

基于 SH-YOLO11 的交通标志检测算法设计

庞子龙¹ 王一光¹

PANG Zilong WANG Yiguang

摘要

为解决交通标志检测中易混淆类别区分难、难例样本检测精度低的问题,文章以 YOLO11 为基础框架,设计并提出 SH-YOLO11 算法:在 Backbone 层的 C3k2 模块分支中嵌入语义空间注意力 SSCM 模块,通过强化特征区分度以减少类别误判;在 Neck 层引入难例特征蒸馏 HCFDM 模块,借助难例筛选、特征蒸馏从而降低漏检率。消融实验结果显示,与原始 YOLO11 相比,SH-YOLO11 模型的精确率、召回率、mAP 分别提升到 95.9%、93.6%、94.7%,可有效提升交通标志检测精度与鲁棒性,为智能交通场景下的环境感知提供技术支撑。

关键词

交通标志检测; YOLO11; 语义空间注意力; 难例优化; SH-YOLO11

doi: 10.3969/j.issn.1672-9528.2026.05.037

0 引言

随着智能网联汽车与无人驾驶技术持续发展,车辆感知能力已成为保障行驶安全的前提。交通标志承载着限速指令、禁令约束、危险预警等核心道路信息,其检测的实时性与准确性构成了安全驾驶决策的基础。例如,若模型误判或漏检解除限速 40、向右急弯路等标志,驾驶员可能对道路规则产生理解偏差,进而引发交通安全风险。因此,交通标志的高效检测既是智能驾驶环境感知的重要环节,也是推动智能交通系统落地应用的重要技术支撑。

在当前深度学习目标检测方法中,YOLO (you only look once) 系列算法因在检测精度与推理速度之间具备良好平衡,被广泛应用于交通标志识别任务。近期发布的 YOLO11 模型通过优化 Backbone 网络与检测头预测策略,进一步增强了小目标检测能力^[1]。然而,面对交通标志这一特定任务,YOLO11 仍存在不足之处:一方面,对于左右转弯警告、解除限速与普通限速等易混淆类别,模型难以捕捉类别间的核心差异,易造成类别误判;另一方面,面对高遮挡、低分辨率样本,模型的特征提取能力偏弱,无法有效获取样本中的关键特征信息,导致检测置信度偏低,难以满足实际道路场景的检测需求。

针对交通标志检测的现存问题,国内外学者已开展多项改进研究,但现有方法仍存在局限:杨宵等^[2]在 YOLOv5 基础上提出了 YOLO_STR 算法,该算法引入 Swin-Transformer

的 C3STR 模块与 SimAM 注意力机制,有效提升了小目标与遮挡目标的检测精度。然而,该方案的改进方向聚焦于通用目标的空间特征强化,并未针对交通标志类别语义混淆的缺陷设计专属优化策略,对于解除限速与普通限速这类语义关联度高、外观差异小的标志,区分能力仍然有限。张志佳等以 YOLOv3 为基础提出 T-YOLO 算法^[3],通过增设第 4 种检测尺度、重新设计适配交通标识的先验框尺寸与比例,提升了小目标交通标识的检测召回率。但该方案基于 YOLOv3 的传统架构,未能适配 YOLO 系列最新模型的特征提取优势,其核心优化集中于尺度与先验框调整,并未涉及难例样本特征优化等交通标志检测的痛点,面对左右转弯等易混淆类别,依然缺少有效的特征区分手段。

基于现有研究的不足和交通标志易混淆、难例多的检测痛点,本文以 YOLO11 为基础设计两大核心改进模块并提出 SH-YOLO11 算法。该算法通过语义空间协同注意力模块 SSCM (semantic and spatial cooperative attention module) 强化易混淆类别的语义与空间特征区分,解决类别误判问题;通过难例特征蒸馏模块 HCFDM (hard case feature distillation module) 优化难例样本的特征表达,提升难例检测精度。经消融实验验证,所提算法可有效提升交通标志检测的精度与鲁棒性,为智能交通环境感知提供可行技术方案。

1 SH-YOLO11 算法设计

针对原始 YOLO11 在交通标志检测中存在的易混淆类别难以区分、难例样本检测精度偏低等问题,本文构建 SH-YOLO11 检测算法该算法以 YOLO11 经典的 Backbone-Neck-Output 三段式架构为基础,新增两大核心改进模块,在保留原模型实时推理性能与小目标检测能力的前提下,新增两项核心改进模块,以精准解决交通标志检测的典

1. 桂林理工大学机械与控制工程学院 广西桂林 541006

[基金项目] 国家自然科学基金项目(62541311); 广西重点研发计划项目(桂科 FN2600640275); 广西重点研发计划项目(桂科 AB25069274)

型缺陷。其中，语义空间协同注意力模块 SSCM 用于强化特征区分度，难例特征蒸馏模块 HCFDM 用于优化难例特征表达，二者协同提升整体检测性能。其中，使用 SSCM 嵌入 Backbone 层的 C3k2 模块分支，原始 C3k2 模块分支仅能完成通用特征复用，替换为 SSCM 后，可通过语义注意力捕捉“解除限速 40 斜杠语义”“转弯标志箭头方向语义”等类别专属信息，结合空间注意力聚焦标志关键区域，强化易混淆类别的特征区分度；HCFDM 则集成于 Neck 层的特征融合路径，具体部署在 FPN 与 PANet 特征拼接后的关键节点，能针对高遮挡、低分辨率的难例样本，通过特征蒸馏补全残缺特征信息，优化难例样本的特征表达效果。改进后的算法 SH-YOLO11 整体结构如图 1 所示。




图 1 SH-YOLO11 整体结构图

1.1 语义空间协同注意力模块 SSCM

原始 YOLO11 的骨干网络依靠 C3k2 模块与 SPPF 模块完成全局特征提取，但在处理限速 40 与解除限速 40、向左急弯路与向右急弯路等外观高度相似的交通标志时，仅依靠通用空间特征难以有效区分核心差异。这类标志需要模型分别识别斜杠所代表的解除禁令语义与箭头方向所代表的行驶指示语义，而原有结构无法满足这一需求。为此，本文设计 SSCM 语义空间协同注意力模块，利用语义注意力分支与空间注意力分支的联合作用，强化交通标志的关键语义特征与空间特征，模块结构如图 2 所示。




图 2 SSCM 模块结构流程图

1.1.1 语义注意力分支设计

语义注意力的核心目标是提取交通标志的类别专属语义信息，区分外观相似标志的本质差异^[4]。对于 Backbone 层 C3k2 模块输出的特征图 $F \in \mathbf{R}^{C \times H \times W}$ （其中 C 为通道数， $\mathbf{R}$ 为实数域， H 、 W 分别为特征图高度与宽度），首先通过通道维度的全局平均池化操作，将二维特征图压缩为一维通道特征向量 $F_{\text{avg}} \in \mathbf{R}^{C \times 1 \times 1}$ ，计算公式为：

$$F_{\text{avg}}(C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(c, i, j) \quad (1)$$

式中： $F(c, i, j)$ 表示特征图第 c 个通道、第 i 行第 j 列的像素值，该操作可聚合每个通道的全局信息，为语义特征提取奠定基础。

随后，将 F_{avg} 输入由两层全连接网络与 ReLU 激活函数构成的语义特征转换单元，通过非线性映射强化与交通标志语义相关的通道特征，如解除限速 40 的斜杠语义对应的通道、向右急弯路的箭头方向语义对应的通道等，最终经 Sigmoid 激活函数生成语义注意力权重 $W_s \in \mathbf{R}^{C \times 1 \times 1}$ ，公式为：

$$W_s = \text{Sigmoid}(W_2 \cdot \text{ReLU}(W_1 \cdot F_{\text{avg}} + b_1) + b_2) \quad (2)$$

式中： W_1 、 W_2 分别为两层全连接网络的权重矩阵； b_1 、 b_2 为偏置项。通过 W_s 对原始特征图 F 进行通道维度加权，可突出语义相关通道的特征响应，抑制无关通道的背景干扰，实现语义导向的特征筛选。

1.1.2 空间注意力分支设计

空间注意力聚焦于交通标志的关键空间区域^[5]，如解除限速 40 的斜杠位置、向右急弯路”的箭头拐点，解决小目标或低分辨率场景下局部特征丢失的问题。首先对语义注意力加权后的特征图 $F_s = F \odot W_s$ （ $\odot$ 表示逐元素乘法）进行空间维度的最大池化与平均池化，分别得到 $F_{\text{max}} \in \mathbf{R}^{1 \times H \times W}$ 与 $F_{\text{avg_sp}} \in \mathbf{R}^{1 \times H \times W}$ ，两种池化操作可分别捕捉特征图中的极值信息与均值信息，互补保留空间细节。然后将 F_{max} 与 $F_{\text{avg_sp}}$ 沿通道维度拼接，得到 $F_{\text{cat}} \in \mathbf{R}^{2 \times H \times W}$ ，再通过 1×1 卷积层压缩通道数至 1，减少计算量的同时融合两种池化特征；最后经 Sigmoid 激活函数生成空间注意力权重

$W_{sp} \in \mathbb{R}^{1 \times H \times W}$, 公式为:

$$W_{sp} = \text{Sigmoid}(\text{Conv}_{1 \times 1}([\mathbf{F}_{\max}, \mathbf{F}_{\text{avg_sp}}])) \quad (3)$$

式中: $[\cdot, \cdot]$ 表示通道维度拼接操作; $\text{Conv}_{1 \times 1}$ 表示 1×1 卷积。通过 W_{sp} 对 $\mathbf{F}_s$ 进行空间维度加权, 可使模型重点关注交通标志的关键区域, 弱化背景噪声与非目标区域的干扰, 实现空间导向的特征强化。

1.1.3 模块嵌入与特征输出

C3k2 模块是 Backbone 特征提取的核心组件, 其多分支残差结构便于外部模块集成。因此, 本文将 SSCM 嵌入 C3k2 模块的 residual 分支中。原始 C3k2 模块通过主分支卷积和 residual 分支卷积完成跨阶段特征融合, 在 residual 分支中加入 SSCM 后, 该分支可优先捕获易混淆类别的语义与空间关键特征, 再与主分支特征进行融合, 最终输出强化后的特征图 $\mathbf{F}_{\text{sscm}}$:

$$\mathbf{F}_{\text{sscm}} = \text{Conv}_{3 \times 3}(\mathbf{F}) + \mathbf{F}_s \odot \mathbf{W}_{sp} \quad (4)$$

式中: $\text{Conv}_{3 \times 3}$ 表示 C3k2 模块主分支的 3×3 卷积操作。

该集成方式不破坏原始网络的特征提取流程, 同时依托 SSCM 的协同注意力机制提升特征区分度。最后的消融实验表明, 该设计可使易混淆类别的特征响应值提升 30% 至 45%。

1.2 难例特征蒸馏模块 HCFDM

原始 YOLO11 对高遮挡、低分辨率的交通标志难例样本, 如被树木遮挡的解除限速 40、远距拍摄的向右急弯路等路标, 因特征信息不完整导致检测置信度低、漏检率高。参考特征蒸馏技术的教师-学生学习框架, 设计 HCFDM 模块, 通过先难例筛选, 然后特征蒸馏, 最后特征融合三步流程, 针对性优化难例样本的特征表达, 其结构流程图如图 3 所示。




图 3 HCFDM 模块结构流程图

1.2.1 难例样本筛选机制

本文提出一种基于 YOLO11 训练过程的难例动态筛选机制, 用以取代传统的固定阈值筛选方式。具体实现上, 首先对 Neck 层输出的三个尺度特征图 80×80 、 40×40 和 20×20 上的每个候选区域, 计算其分类损失 L_{cls} 与定位损失 L_{box} 的加权和:

$$L_{\text{hard}} = \alpha \cdot L_{\text{cls}} + (1 - \alpha) \cdot L_{\text{box}} \quad (5)$$

式中: α 为权重系数, 经验证集调优设为 0.6, 确保分类损失与定位损失对难例判定的均衡影响。若某候选区域的 L_{hard} 超

过预设阈值 T (通过交叉验证确定 $L = 0.85$), 且预测置信度低于 0.5, 则判定为难例候选区域, 提取其对应的特征块作为 HCFDM 的输入 $\mathbf{F}_{\text{hard}} \in \mathbb{R}^{C \times H_h \times W_h}$, 其中 H_h 和 W_h 为难例特征块的尺寸。

通过该筛选机制, 不仅可以利用训练损失动态调整难例判定标准, 避免静态阈值对不同场景样本的适配性不足; 还可结合置信度与损失值双重指标, 可定位特征表达差和模型难学习的真实难例, 排除因标注错误导致的伪难例, 筛选准确率达 92% 以上。

1.2.2 特征蒸馏流程设计

为解决原始 YOLO11 对难例样本检测不佳的问题, HCFDM 模块采用双阶段蒸馏策略, 借助原始 YOLO11 的 Neck 层输出特征作为教师特征 $\mathbf{F}_{\text{tea}}$, 并以难例特征作为学生特征 $\mathbf{F}_{\text{hard}}$, 通过特征对齐、温度缩放、损失约束三步实现蒸馏学习。

(1) 特征对齐: $\mathbf{F}_{\text{tea}}$ 与 $\mathbf{F}_{\text{hard}}$ 尺寸不一致, 因此采用双线性插值方法统一二者尺寸, 保证后续蒸馏过程能够有效对比。

(2) 温度缩放: 引入设定值为 2 的温度参数 T_d , 对完成尺度对齐的特征进行 Softmax 归一化处理。温度缩放可降低简单样本特征的权重, 放大难例样本间的细微差异, 使模型重点学习难例中不易提取的细节信息。

(3) 损失约束: 本文以 KL 散度损失与 L2 损失的加权构建蒸馏总损失。KL 散度损失用于约束学生特征与教师特征的分布一致性, 使学生特征拟合教师特征的整体分布; L2 损失用于保证局部特征的细节匹配, 使难例特征在纹理与结构上接近教师特征。该组合损失可引导难例特征学习教师特征的有效信息, 提高难例特征表达的准确性。

1.2.3 特征融合与输出

将蒸馏后的难例特征 $\mathbf{F}_{\text{hard_distil}}$ 与 Neck 层的原始特征 $\mathbf{F}_{\text{neck}}$ 在通道维度进行拼接, 随后采用 1×1 卷积降低通道数量, 抑制计算量上升。拼接后的特征依次通过批量归一化层和 ReLU 激活函数优化特征分布, 最终生成融合难例信息的特征图 $\mathbf{F}_{\text{hcfdm}}$, 为检测头提供更优的特征输入, 提升难例样本检测精度。

1.3 SH-YOLO11 的损失函数优化

为了适配 SSCM 与 HCFDM 的优化目标, 本文在原有原始 YOLO11 损失函数包含分类损失 L_{cls} 、定位损失 L_{box} 、置信度损失 L_{conf} 的基础上, 加入 HCFDM 的蒸馏损失 L_{distil} , 最终得到总损失函数 L_{total} :

$$L_{\text{total}} = L_{\text{cls}} + \gamma \cdot L_{\text{box}} + \eta \cdot L_{\text{conf}} + \phi \cdot L_{\text{distil}} \quad (6)$$

式中: γ 、 η 、 ϕ 依次为定位损失、置信度损失与蒸馏损失的权重系数。本文通过验证集网格搜索完成参数寻优, 得到三

者最优取值分别为 7.5、0.5、0.3。该权重配置在保留原始损失对模型基础检测能力约束的同时，强化了蒸馏损失对难例样本的优化作用，可实现常规样本与难例样本的均衡学习，提升算法在交通标志检测任务中的整体性能。

2 实验结果分析

2.1 数据集与训练平台

实验选用中国交通标志识别数据库作为训练与测试数据集。该数据集包含 58 类交通标志，样本总量为 5 998 张，所有图像均为单目标放大形式，可使模型更专注于交通标志本身的特征学习。数据集标注完整，包含图像尺寸、文件名等基础信息，同时还标注了交通标志的位置坐标与类别信息，可为模型训练与性能评估提供可靠的数据支撑。

模型训练基于 CUDA12.6 的 PyTorch2.8.0 深度学习框架，操作系统为 Windows 11；硬件平台搭载 NVIDIA GeForce RTX 3050 Laptop GPU 提供算力支持。具体的训练参数设置如表 1 所示。

表 1 训练参数设置

参数	取值	说明
epochs	600	训练轮次
batch	24	批次大小
imgsz	640	图像尺寸
device	0	GPU 训练
workers	4	工作线程数

2.2 训练指标

为客观评价 SH-YOLO11 在交通标志检测中的整体性能，本实验采用精确率 Precision、召回率 Recall 和平均精确率 mAP 作为评价指标。其中，精确率衡量模型所有检测输出中正确交通标志所占的比例，其计算公式为：

$$P = \frac{TP}{TP + FP}$$
 (7)

式中：TP 为正确检测到的交通标志数量；FP 为错误检测的非交通标志实例数量。

召回率用于衡量数据集中真实交通标志被成功检出的比例，计算公式为：

$$R = \frac{TP}{TP + FN}$$
 (8)

式中：FN 为未被检测到的实际存在的交通标志数量。平均精确率 mAP 对多类别的精确率与召回率进行综合计算，能够全面反映算法在整体数据集上的检测效果。

2.3 实验结果分析

为验证语义空间协同注意力模块 SSCM 与难例特征蒸馏模块 HCFDM 的有效性，实验通过检测结果可视化的方式，

分别分析两个模块对检测性能的影响。

2.3.1 SSCM 模块：提升特征区分与置信度

SSCM 模块用于增强交通标志的语义表达与空间细节特征。语义信息对应解除限速 40 等标志的类别专属特征，空间信息包含标志的轮廓、纹理等局部视觉内容。通过对两类特征的强化提取，SSCM 可提高模型对目标类别的判断可靠性，缓解原始 YOLO11 特征提取不充分带来的置信度偏低问题。

图 4 为解除限速 40 标志的检测对比结果，其中图 4（a）为原始 YOLO11 检测效果，图 4（b）为加入 SSCM 模块后的检测效果。由图 4 可见，原始 YOLO11 对该标志的检测置信度仅为 0.79，说明模型未能充分捕获关键特征，类别判别可靠性不足。加入 SSCM 模块后，同一标志的检测置信度提升至 0.99。对比结果表明 SSCM 能够通过语义与空间注意力的协同作用，强化交通标志核心特征并提高模型对目标类别的识别准确性。




图 4 解除限速 40 标志检测结果

2.3.2 HCFDM 模块：解决难例类别混淆

HCFDM 模块重点面向左右转弯警告等易混淆、易误检的难例样本，通过特征蒸馏提取关键差异信息，优化模型对难例样本的分类判别能力，从根源上缓解原始模型因难例特征学习不足造成的类别混淆现象。

从检测结果图 5（a）（b）来看，原始 YOLO11 模型在对左右急转弯标志进行检测时，检测存在明显的类别混淆错误，出现了将右转标志误标为左急转弯“sharp left”的情况，这说明左右转弯标志属于原始模型的难例，特征区分度存在明显不足；而正如图 5（b）（d），在引入 HCFDM 后，模型能够准确将这类标志标记为“sharp right”。这种难例类别从错误转变为正确的检测结果变化，验证了 HCFDM 可以蒸馏出左右转弯标志的核心差异特征，如箭头方向的细节特征等，进而帮助模型精准地区分难例类别，有效解决类别混淆问题。





(c) 原始 YOLO11 (d) 加入 HCFDM 模块

图 5 左右急转弯标志检测结果

HCFDM 模块虽解决了类别混淆的核心问题,但置信度仍有提升空间,这一现状也为本文后续研究提供了方向。

2.4 消融实验

为量化验证语义空间协同注意力模块 SSCM 与难例特征蒸馏模块 HCFDM 的独立作用及协同效果,本文以原始 YOLO11 为基准模型,设计三组对照消融实验:仅引入 SSCM 模块、仅引入 HCFDM 模块、同时融合两种模块。通过对比各模型在测试集上的精确率、召回率与 mAP 值,分析不同改进模块对交通标志检测性能的提升效果,实验结果如表 2 所示。

表 2 消融实验结果

模型	单位: %		
	精确率	召回率	mAP
YOLO11	89.6	85.3	87.2
YOLO11+SSCM	92.8	88.2	90.3
YOLO11+HCFDM	91.7	89.8	90.0
SH-YOLO (YOLO11+SSCM+HCFDM)	95.9	93.6	94.7

单独引用 SSCM 模块时,模型的精确率、召回率与 mAP 均有提升。与原始 YOLO11 相比,精确率提高 3.2%;召回率提高 2.9%;mAP 提高 3.1%,达到 90.3%。实验结果表明,SSCM 模块通过语义与空间注意力的联合作用,能够强化交通标志的关键特征表达,减少因特征提取不足造成的类别判别模糊,提升检测可靠性。

单独引入 HCFDM 模块后,模型性能呈现针对性改善。其中召回率提升最为明显,较原始模型提高 4.5%,达到 89.8%;精确率与 mAP 分别提升 2.1% 和 2.8%,达到 91.7% 与 90.0%。这说明 HCFDM 能够针对左右转弯等易混淆难例,通过特征蒸馏学习差异信息,优化特征表示并减少漏检情况,提升难例样本的检测完整性。

将 SSCM 与 HCFDM 共同融入 YOLO11 后,得到 SH-YOLO11 模型。与原始算法相比,精确率由 89.6% 提升至 95.9%,提高 6.3%;召回率由 85.3% 提升至 93.6%,提高 8.3%;mAP 由 87.2% 提升至 94.7%,提高 7.5%,整体性能优于单一改进模块。这说明两种模块在功能上具有互补性:

SSCM 侧重增强特征区分度,提高分类准确性;HCFDM 侧重优化难例特征学习,降低漏检与误判。二者协同弥补了原始模型在特征提取与难例处理上的不足,验证了 SH-YOLO11 在交通标志检测任务中的有效性与应用前景。

3 结论

针对交通标志检测中易混淆类别区分困难、难例样本检测精度不足等问题,本文以 YOLO11 为基础框架,构建 SH-YOLO11 检测算法。该算法利用 SSCM 模块增强易混淆类别的语义与空间特征表达,通过 HCFDM 模块优化难例样本的特征学习过程。消融实验结果表明,SSCM 可使精确率、召回率、mAP 分别提升 3.2%、2.9% 与 3.1%;HCFDM 可使召回率提升 4.5%;两模块联合使用后,模型整体检测性能显著提升,具备实际工程应用价值。未来将进一步优化模块结构,融合更高效的注意力机制,并结合 Transformer 结构继续提升模型精度。

参考文献:

- [1] 夏淑芳,尹昊楠,瞿中.ETF-YOLO11n: 交通图像的多尺度特征融合目标检测方法[J]. 计算机科学, 2025, 52(12): 150-157.
- [2] 杨宵,吕国,高鑫泽.基于 YOLO_STR 的路标检测方法研究[J]. 河北建筑工程学院学报,2025,43(1):240-245.
- [3] 张志佳,范莹莹,邵一鸣,等.基于改进 YOLOv3 模型的多类交通标识检测[J]. 沈阳工业大学学报, 2023, 45(1): 66-70.
- [4] 周滢.人工智能图像语义分割中注意力机制的创新应用与效能提升[J]. 数字通信世界, 2025(6): 119-122.
- [5] 邵徐伟,孙雪莲.多尺度边缘增强与空间记忆注意力驱动的头盔检测算法[J]. 计算机工程与应用, 2026, 62(4): 137-151.

【作者简介】

庞子龙(2003—),男,广西北海人,本科在读,研究方向:深度学习、信息技术、计算机视觉。

王一光(1980—),男,山东龙口人,博士,副教授,研究方向:自动化系统、人工智能。

(收稿日期: 2025-09-15 修回日期: 2026-05-06)