出来,通过不同的网络分支分别学习,使预测结果更加接近真实。

2 YOLOv8s 算法改进

为了解决交通标志检测中所存在的准确率低、参数量大等问题,本文提出的 SC-YOLOv8 模型结构如图 2 所示,主要有 4 个改进部分。

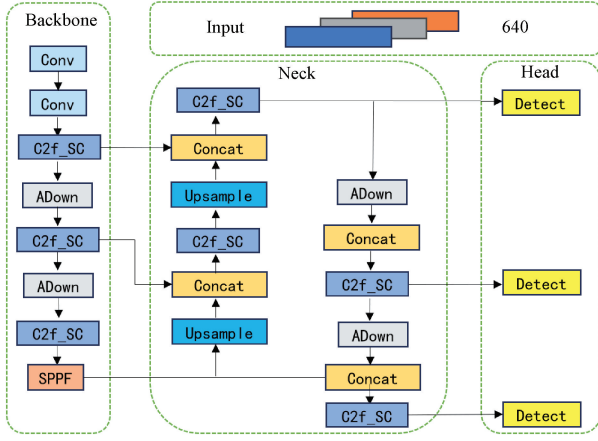


图 2 SC-YOLOv8 模型结构

Fig. 2 SC-YOLOv8 model structure

2.1 ADown 模块

下采样是卷积神经网络中的常用操作,用于减少特征图的空间尺寸,从而减少计算量和参数数量。普通的下采样卷积实现简单,易于理解和使用,但是会丢失部分特征信息。目前主要有两种普通下采样卷积的实现方式,第 1 种是通过设置卷积核的步幅,在每次卷积操作中跳过部分像素;第 2 种是使用池化操作(如最大池化或平均池化)减少输出特征图的尺寸。原模型采用的是普通下采样中的第一种方式,而本文使用的下采样 ADown 模块主要目的是在实现过程中尽可能保留更多的特征信息,提升特征图的质量和模型的检测性能。

ADown 模块首先对输入的特征图进行平均池化操作,有效的减少了特征图的大小以及后续卷积层的计算量,然后在通道维度上分为两部分进行处理,一部分先经过最大池化再进行卷积,另一部分只进行卷积操作,这两部分卷积层的参数是共享的,可以减少模型的参数数量,提高模型的参数效率,最后将输出结果进行拼接得到输出。本文使用下采样 ADown 模块替换普通下采样 Conv,有效的提高了模型对目标的感知能力,提升了交通标志检测的准确性。ADown 模块替换结构如图 3 所示。

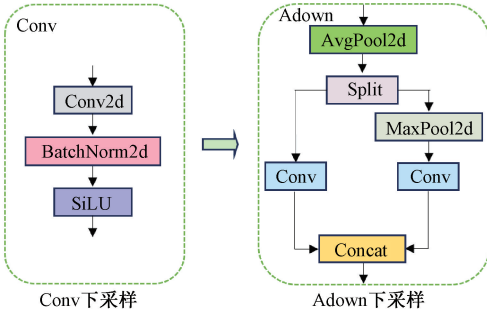


图 3 ADown 模块替换结构

Fig. 3 ADown module replacement structure

2.2 C2f_SC 模块

本文使用 SCConv^[12] 模块替换 C2f 中 Bottleneck,设计了一个全新的 C2f_SC 模块(C2f_SC 模块替换结构如图 4 所示),有效的提高了模型的检测准确率,大幅减少了模型参数。SCConv 模块主要由空间重构单元(spatial recalibration unit, SRU)和通道重构单元 CRU(channel recalibration unit, CRU)组成,同时考虑了空间和通道维度的信息,减少了特征冗余,使模型更加轻量化,SCConv 模块结构如图 5 所示。




图 4 C2f_SC 模块替换结构

Fig. 4 C2f_SC module replacement structure

1) SRU 结构

SRU 结构通过分离-重构两个部分抑制空间冗余,获得空间细化特征 X^w ,能够保持模型的稀疏性,从而减少计算量。对于一个给定的输入特征 X ,首先通过组归一化 GN 得到输出特征 X_{out} 。

$$X_{out} = GN(X) = \gamma \frac{X - u}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (1)$$

然后利用可训练参数 γ 来衡量每个批次和通道的空间像素的方差,归一化后得到相关通道权重 W_γ 。

$$W_\gamma = \frac{\gamma_i}{\sum_{j=1}^c \gamma_j} \quad i, j = 1, 2, \dots, C \quad (2)$$

再通过 Sigmoid 函数将 W_γ 重新加权的权重值映射到 $(0, 1)$ 范围内,并通过阈值(本文取 0.5)进行门控。将高于阈值的权重 W_γ 设为 1,得到有用特征的权重 W_1 ;将低于阈值的权重 W_γ 设为 0,得到冗余特征的权重 W_2 。

$$W = Gate \{ Sigmoid(W_\gamma(GN(X))) \} \quad (3)$$

将输入特征 X 分别乘以 W_1 和 W_2 ,采用交叉相加的方式生成更丰富的信息特征,最终获得空间细化特征 X^w 。

$$X_1^w = W_1 \otimes X \quad (4)$$

$$X_2^w = W_2 \otimes X \quad (5)$$

$$X_{11}^w \oplus X_{22}^w = X^{w1} \quad (6)$$

$$X_{21}^w \oplus X_{12}^w = X^{w2} \quad (7)$$

$$X^{w1} \cup X^{w2} = X^w \quad (8)$$

式中: X 为任意给定的中间映射; u 为 X 的均值; σ 为 X 的标注差; γ 和 β 为可训练的仿射变换; ϵ 为为除法稳定性而加入的一个小的正常数; W 为通过门控得到的有用特征权重 W_1 和冗余特征的权重 W_2 。

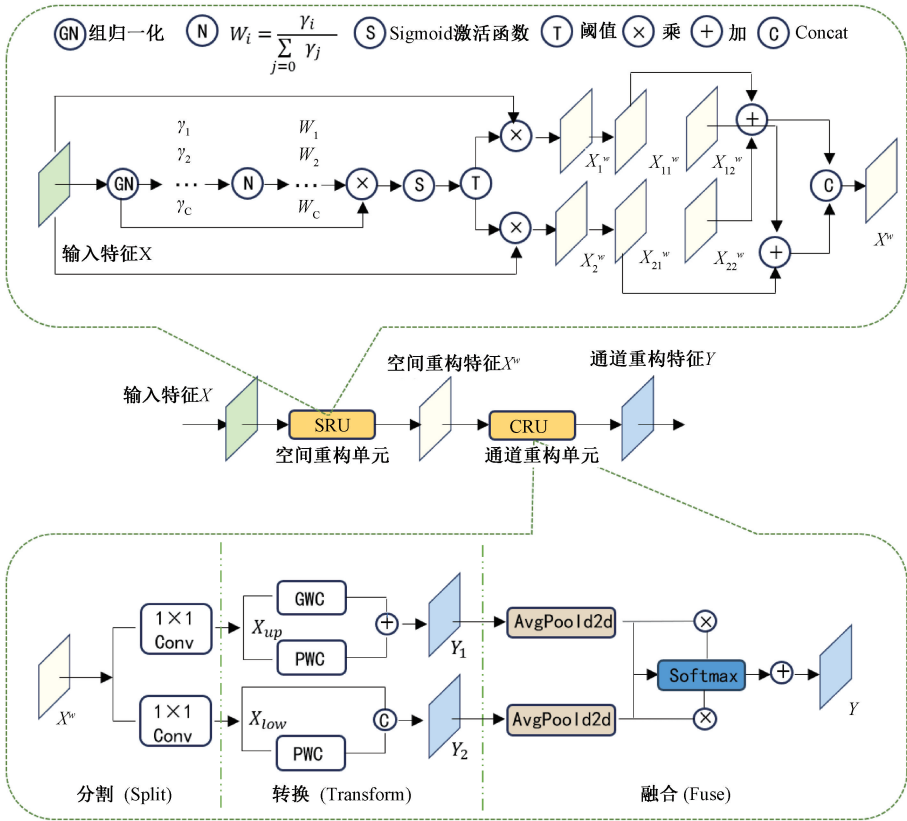


图 5 SCConv 模块结构

Fig. 5 SCConv module structure

2)CRU 结构

经过 SRU 结构之后,空间重构特征图 X^w 在通道维度上仍然存在冗余,CRU 结构可以通过分割 (Split)、转换 (Transform)和融合 (Fuse)3 个操作进一步减少冗余。

分割阶段,将 X^w 的通道分为富特征提取器 X_{up} 和浅特征提取器 X_{low} 。转换阶段, X_{up} 采用高效、低计算成本的逐分组卷积 (grouped convolution, GWC) 和逐点卷积 (pointwise convolution, PWC) 来提取特征 Y_1 , X_{low} 用 1×1 的 PWC 操作来生成具有浅层隐藏细节的特征映射得到 Y_2 。融合阶段,利用简化的选择性卷积网络 (selective kernel networks, SKNet) 方法自适应地合并转换阶段的输出特征 Y_1 和 Y_2 , 最终得到输出特征 Y 。因此输入特征 X 经过 SRU 和 CRU 之后既能减少信息冗余又能提取出有效信息,极大的减少了模型参数量。

2.3 改进目标检测层

由于交通标志的尺寸比较小,而 YOLOv8s 的下采样倍数较大,随着网络层数的加深,小目标的特征信息很容易被忽略^[13],因此增加 160×160 尺度的小目标检测层并去除 20×20 尺度的大目标检测层,改善对小目标的检测能力。该改进方法先从 Backbone 中的第一个 C2f 引出一个输出,尺度为 160×160 ,在 Head 中增加一个 Detect 模块,然后将 Backbone 部分的 10 层网络减少到了 8 层,删去

SPPF 模块前面最近的 Conv 和 C2f 模块,在 Head 中删去一个 Detect 模块。改进的目标检测层分辨率更高,减少了小目标的漏检误检,提高了检测精度。目标检测层替换结构如图 6 所示。

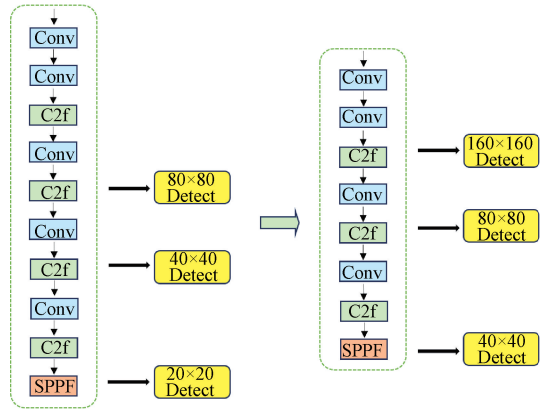


图 6 目标检测层替换结构

Fig. 6 Object detection layer replacement structure

2.4 改进损失函数

原模型 YOLOv8s 使用的是 CIoU 损失函数,CIoU 不仅考虑了预测框与真实框的重叠面积,同时引入了中心点距离以及长宽比,其计算公式如下:

$$CIoU = IoU - \frac{\rho^2(B^{pred}, B^{gt})}{c^2} + \alpha v \quad (9)$$

$$v = \frac{4}{\pi} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w^{pred}}{h^{pred}} \right) \quad (10)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (11)$$

其中, v 用来衡量长宽比, α 表示平衡参数, $\rho^2(B^{pred}, B^{gt})$ 表示预测框与真实框中心点之间的欧氏距离, B^{pred} 表示预测边界框, B^{gt} 表示真实边界框, c 表示归一化因子, w^{gt} 和 h^{gt} 表示真实边界框的宽度和高度, w^{pred} 和 h^{pred} 表示预测边界框的宽度和高度。然而 CIoU 在宽高比的定义上比较模糊, 质量好的回归样本难以进一步优化, 导致正负样本不平衡。因此本文使用 Wise-MPDIoU 替换 CIoU, 缓解正负样本不平衡的问题。

WIoU 通过对预测框和真实框之间的区域进行加权^[14], 解决了 IoU 可能存在的偏差问题, 其计算公式如下:

$$WIoU = \frac{\sum_{i=1}^n \{w_i IoU(b_i, g_i)\}}{\sum_{i=1}^n w_i} \quad (12)$$

其中, b_i 表示第 i 个物体框的坐标, g_i 表示第 i 个物体的真实标注框的坐标, w_i 表示权重值。

MPDIoU 是一种直接最小化预测框和真实框对应左上角、右下角间点距离的改进算法, 对小目标的检测定位上更为准确, 具有更好的鲁棒性, 其计算公式如下:

$$MPDIoU = IoU - \frac{\rho^2(P_1^{pred}, P_1^{gt})}{w^2 + h^2} - \frac{\rho^2(P_2^{pred}, P_2^{gt})}{w^2 + h^2} \quad (13)$$

其中, $P_1^{pred}, P_1^{gt}, P_2^{pred}, P_2^{gt}$ 表示预测框与真实框的左上角、右下角的点, $\rho^2(P_1^{pred}, P_1^{gt})$ 表示计算相应点之间的距离, w 和 h 表示边界框的宽度和高度。本文使用 WIoU 损失函数的思想改进 MPDIoU, 以 Wise-MPDIoU 替换 CIoU, 有助于模型更好地学习目标位置的准确位置, 提高模型的检测准确率, 其计算公式如下:

$$Wise - MPDIoU = WIoU - \frac{\rho^2(P_1^{pred}, P_1^{gt})}{w^2 + h^2} - \frac{\rho^2(P_2^{pred}, P_2^{gt})}{w^2 + h^2} \quad (14)$$

3 实验设计与结果分析

3.1 数据集与实验环境

本实验使用的是 TT100K 中国交通标志数据集, 数据集是由 6 个像素很高的广角单反相机在中国多个城市多种天气条件拍摄的, 整个数据集类别包括指示、禁令及警告标识 3 大类, 共有 221 种不同的交通标志小类别。由于各类别数量分配不平衡, 本实验使用 Python 脚本从其中选取了实例数都大于 100 张的 42 类交通标志, 其中训练集数据 6 598 张, 验证集数据 1 889 张, 测试集数据 970 张。

本实验的操作系统为 64 位 Windows10 专业版, GPU 为 NVIDIA 4090, 编程语言为 Python3.8, 使用深度学习框架 pytorch1.12.0 进行训练, 训练参数配置如表 1 所示。

表 1 训练参数配置

Table 1 Training parameter configuration			
参数名称	配置	参数名称	配置
epochs	120	optimizer	SGD
batchsize	32	momentum	0.937
workers	8	close_mosaic	10
imgsz	640	lr0	0.01

3.2 损失函数对比试验

为了验证损失函数 Wise-MPDIoU 的有效性, 将 Wise-MPDIoU 与 GIoU^[15]、CIoU、MPDIoU 和 FocalerIoU 在原 YOLOv8s 的基础上进行了对比实验, 本实验使用 mAP50 作为主要评估指标辅以精确率 P 、召回率 R 来检测损失函数性能, 损失函数对比结果如表 2 所示。

表 2 损失函数对比结果

Table 2 Comparison results of loss functions			
损失函数	P	R	mAP50
GIoU	82.6	72.0	80.7
CIoU(原 YOLOv8s)	82.1	71.6	80.2
MPDIoU	84.8	68.8	80.2
FocalerIoU	81.5	71.5	80.5
Wise-MPDIoU	84.6	72.2	81.8

由表 2 实验结果可知, 在精确率 P 方面, 损失函数 MPDIoU 位于第一, 本文采用的 Wise-MPDIoU 与此相比仅低 0.02%, 与原模型 YOLOv8s 相比提高了 2.5%; 在召回率 R 方面, Wise-MPDIoU 损失函数表现最好, 较原模型提升了 0.6%; 在平均精度 mAP50 方面, Wise-MPDIoU 性能最佳, 较原模型提升了 1.6%, 较其他损失函数平均提高了 1.33%。由上述可知, 对于精确率 P 这单一指标而言, Wise-MPDIoU 低于 MPDIoU, 但只考虑精确率 P 可能导致正样本的遗漏, 不能反映模型在不同阈值下的综合表现。在 mAP50 平均精度方面, Wise-MPDIoU 高于 MPDIoU, mAP50 同时考虑了准确率和召回率, 提供了模型在不同置信度阈值下的综合表现, 可以更全面的评估模型性能。综合评估下, 本文所改进的损失函数 Wise-MPDIoU 优于其他损失函数, 能够有效的提高交通标志的检测准确率。

3.3 消融实验

为确保本文算法的有效性和合理性, SC-YOLOv8 模型在 TT100K 数据集上进行了①~⑦的消融实验, 其中 ①表示原模型 YOLOv8s, ②~⑥表示基于原模型的单独改进和组合改进, ⑦表示本文改进模型, 消融实验结果如表 3 所示。

表 3 消融实验结果

Table 3 Results of ablation experiment

模型	ADown	Wise_MPDIOU	小目标层	C2f_SCConv	<i>P</i>	<i>R</i>	mAP50	Params
①	—	—	—	—	82.1	71.6	80.2	11.14
②	✓	—	—	—	82.7	70.1	80.4	9.49
③	—	✓	—	—	84.6	72.2	81.8	11.14
④	✓	—	✓	—	84.0	78.3	85.5	3.91
⑤	✓	✓	✓	—	84.4	79.6	86.0	4.68
⑥	—	✓	✓	✓	86.0	78.3	86.2	4.31
⑦	✓	✓	✓	✓	86.9	78.3	86.8	4.29

实验表明,本文的 SC-YOLOv8 模型与模型 ④相比在参数量 Params 方面表现较差,但平均精度 mAP50 高了 1.3%,精确率 *P* 高了 2.9%;本文模型与模型 ⑤相比在召回率方面表现较差,但精确率高了 2.5%,平均精度 mAP50 高了 0.8%;本文模型相比于原模型精确率 *P* 提升了 4.8%,召回率提升了 6.7%,平均精度 mAP50 提升了 6.6%,参数量 Params 下降了 61.5%。综合评估下,SC-YOLOv8 模型在检测精度和参数量方面获得了非常有效的提升,很好的证明了本文算法的有效性。

3.4 算法对比实验

为了验证改进算法 SC-YOLOv8 在交通标志检测算法中的优越性,本文选取 YOLOv5m、YOLOv7-tiny、YOLOv8s 和当前优秀算法(YOLOv5s-Ghost、CGS-Ghost YOLO、Ghost-YOLOv8)与改进的算法进行对比。由于当前优秀算法在数据集上的选取以及环境配置等方面有所不同,现将所有算法放在相同的条件下进行实验,以体现实验的公正性。算法对比实验结果如表 4 所示。

表 4 算法对比实验结果

Table 4 Algorithm comparison experimental results				
模型	<i>P</i>	<i>R</i>	mAP50	Params
YOLOv5m	71.5	74.6	70.2	21.27
YOLOv7-tiny	76.5	69.8	77.1	6.20
YOLOv8s	82.1	71.6	80.2	11.14
YOLOv5s-Ghost ^[16]	65.0	54.0	59.3	5.00
CGS-Ghost YOLO ^[17]	82.4	61.4	68.0	16.60
Ghost-YOLOv8 ^[18]	71.7	66.7	71.9	6.10
SC-YOLOv8(本文)	86.9	78.3	86.8	4.29

实验结果表明 SC-YOLOv8 算法在 TT100K 数据集中平均精度和模型参数量有着非常显著的优势,在准确率方面,较其他模型平均提高了 12.03%;在召回率方面,较其他模型平均提高 11.95%;在平均精度 mAP50 方面,较其他模型平均提高 15.68%;在参数量 Params 方面,较其他模型平均下降 48.36%。实验证明了改进算法在准确率

和参数量的综合评价上较原模型和其他模型均有一定的优势。

为了验证本文改进算法 SC-YOLOv8 的通用性,在 CCTSDB (Chinese comprehensive traffic sign detection benchmark) 数据集^[19]和 TSDD (traffic sign detection dataset)数据集上继续进行算法对比验证,①表示原算法 YOLOv8s,②表示本文改进算法,泛化实验结果如表 5 所示。

表 5 泛化实验结果

Table 5 Generalization experiment results				
数据集	CCTSDB		TSDD	
模型	①	②	①	②
<i>P</i>	73.5	79.6	85.7	88.4
<i>R</i>	61.3	72.4	78.3	82.8
mAP50	67.9	78.1	87.1	90.2
Params	11.14	4.29	11.14	4.29

实验结果表明,在数据集 CCTSDB 和 TSDD 上,本文改进算法 SC-YOLOv8 在精确率 *P*、召回率 *R*、平均精度 mAP50 以及参数量方面全部比原模型 YOLOv8s 优秀,有力的证明了改进算法的有效性。

3.5 检测结果可视化对比

为了检验本文算法改进后的实际检测效果,将原 YOLOv8s 算法(左图)与本文改进算法(右图)应用于雾天、雪天、夜晚等不同环境中进行可视化对比,雾天检测对比如图 7 所示,雪天检测对比如图 8 所示,夜晚检测对比如图 9 所示。

由多种环境下的可视化对比图可知,原 YOLOv8s 算法在雾天与雪天的置信度远远低于本文改进算法,在夜晚环境中甚至出现了漏检情况。综合评估下,改进算法 SC-YOLOv8 有效的改善了原算法中存在的交通标志漏检情况,并且在置信度方面也远远高于原算法,很好的证明了改进算法的优越性。



图 7 雾天检测对比

Fig. 7 Comparison of fog detection



图 8 雪天检测对比

Fig. 8 Comparison of snow detection




图 9 夜晚检测对比

Fig. 9 Comparison of night detection

4 结 论

为了解决交通标志检测中所存在的准确率低、参数量大等问题,提出了一种基于 SC-YOLOv8 的交通标志检测算法。该算法在实验数据集上相比于原算法 mAP 提高了 6.6%,Params 下降了 61.5%,并且在不同环境条件下的检测结果也得到了有效提升,很好的改善了交通标志检测中的误检、漏检问题。后续将更多的关注于遮挡、重叠等交通标志的检测,进一步提高该模型的鲁棒性和应用前景。

参考文献

- [1] TRIKI N, KARRAY M, KSANTINI M. A real-time traffic sign recognition method using a new attention-based deep convolutional neural network for smart vehicles[J]. Applied Sciences, 2023, 13(8): 4793.
- [2] ZOU ZH X, CHEN K Y, SHI ZH W, et al. Object detection in 20 years: A survey[J]. Proceedings of the IEEE, 2023, 113(3): 257-276.
- [3] REN SH Q, HE K M, GIRSHICK R, et al. Faster RCNN: Towards real-time object detection with

region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(6): 1137-1149.

- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th European Conference on Computer Vision, Springer, 2016: 21-37.
- [5] 江金洪, 鲍胜利, 史文旭, 等. 基于 YOLOv3 算法改进的交通标志识别算法[J]. 计算机应用, 2020, 40(8): 2472-2478.
- JIANG J H, BAO SH L, SHI W X, et al. Improved traffic sign recognition algorithm based on YOLOv3[J]. Computer Applications, 2020, 40(8): 2472-2478.
- [6] REDMON J, FARHADI A. YOLOv3: An incremental improvement [C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2018: 1-6.
- [7] JIANG L F, LIU H, ZHU H, et al. Improved YOLO v5 with balanced feature pyramid and attention module for traffic sign detection[C]. MATEC Web of Conferences, 2022.

- [8] HU J, SHEN L, AIBANIE S, et al. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [9] 朱开, 陈慈发. 基于 YOLOv5 的雾霾天气下交通标志识别[J]. 电子测量技术, 2023, 46(8): 31-37.
- ZHU K, CHEN C F. Traffic sign recognition in haze weather based on YOLOv5 [J]. Electronic Measurement Technology, 2023, 46(8): 31-37.
- [10] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [11] 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.
- [12] LI J F, WEN Y, HE L H. SCConv: Spatial and channel reconstruction convolution for feature redundancy[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 6153-6162.
- [13] 杨辉羽, 李海明. 单聚合 YOLO 航拍小目标检测算法[J]. 国外电子测量技术, 2023, 42(4): 131-140.
- YANG H Y, LI H M. Single-aggregation YOLO algorithm for small object detection in aerial images[J]. Foreign Electronic Measurement Technology, 2023, 42(4): 131-140.
- [14] LIU ZH G, SUN B SH, BI K Y. Optimization of YOLOv7 based on PConv, SE attention and Wise-IoU[J]. International Journal of Computational Intelligence and Applications, 2024, 23(1): 2350033-2350054.
- [15] 俞林森, 陈志国. 融合前景注意力的轻量级交通标志检测网络[J]. 电子测量与仪器学报, 2023, 37(1): 21-31.
- YU L S, CHEN ZH G. Lightweight traffic sign detection network with foreground attention fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 21-31.
- [16] 徐正军, 张强, 许亮. 一种基于改进 YOLOv5s-Ghost 网络的交通标志识别方法[J]. 光电子·激光, 2023, 34(1): 52-61.
- XU ZH J, ZHANG Q, XU L. A traffic sign recognition method based on improved YOLOv5s-Ghost network[J]. Journal of Optoelectronics·Laser, 2023, 34(1): 52-61.
- [17] 赵宏, 冯宇博. 基于 CGS-Ghost YOLO 的交通标志检测研究[J]. 计算机工程, 2023, 49(12): 194-204.
- ZHAO H, FENG Y B. Research on traffic sign detection based on CGS-Ghost YOLO[J]. Computer Engineering, 2023, 49(12): 194-204.
- [18] 熊恩杰, 张荣芬, 刘宇红, 等. 面向交通标志的 Ghost-YOLOv8 检测算法[J]. 计算机工程与应用, 2023, 59(20): 200-207.
- XIONG EN J, ZHANG R F, LIU Y H, et al. Ghost-YOLOv8 detection algorithm for traffic signs [J]. Computer Engineering and Applications, 2023, 59(20): 200-207.
- [19] LIN X R, WANG W, ZHU X H, et al. CCTSDB dataset enhancement based on a cross-augmentation method for image datasets [J]. Intelligent Data Analysis, 2024: 1-19. DOI:10.3233/IDA-230075.

作者简介

闫世洋, 硕士研究生, 主要研究方向为多传感器感知融合模式识别。

E-mail: 1602284426@qq.com

罗素云, 副教授, 硕士研究生导师, 主要研究方向为无人驾驶汽车环境感知。

E-mail: luosuyun@sues.edu.cn