

基于改进的小目标交通标志检测算法研究^{*}

韩东旭 谢雨飞

(北京建筑大学智能科学与技术学院 北京 102616)

摘要: 为了解决交通标志小目标检测所存在的漏检、误检和准确率低等问题,本文提出了一种小目标交通标志检测模型 YOLOv8-Faster-Ghost-GAM。该算法首先在主干网络的最后一个 C2f 模块中引入了全局注意力机制(GAM),增强关键特征并抑制无关信息,显著提升了目标检测中的小目标和复杂场景下的识别能力;其次,将主干网络中的每个 C2f 模块替换为 Fasternet,以减少模型参数量,并将普通卷积替换为幻影卷积 Ghost,使用低廉的线性变换较少计算量;最后,采用 WiOU 损失函数,有效提升对低质量样本的识别,精度提升了 1.6%,召回率提升了 3.2%,证明了所作的改进的有效性。

关键词: FasterNet;GAM;小目标交通标志检测;YOLOv8;Ghost;WiOU

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 improved small target traffic sign detection algorithm

Han Dongxu Xie Yufei

(School of Intelligent Science and Technology, Beijing University of Civil Engineering and Architecture, Beijing 102616, China)

Abstract: In order to address the issues of missed detections, false positives, and low accuracy in small traffic sign detection, this paper proposes a detection model for small traffic signs, named YOLOv8-Faster-Ghost-GAM. The algorithm introduces a global attention mechanism (GAM) into the last C2f module of the backbone network, enhancing key features and suppressing irrelevant information to significantly improve the detection of small targets and the recognition capability in complex scenarios. Additionally, each C2f module in the backbone network is replaced with FasterNet to reduce the number of model parameters, and standard convolutions are replaced with Ghost convolutions, which use inexpensive linear transformations to reduce computational effort. Finally, the WiOU loss function is employed to effectively improve the recognition of low-quality samples, resulting in a 1.6% increase in precision and a 3.2% increase in recall, thereby demonstrating the effectiveness of the proposed improvements.

Keywords: FasterNet;GAM;small target traffic sign detection;YOLOv8;Ghost;WiOU

0 引言

伴随着中国科技的飞速发展,智能驾驶领域的研究与应用也取得了显著突破^[1]。交通标志检测,作为智能驾驶的核心基础技术^[2],其重要性不言而喻。然而,交通标志图像通常由车载摄像头采集,小尺寸的标志在背景图像中所占比例微乎其微,加之数据分布不均、种类繁多,这些挑战使得检测系统难以实现准确而高效的识别,进而可能引发交通事故。为应对这一挑战,智能交通系统(intelligent transportation system, ITS)^[3]应运而生,推动了车辆驾驶和无人驾驶领域的交通管理智能化发展。ITS 不仅是未来交通的方向,更是一场颠覆传统的革命,助力在复杂的城市交通中,安全、顺畅地前行。

传统的交通标志检测技术依赖于手工提取特征,如颜色、形状和纹理等进行识别^[4-7]。随着硬件升级,深度学习在复杂场景下的交通标志检测性能远超传统算法,引发研究者聚焦于性能提升。

当前,交通标志检测算法的主流分为一阶段和两阶段两大类。一阶段算法在推理速度和模型轻量化方面表现出显著优势,尽管其识别精度仍有提升空间,典型的代表包括 YOLO 系列和 SSD 等。而二阶段算法,以 Faster R-CNN^[8]、R-CNN^[9]以及 Faster R-CNN^[10]等为代表,它们在检测精度上有着较好的表现。

文献[11]针对小目标检测难题,开发了三级交通标志检测器,结合 BlockNet 与 RPN-RCNN 网络,通过分阶段处

理实现高效检测,在 TT100K 数据集上达到高召回率与准确率,检测速度高达 102 fps。文献[12]针对 PVANet 在小目标检测上的局限,提出改进算法,在 TT100K 数据集上展现了优异性能和良好的实时性。文献[13]针对雾霾天气,提出基于 YOLOv5 的交通标志识别模型,通过卷积注意力机制、BiFPN 融合和 CIoU 损失函数优化,提升识别精度至 92.5%,实现实时检测。

文献[14]基于 YOLOv4 设计小目标检测网络,通过改进多尺度预测、集成 ASPP 和 PANet+ASFF 模块以增强信息保留和检测效率,并利用 K-means++ 调整尺寸实现模型轻量化,在均衡数据集上表现优异。文献[15]针对交通标志检测存在参数量大,精确度低,提出 SC-YOLOv8 的检测算法,替换下采样模块和 C2f 中的 Bottleneck,优化检测层,并改进损失函数。在 TT100K 数据集上验证,相比原 YOLOv8s 模型,精确率、召回率和 mAP50 分别提升 4.8%、6.7% 和 6.6%,参数量下降 61.5%,证明了改进的有效性。文献[16]改进 SSD 算法,采用 ResNest 和 RFB 模块,结合 Bi-FPN 和 K-means++,显著提升小交通标志检测精度。

文献[17]针对道路交通标志小目标检测问题,提出 Faster-YOLOv8 算法,在 TT100K 数据集上显著提高检测性能。文献[18]针对交通标志小目标检测的改进算法 FKDS-YOLOv8s,通过重构网络模块、设计新型检测头、引入动态上采样器和注意力机制等手段,显著提升了检测性能。文献[19]是一种高效的无人边防遮挡小目标检测 FDBYOLOv5 算法,通过优化网络结构和引入新模块,提升了检测精度和速度,减少了资源消耗,适用于复杂环境。文献[20]改进 YOLOv8s 算法,显著提升了复杂海洋遥感图像中小型船舶的检测精度,为船舶监控提供了高效的技术进步。在当前的研究中,针对 YOLO 算法的结构、注意力机制以及损失函数的优化,已取得显著成效。然而,如何在保持模型轻量化的同时,进一步提高检测准确率,这一平衡问题仍然是一个关键挑战。为此,深入探索轻量级网络与注意力机制的融合策略,以期在小目标交通标志检测领域实现性能的显著提升。通过这种创新结合,在确保模型高效运行的同时,增强对小目标的识别能力。

YOLOv5 通过整合众多优化策略,显著提升了检测交通标志的效能。然而,在图像特征及全局上下文信息的利用方面,仍存在一定的局限性。相比之下,YOLOv8 在头部结构上进行了创新性的改进,将原先的耦合头结构优化为解耦头结构,实现了分类与检测任务的分离,并从基于锚点(anchor-based)的检测方法转变为无锚点(anchor-free)技术。这些改进不仅进一步提升了模型的性能,也更加适应于实时场景的需求,使得 YOLOv8 在目标检测领域的表现更为卓越。

因此针对道路交通标志小目标检测的误检、漏检、准确率不足及复杂环境挑战,本文提出 YOLOv8-Faster-Ghost-

GAM 改进方法。本文工作如下:

1)该方法在主干网络 C2f 模块后嵌入全局注意力机制(global attention mechanism, GAM),增强特征交互,虽增加模型复杂度,但提升性能;

2)融合 FasterNet 减少计算和内存访问,采用 Ghost 卷积降低成本;

3)引入(weighted intersection over union, WIoU)损失函数提升低质量框识别,增强模型泛化性。实验结果显示,本方法在准确率和召回率上均有显著提高。

1 YOLOv8n 的网络架构

YOLOv8 作为一种高效的单阶段目标检测算法,以其迅速的识别与定位能力以及易部署性而著称。该算法包括 n、s、l、m 和 x 等多个版本。在这些版本中,YOLOv8n 以最少的参数量和最高的计算效率领先,但其平均检测精度略低。

当前最新的 YOLOv8 网络模型的改进有 Faster-YOLOv8、Ghost-YOLOv8、SC-YOLOv8 和基于 YOLOv8 模型改进等算法,在 YOLOv8 的不同变体中,Faster-YOLOv8 通过融合 C2f 与 Faster 优势、引入 EMA 注意力机制、设计小目标检测层以及采用 SioU 损失函数,实现了参数量的精简和性能的提升,但在复杂背景和遮挡下性能受限;Ghost-YOLOv8 利用 GhostConv 和 C2fGhost 模块,结合 GAM 注意力机制和小目标检测层,以及 GIoU 损失函数,优化了边缘设备的检测精度和参数量;SC-YOLOv8 通过 Adown、C2f_SC 模块和 Wise-MPDioU 损失函数,提升了精度和召回率,但实时性和遮挡处理能力有待提高;基于 YOLOv8 的改进模型通过注意尺度序列融合机制、小目标检测层、RT-DETR 检测头和 inner-mpdiou 损失函数,确保了实时性和精度,但面临数据集多样性和计算资源的需求;本文算法通过在主干引入 GAM 全局注意力机制、替换 C2f 模块为 FasterNet 和 Ghost 卷积替换普通卷积,以及采用 WIoU 损失函数,实现了精度和召回率的提升而参数量增加不多。对比来看,这些改进各有侧重,Faster-YOLOv8 和 Ghost-YOLOv8 更注重精度与效率的平衡,而 SC-YOLOv8 和本文算法则在提升检测性能的同时,努力降低模型复杂度。各改进版本的 YOLOv8 模型在相同的数据集 TT100K 下,选择的数据集有些许差别,均展现出了不同程度的性能提升;Faster-YOLOv8 实现了轻微的精度、召回率和 mAP50 提升;Ghost-YOLOv8 在精度和 mAP50 上取得了显著的提升,尤其在精度上提升近十个百分点;SC-YOLOv8 在精度、召回率和 mAP50 上均有中等程度的提升;基于 YOLOv8 的模型改进在 mAP50 上提升显著,并显著降低了模型大小;而本文算法则在精度、召回率和 mAP50-95 上实现了均衡的提升,显示出较为全面的性能优化。简而言之,各模型改进旨在优化性能和适应边缘设备,但各自在实时性、遮挡处理和数据集适应性上存在不同

的挑战。

YOLOv8 网络结构图如图 1 所示,由主干网络(Backbone)、颈部(Neck)和头部(Head)三部分组成的。

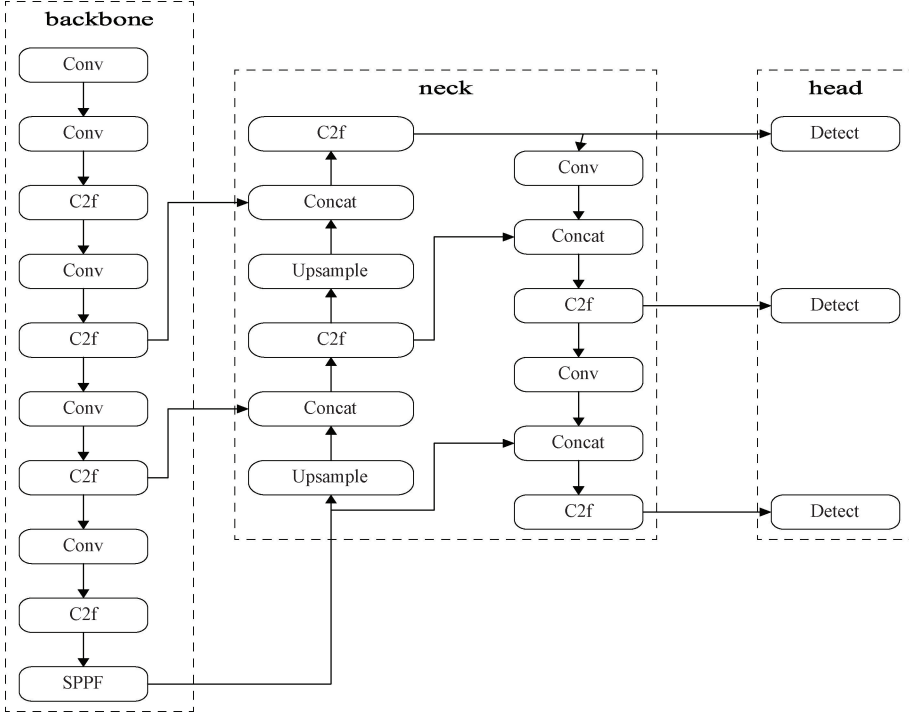


图 1 YOLOv8 网络架构
Fig. 1 YOLOv8 network architecture

2 改进后的网络模型

YOLOv8n 虽然检测速度快,但是对小目标检测效果并不尽人意,为了提高对小目标的检测精度,笔者提出了 YOLOv8-Faster-Ghost-GAM 网络模型,如图 2 所示。

图 2 中,主干部分增加了 GAM 注意力机制,用于增强图像的特征表达和提取能力,不可避免增加了模型的复杂度;引入 FasterNet 是为了减少模型的计算量;引入 Ghost 幻影卷积替换网络中的普通卷积,降低计算成本;引入 WiOU 替代 Ciou,提高模型在复杂情况下对检测的泛化性。

2.1 FasterNet 模块

为了降低模型的复杂度,提高交通标志检测的效率,本文作者采用了轻量级网络架构 FasterNet^[21]。该网络基于新提出的 PConv 卷积操作,通过同步减少冗余计算和内存访问,实现了对空间特征的更高效提取。FasterNet 的网络结构可分为 4 个层次,每一阶段均包含 FasterBlock 模块。在网络的后 3 层,分别是全局平均池化层、 1×1 卷积层以及全连接层,这些层次的设计旨在进行特征转换与分类任务。具体网络结构如图 3 所示。

为了全面利用各通道信息,每个 FasterBlock 均设计了一个精心构造的 PConv 层,其后紧跟两个 1×1 的卷积层。这种结构使得网络在特征提取过程中能够更加聚焦

Backbone 网络主要由 CBS、C2f 和 SPPF 模块构成。在 C2f 模块中,丰富的跳跃连接和额外的分割操作有助于增强背景图像特征信息的传递。

于输入特征图的中心区域,从而应对遮挡问题,并确保清晰特征的保留。此外,归一化层与激活层对于构建高效神经网络至关重要,但它们的过度使用可能会限制目标特征的丰富性,进而影响模型的检测能力,并可能导致计算效率的降低。PConv 和 FasterBlock 结构如图 4 和 5 所示。

假设输入特征图与输出特征图的尺寸是 $h \times w \times c$ 、 $h_1 \times w_1 \times c_1$,卷积核为 $k \times k$ 。采用浮点操作(floating-point operations, FLOPs)来计算模型复杂度,通常选择前段或者后端连续的 c_p 通道,计算复杂度为:

$$F_{SC} = h_1 \times w_1 \times c_1 \times c \times k^2 \quad (1)$$

$$F_{PC} = h_1 \times w_1 \times c_p^2 \times k^2 \quad (2)$$

式中: F_{SC} 代表 PConv; F_{PC} 代表普通卷积的计算复杂度。假设取 $c_p/c = 1/4$,则 PConv 的 FLOPs 仅为普通卷积的 $1/16$ 。进而可以计算内存访问量

$$G_{PC} = h_1 \times w_1 \times 2c_p + k^2 \times c_p^2 \quad (3)$$

同理,当 $c_p/c = 1/4$ 时,内存访问量也为普通卷积的 $1/16$ 。

因此采用 PConv 设计,具有多尺度特征融合能力,有助于处理小目标交通标志的多尺度信息,加速网络的训练及推理过程,提高网络性能。

2.2 GAM 注意力机制

GAM^[22] 全局注意力机制是基于全局观察和建模来提

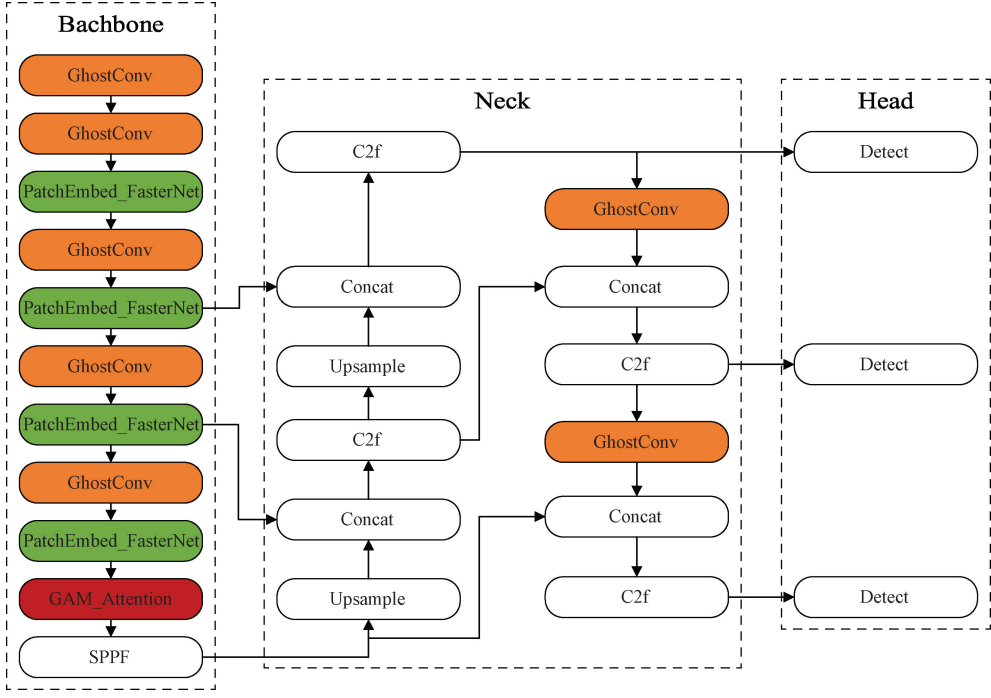


图 2 YOLOv8-Faster-Ghost-GAM 网络模型

Fig. 2 YOLOv8-Faster-Ghost-GAM network model

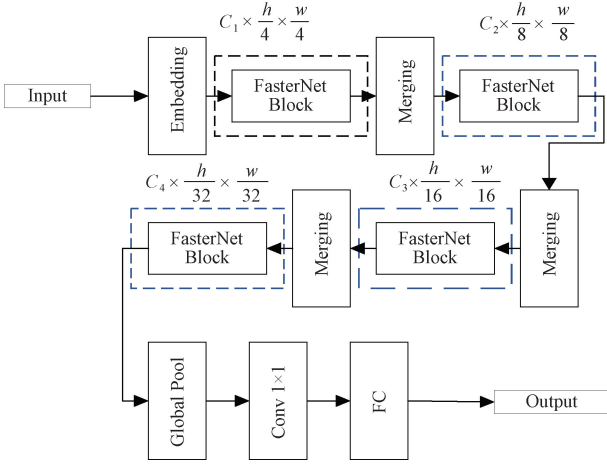


图 3 FasterNet 网络结构

Fig. 3 FasterNet network architecture

取背景图形特征的重要信息,用以增强不同通道之间与空间的交互作用,GAM 注意力如图 6 所示,给定输入特征图(F_1)、中间特征图(F_2)、输出特征图(F_3),输入特征图先与通道注意力图进行逐通道乘法运算,再与空间注意力图进行乘法运算。 M_c 表示通道注意力图, M_s 表示空间注意力图, \otimes 表示级联。

$$\begin{aligned} F_2 &= M_c(F_1) \otimes F_1 \\ F_3 &= M_s(F_2) \otimes F_2 \end{aligned} \quad (4)$$

通道注意力子模块在 3 个维度 $C \times H \times W$ 上使用 3D 置换方式得到存储信息,其次使用多层感知机 (multilayer

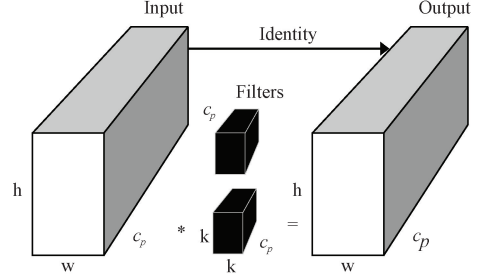


图 4 PConv 网络结构

Fig. 4 PConv network architecture

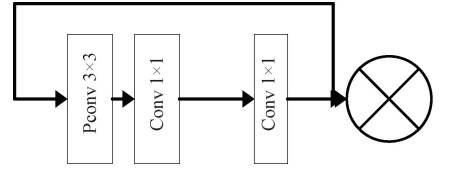


图 5 FasterBlock 网络结构

Fig. 5 FasterBlock network structures

perceptron, MLP) 用以提高通道与空间之间的联系,如图 7 所示。

空间注意力子模块对输入图的空间信息融合采用了两个 7×7 Conv 的卷积,模块使用相同的缩小比率,如图 8 所示。

2.3 GhostNet 模块

GhostNet^[23] 是主流的轻量级网络,引入新式卷积 GhostConv 来替代普通卷积,前提保证输出特征图的尺寸

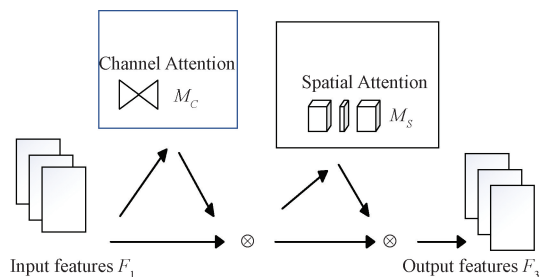


图 6 GAM 注意力

Fig. 6 GAM attention

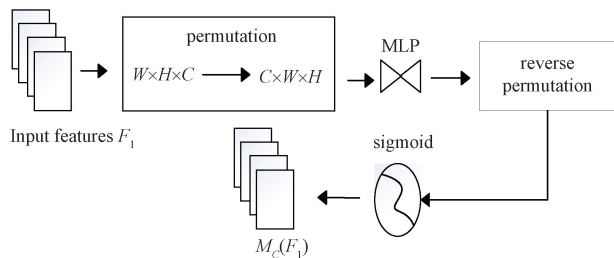


图 7 通道注意力子模块

Fig. 7 Channel attention submodule

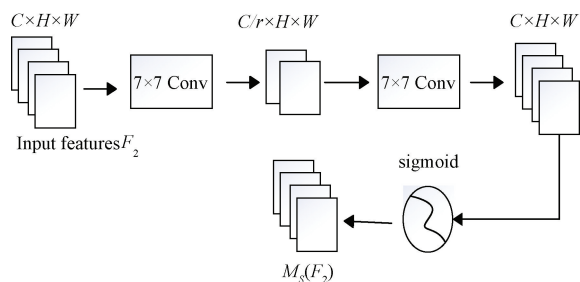


图 8 空间注意力子模块

Fig. 8 Spatial attention submodule

与通道数保持不变,能够有效减少计算量和参数量。旨在通过廉价操作生成更多的特征图,经过一系列线性变换,使用卷积核和低成本计算获取从原始特征提取的特征图,最终合并起来,如图 9 所示。

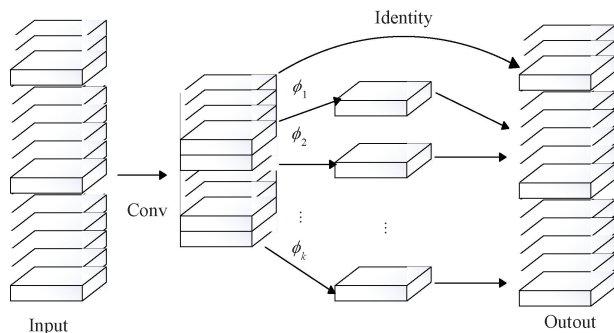


图 9 GhostNet 模块网络

Fig. 9 GhostNet module network

Ghost Bottleneck 的设计巧妙而高效,首先通过幻影卷积层巧妙地衍生出两个特征图。紧接着,这两个特征图由批量归一化(batch normalization, BN)和 SiLU 激活函数的处理,进一步提炼和增强了特征的表达能力。随后,第 2 个幻影卷积层对这些经过处理的特征图进行操作,以细化特征信息。

最终,通过加法操作,将所有处理过的特征图融合为一,得到了最终的输出特征图,为网络的深度学习任务提供了精准的特征表示。

2.4 WiOU^[24]边界框损失函数

损失函数在目标检测具有重大意义,精确的边界框损失函数可以增强模型的性能。YOLOv8 原模型采用的是距离与长宽比(complete intersection over union, CIOU)等几何因素,会造成模型的泛化性降低。目前主流的损失函数被广泛应用于 YOLOv8 的改进中。(enhanced intersection over union, EIOU)计算量较大,减少推理速度;(scale-invariant intersection over union, SIOU)增强计算复杂度及超参数调节;Focal loss 容易忽视样本的学习。基于此采用 Wise-IoU(WiOU)动态非单调的机制作为损失函数,设计一种合理的梯度增益分配,减少了极端样本中出现大梯度或有害梯度,该损失函数过多关注普通样本的质量,进而提高网络模型的泛化性和整体性能。WiOU 的计算公式如下:

$$L_{WiOUv1} = R_{WiOU} \times L_{IoU} L_{WiOUv1} = R_{WiOU} \times L_{IoU} \quad (5)$$

$$R_{WiOU} = \exp \left\{ \frac{(a - a_{gt})^2 + (b - b_{gt})^2}{(W_{\min}^2 + H_{\min}^2)} \right\} \quad (6)$$

$$L_{IoU} = 1 - IoU \quad (7)$$

式中: L_{IoU} 为交并比,模型预测和实际目标的重叠程度; R_{WiOU} 为放大倍数; W_{\min} 、 H_{\min} 为最小的封闭框宽与高;图像的横纵左边 a 、 b 代表图像像素点;中心横纵坐标 a_{gt} 、 b_{gt} 。

改进后的模型将采用 WiOU 替代 CiOU,能够增强对低质量框的识别能力,进而提升交通标志的准确率以及模型的泛化性。

3 实验结果与分析

3.1 TT100K 数据集

TT100K 图标是清华和腾讯联合在真实场景下公布的中国交通标志数据集,来自于中国多个城市街道全景图,包含不同光照以及特殊天气情况。本实验从中选取 28 类交通标志,共有 9 575 张图像,训练集为 6 714,验证集为 1 904,测试集为 957 张图像。

3.2 实验环境

操作系统为 Window11;硬件为 GPU 的 NVIDIA GEFORCE RTX4060;环境配置为 Python 3.9.19、Pytorch 2.4.1、CUDA v12.2 和 CUDNN v8.9.7。训练参数设置如表 1 所示。

表 1 训练参数
Table 1 Training parameters

参数名称	参数设置
image	640
epochs	100
Batch size	16
works	8
Lr0	0.01
optimizer	SGD

3.3 评价指标

为了衡量目标检测模型对交通标志的准确率,采用以下指标来评估模型性能精度(precision, P)、召回率(recall, R)、与 IOU 为 0.5、0.50~0.90 时的平均精度均值(mean

average precision, mAP)来进行评价。相应计算公式如下:

$$P = \frac{TP}{TP + FP}$$
 (8)

$$R = \frac{TP}{TP + FN}$$
 (9)

$$mAP = \frac{1}{n} \sum_{i=1}^N AP_i = \frac{1}{n} \sum_{i=1}^N \int P dR$$
 (10)

式中:TP 为检测正确目标数量;FP 为检测错误目标数量;FN 为漏检目标数量;AP 指平均精度,积分下的面积;N 为类别数量。

3.4 消融实验

为了验证本文算法改进的有效性,在相同的硬件以及模型参数相同的条件下,消融实验结果如表 2 所示。

表 2 消融实验结果对比
Table 2 Comparison of ablation study results

实验	GAM	FasterNet	Ghost	WiOU	Precision/%	Recall/%	mAP50/%	mAP50-95/%	FPS
1					84.0	72.3	81.6	61.5	279.97
2	✓				90.2	76.6	85.6	67.8	61.33
3		✓			65.8	58.7	63.9	47.5	392.34
4			✓		80.1	73.0	79.2	63.1	299.58
5				✓	83.0	74.3	80.5	63.0	250.32
6	✓	✓			87.2	74.3	82.6	65.4	225.45
7	✓	✓	✓		86.3	71.5	80.2	62.0	253.56
8	✓	✓	✓	✓	85.6	75.5	79.5	62.8	150.84

经过对实验 1 与 2 的对比分析,在主干网络的最后一个 C2f 模块中引入全局注意力机制(GAM)以替代原有结构,显著提升了模型的性能,准确率提高了 6.2%,召回率提升了 4.3%,mAP50 增长了 4%,mAP50-95 更是提升了 6.3%。然而,这也伴随着网络深度的增加,导致模型复杂度上升。鉴于此,开展了实验 3,通过与实验 1 的对比发现,采用 FasterNet 轻量级网络替换 C2f 模块,旨在降低计算负担,尽管如此,各项评价指标均有所回落。进一步对比实验 1 与 4 的结果,发现召回率小幅提升了 0.7%,mAP50-95 增长了 1.6%。实验 1 与 5 的对比显示,召回率大约提升了 2%,mAP50-95 提升了 1.5%。实验 7 与 1 的对比,我精度有了明显的提升,增长了 2.3%,而 mAP50-95 也呈现出良好的增长趋势,增加了 0.5%。这一结果表明,在实验 7 中对模型的优化策略取得了积极的成效,使得模型在识别准确性和综合性能方面均有所提高。实验 8 与 1 的对比更为亮眼。精确度提升了 1.6%,召回率增长了 3.2%,而 mAP50-95 更是实现了 1.3% 的增长。这些数据充分说明,实验 8 在保持模型高效运行的同时,进一步提高了识别的准确性和全面性,总体来看,这些实验成果为后续模型优化和算法改进提供了有力的依据。

上述实验所做的改进策略均是与 YOLOv8 原模型进行一系列优化策略的比较与分析。虽然各项指标的变化看似无规律可循,但实际上每一次改进都具有一定的积极意义。

首先,引入了 GAM 全局注意力机制,这一策略显著提升了检测精度,尽管模型复杂度有所增加,但这一改进无疑为后续工作奠定了坚实基础。随后,为了平衡计算量与性能,采用了轻量级网络 FasterNet 替换了主干部分的 C2f 模块,使得模型更加轻量化。尽管这一替换导致检测精度有所下降,但为探索模型轻量化提供了宝贵经验。接着,采用幻影卷积 Ghost 替代了所有普通卷积,进一步降低了模型参数量,此外,引入 WiOU 损失函数,有效提升了小目标样本的识别能力,相较于其他损失函数,WiOU 在处理小目标检测、平衡正负样本以及提升模型收敛速度方面表现更为优异,从而增强了模型的鲁棒性。

虽然每种改进策略单独评价时,指标有升有降,但当这些策略综合起来时,发现模型的精度、召回率和 mAP50-95 均得到了显著提升。这充分说明,本次改进策略的整体效果是积极的,具有实际应用价值。因此,可以认为这些优化措施对于提升模型整体性能具有重要意义,能够有效完成道路交通标志的检测任务。

3.5 模型对比实验

为评估所提出改进模型的性能,本文将 YOLOv8-Faster-Ghost-GAM、Yolov5s、Yolov8-c2f-EMA、Yolov9t、Yolov10n 和当前最新优秀算法 (SC-YOLOv8、Ghost-YOLOv8^[25]、改进的 YOLOv5^[26]) 等模型进行了详细对比,具体结果展示如表 3 所示。

表 3 不同模型实验结果对比
Table 3 Comparison of experimental results between different models

名称	Precision/ %	Recall/ %	mAP50/ %	mAP50-95/ %	FPS
Yolov8	84.0	72.3	81.6	61.5	279.97
Yolov5s	81.9	70.9	78.1	57.9	178.16
Yolov8-c2f-EMA	81.0	62.7	73.4	55.9	255.05
Yolov9t	77.1	66.8	73.5	54.7	180.08
Yolov10n	78.8	69.1	75.5	57.2	294.12
SC-YOLOv8	82.0	65.3	76.1	59.1	252.03
Ghost-YOLOv8	76.9	67.9	75.5	56.9	189.32
改进的 YOLOv5	79.4	64.4	75.3	60.4	260.57
本文	85.6	75.5	79.5	62.8	150.84

实验结果明确显示,本文提出的算法在 TT100K 数据集上展现出卓越的性能,无论是在精度、召回率还是平均精度方面均具有显著优势。相较于原模型,改进后的模型在 Precision、Recall、mAP50-95 指标上分别实现了 1.6%、3.2%、1.3% 的提升,尽管 mAP50 略有下降,减少了 2.1%。

在与 Yolov5s、Yolov8-c2f-EMA、Yolov9t、Yolov10n 等模型的比较中,本文算法在精度上分别高出 3.7%、4.6%、8.5%、6.8%;在召回率上分别高出 4.6%、12.8%、8.7%、6.4%;在 mAP50 指标上,本文算法分别优于对比模型 1.4%、6.1%、6%、4%;而在 mAP50-90 指标上,分别提升了 4.9%、6.9%、8.1%、5.6%。综合这些数据,本文提出的模型相较于当前主流模型具有明显优势,有效验证了算法的先进性和有效性。

3.6 注意力机制对比实验

本文模型在当前主流注意力机制对比情况下,严格控制实验参数一致,实验结果如表 4 所示。

表 4 不同注意力机制对比
Table 4 Comparison of different attention mechanisms

名称	Precision/ %	Recall/ %	mAP50/ %
CBAM	83.7	65.7	75.9
GAM	90.2	76.6	85.6
ResBlock-CBAM	82.6	66.9	76.7
ECA	79.4	64.4	75.3

根据表 4 的数据分析,可以观察到全局注意力机制 (GAM)在本文所探讨的检测场景中表现出了卓越的性能。

GAM 不仅在精度、召回率获得显著提升,而且在 mAP50 这一综合评价指标上也实现了显著的进步。这一结果表明,GAM 能够更有效地捕捉图像中的关键信息,从而提高检测的准确性和全面性。

尽管 GAM 带来了显著的性能提升,但也注意到,这种提升并非没有代价。GAM 的引入确实增加了模型的计算负担。这意味着,在享受更高检测性能的同时,不得不面对计算资源消耗的增加。然而,从整体来看,GAM 所提供的性能优势在很大程度上弥补了其在计算效率上的不足。在实际应用中,这种权衡往往是可接受的,特别是在对检测精度有较高要求的场景下。

综上所述,全局注意力机制 GAM 在本文的研究背景下,无疑是一种有效的提升策略。它通过增强模型对全局特征的感知能力,显著提高了检测任务的性能。尽管伴随着计算量的增加,但其带来的性能提升对于许多应用场景来说,是值得这一代价的。

3.7 检测效果对比

为了细致评估改进算法的检测效能,本文从测试集中挑选的部分图片进行效果验证。如图 10 所示,这一系列测试结果清晰地展示了改进算法在目标检测领域的显著进步。特别是在小目标检测方面,改进算法展现出了精度的提升。

这一改进不仅增强了算法对细节的捕捉能力,也优化了其在复杂场景中的表现。通过这些测试图片,可以直观地看到,即使是尺寸较小、特征不明显的目标,也能被改进后的算法准确识别和定位。这一成果无疑为算法在实际应用中的广泛部署提供了更为坚实的性能保障。



图 10 检测效果对比图

Fig. 10 Detection performance comparison chart

4 结 论

针对小尺寸交通标志种类繁多、易发生漏检和误检,以及在恶劣天气条件下检测准确率较低的问题,本文构建了YOLOv8-Faster-Ghost-GAM模型。该模型不仅能够特殊天气条件下准确检测道路交通标志,而且显著提升了检测的准确率。实验结果亦证实,改进后的模型在确保准确率提高的同时,仅适度增加了模型的参数量,依然能够满足实时监测的需求。然而,仍有一些挑战需要进一步探究。实际应用中的特殊场景更为复杂多样,因此亟需构建一个更加全面和均衡的数据集;同时,应进一步关注夜间、遮挡和重叠情况下交通标志的检测问题。未来的工作将包括使用Tensorrt进行量化推理加速,以提升模型的推理速度,使其更加易于部署到嵌入式设备上,从而实现实时检测的目标。

参考文献

- [1] 王丙琛, 司怀伟, 谭国真. 基于深度强化学习的自动驾驶车控制算法研究[J]. 郑州大学学报(工学版), 2020, 41(4): 41-45.
- [2] 陈飞, 刘云鹏, 李思远. 复杂环境下的交通标志检测与

识别方法综述[J]. 计算机工程与应用, 2021, 57(16): 65-73.

CHEN F, LIU Y P, LI S Y. A review of traffic sign detection and recognition methods in complex environments [J]. Computer Engineering and Applications, 2021, 57(16): 65-73.

- [3] SHIVENDRA A, KUMARSWAMY S. Intelligent transportation system [J]. Perspectives in Science, 2016, 7(3): 304-311.
- [4] CHEN Y, XIE Y, WANG Y. Detection and recognition of traffic signs based on HSV vision model and shape features [J]. Computer, 2013, 8(5): 1366-1370.
- [5] 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.
- [6] ZHAO H, FENG Y B. Research on traffic sign detection based on CGS-Ghost YOLO[J]. Computer Engineering, 2023, 49(12): 194-204.
- [7] ZHANG J M, YE Z, JIN X K, et al. Real-time traffic sign detection based on multiscale attention and spatial information aggregator [J]. Journal of Real-Time Image Processing, 2022, 19(6): 1155-1167.
- [7] GAO E, HUANG W, SHI J, et al. Long-tailed traffic sign detection using attentive fusion and

- hierarchical group softmax[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 24105-24115.
- [8] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [9] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [10] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [11] SONG Y, FAN R, HUANG S, et al. A three-stage real-time detector for traffic signs in large panoramas[J]. Computational Visual Media, 2019, 5(4): 403-416.
- [12] 周苏, 支雪磊, 刘懂, 等. 基于卷积神经网络的小目标交通标志检测算法[J]. 同济大学学报(自然科学版), 2019, 47(11): 1626-1632.
- ZHOU S, ZHI X L, LIU D, et al. Small target traffic sign detection algorithm based on convolutional neural network[J]. Journal of Tongji University (Natural Science Edition), 2019, 47(11): 1626-1632.
- [13] 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 conditions based on YOLOv5 [J]. Electronic Measurement Technology, 2023, 46(8): 31-37.
- [14] 张福东. 基于深度学习的交通标志小目标检测与识别研究[D]. 天津: 天津理工大学, 2022.
- ZHANG F D. Research on small target detection and recognition of traffic signs based on deep learning[D]. Tianjin: Tianjin University of Technology, 2022.
- [15] 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.
- YAN SH Y, LUO S Y. Research on traffic sign detection algorithm based on SC-YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(15): 117-124.
- [16] 赵友章, 吕进. 基于改进 SSD 的交通标志检测算法[J]. 电子测量技术, 2023, 46(7): 151-158.
- ZHAO Y ZH, LYU J. Traffic sign detection algorithm based on improved SSD [J]. Electronic Measurement Technology, 2023, 46(7): 151-158.
- [17] 高良鹏, 赵博文, 简文良. 基于 Faster-YOLOv8 网络模型的车载交通标志检测算法研究[J]. 重庆交通大学学报(自然科学版), 2024, 43(8): 114-123.
- GAO L P, ZHAO B W, JIAN W L, et al. Study on vehicle-mounted traffic sign detection algorithm based on Faster-YOLOv8 network model [J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2024, 43(8): 114-123.
- [18] 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.
- WANG H, ZHANG Q M, GONG D CH. Traffic sign small target detection algorithms in complex scenes [J]. Electronic Measurement Technology, 2025, 48(2): 158-169.
- [19] 王慧云, 赵俊生, 王禹, 等. 面向无人边防的复杂环境遮挡小目标检测算法[J]. 电子测量技术, 2024, 47(21): 168-177.
- WANG H Y, ZHAO J SH, WANG Y, et al. Algorithms for detecting small targets occluded in complex environments for unmanned border defense[J]. Electronic Measurement Technology, 2024, 47(21): 168-177.
- [20] 朱圣博, 魏利胜, 高港, 等. 基于改进 YOLOv8s 的光学遥感小型船舶检测算法[J]. 电子测量与仪器学报, 2024, 38(10): 48-57.
- ZHU SH B, WEI L SH, GAO G, et al. An improved YOLOv8s-based algorithm for detecting small vessels in optical remote sensing[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 48-57.
- [21] CHEN J, KAO S H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural network[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada. IEEE, 2023: 12021-12031.
- [22] LIU Y C, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions[J]. ArXiv preprint arXiv: 2112.05561, 2021.
- [23] HAN K, WANG Y H, TIAN Q, et al. Ghostnet:

- More features from cheap operations[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA: IEEE, 2020: 1580-1589.
- [24] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [25] 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): 141-147.
- ZHAO H P, CAO J SH, PAN D J, et al. Improved small object detection of traffic signs using YOLOv8 algorithm[J]. Modern Electronic Technology, 2024, 47(20): 141-147.
- [26] 高翊轩,李昕,刘婧彤.改进 YOLOv5 的小目标交通标志检测方法[J]. 计算机工程与设计, 2024, 45(12): 3639-3647.
- GAO Y X, LI X, LIU J T, et al. Improve the small target traffic sign detection method for YOLOv5[J]. Computer Engineering and Design, 2024, 45(12): 3639-3647.

作者简介

韩东旭(通信作者),硕士研究生,主要研究方向为计算机视觉。

E-mail: 2857606507@qq.com

谢雨飞,副教授,硕士研究生导师,主要研究方向复杂系统建模与求解。

E-mail: xieyufei@bucea.edu.cn