

基于改进YOLOv8的交通标志检测算法研究

李建东^{1,2}, 徐米雪¹

(1. 辽宁工程技术大学软件学院, 辽宁 葫芦岛 125105; 2. 辽宁工程技术大学矿业学院, 辽宁 阜新 123000)

摘要: 智能交通的快速发展,使得快速准确地识别交通标志对保障交通安全至关重要。针对传统交通标志识别算法存在精度低、速度较慢等问题,提出了一种基于改进YOLOv8模型的交通标志检测算法。首先,设计空间下采样Conv-SPD模块用于提升特征提取能力;然后,构建混合主干网络FasterNet-EMA,引入高效多尺度注意力模块,增强模型对交通标志的关注度;最后,通过优化损失函数MPDIoU,从而提高目标检测精度。实验结果表明,与YOLOv8n相比,改进算法在保证实时性的同时,在TT100K数据集上的mAP@0.5和mAP@0.5:0.95分别提高了7.3%和6.9%;在CCTSDb-2021数据集上mAP@0.5和mAP@0.5:0.95分别提升了3.6%和1.9%。研究结果表明,改进算法提高了交通标志检测的精度与鲁棒性,为智能驾驶系统提供了更具实用价值的感知方案。

关键词: 交通标志;YOLOv8;Conv-SPD模块;多尺度注意力机制;最小点距回归框

DOI: 10.11907/rjtk.251159

扫描二维码阅读全文:



中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2026)005-0212-09

Research on Traffic Sign Detection Algorithm Based on Improved YOLOv8

LI Jiandong^{1,2}, XU Mixue¹

(1. School of Software, Liaoning Technical University, Huludao 125105, China;

2. School of Mining, Liaoning Technical University, Fuxin 123000, China)

Abstract: With the rapid development of intelligent transportation, it is of great significance to quickly and accurately identify traffic signs to ensure traffic safety. In order to solve the problems of low accuracy and slow speed of traditional traffic sign recognition algorithms, this paper studies a traffic sign detection algorithm based on the improved YOLOv8 model. Firstly, the spatial downsampling Conv-SPD module was designed to improve the feature extraction ability. Then, the hybrid backbone network FasterNet-EMA was constructed, and an efficient multi-scale attention module was introduced to enhance the model's attention to traffic signs. Finally, the loss function MPDIoU was optimized to improve the accuracy of target detection. Experimental results show that compared with YOLOv8n, the improved algorithm improves the mAP@0.5 and mAP@0.5:0.95 on the TT100K dataset by 7.3% and 6.9%, respectively, and the mAP@0.5 and mAP@0.5:0.95 on the CCTSDb-2021 dataset by 3.6% and 1.9%, respectively. The results show that the improved algorithm improves the accuracy and robustness of traffic sign detection, and provides a more practical perception scheme for the intelligent driving system.

Key Words: traffic sign; YOLOv8; Conv-SPD module; multi-scale attention mechanism; minimum point distance regression box

0 引言

随着城市化进程的加速与机动车保有量的持续攀升,道路交通系统变得日益复杂。交通标志作为保障道路交通安全、维持交通秩序的关键要素,其准确识别与快速检测对于智能交通系统的有效运行具有重要意义。在此背景下,交通标志识别算法研究已成为智能交通领域的重要

核心环节,不仅为自动驾驶车辆提供决策依据的关键技术,还能协助交通管理部门实现高效监管和智能化运管,进一步推动智能交通系统朝着更智能化、更高效化的方向稳健发展。现代交通环境中,交通标志种类繁多,涵盖禁令标志、指示标志、警告标志等多种类型,且这些交通标志的形状、颜色、图案各异^[1]。传统的交通标志识别方法主要依赖于人工特征提取,不仅耗时费力,而且在面对复杂多变的交通场景时,其适应性与准确性较差。特别是在不

收稿日期: 2025-04-15

基金项目: 辽宁省教育厅基本科研项目(JYTMS20230804)

作者简介: 李建东(1979-),男,硕士,辽宁工程技术大学软件学院副教授,研究方向为图像处理、大数据和云计算;徐米雪(1999-),女,辽宁工程技术大学软件学院硕士研究生,研究方向为图像处理和目标检测。本文通讯作者: 徐米雪。

同光照条件、天气状况下,以及部分标志被遮挡、污损时,传统方法容易出现误判或漏判^[2]。

1 相关研究

传统交通标志识别方法多采用单阶段检测框架的基准模型,虽能实现实时检测,但在复杂道路场景下面临小目标漏检、光照敏感度高为关键问题。近年来,基于注意力机制与特征融合的改进方案逐渐成为研究热点,但模型轻量化与检测精度的矛盾仍未得到有效解决。李文举等^[3]在YOLOv5基础上引入自适应空间特征融合模块,通过特征图权重动态分配使mAP提升了3.2%,但其改进方案导致模型计算量增加27%,难以满足车载终端部署需求。针对此问题,曹立等^[4]提出FMS-YOLOv5s模型,采用深度可分离卷积与通道剪枝技术将参数量压缩至3.8M,在保持86.7% mAP的同时实现了42FPS的检测速度,但其轻量化设计导致小目标识别精度下降了9.5%。余荣威等^[5]构建的改进YOLOv8模型创新性地将C3CA模块引入主干网络,通过坐标注意力机制增强特征表达能力,在TT100K数据集上达到91.4%的检测精度,但未考虑模型在雾霾、雨雪等恶劣天气下的鲁棒性。Luo等^[6]研发的YOLOv8-CE模型虽通过多尺度特征金字塔改进实现了96.3%的日间检测准确率,但在夜间低照度场景下的误检率仍高达18.6%。Sun等^[7]通过优化主干网络并引入动态检测策略,有效提升了模型在复杂场景下的适应能力及其对小目标特征提取的性能。Kandasamy等^[8]提出的TrafficSignNet算法设计光照不变性特征提取模块,通过多光谱数据增强,使模型在极端光照条件下的F1-score提升至89.2%,但其依赖大规模合成数据的训练策略,降低了实际道路场景的泛化能力。Chu等^[9]提出的TRD-YOLO算法构建了特征细化蒸馏结构,针对小目标检测任务进行了专门优化,在GTSDB数据集的mini类别上实现了84.3%的召回率,但对存在遮挡的目标仍存在24.6%的漏检率。雷雪梅等^[10]提出的双注意力机制模型,通过通道-空间注意力协同工作,在BDD100K数据集上实现81.9%的mAP,但其双向特征加权融合策略未充分考虑多尺度特征间的语义鸿沟问题。

现有研究在以下3个方面存在共性局限:

(1)动态环境适应能力不足,多数模型仅在标准数据集上表现良好,未构建全天候场景验证体系。

(2)模型改进策略呈现精度优先或速度优先的单一导向,缺乏精度-速度-鲁棒性的多目标协同优化。

(3)对小尺度、部分遮挡目标的特征表征仍依赖传统卷积核,未有效挖掘Transformer等新型架构的全局上下文感知优势。

本文提出基于改进YOLOv8的交通标志检测算法,首先,采用空间深度卷积(Symmetric Positive Definite Matrix

Convolution, Conv-SPD)替换传统池化层,缓解复杂场景下的细节丢失问题;其次,构建混合主干网络(FasterNet with Efficient Multi-scale Attention, FasterNet-EMA),融合多尺度注意力机制与轻量化残差结构,实现精度-速度-鲁棒性的多目标平衡;最后,设计最小距离的边界框回归损失函数(Minimum Point Distance Intersection over Union, MPDI-oU),通过融合最小点距与宽高相关系数优化边界框回归,显著增强几何特征感知能力。

2 YOLOv8模型结构

2.1 Backbone部分

YOLOv8的Backbone部分主要用于特征提取,通常由一系列卷积层和池化层组成,能够有效地从输入图像中提取不同层次的特征。浅层提取边缘等基础特征,而深层则提取更抽象的语义特征,这些特征为后续的目标检测任务提供关键信息^[11]。Bottleneck结构如图1所示。




Fig. 1 The bottleneck structure diagram

图1 Bottleneck结构图

2.2 Neck部分

Neck部分是对Backbone提取的特征进行融合和增强,通常会采用特征金字塔网络(Feature Pyramid Network, FPN)或者类似的结构,将不同尺度的特征图进行融合,使模型能够同时利用高层语义特征和低层的细节特征,并且在检测不同大小的目标时都能有很好的表现^[12-13]。YOLOv8的Neck部分在YOLOv5的基础上,使用比空间金字塔池化(Spatial Pyramid Pooling, SPP)更快的池化模块(Spatial Pyramid Pooling-Fast, SPPF)。SPP与SPPF结构示意图如图2所示。

2.3 Head部分

YOLOv8模型的Head部分是进行目标检测的最终预测,接收Neck部分传递的特征,并通过多个卷积层对其进行提炼,进一步调整特征维度。Head能够在多尺度的特征上进行预测,输出目标的类别概率以及边界框的坐标。这一部分与损失函数相关,通过训练过程不断优化模型的预测性能^[14]。YOLOv8 Head结构如图3所示。




Fig. 2 Schematic representation of the SPP and SPPF structures

图2 SPP与SPPF结构示意图




Fig. 3 Schematic representation of the YOLOv8 Head structure

图3 YOLOv8 Head结构示意图

3 基于改进 YOLOv8 的交通标志检测算法

3.1 空间下采样模块

在改进 YOLOv8n 模型的算法框架中,传统的跨步卷积下采样方法由于仅依据固定步长进行采样,在处理图像空间信息时,难以充分捕捉部分关键空间信息,导致提取的特征难以全面且精准地反映图像的空间细节,进而降低了特征的准确性^[15-16]。

Conv-SPD 图像处理与目标识别的核心在于通过卷积核精准捕获输入特征图中的局部特征,不同大小的卷积核可以感受不同尺度的信息,从而提取丰富的多尺度特征,全面涵盖图像的细节与全局特征。通过下采样操作,特征图的空间维度得以降低,在减少计算量的同时,能够有效保留图像中的重要信息,突出关键特征,并增强模型对特征的敏感度。经过卷积与下采样的相互配合,网络能够更好地聚焦于目标的核心特征,过滤冗余信息,最终提升对目标的识别和分类能力,同时,在复杂的图像场景中准确判断目标类别^[17]。假设特征图 F 的大小为 $H \times W$, 其中, H 和 W 分别表示高度和宽度,特征重要性 I 计算公式如式(1)所示:

$$I(x, y) = \alpha \cdot |\nabla F(x, y)| + \beta \cdot \text{entropy}(F(x, y)) \quad (1)$$

其中, α 和 β 是权重参数, $\nabla F(x, y)$ 表示特征图在位置 (x, y) 的梯度, $\text{entropy}(F(x, y))$ 表示该位置的熵值。根据特征重要性对特征图进行采样,选择重要性高的位置进行密集采样,如式(2)所示:

$$S = \{(x_i, y_i) | I(x_i, y_i) > T\} \quad (2)$$

其中, T 表示设定的阈值。在密集采样之后,需要对采样得到的特征进行降维处理,以减少计算量并保留关键信息。降维处理可以通过特征合并或加权处理来实现。假设采样后的特征集合为 S , 降维处理表示如式(3)所示:

$$F' = \text{reduce}(F(S)) \quad (3)$$

其中, reduce 表示降维操作。将相邻的特征点合并为一个特征点,根据特征的重要性对特征进行加权,从而保留重要特征。

传统方法依赖固定步长采样,容易丢失关键空间信息,而 Conv-SPD 通过基于特征重要性的智能采样策略,能够主动识别特征密集区域实施差异化采样,即高重要性区域密集保留细节,低重要性区域降维处理^[18]。自适应机制在 YOLOv8n 框架中实现了双重突破——通过特征加权和合并技术,将计算量降低 23%。主干网络改进,如图 4 所示。通过 Conv-SPD→C2f 的级联结构,在 640×640 像素输入范围内构建了更精准的空间特征金字塔,其优势在 MS-COCO 数据集的遮挡场景测试中尤为突出。




Fig. 4 The backbone network improvement

图4 主干网络改进

3.2 高效多尺度注意力模块

基于改进 YOLOv8 的交通标志检测算法中,高效多尺度注意力 (Efficient Multi-Scale Attention, EMA) 能够同时关注不同尺度特征,如小尺度特征中的细节和大尺度特征中的语义信息^[19]。EMA 首先通过特征分组的方式对输入特征图进行划分,精准地梳理特征信息,随后,利用两条不同的分支来提取注意力权重。这两条分支在功能上相互协作又各有侧重,从而能够更全面地捕捉特征间的关系。此外,通过跨空间学习将分支特征进行融合,使不同空间位置的特征相互补充、相互影响,从而让模型可以更有效地聚焦于关键特征,抑制无关信息,极大地增强了模型在复杂场景下对目标的检测能力^[20]。表达式如式(4)一式(5)所示:

$$F' = M_a(S_m(P_A(f^{1*1})), f^{3*3}) \quad (4)$$

$$F'' = M_a(S_m(P_A(f^{3*3})), f^{1*1}) \quad (5)$$

其中, f 为分支输出, M_a 表示矩阵乘法运算, S_m 表示 Softmax 函数, P_a 为平均池化操作。具体表达式如式(6)

所示:

$$Z_c = \frac{1}{H+W} \sum_{i=0}^{i=0} \sum_{j=0}^{j=0} x_c(i,j) \quad (6)$$

其中, Z_c 表示经过平均池化后的结果。其中, H 和 W 分别表示特征图的高度和宽度。对每个通道,将该通道上所有位置的像素值 $x_c(i,j)$ 进行累加,得到平均池化后的输出值。通过聚合所有通道的结果,得到最终输出,如式(7)所示:

$$F_o = F_i \otimes \sigma(F' \oplus F'') \quad (7)$$

其中, F_o 表示最终输出特征图, F_i 为输入特征图。本文提出将 FasterNet 与 EMA 模块融合,形成 FasterNet-EMA 模块,模块结构如图5所示。




Fig. 5 The FasterNet-EMA structure
图5 FasterNet-EMA 结构

FasterNet 以部分卷积为核心构建,采用 3×3 卷积核,并通过分组稀疏化的通道连接方式,仅对输入通道的 $1/4$ 或 $1/8$ 子集执行空间卷积。主干网络设计为4个阶段,每个阶段的通道数逐级倍增($64 \rightarrow 128 \rightarrow 256 \rightarrow 512$)。每个阶段堆叠2~4个 Pconv 层,并通过步长为2的卷积进行下采样。随后,通过 1×1 卷积实现跨通道交互,并搭配 BN 和 SiLU 激活函数。Pconv 的分组稀疏策略与 EMA 的特征分组形成结构对齐,Concat 融合后的拼接特征输入 EMA 模块,使双分支注意力可在压缩后的空间维度($H \times W \rightarrow 7 \times 7$)和分组通道维度执行多尺度校准,最终通过 1×1 卷积恢复原通道数^[21]。利用 FasterNet 的快速特征提取优势优化信息处理流程,并通过 EMA 的双分支协同机制实现空间和通道维度的联合注意力校准。相较于传统的单一尺度注意力模块,该方法在保持计算效率的同时,能够更精准地捕捉复杂场景下小目标的细节特征与大范围语义信息的关联性^[22]。

3.3 损失函数

MPDIoU 损失函数综合考虑预测框与真实框的位置关系及其他因素,使模型在训练中更准确地优化目标边界框,提升检测精度,尤其适用于交通标志检测任务^[23]。边界框回归损失函数大多是基于交并比(Intersection over Union, IoU)表示,如式(8)所示:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (8)$$

YOLOv8 中使用 CIoU 作为回归损失^[23]。其定义如式(9)所示:

$$CIoU = IoU - \frac{\rho^2(A, B)}{C^2} - \alpha v \quad (9)$$

其中, $CIoU$ 表示完全交并比。IoU 是交并比,衡量预测

框与真实框的重叠程度^[24]。 $\frac{\rho^2(A, B)}{C^2}$ 表示预测框和真实框中心点之间的欧氏距离平方与最小外接矩形对角线长度平方的比值。 αv 是一个包含形状和方向因素的惩罚项,用于进一步优化预测框的形状和方向,使得预测框更准确地逼近真实框,从而能够更好地判断出预测框与真实框的位置关系。

其中,衡量目标框和预测框之间长宽比一致性的参数如式(10)所示:

$$v = \frac{4}{\pi^2} (\arctan \frac{w_A}{h_A} - \arctan \frac{w_B}{h_B})^2 \quad (10)$$

本文引入基于 MPDIoU 的损失函数作为改进模型的回归损失,如式(11)一式(12)所示:

$$L_{MPDIoU} = 1 - MPDIoU \quad (11)$$

$$MPDIoU = IoU - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \quad (12)$$

其中, d_1 、 d_2 表示预测框与真实框的左上角与右上角之间的距离。

语义相似度通过类别嵌入向量计算,如式(13)所示:

$$S(s_i, s_g) = \cos(w_i, w_g) = \frac{w_i^\top w_g}{\|w_i\| \cdot \|w_g\|} \quad (13)$$

其中, w_i 、 $w_g \in R^n$ 为类别语义嵌入,通过可训练的嵌入层获得。

现有的损失函数主要基于目标的几何位置关系,没有充分利用目标的语义信息,损失函数中加入语义相似度项如式(14)所示:

$$L_{new} = \sum_t (1 - MPDIoU_t) + \lambda \sum_{t, t'} |S(s_t, s_{t'}) - S_{gt}(s_t, s_{t'})| \quad (14)$$

其中, $MPDIoU_t$ 是交通标志 t 的检测准确性指标, λ 是平衡参数, S_{gt} 是交通标志之间的真实语义相似度。

基于上述研究,本文提出的 YOLOv8n 改进算法围绕三重核心优化策略展开,其网络结构改进细节如图6所示。




Fig. 6 Network structure of the improved YOLOv8n algorithm
rithm

图6 改进YOLOv8n算法的网络结构

(1)引入 Conv-SPD 模块。基于特征重要性动态调整采样密度,同时,结合 C2f 级联结构构建空间特征金字塔。针对传统跨步卷积下采样易丢失关键空间信息的问题,通过多尺度卷积核捕获局部特征并提取全局细节。

(2)嵌入多尺度注意力机制。通过分组特征划分和双分支注意力机制协同提取多尺度信息。EMA 利用跨空间学习融合不同分支的权重,使模型聚焦关键特征并抑制噪声,同时,结合 FasterNet 的稀疏卷积策略优化计算效率。

(3)损失函数优化。传统的损失函数通常依赖于几何位置关系^[25]。本文提出了一种改进的 MPDIoU 损失函数,综合考虑了目标的中心点距离、最小外接矩形以及语义相似度。同时,引入了预测框与真实框角点之间的距离比值,并通过语义嵌入向量来计算类别之间的相似性,从而有效优化了边界框回归的精度。

4 实验分析

4.1 实验环境及数据集

实验在 Linux 环境下的 ubuntu20.04 操作系统中执行,显卡为 GPU NVIDIA RTX 3080Ti, CPU 是 Intel (R) Xeon (R) Silver 4214R。采用深度学习框架 PyTorch 2.0.0, Python 版本为 3.8, CUDA 版本为 11.8。训练参数如表 1 所示。

在实际交通场景中,标志检测面临着诸多关键挑战,主要体现在密集遮挡、复杂背景干扰以及极端光照变化等方面。这些因素会显著影响检测系统的性能表现。本文选取 TT100K^[26]和 CCTSDB-2021^[27]两大主流数据集进行验证。TT100K 数据集是由清华—腾讯联合实验室发布的交通标志数据集,包含 100 000 张高分辨率图像和 30 000 个精细标注的交通标志,涵盖雨雾天气、运动模糊等复杂场景。CCTSDB-2021 数据集是由长沙理工大学团队开发,

Table 1 Training parameters

表 1 训练参数

参数	设置
optimizer	SGD
lr0	0.01
epochs	300
lrf	0.01
batchsize	32
workers	12
close_mosaic	10
momentum	0.937

包含近 20 000 张图像和 40 000 个标注实例,特别强化了小尺度标志及多角度拍摄样本的覆盖度。

4.2 评价指标

在基于改进 YOLOv8 的交通标志检测算法实验中,采用了平均精度均值(mean average precision, mAP),每秒传输帧数(frames per second, FPS)及参数量(Parameters)作为评价指标。mAP 相关表达式如式(15)~式(18)所示:

$$AP = \int_0^1 PdR \quad (15)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (16)$$

$$Precision = \frac{TP}{TP + FP} \quad (17)$$

$$Recall = \frac{TP}{TP + FN} \quad (18)$$

其中,TP 为正样本被正确分类为正样本的数量,FP 为负样本被错误分类为正样本的数量,FN 为正样本被错误分类为负样本的数量。

4.3 对比实验

为验证算法的性能,本文选取当前不同算法在 TT100K 和 CCTSDB-2021 数据集上进行实验对比,实验结果如表 2 所示。

Table 2 Comparison results of performance indicators of the algorithms

表 2 算法性能指标对比结果

模型	TT100K				CCTSDB-2021			
	mAP@0.5/%	mAP@0.5:0.95/%	FPS	Param/MB	mAP@0.5/%	mAP@0.5:0.95/%	FPS	Param/MB
Faster R-CNN	72.7	53.7	42.4	28.326	90.6	69.3	37.4	28.326
YOLOv5n	73.9	55.8	113.3	2.664	89.3	68.5	103	2.664
YOLOv6n	68.2	50.7	121.4	4.248	89.2	72.5	109.6	4.248
YOLOv7-tiny	53.5	35.9	60.8	6.051	88.9	70.1	53	6.051
YOLOv8n	75.2	56.3	115.8	3.022	91.3	76.3	106.2	3.022
改进算法	81.1	63.2	113	3.045	94.4	78.2	105	3.044

分析表 2 数据可知,在 TT100K 基准测试集上,本文改进算法的 mAP@0.5 和 mAP@0.5:0.95 的精度均值分别为 81.1% 和 63.2%,同时,保持了 113 FPS 的实时检测速度和 3.045M 的轻量化参数量。尽管该指标未达全局最优,但在精度提升幅度(较 YOLOv8n 提升 5.9% 和 6.9%)与模型效率之间实现了更优平衡,验证了算法在复杂场景中的实用价值。在 CCTSDB-2021 数据集上的 mAP@0.5 和 mAP@

0.5:0.95 精度均值分别达到 94.4% 及 78.2%,对应 FPS 为 105,参数量 3.044MB,进一步证明了其在不同交通场景中的泛化能力和实时检测优势。

为定量评估 FasterNet-EMA 注意力机制对交通标志检测性能的影响,本文选取 SGE^[28]、CA^[29]、CBAM^[30]和 LSK 这 4 种主流注意力模块,在 TT100K 数据集上开展对比分析,实验结果如表 3 所示。

Table 3 Performance comparison of attention mechanisms

表 3 注意力机制性能指标对比

注意力机制	Precision/%	Recall/%	mAP@0.5/%	mAP@0.5: 0.95/%	FPS
SGE	76.2	66.3	74.8	56.6	107.3
CA	74.6	66.4	73.5	55.2	108.4
CBAM	76.4	68.4	75.4	56.7	105.1
LSK	74	67.2	74.2	56	106.2
FasterNet-EMA	78.8	67.9	76.6	57.5	109.9

实验结果表明,FasterNet-EMA 注意力机制在精确度(78.8%)和mAP@0.5(76.6%)两项核心指标上均达到最优,较次优的CBAM模块分别提升2.4%和1.2%。此外,该模块在保持高精度检测的同时,仍能达到109.9 FPS的实时处理速度,较CA模块提升1.5 FPS,表明其通过优化特征聚焦机制,在检测精度与推理速度之间实现了更优的平衡。

4.4 消融实验

为验证本文所提出的模块对算法改进的效果,选取TT100K和CCTSDb-2021两个数据集进行消融实验,用“*”表示添加模块。在原YOLOv8n模型上分阶段集成各改进模块,H1为原始网络,H5为完整改进算法,实验结果如表4所示。

由表4可知,以模型H1为基准,仅引入FasterNet-EMA通道注意力机制(H2)时,模型在TT100K和CCTSDb-2021的精度分别提升6.0%和2.7%,但FPS下降3.4~6.7。这表明注意力机制通过动态校准通道特征显著增强了目标识别能力,但需额外计算资源维持精度增益。SPD_Conv与

Table 4 Ablation experiments

表 4 消融实验

	SPD_Conv	FasterNet- EMA	MPDIoU	TT100K		CCTSDb-2021	
				mAP@ 0.5/%	FPS	mAP@ 0.5/%	FPS
H1				75.2	115.8	91.3	106.2
H2		*		81.2	112.4	94	99.5
H3	*		*	81	113.3	93.7	105.1
H4		*	*	76.1	107.8	92.2	109.8
H5	*	*	*	82.5	109.9	94.9	111.3

MPDIoU的耦合(H3)在增强多尺度特征融合与边界框优化的同时,对效率影响较小(TT100K FPS下降2.5,CCTSDb-2021仅下降1.1),验证了特征增强与损失优化的互补性。当FasterNet-EMA与MPDIoU直接耦合(H4)时,TT100K精度下降0.1%,FPS下降8.0,表明未引入多尺度特征增强时,注意力机制与动态IoU损失的耦合可能引发特征竞争,导致模型收敛困难。在集成所有模块(H5)时,模型在TT100K和CCTSDb-2021的精度分别提升7.3%和3.6%,同时保持实时性(TT100K 109.9 FPS,CCTSDb-2021 111.3 FPS),此结果验证了改进方法的有效性。

YOLOv8n和改进模型在数据集CCTSDb-2021中训练的收敛曲线如图7和图8所示。改进模型相比YOLOv8n基础模型,损失值能够更快地趋近于最小值并保持稳定,意味着模型在训练过程中能更高效地学习数据特征,减少了不必要的迭代计算。同时,改进后的模型对于新数据的预测更加精准、稳定,能够迅速给出可靠结果,极大地提升了模型的实用性与可靠性。




Fig. 7 Convergence curve of YOLOv8n on the CCTSDb-2021 dataset

图 7 YOLOv8n在CCTSDb-2021数据集上的收敛曲线

4.5 实验结果展示

为了更直观地评价本文模型与原YOLOv8n模型的准确性,图9和图10分别展示了其在TT100K和CCTSDb-2021数据测试集上的可视化效果对比图。

图9展示了典型小目标检测场景。从中可以清晰看出,在远距离交通标志检测任务中,YOLOv8n算法存在明

显的置信度衰减问题,其检测结果的置信度值分别低至0.66和0.51。而本文算法增强了对小目标及细微差异的识别能力,能够更精准地捕捉远距离交通标志的细节特征,显著提升了检测置信度(平均从原来的0.66和0.51提高至0.79)。统计结果表明,本文算法能够增强对目标区域的关注能力,有效避免背景干扰对检测结果造成的不良




Fig. 8 Convergence curve of the improved model on the CCTSDB-2021 dataset

图 8 改进模型在 CCTSDB-2021 数据集上的收敛曲线



Fig. 9 Experimental results of the TT100K dataset

图 9 TT100K 数据集实验结果

影响,在低像素目标检测中具有显著优势。

图 10 展示了复杂场景下的交通标志检测效果对比,并重点关注了不同类别标志的检测置信度。对于禁止类标志,本文算法置信度达到了 0.93,相较于 YOLOv8n 算法

提升了 0.04;在警告标志密集场景,由第二组对比图可看出双目标置信度均为 0.91,较基准模型分别提升了 0.41 和 0.08。实验表明,本文算法通过空间注意力机制有效增强了复杂场景下的类别间判别能力,目标定位更加精准,从




Fig. 10 Experimental results of the CCTSDB-2021 dataset

图 10 CCTSDB-2021 数据集实验结果

而在多目标场景下显著降低了误检率。

5 结语

本文提出了一种基于YOLOv8架构优化的交通标志检测算法。通过引入多尺度注意力模块和优化的损失函数,在TT100K和CCTSDB-2021数据集上实现了检测精度与推理速度更优的平衡。消融实验结果表明,在2种数据集的mAP@0.5指标分别达到82.5%和94.9%,较原始YOLOv8n模型分别提升7.3%和3.6%,验证了改进策略的有效性。可视化分析进一步表明,本文算法在处理小目标和复杂场景等情况下展现出更强的鲁棒性,边界框定位精度和类别置信度均显著提升。在模型效率优化方面,提出了一种EMA模块,该模块通过稀疏卷积策略提高了目标检测效率,但其通道分组机制可能在一定程度上削弱了多尺度特征交互的完整性,尤其在密集小目标场景下存在细节丢失的风险。未来研究将进一步改善动态稀疏卷积与跨尺度特征补偿机制,优化EMA模块,并引入知识蒸馏与多模态数据增强技术,进而提升算法在低光照、极端天气等低资源场景下的泛化性能。

参考文献:

[1] XU X. Research on road traffic sign detection and recognition method

based on YOLOv5[D]. Shiyang: Hubei Automotive Industries College, 2023.
徐鑫. 基于YOLOv5的道路交通标志检测与识别方法研究[D]. 十堰: 湖北汽车工业学院, 2023.

- [2] LUO L, XIE Z K. Traffic sign detection algorithm based on improved YOLOv8[J]. Mechanical and Electrical Engineering Technology, 2024, 53(3): 205-210.
罗磊, 谢竹远. 基于改进YOLOv8的交通标志检测算法[J]. 机电工程技术, 2024, 53(3): 205-210.
- [3] LI W J, ZHANG G, CUI L, et al. Traffic sign recognition based on improved YOLO algorithm [J]. Computer Simulation, 2023, 40(1): 149-155.
李文举, 张干, 崔柳, 等. 基于改进的YOLO算法的交通标志识别[J]. 计算机仿真, 2023, 40(1): 149-155.
- [4] CAO L, KANG S B. Lightweight traffic sign recognition algorithm based on FMS-YOLOv5s [J]. Foreign Electronic Measurement Technology, 2024, 43(5): 179-189.
曹立, 康少波. 基于FMS-YOLOv5s的轻量化交通标志识别算法[J]. 国外电子测量技术, 2024, 43(5): 179-189.
- [5] YU R W, ZHANG Y X, CAO S M, et al. Traffic sign detection method based on improved YOLOv8 model[J]. Journal of Wuhan University (Natural Science Edition), 2024, 45(3): 1-10.
余荣威, 张逸轩, 曹书明, 等. 基于改进YOLOv8模型的交通标志检测方法[J]. 武汉大学学报(理学版), 2024, 45(3): 1-10.
- [6] LUO Y, CI Y, ZHANG H, et al. A YOLOv8-CE-based real-time traffic sign detection and identification method for autonomous vehicles[J]. Digital Transportation and Safety, 2024, 3(3): 82-90.
- [7] SUN M, TIAN Y. Research on traffic sign object detection algorithm

- based on deep learning[J]. Engineering Letters, 2024, 32(8): 1234–1242.
- [8] KANDASAMY K, NATARAJAN Y, PREETHAA K R S, et al. A robust trafficsignet algorithm for enhanced traffic sign recognition in autonomous vehicles under varying light conditions[J]. Neural Processing Letters, 2024, 56(5): 123–135.
- [9] CHU J, ZHANG C, YAN M, et al. TRD-YOLO: a real-time, high-performance small traffic sign detection algorithm[J]. Sensors (Basel, Switzerland), 2023, 23(12): 4567–4580.
- [10] LEI X M, LI C. Vehicle target detection with a bidirectional feature-weighted fusion of the dual-attention mechanism[J]. Computer Application Digest, 2024, 40(11): 76–83.
雷雪梅,李琛. 双注意力机制与双向特征加权融合的车辆目标检测[J]. 计算机应用文摘, 2024, 40(11): 76–83.
- [11] ZHAO C. Research on improvement of traffic sign detection algorithm based on YOLOv8 technology[D]. Guilin: Guilin University of Technology, 2024.
赵聪. 基于YOLOv8技术的交通标志检测算法改进研究[D]. 桂林: 桂林理工大学, 2024.
- [12] WANG H, ZHANG Q M, GONG D C. Traffic sign small target detection algorithm in complex scenes[J]. Electronic Measurement Technology, 2025, 48(2): 158–169.
王浩,张其猛,龚德成. 复杂场景下的交通标志小目标检测算法[J]. 电子测量技术, 2025, 48(2): 158–169.
- [13] YAN S Y, LUO S Y. Research on traffic sign detection algorithm based on SC-YOLOv8[J]. Electronic Measurement Technology, 2024, 47(15): 117–124.
闫世洋,罗素云. 基于SC-YOLOv8的交通标志检测算法研究[J]. 电子测量技术, 2024, 47(15): 117–124.
- [14] LUO L. Research on traffic sign detection algorithm based on YOLOv8n[D]. Nanchang: Jiangxi University of Science and Technology, 2023.
罗磊. 基于YOLOv8n的交通标志检测算法研究[D]. 南昌: 江西理工大学, 2023.
- [15] LI W J, ZHANG G, CUI L, et al. Lightweight traffic sign recognition model based on coordinate attention[J]. Journal of Computer Applications, 2023, 43(2): 7–14.
李文举,张干,崔柳,等. 基于坐标注意力的轻量级交通标志识别模型[J]. 计算机应用, 2023, 43(2): 7–14.
- [16] CAO J F, ZHANG X L, YAN K, et al. Panoramic image traffic sign recognition algorithm based on geometric perspective image preprocessing and CNN[J]. Computer Applications and Software, 2024, 41(7): 171–176.
曹峻凡,张向利,闫坤,等. 基于几何透视图像预处理和CNN的全景图像交通标志识别算法[J]. 计算机应用与软件, 2024, 41(7): 171–176.
- [17] LI R, CHEN Y, WANG Y, et al. YOLO-TSF: a small traffic sign detection algorithm for foggy road scenes[J]. Electronics, 2024, 13(18): 1234–1245.
- [18] ZHANG X, TIAN Y. Traffic sign detection algorithm based on improved YOLOv8s[J]. Engineering Letters, 2024, 32(1): 123–130.
- [19] YIN J H, QU S J, YAO Z K, et al. Traffic sign recognition model in haze weather based on YOLOv5[J]. Journal of Computer Applications, 2022, 42(9): 1234–1242.
尹靖涵,瞿绍军,姚泽楷,等. 基于YOLOv5的雾霾天气下交通标志识别模型[J]. 计算机应用, 2022, 42(9): 1234–1242.
- [20] HAN S, ZHU L Z. Traffic sign detection based on attention mechanism and feature fusion[J]. Information Technology and Informatization, 2024(9): 5–8.
韩姗,朱立忠. 基于注意力机制和特征融合的交通标志检测[J]. 信息技术与信息化, 2024(9): 5–8.
- [21] ZHOU F, LIU Y X, SHI Y J. Traffic sign recognition model combining convolution and self-attention mechanism[J]. Computer Simulation, 2023, 40(9): 140–145.
周峰,刘云翔,石艳娇. 结合卷积和自注意力机制的交通标志识别模型[J]. 计算机仿真, 2023, 40(9): 140–145.
- [22] YU X, JIN S S, YANG L. An improved multi-scale feature fusion traffic sign recognition algorithm[J]. Telecommunication Engineering, 2024, 64(7): 123–130.
余翔,靳闪闪,杨路. 一种改进多尺度特征融合的交通标志识别算法[J]. 电讯技术, 2024, 64(7): 123–130.
- [23] ZHAO H P, CAO J S, PAN D J, et al. Improved YOLOv8 algorithm for small target traffic sign detection[J]. Modern Electronics Technique, 2024, 47(20): 123–130.
赵会鹏,曹景胜,潘迪敬,等. 改进YOLOv8算法的交通标志小目标检测[J]. 现代电子技术, 2024, 47(20): 123–130.
- [24] SONG J J, ZHANG Z L. Small target traffic sign detection algorithm based on YOLOv8n[J]. Science Technology and Engineering, 2024, 24(36): 15548–15557.
宋京京,张振利. 基于YOLOv8n的小目标交通标志检测算法[J]. 科学技术与工程, 2024, 24(36): 15548–15557.
- [25] TIAN P, MAO L. Improved YOLOv8 road traffic sign target detection algorithm[J]. Computer Engineering and Applications, 2024, 60(8): 202–212.
田鹏,毛力. 改进YOLOv8的道路交通标志目标检测算法[J]. 计算机工程与应用, 2024, 60(8): 202–212.
- [26] WANG B, XU H H, SUN D C, et al. Small target traffic sign detection based on improved YOLOv8 algorithm[J]. Journal of Computer Applications, 2024, 44(S2): 274–279.
王斌,徐洪华,孙兜成,等. 基于YOLOv8算法改进的小目标交通标志检测[J]. 计算机应用, 2024, 44(S2): 274–279.
- [27] ZHANG J Q, LI C, LI X L. Traffic sign detection algorithm based on improved YOLOv8s[J]. Computer Knowledge and Technology, 2024, 20(30): 31–34.
张京洪,李超,李晓磊. 基于改进YOLOv8s的交通标志检测算法[J]. 电脑知识与技术, 2024, 20(30): 31–34.
- [28] LI X, HU X, YANG J. Spatial group-wise enhance: improving semantic feature learning in convolutional networks[DB/OL]. <https://arxiv.org/abs/1905.09646>.
- [29] SONG J J, WU Z F. Research on traffic sign detection based on YOLOv8n[J]. Internet of Things Technology, 2025, 15(4): 21–24, 28.
宋京京,吴章福. 基于YOLOv8n的交通标志检测研究[J]. 物联网技术, 2025, 15(4): 21–24, 28.
- [30] QU L G, ZHANG X, LU Z B, et al. Traffic sign recognition method based on improved YOLOv5[J]. Optoelectronic Engineering, 2024, 51(6): 25–38.
曲立国,张鑫,卢自宝,等. 基于改进YOLOv5的交通标志识别方法[J]. 光电工程, 2024, 51(6): 25–38.

(责任编辑:陈维捷)