

基于改进YOLOv8的交通标志检测算法研究

谷喜阳, 谢颖华*

东华大学信息科学与技术学院, 上海

收稿日期: 2025年4月25日; 录用日期: 2025年5月23日; 发布日期: 2025年5月30日

摘要

随着智能交通系统的快速发展, 交通标志检测在自动驾驶和辅助驾驶系统中扮演着至关重要的角色。为了应对交通标志检测对低延时和高精确度的要求, 本文在YOLOv8n模型的基础上进行了改进, 旨在提升检测速度和准确率。首先, 从提升检测速度的角度出发, 本文提出了一种轻量化的卷积模块GhostConv, 用于替代YOLOv8模型中的原始Conv模块, 同时引入GhostC2f结构替换原始的C2f结构, 以进一步减少计算复杂度并加速推理过程。其次, 从提升检测准确率的角度出发, 本文提出设计了SPPF-LSKA模块, 增强了模型对交通标志特征的提取能力。此外, 本文还提出使用Slou损失函数替换原始的Ciou损失函数, 以更好地优化边界框回归, 进一步提升检测精度。实验结果表明, 改进后的模型在保持较低延时的同时, 显著提升了交通标志检测的准确率, 能够更好地满足实际应用需求。

关键词

交通标志检测, YOLOv8n, GhostConv, SEAMHead, Slou函数

Research on Traffic Sign Detection Algorithm Based on Improved YOLOv8

Xiyang Gu, Yinghua Xie*

Information Science and Technology Academy, Donghua University, Shanghai

Received: Apr. 25th, 2025; accepted: May 23rd, 2025; published: May 30th, 2025

Abstract

With the rapid development of intelligent transportation systems, traffic sign detection plays a critical role in autonomous and assisted driving systems. To address the requirements of low latency and high accuracy in traffic sign detection, this paper improves the YOLOv8n model by focusing on enhancing detection speed and accuracy. First, from the perspective of improving detection speed, we propose a lightweight convolutional module GhostConv to replace the original Conv module in the YOLOv8 model, and introduce GhostC2f structure to replace the original C2f structure, to further reduce the computational complexity and accelerate the inference process. Secondly, from the perspective of improving detection accuracy, we propose to design the SPPF-LSKA module, which enhances the model's ability to extract traffic sign features. In addition, we propose to use the Slou loss function to replace the original Ciou loss function, to better optimize the boundary box regression and further improve the detection accuracy. Experimental results show that the improved model maintains a low latency while significantly improving the accuracy of traffic sign detection, which can better meet the practical application requirements.

*通讯作者。

文章引用: 谷喜阳, 谢颖华. 基于改进 YOLOv8 的交通标志检测算法研究[J]. 计算机科学与应用, 2025, 15(5): 778-788.
DOI: 10.12677/csa.2025.155151

we propose a lightweight GhostConv module to replace the original Conv module in YOLOv8, and introduce the GhostC2f structure to substitute the original C2f structure, thereby reducing computational complexity and accelerating inference. Second, in this paper, the sppf-lsca module is designed to enhance the ability of the model to extract the characteristics of traffic signs. Additionally, we employ the SIoU loss function instead of the original CIoU loss function to optimize bounding box regression and further improve detection precision. Experimental results demonstrate that the improved model achieves significantly higher accuracy while maintaining low latency, better meeting the demands of real-world applications.

Keywords

Traffic Sign Detection, YOLOv8n, GhostConv, SEAMHead, SIoU Loss Function

Copyright © 2025 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

随着自动驾驶技术的快速发展,交通标志检测系统已[1]成为智能车辆环境感知体系的核心组件。作为道路基础设施的重要组成部分,交通标志[2]通过图形符号传递限速、转向、警示等关键信息,直接影响行车安全与交通管理效率。据统计,全球每年因驾驶员误判或忽视交通标志导致的交通事故占比超过12%,而准确率低于95%的检测系统可能引发每秒数米的车辆定位偏差。因此,开发具备实时性、高鲁棒性的交通标志检测算法[3],对推动智能交通系统(ITS)落地具有迫切需求。

目前交通标志的检测方法主要有两种:基于传统特征提取的方法和基于深度学习的方法。传统交通标志检测方法主要依赖人工设计的特征提取与模式识别技术,其核心思想是通过颜色、形状、纹理等先验知识构建特征描述子,结合分类器实现标志定位与识别。在复杂环境下识别准确率低、识别速度慢,不能满足检测需求。近年来,深度学习技术的突破为目标检测领域带来范式变革。基于深度学习的目标检测算法主要分为两类,一类是两阶段算法,典型的有 R-CNN [4]、Fast R-CNN [5]、R-FCN [6]、Mask R-CNN [7]等算法,通过“候选框生成+精细检测”两步骤实现高精度定位与分类,但计算复杂度较高,推理速度较低,适用于对实时性要求不严苛的场景(如医学图像分析);另一类是单阶段算法,以 YOLO [8]和 SSD [9]算法为代表。单阶段目标检测算法通过端到端架构直接预测目标位置与类别,摒弃传统两阶段方法中的候选框生成步骤,大幅提升检测效率。其核心思想是将检测任务建模为密集网格回归问题,通过锚框机制在图像网格单元中直接回归边界框坐标、置信度及类别概率。YOLO 算法将输入图像划分为 $S \times S$ 网格并利用多尺度特征图进行预测,结合全局上下文信息实现高效检测,其中 YOLOv5/v8 通过优化特征融合与损失函数,在 COCO 数据集上以 45%的 mAP 和超过 30 FPS 的速度平衡精度与实时性。单阶段算法凭借高计算效率广泛应用于自动驾驶[10]、视频监控等实时场景,但其轻量化需求(如采用 MobileNet 主干网络)与模型压缩技术(如量化、剪枝)的结合,仍是平衡边缘设备部署中精度与速度的关键挑战。

2. YOLOv8 算法

YOLOv8 (You Only Look Once version 8)是 Ultralytics 公司于 2023 年推出的目标检测算法,其结构模型如图 1 所示,作为 YOLO [11]系列的最新一代模型,它在速度、精度和易用性之间实现了进一步平衡。该模型继承 YOLO 系列核心架构,通过改进特征金字塔网络和损失函数策略,在 PASCAL VOC、COCO

等基准数据集上的实验表明, 其单阶段检测架构有效平衡了计算效率与检测精度。




Figure 1. YOLOv8 model

图 1. YOLOv8 结构图

2.1. 主干结构

该模型的主干网络主要由 Conv 模块、C2f (Cross Stage Partial Fusion)模块、SPPF (Spatial Pyramid Pooling-Fast)模块组成。基础卷积模块由卷积层、批归一化层与 SiLU 激活函数构成, 典型配置为 3×3 核、步长 2 和 64 输出通道, 兼顾特征提取效率与训练稳定性。批归一化层通过标准化处理加速收敛, 而 SiLU 函数增强非线性表达能力。

跨阶段特征融合单元采用双分支结构优化计算效率: 短连接分支保留原始特征, 另一分支通过堆叠 Bottleneck 层提取高阶语义信息, 最终融合两路特征实现梯度流优化。此设计通过减少冗余计算提升推理速度, 同时增强多层次特征复用能力。

末端的多尺度池化组件采用级联策略聚合不同感受野特征: 并行执行 5×5 、 9×9 、 13×13 池化操作后, 通过拼接与卷压缩整合多尺度上下文信息。相比传统金字塔池化结构, 其计算效率提升显著, 尤其在小目标检测任务中精度优势明显。

整体架构通过模块协同实现精度与速度平衡: 基础模块保障特征提取鲁棒性, 融合单元强化梯度传播, 池化组件提升多尺度表征能力, 最终在复杂场景中达成高效检测目标。

2.2. 颈部结构

目标检测模型的颈部结构承担着多层次特征整合与优化的关键功能。其核心设计通过多模块协同实现跨尺度信息融合, 以增强检测任务的特征表达能力。其中, 特征金字塔网络(FPN)模块通过双向跨层连接机制, 将高分率低阶特征与深层高阶语义特征进行融合, 构建具有丰富多尺度信息的金字塔结构。这种架构使得浅层特征保留细节纹理, 适用于微小目标识别, 而深层特征携带全局语义, 助力大目标定位, 二者互补显著提升模型尺度适应性。

在特征处理流程中, 通道扩展模块率先对主干网络输出进行通道维度调整, 通过卷积操作扩展特征图容量, 为后续处理提供充足的特征空间。紧随其后的特征复用模块采用双分支拓扑结构: 主支路保留

原始特征传递路径,支路通过多层非线性变换结构提取高阶语义,最终通过通道维度拼接实现特征复用。这种设计在减少计算量的同时,增强了对交通标志边缘纹理的表征能力。

多级模块的堆叠式应用进一步强化特征交互,通过重复执行通道调整、特征复用和跨尺度融合操作,构建递进式的特征增强机制。最终,优化后的多尺度特征被输送至检测头,其中高层特征负责大目标粗定位,中层特征平衡语义与细节,底层特征专注微小目标捕捉。有效平衡了精度与效率的工程化需求。

2.3. 检测头

目标检测模型的头部结构承担着特征解码与预测任务的核心功能,其设计直接影响最终检测精度与推理效率。在典型框架中,多层级特征首先经过通道调整层处理,通过 3×3 卷积与 SiLU 激活函数增强局部特征表达能力,同时保持空间分辨率不变。针对分类与回归任务的差异性,模型采用任务解耦机制,通过独立分支网络分别优化类别概率预测和边界框坐标回归,实验表明该策略可使检测精度提升约 3.5%。在回归分支中,模型摒弃传统锚框机制,采用中心点直接预测方法,通过输出目标宽高与中心偏移量简化计算流程,减少参数冗余。

损失函数设计方面,引入复合交并比优化策略(CIoU),综合考虑边界框重叠区域、中心点距离及宽高比匹配度,有效缓解倾斜目标的定位偏差问题。针对预测结果的后处理,基于置信度阈值与空间重叠度评估的非极大值抑制算法(NMS)被用于消除冗余检测框,优先保留高置信度预测结果。此外,通过动态权重分配机制平衡不同尺度目标的损失贡献,提升小目标检测的敏感性。整体架构通过模块化协同优化,在工业级硬件平台上实现了精度与效率的工程化平衡。

3. YOLOv8n 算法改进

3.1. 轻量化改进

在道路交通标志检测中,实时性尤为重要。为了提升检测过程中的速度,将 YOLOv8n 中的传统卷积模块 Conv 被轻量化卷积模块 GhostConv 替换,基于此,YOLOv8 对原始模型的 C2F 结构进行改造,用 GhostC2f 来替代 C2F。GhostNet 由华为诺亚方舟实验室提出,是一种面向移动端与嵌入式设备的高效轻量化网络架构。其核心创新在于 Ghost 模块,通过“特征冗余利用”思想重构传统卷积:将输入特征拆分为“本征特征”与“Ghost 特征”,前者通过少量常规卷积提取核心信息,后者利用低成本深度卷积或线性变换生成冗余特征,最后拼接两部分结果作为输出。该设计显著降低计算量,例如生成相同数量特征图时,Ghost 模块的计算成本仅为传统卷积的 1/4。GhostConv 的基本结构如图 2 所示。




Figure 2. The basic architecture of GhostConv

图 2. GhostConv 的基本结构

3.2. SPPF-LSKA 改进

SPPF (Spatial Pyramid Pooling Fast)模块是 YOLOv8 主干网络(Backbone)的关键组件之一, 位于特征提取网络的末端, 负责聚合多尺度上下文信息, 增强模型对不同尺寸目标的检测能力。其核心功能是通过多级池化操作融合不同感受野的特征, 提升模型在复杂场景(如小目标密集、目标尺度变化大)下的鲁棒性。SPPF 模块是对传统 SPP (Spatial Pyramid Pooling)的优化版本, 主要改进在于计算效率与特征融合方式。SPPF-LSKA (Spatial Pyramid Pooling Fast with Large Selective Kernel Attention)是一种结合了多尺度池化与大选择性核注意力的复合模块, 旨在提升目标检测和图像识别任务中对多尺度目标、复杂背景的特征提取能力。LSKA [12]注意力机制(Large Kernel Attention)是一种高效的大核注意力模块, 旨在通过扩展感受野捕获长距离依赖关系, 同时避免传统大核卷积的计算负担。其核心设计将大核卷积分解为深度卷积(Depthwise Convolution)与自适应空洞卷积(Dilated Conv)的组合, 在保持大尺度上下文感知能力的前提下, 将计算复杂度降低至传统方法的 1/4。LSKA 通过动态通道权重调整聚焦关键区域, 在图像分类、目标检测任务中显著提升模型对复杂背景与微小目标的区分能力, 适用于自动驾驶、医学影像等需高分辨率输入的实时场景。因此, 本文在 YOLOv8 基础模型 SPPF 模块中引入 LSKA 注意力机制用于增强对多尺度目标的特征表达能力, 得到 SPPF-LSKA, 如图 3 所示




Figure 3. SPPF-LSKA

图 3. SPPF-LSKA

3.3. 损失函数改进

YOLOv8 模型采用的 CIOU (Complete Intersection over Union) 损失函数是一种针对边界框回归优化的高级损失计算方法, 旨在提升目标检测的定位精度。CIOU 在传统 IoU (交并比) 的基础上, 综合了三个关键因素: 重叠区域面积、中心点距离和宽高比一致性, 从而更全面地衡量预测框与真实框的匹配程度。相较于早期版本, CIOU 通过引入宽高比惩罚项, 解决了目标形状不一致导致的定位偏差问题。但其仍存在动态场景适应性不足、对极端尺度目标敏感等不足。因此本文选择引入 SIOU (Shape-Enhanced Intersection over Union) 替换原始模型的 CIou, 提高模型的检测效果。其计算公式如下, 其中 θ 表示预测框与真实框的角度差异惩罚项; $\rho^2(b, b^{gt})$ 代表预测框和真实框代表预测框与真实框中心点欧氏距离的平方; c 代表最小包围框的对角线长度; w 和 h 代表预测框的宽高, w^{gt} 和 h^{gt} 代表真实框的宽高。

$$L_{SIOU} = 1 - IoU + \frac{\theta}{4} + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt}) + \rho^2(h, h^{gt})}{4} \quad (1)$$

3.4. 改进后的 YOLOv8 结构

针对交通标志检测对实时性与精度的双重需求, 本文提出一种基于轻量化架构与注意力增强的目标检测模型优化策略。在模型效率优化方面, 采用轻量化卷积模块 GhostConv 替代传统卷积层, 同时, 重构跨阶段特征复用模块(C2f), 用 GhostC2f 去替代, 加速模型推理过程。在精度提升维度方面, 设计多尺度通道注意力检测头(SEAMHead), 并且进一步优化边界框回归损失函数, 采用 SIOU 损失函数替代传统 CIOU 损失函数。最终改进后的 YOLOv8 结构如图 4 所示




Figure 4. Improved YOLOv8 structure

图 4. 改进后的 YOLOv8 结构

4. 实验结果与分析

4.1. 实验环境及参数设置

本文采用云服务器平台 AutoDL 提供的算力进行模型训练。实验环境为, 硬件配置: CPU 为 16 vCPU Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10GHz, 运行内存为 120 GB。GPU 型号是单张显存为 24GB 的 RTX 4090; 采用 Pytorch1.11.0 框架, Python3.8, Cuda11.3 作为实验环境。整个训练过程分为 300 个 epoch 进行, 批次为 16, 初始学习率为 0.01, 动量大小为 0.937, 权重衰减系数为 0.0005。

4.2. 数据集及数据扩充

本实验使用清华-腾讯 100K (TT100K) [13] 数据集, 这是清华大学和腾讯联合创建的大规模交通标

志识别数据集。TT100K 数据集由 9176 张大小为 2048×2048 的高分辨率图像组成, 涵盖了 151 种不同类型的道路交通标志。该数据集的丰富种类很适合卷积神经网络的特征学习机制。但该数据集存在图片数量不均衡现象, 一些类别(如禁令标志)样本量达千张, 而部分类别有效样本不足十例, 并且数据集目标尺寸分布存在结构性失衡。因此为了确保有效的模型训练, 需要对该数据集进行预处理。在本文中, 使用了旋转图片(如图 5)、调整图片亮度(如图 6)、增加检测目标(如图 7)三种数据增强方法, 以提升模型在复杂场景下的鲁棒性和适应性。除此之外, 本文还随机组合使用这三种数据增强方法进行数据增强, 每次数据增强时随机选择是否应用旋转、亮度调整以及增加检测目标这三种方法中的一个、两个或全部三种。通过这种方式, 每张图片在增强过程中都有机会经历不同的变换组合, 从而大大增加了数据的多样性。最终得到增强后的数据集由 11584 张图像组成, 训练集中有 8901 张图像, 测试集中有 2683 张图像。



Figure 5. Image rotation
图 5. 图像旋转



Figure 6. Image brightness adjustment
图 6. 图像亮度调整



Figure 7. Add detection target
图 7. 增加检测目标

4.3. 评价指标

在本文中, 主要涉及到的评价指标有 P (Precision)精确度、R (Recall)召回率、AP (Average Precision)平均精度、mAP (Mean Average Precision)平均精度均值等指标。精确度 P 的计算公式如式(2)下, 其中 TP (True Positive)是指正确检测的正样本数, FP(False Positive)是指代表误检为目标的负样本数。

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

召回率 R 的计算公式如式(3)所示, 其中 FN(False Negative)代表模型漏检的正样本数,

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

平均精度 AP 的计算公式如式(4)所示。

$$AP = \int_0^1 P(R)dr \quad (4)$$

平均精度均值 mAP 的公式如式(5)所示, N 代表类别总数, 该指标是 AP 的均值, 用于评价模型的整体性能。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

4.4. 实验结果

本文对 YOLOv8n 模型进行了改进, 通过引入不同的模块来提升模型的检测速度和准确率, 并对改进后的模型进行了性能评估。为验证模型改进后的效果, 在训练集、验证集和测试集上进行实验, 结果如表 1 所示。

Table 1. Comparison table of ablation experiment data

表 1. 消融实验数据对照表

Model	YOLOv8n	Ghost (G)	SPPF-LSKA (SL)	SIoU (S)	mAP (%)	Parameters	Model	YOLOv8n	Ghost (G)
YOLOv8n	✓				68.8	3.02	8.2	6.1	4.3
YOLOv8n-G	✓	✓			66.4	1.73	5.2	3.6	2.7
YOLOv8n-SL	✓		✓		72.9	3.29	8.5	6.5	4.6
YOLOv8n-S	✓			✓	72.7	3.02	8.2	6.1	4.4
YOLOv8n-GSLS	✓	✓	✓	✓	72.3	2.13	5.9	4.0	3.1

实验结果表明, 不同改进策略对目标检测模型的性能产生显著差异。引入 Ghost 模块的轻量化改进模型(YOLOv8n-G)在参数规模(1.73 M)、计算量(5.2×10^9)及模型体积(3.6 MB)方面较基线模型压缩显著, 推理速度提升至 2.7 ms, 但其检测精度(mAP)出现约 1.6%的轻微下降, 表明轻量化设计虽能有效降低资源消耗, 但需辅以特征增强机制缓解精度损失。相比之下, 嵌入 SPPF-LSKA 模块的多尺度感知模型(YOLOv8n-SL)通过大感受野特征融合, 将 mAP 提升至 72.9%, 但代价是参数量增至 3.29 M、计算量升至 8.5×10^9 , 模型体积扩展至 6.5 MB, 推理延迟增至 4.6 ms, 适用于算力充裕的高精度需求场景。值得注意的是, 仅采用 SIoU 损失函数优化的模型(YOLOv8n-S)在不增加参数规模(3.02 M)与计算量(8.2G FLOPs)的前提下, 使 mAP 达到 72.7%, 验证了损失函数设计对定位精度提升的有效性。最终的综合改进模型(YOLOv8n-GSLS)集成轻量化架构、多尺度感知与损失函数优化策略, 在精度(72.3% mAP)、效率(3.1

ms)与资源消耗(2.13 M、 5.9×10^9)间实现均衡, 模型体积压缩至 4.0 MB。这一结果表明, 模型在保持较高检测精度的同时, 实现了参数量、计算量和模型大小的减少, 以及推理速度的提升, 展现了较好的性能平衡。

为了直观地对比本文 YOLOv8n-GSLS 模型改进的效果, 本文特选取了三组图片进行各个模型的效果对比, 对比的结果如下图 8 所示。



Figure 8. Comparison of detection results before and after improvements

图 8. 改进前后检测效果对比

由图可知, 原始 YOLOv8n 模型与改进型 YOLOv8n-GSLS 模型在交通标志检测任务中均表现出优异的识别精度, 且均未出现漏检现象。然而, 深入分析显示, 优化后的 YOLOv8n-GSLS 模型在多数测试场景中展现出更优的综合性能: 其检测框定位精度与分类置信度较基线模型均有所提升。这些结果充分验证了本文提出的轻量化架构优化与多尺度特征增强策略的有效性, 证明 YOLOv8n-GSLS 模型在交通标志检测任务中具有更强的工程化优势。

4.5. 主流模型对比实验

为验证本文所提出算法的优越性, 将本文改进后的算法与目前主流的交通标志检测算法进行对比, 选取 YOLOv8n、YOLOv5n、YOLOv6n、YOLOv9n 与本文改进算法进行对比实验, 从平均精度(mAP)、参数量、计算量(GFLOPs)、模型大小和推理速度五个维度进行评估。实验结果如表 2。

Table 2. Algorithm comparison

表 2. 算法对比

模型	mAP (%)	Pa-rameters	GFLOPs (10)	Size (MB)	mAP (%)
YOLOv8n	68.8	3.02	8.2	6.1	4.3
YOLOv5n	65.1	2.51	7.2	5.3	4.4
YOLOv6n	66.8	4.24	11.9	8.7	5.6
YOLOv9n	67.5	7.30	27.4	28.7	12.5
YOLOv8n-GSLS	72.3	2.13	5.9	4.0	3.1

5. 结束语

本研究针对现有交通标志检测模型在复杂场景下小目标识别精度不足及背景干扰引发的漏检问题, 提出一种以 YOLOv8n 为框架[14]的优化检测模型。通过引入多尺度特征增强机制与动态注意力引导策略, 强化模型对微小标志的纹理捕捉能力及复杂环境下的抗干扰性能。实验结果表明, 改进模型在交通标志数据集上的平均精度均值(mAP)达到 72.3%, 相较基线模型性能提升 3.5%, 并且参数量相较原模型也大大减少。后续将同时推进算法在嵌入式硬件平台(如 Jetson Orin)的工程化部署, 为自动驾驶系统的实时环境感知提供高可靠技术支撑。

参考文献

- [1] 陈晗晗, 王俊英, 任肖月. 交通标志的检测与识别方法研究综述[J]. 信息技术与信息化, 2024(3): 77-82.
- [2] 李铭兴, 徐成, 李学伟. 交通标志识别研究综述[C]//中国计算机用户协会网络应用分会. 中国计算机用户协会网络应用分会 2021 年第二十五届网络新技术与应用年会论文集. 北京: 北京联合大学北京市信息服务工程重点实验室, 2021: 201-204.
- [3] 马健, 张敏, 张丽岩, 等. 交通标志识别系统研究综述[J]. 物流科技, 2021, 44(10): 69-74.
- [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. *Proceedings of the IEEE International Conference on Computer Vision*, Santiago, 7-13 December 2015, 1440-1448.
- [6] Khishe, M. and Mosavi, M.R. (2020) Chip Optimization Algorithm. *Expert System with Applications*, **149**, Article ID: 113338.
- [7] He, K., Gkioxari, G., Dollar, P. and Girshick, R. (2017) Mask R-CNN. 2017 *IEEE International Conference on Computer Vision (ICCV)*, Venice, 22-29 October 2017, 2961-2969. <https://doi.org/10.1109/iccv.2017.322>
- [8] Bochkovskiy, A., Wang, C.Y. and Liao, H.Y.M. (2020) YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv: 2004.10934.
- [9] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., et al. (2016) SSD: Single Shot Multibox Detector. In: Leibe, B., Matas, J., Sebe, N. and Welling, M., Eds., *Computer Vision—ECCV 2016*, Springer, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [10] 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.
- [11] 王琳毅, 白静, 李文静, 等. YOLO 系列目标检测算法研究进展[J]. 计算机工程与应用, 2023, 59(14): 15-29.
- [12] Lau, K.W., Po, L. and Rehman, Y.A.U. (2024) Large Separable Kernel Attention: Rethinking the Large Kernel Attention

- Design in CNN. *Expert Systems with Applications*, **236**, Article ID: 121352. <https://doi.org/10.1016/j.eswa.2023.121352>
- [13] Zhu, Z., Liang, D., Zhang, S., Huang, X., Li, B. and Hu, S. (2016) Traffic-Sign Detection and Classification in the Wild. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 2110-2118. <https://doi.org/10.1109/cvpr.2016.232>
- [14] 史涛, 崔杰, 李松. 优化改进 YOLOv8 实现实时无人机车辆检测的算法[J]. 计算机工程与应用, 2024, 60(9): 79-89.