

# 基于改进YOLOv8的恶劣天气交通标志检测算法

王启星, 洪智勇\*, 熊利平\*

五邑大学电子与信息工程学院, 广东 江门

收稿日期: 2026年3月22日; 录用日期: 2026年4月12日; 发布日期: 2026年4月24日

## 摘要

交通标志检测是自动驾驶环境感知系统的重要组成部分。针对恶劣天气条件下图像对比度降低、特征模糊和细节丢失导致的漏检、误检问题, 以及车载边缘平台对模型轻量化和实时性的要求, 本文提出了一种改进YOLOv8的恶劣天气交通标志检测算法。首先, 在骨干网络中引入GCConv模块, 以增强复杂场景下的特征提取能力; 其次, 在LSCD检测头的基础上改进设计SA-LSCD检测头, 以降低模型参数量和计算量并增强多尺度特征表达能力; 最后, 采用Focaler-PIoU2损失函数替代CIoU损失函数, 以提升小目标边界框回归精度。实验结果表明, 相比原始YOLOv8n, 改进模型的参数量由3.01 M降低至2.36 M, FLOPs由8.1 G降低至6.5 G, FPS由125提升至141, mAP50由81.7%提升至84.4%, mAP50-95由53.2%提升至55.6%。该方法在保持模型轻量化和实时性的同时, 有效提升了恶劣天气下交通标志检测的精度与鲁棒性。

## 关键词

YOLOv8, 恶劣天气, 交通标志检测, 轻量化

# Improved YOLOv8 for Traffic Sign Detection Algorithm in Adverse Weather Conditions

Qixing Wang, Zhiyong Hong\*, Liping Xiong\*

School of Electronics and Information Engineering, Wuyi University, Jiangmen Guangdong

Received: March 22, 2026; accepted: April 12, 2026; published: April 24, 2026

## Abstract

Traffic sign detection is an essential component of environmental perception systems for autonomous

\*通讯作者。

文章引用: 王启星, 洪智勇, 熊利平. 基于改进YOLOv8的恶劣天气交通标志检测算法[J]. 图像与信号处理, 2026, 15(2): 282-293. DOI: 10.12677/jisp.2026.152024

driving. To address the problems of missed detections and false detections caused by reduced image contrast, blurred features, and loss of detail under adverse weather conditions, as well as the requirements for lightweight design and real-time performance on vehicular edge platforms, this paper proposes an improved YOLOv8-based algorithm for traffic sign detection in adverse weather. First, the GCCConv module is introduced into the backbone network to enhance feature extraction capability in complex scenarios. Second, the SA-LSCD detection head is developed based on the LSCD head to reduce the number of model parameters and computational cost while strengthening multi-scale feature representation. Finally, the Focaler-PIoU2 loss function is adopted to replace the original CIoU loss so as to improve the bounding box regression accuracy for small targets. Experimental results show that, compared with the original YOLOv8n, the improved model reduces the number of parameters from 3.01 M to 2.36 M, the FLOPs from 8.1 G to 6.5 G, and increases the FPS from 125 to 141, while improving mAP50 from 81.7% to 84.4% and mAP50-95 from 53.2% to 55.6%. The proposed method effectively improves the accuracy and robustness of traffic sign detection in adverse weather while maintaining a lightweight model design and real-time performance.

## Keywords

YOLOv8, Adverse Weather Conditions, Traffic Sign Detection, Lightweight

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着人工智能的快速发展,无人驾驶技术正在日益受到人们的广泛关注。交通标志检测是无人驾驶系统中的关键任务之一,其结果直接影响车辆场景感知以及决策控制的准确性,关系到道路安全性。然而,恶劣天气条件(如雨、雪、雾霾等)会造成图像对比度降低、模糊遮挡和亮度失真等问题,使交通标志的视觉特征难以提取和判别,从而增加检测误检和漏检的风险[1]。因此,研究恶劣天气实现高精度与高速响应的交通标志检测方法具有重要意义。

传统的交通标志检测方法主要依赖颜色、形状、边缘等浅层视觉特征进行识别,这类方法在场景简单、光照稳定的环境下能够取得一定效果,但在复杂背景、尺度变化、遮挡干扰以及恶劣天气条件下,往往存在特征表达能力不足、鲁棒性较差和泛化能力有限等问题[2]。相比之下,基于深度学习的卷积神经网络目标检测算法能够通过多层特征提取自动学习更具判别性的语义信息,在交通标志识别任务中表现出更高的精度和更强的环境适应能力,尤其在雨、雾、雪等恶劣天气条件下具有更好的应用前景[3]。

基于深度学习的目标检测算法,按照检测流程的不同,主要可分为两阶段检测算法和单阶段检测算法。两阶段检测算法以 R-CNN [4]、Fast R-CNN [5]和 Faster R-CNN [6]为代表,这类方法通常先生成候选区域,再对候选区域进行分类与定位回归,因而具有较高的检测精度,但其推理过程相对复杂,检测速度较慢,难以满足车载场景对实时性的要求。相较而言,单阶段检测算法以 YOLO 系列[7]和 SSD [8]为代表,能够直接在整幅图像上完成密集预测,在检测速度方面具有显著优势,更适合实时交通标志检测任务。然而,单阶段检测器在实际应用中仍然存在一定局限,例如对小目标和模糊目标的特征表达不足,复杂天气条件下检测鲁棒性不强,以及依赖锚框机制和非极大值抑制所带来的定位误差与后处理开销等问题。

对于交通标志检测的小目标识别问题, Sun 等人[9]提出了 MDSF-YOLO 算法。该方法以 YOLOv11s 为基础, 引入多尺度序列融合(MSF)和膨胀残差(DWR)模块, 并增加 P2 解耦检测头, 以提升小尺度交通标志的特征融合、定位与识别能力。但该算法在引入多尺度融合和膨胀卷积后, 计算开销有所增加, 推理速度受到一定影响, 后续仍需进一步优化其实时性与部署效率。Chen 等人[10]提出了 YOLO-TS 算法, 通过感受野对齐、多尺度高分辨率特征融合和抗栅格感受野模块提升小目标及恶劣天气下的检测性能, 并构建了新的恶劣天气数据集; 但其对更多国家标志与更复杂动态场景的泛化能力仍需进一步验证。Qiu 等人[11]提出了 DP-YOLO 轻量化小目标检测算法。该方法以 YOLOv8s 为基础, 通过删除大目标检测层、增加小目标检测层, 并引入 DBBNCSPPELAN4、PTCSP 和 W3F\_MPDIoU 损失函数, 提升了小尺度交通标志检测精度并显著降低了参数量; 但其以牺牲部分大目标检测性能为代价, 且在嵌入式实时部署方面仍有进一步的优化空间。Farhat 等人[12]提出了 YOLOv8-TSR 算法。该方法以 YOLOv8 为基础, 通过引入 TSRF 轻量化多尺度卷积模块、EMA 机制下的 SPPFR 模块、小目标检测头、Transformer 预测头以及改进损失函数, 提升了复杂天气和多尺度场景下的交通标志识别精度与实时性; 但其在夜间或低可见度条件下仍存在检测困难, 且新增预测头会带来一定的计算与存储开销。

对于交通标志检测的轻量化问题, Wang 等人[13]提出一种基于改进 YOLOv8n 的交通标志检测方法, 通过 AFP、LW\_C2f 和 Wise-IoU 提升小目标检测精度并实现轻量化; 但其在雨雾等恶劣天气下的鲁棒性仍有不足。Chu 等人[14]提出了 Ghost-YOLO 轻量化检测框架。该方法以改进 YOLOv11s 为基础, 采用 GhostNetV3 替换主干网络并引入 DWConv 模块, 在保证检测精度的同时提升了实时性与轻量化水平; 但其在极端天气和光照变化等复杂场景下的鲁棒性仍有待进一步提高。Chen 等人[15]提出了 HCLT-YOLO 算法。该方法采用 CNN-轻量 Transformer 混合架构, 并引入 C-Repvit、DG-C2f、小目标检测层和 SIoU, 以提升复杂交通场景下尤其是小目标交通标志的检测精度与实时性; 但其引入 Transformer 和小目标检测层后计算复杂度仍有所增加, 且在低照度场景下仍存在漏检问题。Lin 等人[16]提出了 YOLO-LLTS 算法。该方法通过引入 HRFM-SOD、MFIA 和 PGFE 模块, 并构建 CNTSSS 夜间交通标志数据集, 以提升低光照环境下小目标交通标志的检测精度与实时性; 但其在极端低照度或缺少路灯照明的场景中仍存在漏检问题, 后续仍需进一步增强夜间复杂环境下的鲁棒性。

针对上述存在的问题, 本文提出了一种基于改进 YOLOv8 的恶劣天气交通标志检测模型, 以解决现有检测网络在复杂天气条件下存在的特征提取能力不足、小目标定位精度不高以及模型轻量化与检测性能难以兼顾等问题。主要研究内容如下:

1) 在骨干网络中引入 GCConv [17]模块, 对骨干网络各阶段的基础卷积层进行替换, 在不显著增加计算开销的前提下增强网络对交通标志关键特征的提取与表达能力, 从而提高模型对复杂背景、模糊目标及弱纹理目标的识别效果。

2) 针对原始检测头参数量较大、轻量化与检测性能难以兼顾的问题, 本文在 LSCD [18]轻量级共享卷积检测头的基础上, 面向恶劣天气条件下交通标志小目标检测任务, 对其进行了改进设计, 提出了 SA-LSCD 检测头。该检测头在保留共享卷积轻量化优势的同时, 增强了对多尺度特征和细粒度信息的表征能力, 从而实现了模型复杂度与检测精度的协调优化。

3) 采用由 Focaler-IoU [19]和 Powerful-IoU [20]改进构建的 Focaler-PIoU2 边界框损失函数替代原有 CIoU [21]损失函数, 以增强模型对小目标边界框回归的优化能力, 提高交通标志尤其是小尺度目标的检测精度。

## 2. YOLOv8 改进算法

YOLOv8 是 Ultralytics 提出的单阶段目标检测模型, 整体由输入端、主干网络、颈部网络和检测头组

成, 并提供 n、s、m、l、x 五种规模版本, 以满足不同算力场景的需求。

在输入阶段, YOLOv8 采用 Mosaic 数据增强[22], 并结合自适应缩放与填充策略, 以增强模型对复杂场景的鲁棒性。在主干网络中, C2f 模块替代了部分传统结构, 通过更高效的特征分流与融合, 强化浅层与深层信息的传递。同时, SPPF 模块采用多尺度池化以扩大感受野, 提高模型对不同尺寸目标的检测能力。在颈部网络中, YOLOv8 结合 FPN 与 PAN 架构, 对多层特征进行上采样、下采样及融合处理, 从而同时保留浅层特征的位置信息与深层特征的语义信息, 增强多尺度目标的检测能力。检测头采用解耦设计, 将分类任务与边界框回归任务分离, 以减少任务间干扰, 提高检测精度和训练效率。YOLOv8 还采用 Anchor-Free [23]机制, 降低了对锚框设计的依赖, 并简化了后处理流程。

为解决恶劣天气条件下的计算效率和检测精度问题, 本文在 YOLOv8 的基础上引入了 GCConv 模块、检测头 SA-LSCD 以及 Focaler-PIoU2 损失函数, 其网络结构如图 1 所示。

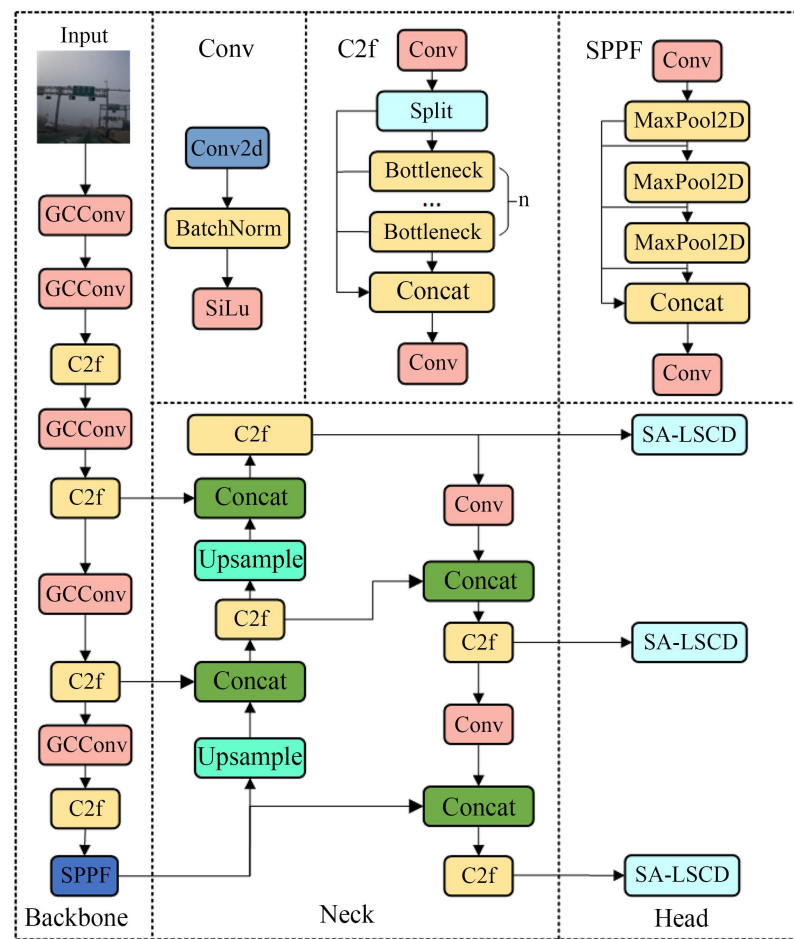


Figure 1. Network structure diagram of the improved YOLOv8 model

图 1. 改进 YOLOv8 网络结构图

## 2.1. GCConv

传统卷积由于结构简单, 在雨雾、强光、沙尘等恶劣天气下处理其图像时, 检测精度和速度容易受到影响。为此, 本文引入 GCConv 模块, 通过“训练时多路径、推理时单路径”的核心设计, 将其应用于主干特征提取网络, 强化特征表达能力, 结构如图 2 所示。

在训练阶段，GCCConv 首先采用多个  $3 \times 3$  卷积和  $1 \times 1$  卷积的两条并行路径来提取输入特征图的特征信息，其中  $3 \times 3$  卷积分支主要用于捕捉较大感受野的信息， $1 \times 1$  卷积分支负责压缩通道维度；当输入特征图的通道数与输出通道数相同时，残差路径打开，用于缓解梯度消失问题；最后将各个卷积分支的输出特征图通过逐元素相加进行融合，再通过 SiLU 激活函数进行非线性变换。

在推理阶段，GCCConv 模块通过结构重参数化[24]技术，将多路径卷积和批归一化参数整合为一个单一的  $3 \times 3$  卷积核。既保留了训练阶段多路径的特征提取精度，也消除了多分支计算的冗余。

这一优化使得 GCCConv 模块在不牺牲检测精度的前提下带来轻微速度增益。

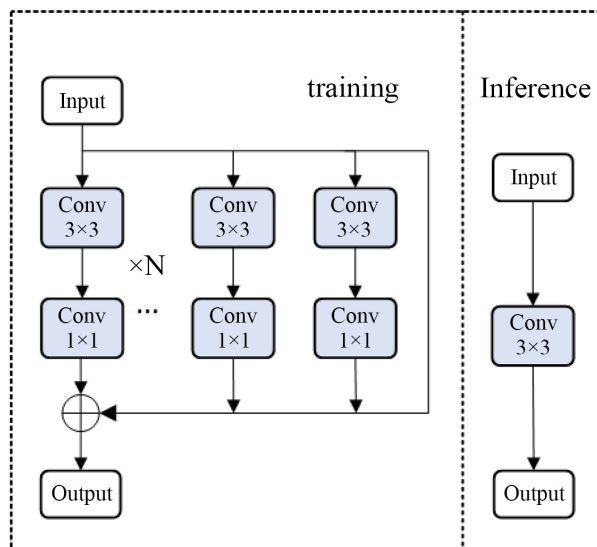


Figure 2. GCCConv network structure

图 2. GCCConv 网络结构

## 2.2. SA-LSCD

为降低检测头参数冗余与计算开销，同时提升不同尺度特征的表达适配性，本文设计了一种基于尺度门控的跨尺度参数共享型紧凑检测头(Scale-Aware Lightweight Shared Convolutional Detection Head, SA-LSCD)。该检测头在跨尺度参数共享的基础上，引入轻量级尺度门控校准单元，对不同尺度特征进行自适应调节，从而在保持检测头紧凑性的同时增强多尺度目标检测能力，其结构如图 3 所示。

从结构上看，SA-LSCD 采用多尺度特征统一映射、共享卷积提取和分类-回归解耦预测的整体框架。首先，来自不同检测层的特征图通过  $1 \times 1$  卷积完成通道对齐，并映射到同一隐藏维度；随后，通过共享的  $3 \times 3$  卷积模块进行特征提炼，以减少不同尺度检测头重复构建卷积层带来的参数开销。在此基础上，本文进一步在共享卷积输出之后引入尺度门控单元，利用当前尺度特征的全局上下文信息生成通道响应权重，对共享特征进行自适应校准，从而保留必要的尺度差异表达。

在预测阶段，SA-LSCD 仍采用分类分支与回归分支解耦的方式完成目标检测任务。其中，回归分支负责边界框位置预测，并结合尺度调节因子对不同特征层输出进行缩放；分类分支用于输出目标类别概率。由于尺度门控模块结构轻量，因此不会显著增加检测头的部署负担。

总体而言，SA-LSCD 一方面通过跨尺度共享卷积压缩了检测头参数数量和计算量，另一方面通过尺度门控机制提升了共享特征对不同尺度目标的适配能力，从而在轻量化条件下兼顾检测精度与部署效率。

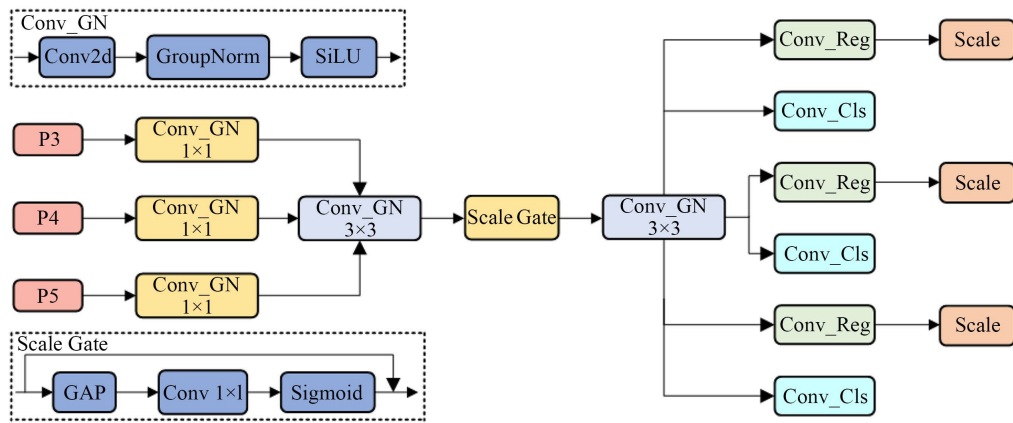


Figure 3. SA-LSCD network structure  
图 3. SA-LSCD 网络结构

### 2.3. Focaler-PIoU2 损失函数

边界框回归损失函数直接决定目标检测模型的定位精度，YOLOv8 模型默认的 CIoU 损失函数惩罚力度固定，无法根据实际情况自适应调整。在恶劣天气条件下，交通标志常出现模糊、遮挡等问题，CIoU 对轻微框偏移矫正效果较弱，且在预测框与真实框无重叠时易发生梯度消失，影响模型训练和精度。

为解决上述问题，本文将 Focaler-IoU 应用于 PIoU2 损失函数，提出了一种 Focaler-PIoU2 损失函数。

PIoU2 损失函数定义如下，通过引入一个适应目标尺寸的惩罚因子  $P$  和双重指数惩罚机制，对目标框和预测框的几何差异进行惩罚。

$$L_{PIoU2} = 1 - 3\lambda q e^{-(\lambda q)^2} \left( 1 - IoU + \left( 1 - e^{-P^2} \right) \right) \quad (1)$$

惩罚因子  $P$  定义如下，其中  $d_{w1}$  和  $d_{w2}$  是预测框和目标框对应边之间的水平距离， $d_{h1}$  和  $d_{h2}$  是预测框和目标框对应边之间的垂直距离， $w_2$  和  $h_2$  分别为目标框的宽度和高度。

$$P = \frac{1}{4} \left( \frac{d_{w1} + d_{w2}}{w_2} + \frac{d_{h1} + d_{h2}}{h_2} \right) \quad (2)$$

重构后的 Focaler-IoU 定义如下，IoU 表示原始的交并比(Intersection over Union)，通过适当地调节  $d$  和  $u$  的值，可以使模型更加关注特定的回归样本，提高模型的定位精度。

$$IoU_{focaler} = \begin{cases} 0, & IoU < d \\ \frac{|IoU| - d}{u - d}, & d \leq IoU \leq u \\ 1, & IoU > u \end{cases} \quad (3)$$

Focaler-PIoU2 损失函数公式为：

$$L_{PIoU2-Focaler} = 1 - 3\lambda q e^{-(\lambda q)^2} \left( 1 - IoU^{Focaler} + \left( 1 - e^{-P^2} \right) \right) \quad (4)$$

## 3. 实验结果与分析

### 3.1. 数据集

本文围绕雨、雪、雾等恶劣天气条件下的交通标志检测任务构建实验数据。具体地，以 THOR [25] 数

据集为基础,从中筛选出 1472 张恶劣天气图像;同时,从 CCTSDB2021 [26]-[32]数据集中选取 1500 张恶劣天气交通标志图像,与前者共同构成主实验数据集。两部分数据在使用前完成了类别标签统一和标注格式转换,最终形成包含 2972 张真实道路场景图像的恶劣天气交通标志数据集。为便于后续实验描述,本文将该主实验数据集命名为 THCT 数据集。结合检测任务需求,本文将交通标志统一划分为指示标志、禁止标志和警告标志三类。融合后的数据集在天气类型、场景背景和标志尺度等方面具有较好的多样性,有利于提升模型对复杂恶劣天气场景的适应能力。在数据划分上,本文按照 8:1:1 的比例将 THCT 数据集划分为训练集、验证集和测试集。其中,训练集用于模型学习,验证集用于参数调整与模型选择,测试集用于最终性能评估。为保证不同数据源和不同天气类型在各子集中的分布相对均衡,划分时先分别对 THOR 和 CCTSDB2021 的恶劣天气子集进行独立划分,再将对应部分合并。

THCT 数据集样例如图 4 所示,其中第一行是 THOR 恶劣天气子集,第二行是 CCTSDB2021 恶劣天气子集。



Figure 4. Sample images of the THCT dataset

图 4. THCT 数据集样例图

### 3.2. 实验环境

本实验基于 64 位的 Ubuntu 18.04.6 LTS 操作系统, GPU 为 NVIDIA A100-PCIe, 显存为 40 GB, 基于 Python 3.10 环境, 采用 PyTorch 1.10.0 作为深度学习框架, CUDA 版本为 12.0。输入图像尺寸为  $640 \times 640$  像素, 训练轮次(epoch)为 200, 批次大小(batch size)为 32。学习率设定为 0.001, 其他参数为默认值。

### 3.3. 评价指标

为了评估模型的改进, 本实验使用精确度  $P$  (Precision)、召回率  $R$  (Recall)、平均精度均值(mAP50, mAP50-95)、模型参数量(Params)、浮点运算次数(FLOPs)和每秒帧数 FPS 作为评价指标。公式如下:

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$AP = \int_0^1 P(R) dR \quad (7)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i \quad (8)$$

其中, TP (True Positives)表示模型预测正确的正样本数量, FP (False Positives)表示预测错误的正样本数量, FN (False Negatives)表示预测错误的负样本数量。 $P$  表示正确预测到的正样本在所有预测为正样本中的占比,  $R$  表示正确预测到的正样本在所有真正样本中的占比。AP (Average Precision)表示模型预测某一类别的准确度, mAP (mean Average Precision)表示所有 AP 的平均值。mAP50 表示在预测框与真实框的交并比(IoU)阈值为 0.5 时的 mAP 值, mAP50-95 表示在预测框与真实框的交并比(IoU)阈值为 0.5~0.95 时所有 mAP 的平均值。

### 3.4. 实验结果

#### 3.4.1. 消融实验

为验证 GCCConv、SA-LSCD 和 Focaler-PIoU2 三种改进策略的有效性, 本文以 YOLOv8n 为基线模型进行了消融实验, 结果如表 1 所示。

由表 1 可知, 单独引入 GCCConv 后, 模型参数数量和计算量保持不变, 但 mAP50 由 81.7% 提升至 83.3%, mAP50-95 同步提升, FPS 由 125 提高到 126, 说明该模块能够在不增加复杂度的情况下增强特征提取能力并带来轻微速度增益。单独采用 SA-LSCD 后, 模型参数数量和 FLOPs 分别降至 2.36 M 和 6.5 G, FPS 提升至 139, 体现出较好的轻量化效果, 同时检测精度基本保持稳定, 说明该模块在降低模型开销方面具有明显优势。当 GCCConv 与 SA-LSCD 组合使用时, 模型在保持轻量化的同时进一步提升了检测精度, mAP50 和 mAP50-95 均优于单一改进策略, FPS 达到 141, 表明二者具有较好的互补性。在此基础上继续引入 Focaler-PIoU2 损失函数后, 模型取得最优性能, Precision、Recall、mAP50 和 mAP50-95 均达到最高, 其中 mAP50 和 mAP50-95 分别提升至 84.4% 和 55.6%, 且未增加额外参数开销, FPS 仍保持 141。

综合来看, GCCConv 主要提升特征提取能力, SA-LSCD 主要降低模型复杂度并提升推理效率, Focaler-PIoU2 则进一步优化了边界框回归性能。三者结合后, 使模型在精度、轻量化与实时性之间取得了较好的平衡, 验证了本文改进方法的有效性。

Table 1. Ablation experiments

表 1. 消融实验

GCCConv	SA-LSCD	Focaler-PIoU2	$P/\%$	$R/\%$	mAP50/%	mAP50-95/%	Params (M)	FLOPs (G)	FPS
×	×	×	87.9	72.1	81.7	53.2	3.01	8.1	125
√	×	×	88.6	76.9	83.3	54.5	3.01	8.1	126
×	√	×	88.3	75.7	81.8	53.0	2.36	6.5	139
√	√	×	91.4	77.3	83.9	55.1	2.36	6.5	141
√	√	√	92.3	77.5	84.4	55.6	2.36	6.5	141

#### 3.4.2. 对比实验

为进一步评估本文算法的综合性能, 本文在相同数据集与实验条件下, 将所提出的方法与 YOLOv5n、YOLOv8n、YOLOv9t 及 YOLOv12n 等主流轻量化检测模型进行了对比, 实验结果如表 2 所示。

从表 2 可以看出, 本文方法在 Precision、Recall、mAP50 和 mAP50-95 四项精度指标上均优于其他对比模型, 表现出最佳的综合检测性能。其中, 本文方法的 Precision 和 Recall 分别达到 92.3% 和 77.5%, 相

比基线 YOLOv8n 分别提升 4.4 个百分点和 5.4 个百分点；mAP50 和 mAP50-95 分别达到 84.4%和 55.6%，较基线分别提升 2.7 个百分点和 2.4 个百分点，同时 FPS 由 125 提升至 141，说明该方法不仅能够更准确地区分目标与背景，还能有效提升真实目标的检出能力，同时增强目标定位的稳定性和推理效率。

从模型复杂度来看，本文方法在取得更优检测性能的同时，仍保持了较好的轻量化特性。与 YOLOv8n 相比，参数量由 3.01 M 降低至 2.36 M，FLOPs 由 8.1 G 降低至 6.5 G，FPS 提升至 141，表明该方法是在控制计算开销的基础上实现性能优化，而非单纯依赖增加模型规模获取精度提升，因此更适合部署在车载边缘设备等资源受限场景中。


此外，YOLOv5n 的 mAP50 略高于基线模型，且 FPS 达到 133，但其 mAP50-95 低于 YOLOv8n，说明其在高 IoU 阈值下的定位能力仍有不足；YOLOv9t 和 YOLOv12n 虽具有一定轻量化优势，但其 FPS 分别仅为 65 和 71，且 Recall 和 mAP 指标下降明显，整体检测性能不如本文方法。总体而言，本文方法在保证较低参数量和计算量的基础上，实现了更高的检测精度、更好的定位性能以及更快的推理速度，验证了其在恶劣天气交通标志检测任务中的有效性和优越性。

**Table 2.** Comparative experiments

**表 2.** 对比实验

模型	P/%	R/%	mAP50/%	mAP50-95/%	Parms (M)	FLOPs (G)	FPS
YOLOv8n (baseline)	87.9	72.1	81.7	53.2	3.01	8.1	125
YOLOv5n	86.6	72.4	82.3	52.3	2.5	7.1	133
YOLOv9t	83.5	67.5	73.9	48.2	1.97	7.6	65
YOLOv12n	83.3	63.9	71.1	47.2	2.56	6.3	71
本文	92.3	77.5	84.4	55.6	2.36	6.5	141

### 3.4.3. 可视化结果分析



**Figure 5.** Comparison diagram of traffic sign detection effect  
**图 5.** 交通标志检测效果对比图

为直观验证本文改进算法在恶劣天气条件下的检测效果，从 THCT 测试集中选取了雾天、雨天和雪天 3 类典型场景图像，并将原始 YOLOv8n 模型与本文改进模型的检测结果进行可视化对比，结果如图 5 所示。总体来看，本文模型在三类场景下均表现出更好的检测效果，能够在复杂背景、局部遮挡和低对比度条件下检测出更多交通标志目标，且检测置信度和定位精度均优于原始 YOLOv8n。从图中还可以看出，本文模型对右侧远距离小目标及边缘区域交通标志的响应更加稳定，在多目标同时存在时仍能保持较好的检测完整性。

具体而言，在雾天场景下，YOLOv8n 漏检了被部分遮挡的“长青高速公路”指示牌，而本文模型仍能有效检测出该目标；在雨天场景下，YOLOv8n 漏检了被遮挡的“G318”红色指示牌，而本文模型能够准确识别；在雪天场景下，本文模型对两个限速标志的检测置信度更高，边界框更贴合目标区域。说明本文改进算法能够有效减少漏检现象，提升对远距离、小尺度及局部遮挡交通标志的检测能力，在恶劣天气条件下表现出更好的鲁棒性和目标感知能力。

#### 4. 结论

本文针对恶劣天气条件下交通标志检测中存在的特征表达不足、小目标定位精度不高以及轻量化与检测性能难以兼顾等问题，提出了一种改进的 YOLOv8 检测算法。该方法通过在骨干网络中引入 GCCConv 模块增强复杂场景下的特征提取能力，采用 SA-LSCD 轻量化检测头降低模型参数数量与计算量，并结合 Focaler-PIoU2 损失函数优化边界框回归过程，从而提升模型整体检测性能。

实验结果表明，本文方法在恶劣天气交通标志数据集上取得了较好的检测效果。相比原始 YOLOv8n，改进模型的 mAP50 由 81.7% 提升至 84.4%，mAP50-95 由 53.2% 提升至 55.6%；同时，参数量由 3.01 M 降低至 2.36 M，FLOPs 由 8.1 G 降低至 6.5 G，FPS 由 125 提升至 141。对比实验结果表明，本文方法具有较好的综合性能。

需要指出的是，本文方法虽然在精度、轻量化与实时性之间取得了一定平衡，但其性能提升仍主要体现在整体指标层面，对于远距离、小尺度及受遮挡交通标志的漏检问题仍未完全解决；此外，轻量化检测头在复杂退化场景下对细粒度特征的保持能力仍有进一步提升空间。未来可结合本文实验中暴露出的薄弱环节，重点围绕困难样本挖掘、多尺度细节增强以及复杂天气下弱特征目标的判别能力提升开展研究，以进一步提高模型在真实智能交通场景中的适用性。

#### 参考文献

- [1] Li, J., Deng, Q.W., Gao, W.X., et al. (2025) DSF-YOLO for Robust Multiscale Traffic Sign Detection under Adverse Weather Conditions. *Scientific Reports*, **15**, Article No. 24550. <https://doi.org/10.1038/s41598-025-02877-0>
- [2] Zhang, H., Liang, M. and Wang, Y. (2025) YOLO-BS: A Traffic Sign Detection Algorithm Based on YOLOv8. *Scientific Reports*, **15**, Article No. 7558. <https://doi.org/10.1038/s41598-025-88184-0>
- [3] Benfaress, I., Bouhoute, A. and Zinedine, A. (2025) Advancing Traffic Sign Recognition: Explainable Deep CNN for Enhanced Robustness in Adverse Environments. *Computers*, **14**, Article 88. <https://doi.org/10.3390/computers14030088>
- [4] Girshick, R., Donahue, J., Darrell, T. and Malik, J. (2014) Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 23-28 June 2014, 580-587. <https://doi.org/10.1109/cvpr.2014.81>
- [5] Girshick, R. (2015) Fast R-CNN. 2015 *IEEE International Conference on Computer Vision (ICCV)*, Santiago, 7-13 December 2015, 1440-1448. <https://doi.org/10.1109/iccv.2015.169>
- [6] Ren, S., He, K., Girshick, R. and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/tpami.2016.2577031>
- [7] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788.

- <https://doi.org/10.1109/cvpr.2016.91>
- [8] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., *et al.* (2016) SSD: Single Shot Multibox Detector. In: *Lecture Notes in Computer Science*, Springer, 21-37. [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2)
- [9] Sun, Y., Zhang, C., Li, X., Jing, X., Kong, H. and Wang, Q. (2025) MDSF-YOLO: Advancing Object Detection with a Multiscale Dilated Sequence Fusion Network. *IEEE Transactions on Neural Networks and Learning Systems*, **37**, 1236-1247. <https://doi.org/10.1109/tnnls.2025.3617122>
- [10] Chen, J., Huang, H., Zhang, R., Lyu, N., Guo, Y., Dai, H., *et al.* (2025) YOLO-TS: Real-Time Traffic Sign Detection with Enhanced Accuracy Using Optimized Receptive Fields and Anchor-Free Fusion. *IEEE Transactions on Intelligent Transportation Systems*, **26**, 19995-20011. <https://doi.org/10.1109/its.2025.3597710>
- [11] Qiu, J., Zhang, W., Xu, S. and Zhou, H. (2025) DP-YOLO: A Lightweight Traffic Sign Detection Model for Small Object Detection. *Digital Signal Processing*, **165**, Article ID: 105311. <https://doi.org/10.1016/j.dsp.2025.105311>
- [12] Farhat, W., Rhaïem, O.B., Faïedh, H. and Souani, C. (2025) YOLO-TSR: A Novel YOLOv8-Based Network for Robust Traffic Sign Recognition. *Transportation Research Record*, **2679**, 443-466. <https://doi.org/10.1177/03611981251327213>
- [13] Wang, G., Jin, P., Qi, Z. and Li, X. (2025) Traffic Sign Detection Method Based on Improved YOLOv8. *Scientific Reports*, **15**, Article No. 19385. <https://doi.org/10.1038/s41598-025-03792-0>
- [14] Chu, X., Zhou, Z., Liao, W. and Pan, X. (2025) Ghost-YOLO: A Lightweight Traffic Sign Detection Framework via GhostNetV3. *2025 4th Conference on Fully Actuated System Theory and Applications (FASTA)*, Nanjing, 4-6 July 2025, 1557-1562. <https://doi.org/10.1109/fasta65681.2025.11138702>
- [15] Chen, Z., Yang, K., Wu, Y., Yang, H. and Tang, X. (2025) HCLT-YOLO: A Hybrid CNN and Lightweight Transformer Architecture for Object Detection in Complex Traffic Scenes. *IEEE Transactions on Vehicular Technology*, **74**, 3681-3694. <https://doi.org/10.1109/tvt.2024.3496513>
- [16] Lin, Z., Wu, Y., Ma, Y., Chen, J., Zhang, R., Wu, J., *et al.* (2025) YOLO-LLTS: Real-Time Low-Light Traffic Sign Detection via Prior-Guided Enhancement and Multibranch Feature Interaction. *IEEE Transactions on Instrumentation and Measurement*, **74**, 1-18. <https://doi.org/10.1109/tim.2025.3604925>
- [17] Yang, G., Wang, Y., Shi, D. and Wang, Y. (2025) Golden Cudgel Network for Real-Time Semantic Segmentation. *2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 10-17 June 2025, 25367-25376. <https://doi.org/10.1109/cvpr52734.2025.02362>
- [18] Yin, B. (2024) Lightweight Fire Detection Algorithm Based on LSCD-FasterC2f-YOLOv8. *2024 5th International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)*, Wenzhou, 20-22 September 2024, 64-67. <https://doi.org/10.1109/icbase63199.2024.10762124>
- [19] Zhang, H. and Zhang, S. (2025) Focaler-IoU: More Focused Intersection over Union Loss. arXiv: 2401.10525.
- [20] Liu, C., Wang, K., Li, Q., Zhao, F., Zhao, K. and Ma, H. (2024) Powerful-IoU: More Straightforward and Faster Bounding Box Regression Loss with a Nonmonotonic Focusing Mechanism. *Neural Networks*, **170**, 276-284. <https://doi.org/10.1016/j.neunet.2023.11.041>
- [21] Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R. and Ren, D. (2020) Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression. *Proceedings of the AAAI Conference on Artificial Intelligence*, **34**, 12993-13000. <https://doi.org/10.1609/aaai.v34i07.6999>
- [22] Hu, Z., Chen, W., Yang, D., Wang, Z. and Wang, P. (2025) Enhancing Object Detection in Remote Sensing Images with Improved YOLOv8 Model. *Scientific Reports*, **15**, Article No. 42488. <https://doi.org/10.1038/s41598-025-26536-6>
- [23] Cao, Y.P., Luo, H.W., Wang, M.D., *et al.* (2025) Enhanced YOLOv8 for Accurate and Efficient Floating Object Detection on Water Surfaces. *Scientific Reports*, **16**, Article No. 2907. <https://doi.org/10.1038/s41598-025-32817-x>
- [24] Ding, X., Zhang, X., Ma, N., Han, J., Ding, G. and Sun, J. (2021) RepVGG: Making VGG-Style Convnets Great Again. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 13728-13737. <https://doi.org/10.1109/cvpr46437.2021.01352>
- [25] Wang, F., Bai, J., Wang, M., Liu, B., Xue, H. and Chen, J. (2026) Robust Traffic Sign Detection in Real-World Harsh Conditions: A Pioneering Benchmark Dataset and Attention-Based Methodology. *Engineering Applications of Artificial Intelligence*, **166**, Article ID: 113526. <https://doi.org/10.1016/j.engappai.2025.113526>
- [26] Zhang, J., Lv, Y., Tao, J., Huang, F. and Zhang, J. (2024) A Robust Real-Time Anchor-Free Traffic Sign Detector with One-Level Feature. *IEEE Transactions on Emerging Topics in Computational Intelligence*, **8**, 1437-1451. <https://doi.org/10.1109/tetci.2024.3349464>
- [27] Zhang, J., Zou, X., Kuang, L.D., *et al.* (2022) CCTSDB 2021: A More Comprehensive Traffic Sign Detection Benchmark. *Human-Centric Computing and Information Sciences*, **12**, 1-21.
- [28] Zhang, J., Zheng, Z., Xie, X., Gui, Y. and Kim, G. (2022) ReYOLO: A Traffic Sign Detector Based on Network Reparameterization and Features Adaptive Weighting. *Journal of Ambient Intelligence and Smart Environments*, **14**, 317-

- 
334. <https://doi.org/10.3233/ais-220038>
- [29] Zhang, J., Ye, Z., Jin, X., Wang, J. and Zhang, J. (2022) Real-Time Traffic Sign Detection Based on Multiscale Attention and Spatial Information Aggregator. *Journal of Real-Time Image Processing*, **19**, 1155-1167. <https://doi.org/10.1007/s11554-022-01252-w>
- [30] Zhang, J., Wang, W., Lu, C., Wang, J. and Sangaiah, A.K. (2022) Lightweight Deep Network for Traffic Sign Classification. *Annals of Telecommunications*, **75**, 369-379. <https://doi.org/10.1007/s12243-019-00731-9>
- [31] Zhang, J., Xie, Z., Sun, J., Zou, X. and Wang, J. (2020) A Cascaded R-CNN with Multiscale Attention and Imbalanced Samples for Traffic Sign Detection. *IEEE Access*, **8**, 29742-29754. <https://doi.org/10.1109/access.2020.2972338>
- [32] 李旭东, 张建明, 谢志鹏, 等. 基于三尺度嵌套残差结构的交通标志快速检测算法[J]. 计算机研究与发展, 2020, 57(5): 1022-1036.