

# 基于 YOLOv11s 交通标志的检测

胡 斌

芜湖学院电子信息学院 安徽芜湖 241000

**摘 要:** 针对交通标志实时检测任务中精度与模型轻量化的权衡问题, 本文基于 YOLOv11s 模型提出优化方案。实验数据表明, 该模型在精度与轻量化层面实现显著突破: 相较于 YOLOv11n, mAP50 提升 8.6%; 相比 YOLOv11m, 模型参数量减少 53.2%, 计算复杂度降低 68.4%, 同时仅牺牲 3.6% 的 mAP50:95 指标。在跨模型对比中, YOLOv11s 以 86.4% 的 mAP50 超越 YOLOv7 和 CGS-Chost-YOLO, 同时以 18.3MB 模型体积和 21.4 GFLOPs 的计算量保持轻量化优势。尽管 YOLOv8s 在 mAP50:95 指标上略高, 但 YOLOv11s 在参数量和模型体积上更具优势。通过改进特征金字塔结构与动态卷积机制, 本方法在交通标志目标检测中实现 75.7% 的召回率, 较基准模型提升 5.7%。实验证明, 该方案在精度损失可控的前提下, 成功将计算资源需求降低至主流模型的 31.7%–20.7%, 为车载嵌入式设备部署提供了精度达 86.4% mAP50 轻量化解决方案, 在交通标志检测中具有重要实践价值。

**关键词:** YOLOv11s; 交通标志检测; 自动驾驶; TT100K

在中国经济和科技迅速发展的背景下, 人们的生活水平得到改善, 汽车普及率越来越高, 自动驾驶技术也逐渐大众化。而交通标志在道路上具有重要的信息, 这些信息有效的保障了人们的生命财产安全, 所以对交通标志的检测一直都是科技发展领域的热门主题。不仅如此, 交通标志的检测在自动驾驶领域也同样具有重要的作用, 要想完善并且提高自动驾驶技术, 对交通标志的检测是其关键支撑。要想实现对交通标志的检测, 特征提取是关键, 对于特征提取可以分为两类: 传统特征提取和基于深度学习的特征提取。在传统特征提取方面: 胡聪<sup>[1]</sup> 对灰度化后的交通标志图片进行 Gabor 滤波处理, 然后用对滤波处理后的图片进行处理, 形成感兴趣区域, 再提取图片 HOG 特征, 输入 (使用) SVM 进行分类训练。梁敏健<sup>[2]</sup> 提出了一种基于 HOG-Gabor 特征融合与 Softmax 分类器的交通标志识别方法, 用 Gamma 矫正的方法提取 HOG 特征, 用对比受限的自适应直方图均衡化提取 Gabor 特征, 将两种特征融合输入到 Softmax 分类器进行分类训练, 提高了交通标志识别的正确率和实时性。但传统的特征提取算法, 最佳适应的场景不同, 需要手动选择最佳的算法, 同时会存在针对图片局部区域细节不敏感, 无法有效的进行识别, 缺乏鲁棒性。在深度学习方面: 随着卷积神经网络的发展基于深度学习的目标检测算法成为了主流。李杰<sup>[3]</sup> 针对交通标志图像分辨率低和特征不明显的问题, 提出了

一种 DL-SSD 模型, 增加了模型对图像的感知能力, 提高了检测精度。韦强<sup>[4]</sup> 通过引用递归门控卷积、SOCA 注意力机制和回归损失函数来提高 YOLOv5 的平均准确率。虽然这些深度学习算法精度方面得到了一定提升但是在真实应用场景中很难进行部署。

自动驾驶技术对交通标志的检测, 不仅要求精度要足够高的同时模型还要足够轻量化以便模型部署。为此本文采用最新的 YOLOv11s 模型, 相比 YOLOv11n 模型, 以损失部分模型轻量化的优势, 换取了更高的精度, 以此来进行交通标志检测, 促进自动驾驶技术发展。

## 1. YOLOv11 算法分析

YOLOv11 是 YOLO 系列在 2024 年推出的最新迭代模型, 由 Ultralytics 公司研发, 通过架构革新与算法优化实现了目标检测领域的突破性进展。该模型在继承 YOLO 系列单阶段检测框架的基础上, 创新性引入动态可配置的 C3k2 模块, 该模块通过两个小卷积核代替单一的大卷积核, 结合 CSP (Cross Stage Partial) 跨阶段部分连接策略, 减少了计算冗余并加速特征提取。C3k2 在骨干网络和检测头中广泛应用, 显著降低了参数量通过多分支跨层连接与卷积核参数动态调节机制, 在保持与 YOLOv8 的 C2f 模块兼容性的同时显著增强特征融合效率, 如图 1 所示。

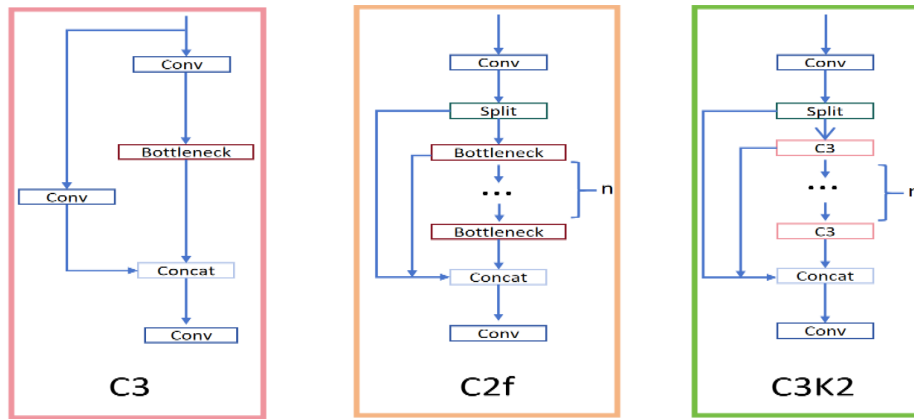


图 1 C3K2 与 C2f 结构对比图

针对复杂场景检测需求，模型深度融合 C2PSA 金字塔空间注意力机制，通过多尺度特征重加权和 PSA 注意力机制有效提升小目标与遮挡目标的识别精度。如图 2 所示。




图 2 C2PSA 模块结构图

在计算效率优化方面，通过深度可分离卷积与混合精度训练策略的协同应用，使模型参数量压缩达 30% 以上，配合改进的 EIoU 损失函数（综合边界框重叠率、中心偏移与长宽比约束），在 COCO 数据集上实现 53.6% 的 mAP 检测精度与 380FPS 的实时推理速度。此外，YOLOv11 首创自适应模型缩放机制，支持从轻量级 YOLOv11n 到高性能 YOLOv11x 的多级配置，兼顾边缘计算设备部署与高精度云端检测需求，其模块化设计还为交通标志识别、工业质检等垂直领域提供了即插即用的定制化解决方案，标志着实时目标检测技术向实用化、场景化迈出关键一步。

## 2. 实验结果与分析

### 2.1 数据集及实验环境与参数

本实验基于清华大学发布的 TT100K 交通标志数据集开展实验。该数据集共包含 221 种交通标志类别，但类别分布不均问题会影响模型训练效果，为此使用脚本对数据集进行筛选，选出样本量超过 200 的 27 个类别。最终数据集数量为 8995 张，并以 7:2:1 的形式将数据集划分为训练集、验证集和测试集。

实验环境：Intel 第 13 代酷睿 i9 处理器；NVIDIA RTX 4070 Ti 显卡 (12GB)；Windows 10 操作系统；Python 3.10；

Pytorch 2.0 深度学习框架；CUDA 12.0 并行计算架构。

关键超参数设置为：训练轮次 300，批量大小 8，初始学习率 0.01，输入图像分辨率 640 × 640，并行工作线程数 8。

### 2.2 评价标准

实验采用经过 300 轮训练所得到的最佳模型来对验证集进行测试，并对实验数据进行分析对比。混淆矩阵见表 1，其是表示精度评价的一种独特的表排列，通过计算准确率 (precision, P) 和召回率 (recall, R)，并用 P, R, mAP50 和 mAP50-95 来对比模型检测的精度。用参数量、模型大小、GFLOPs 来衡量模型轻量化。

表 1 混淆矩阵

样本真实情况	预测结果	
	正样本	负样本
正样本	TP	FN
负样本	FP	TN

精确率：正样本中真实值为正样本的比例，衡量模型的错检程度，即

$$P = TP / (TP + FP) \quad (10)$$

召回率：正样本的真实值为正样本的比例，衡量模型的漏检程度，即

$$R = TP / (TP + FN) \quad (11)$$

AP (average precision): 所有预测图片内某一类别 PR 曲线 (横轴为 Recall, 纵轴为 Precision) 下的面积，即

$$AP = \int_0^1 P(t) dt \quad (12)$$

mAP50: 当 IOU=0.5 时，所有类别的平均准确率，衡量模型检测好坏程度，即

$$mAP = \sum_{n=1}^N AP_n / N \quad (13)$$

为了验证改进的检测算法性能，将该模型与近几年

YOLO 系列模型以及不同尺度的 YOLOv11 算法进行对比实验, 见表 2。

表 2 算法对比结果

模型	P(%)	R(%)	mAP50(%)	mAP50:95(%)	参数量 (m)	模型大小 (MB)	GFLOPs
YOLOv7	54.8	55.6	56.3	40.2	36.6	71.6	103.6
YOLOv8s	84.6	79.4	87.2	67.5	11.1	21.4	28.5
CGS-Chost-YOLO <sup>[5]</sup>	67.7	61.1	66.0	46.8	6.3	12.2	17.0
YOLOv11n	76.0	70	77.8	58.4	2.59	5.5	6.3
YOLOv11s	86.9	75.7	86.4	65.8	9.4	18.3	21.4
YOLOv11m	89.0	80.6	90.0	69.4	20.1	40.6	67.8

从表 2 可知, YOLOv11 比起近几年的 YOLO 系列, 再精度、轻量化方面都优于 YOLOv7, 尤其是在轻量化方面, YOLOv11n 的模型大小比 YOLOv7 低了 66.1MB, 而同级别的 YOLOv8s 和 YOLOv11s 相比模型大小低了 3.1MB。在精确率上 YOLOv11s 比起 YOLOv7 和 YOLOv8s 分别高了 32.1% 和 2.3%。与同样做交通标志检测的 CGS-Chost-YOLO 相比精确率提升的很显著, 而模型大小和计算量只是略微提升。与不用尺度的 YOLOv11 相比, YOLOv11m 比起 YOLOv8 精

提高了 10.7、22.3MB 和 46.4。但 YOLOv11n 的精确率只有 76.0% 远远达不到交通目标检测的需求, 而 YOLOv11s 相比其提高了 10.9%, 但是轻量化方面损失较小, 因此选用 YOLOv11s 进行交通标志检测不仅精确率高, 而且模型体积和计算量相对较小, 能够更好的部署模型进行实际运用。

为了验证算法的通用性, 在 CCTSDB 数据集、RSOD-aircraft 数据集以及 SKU-100k 数据集进行了验证, 泛化实验结果见表 3。

表 3 泛化实验结果

评价指标	CCTSDB		RSOD-aircraft		SKU-100k	
	YOLOv8s	YOLOv11s	YOLOv8s	YOLOv11s	YOLOv8s	YOLOv11s
P(%)	81.5	90.1	95.1	97.4	90.9	91.4
R(%)	53.7	74.9	84.5	85.0	86.3	85.6
mAP50(%)	61.9	84.1	91.7	92.8	91.8	91.5
mAP50-95(%)	32.8	56.9	62.7	62.4	60.0	59.7

从表 3 可知, 在数据集 CCTSDB 上, YOLOv11s 在 P, R, mAP50 和 mAP50-95 指标上的全部数据均表现的原 YOLOv8s 模型优秀。在 RSOD-aircraft 上, 只有 mAP50-95 比 YOLOv8s 低了 0.3%。在 SKU-100k

数据集上, 虽然 R, mAP50 和 mAP50-95 平均低了 0.43%, 精确率 p 达到了 91.4%。因此 YOLOv11s 在不同数据集上都有较好的泛化性。

### 3. 结论

为了解决交通标志实时检测效果, 本文使用了 YOLOv11 系列中的 YOLOv11s 模型。该模型比起近几年的 YOLO 系列在精度和轻量化上都有较大的提升; 相比其他交通标志加测的算法, 其精度可以满足真实应用场景中的精度需求; 而相比不同尺度的 YOLOv11 系列, 其精度远远高于 YOLOv11n, 其模型大小、参数量和计算量远远低于 YOLOv11m, 且 YOLOv11m 比起 YOLOv11s 提升较小。而

YOLOv11s 以损失较小轻量化上的优势, 换取精度上较大的提升。该模型具有检测精度高、体积较小等优点与对比的模型相比 mAP50、参数量和 GFLOPs 均具有一定的优势, 实现了在高的检测精度条件下轻量化目标。因此, 该模型是精度高、体积较小的轻量化模型, 在交通标志检测上具有很强的应用前景。

### 参考文献:

- [1] 胡聪, 何晓晖, 邵发明, 等. 基于极大极稳定区域及 SVM 的交通标志检测 [J]. 计算机科学, 2022, 49(S1): 325-330.
- [2] 梁敏健, 崔啸宇, 宋青松, 等. 基于 HOG-Gabor 特征融合与 Softmax 分类器的交通标志识别方法 [J]. 交通运输工程
- [3] 李杰, 高尚兵, 胡序洋, 等. 基于 DL-SSD 模型的交通标志检测算法 [J]. 扬州大学学报 (自然科学版), 2022, 25(05): 47-53.

[4] 韦强, 胡晓阳, 赵虹鑫. 改进 YOLOv5 的交通标志检测方法 [J]. 计算机工程与应用, 2023, 59(13): 229–237.

[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.

**作者简介:**

胡斌 (2003—), 男, 汉族, 安徽省黄山市人, 大学本科,

研究方向为计算机视觉, 自动驾驶。

**基金项目:**

2023 年国家级大学生创新创业训练计划项目 (202313617006); 2022 年度高等学校省级质量工程项目 (S202213617007)。