光电技术及应用

DOI：10.16818/j.issn1001－5868.20260512004

基于改进RT-DETR的低光照交通标志检测识别算法

孟奥运*，陈世国

（贵州师范大学 物理与电子科学学院，贵阳 550025）

摘　要： 针对夜间低光照环境下噪声干扰强造成关键特征丢失、交通标志检测精度下降的问题，文章提出一种基于改进实时端到端目标检测器（RT-DETR）的低光照交通标志检测识别算法。在特征提取阶段，引入轻量级网络RepViT重构主干网络，提升对低分辨率模糊目标的特征学习能力。设计低光照小目标增强模块（LSEM），采用通道级特征重标定与空间多尺度感知相协同，有效突出高亮通道响应并抑制暗区噪声。在解码器输入端加入非对称方向特征增强（ADFE）模块，利用大核条形卷积扩大方向感受野，减弱局部暗噪声对边缘特征的干扰，精准检测由反光材质保留的几何边界。在CNTSSS夜间交通标志数据集上的实验结果表明，改进模型的参数量和计算量相比未改进的分别减少了30.7%和27.8%，平均精度均值提升了2.1%，达到90.2%，在夜间交通标志检测任务中表现出较好的检测性能。

关键词： 目标检测；低光照；交通标志；RT-DETR；特征提取

中图分类号： TP391.4　**文章编号：** 1001－5868(2026)05－0961－07

Low-Light Traffic Sign Detection and Recognition Based on an Improved RT-DETR Network

MENG Aoyun, CHEN Shiguo

(School of Physics and Electronic Science, Guizhou Normal University, Guiyang 550025, CHN)

Abstract: To address the problem of reduced traffic sign detection accuracy in intelligent driving systems under nighttime low-light conditions owing to strong noise interference and the loss of critical features, this paper proposes a low-light traffic sign detection and recognition algorithm based on an improved Real-Time Detection Transformer (RT-DETR) framework. In the feature extraction stage, a lightweight RepViT network is introduced to reconstruct the backbone network, thereby enhancing the feature learning capability for low-resolution and blurred targets. In addition, a Low-light Small-target Enhancement Module (LSEM) is designed to combine channel-level feature recalibration with spatial multiscale perception to effectively emphasize high-response channels while suppressing noise in dark regions. Furthermore, an Asymmetric Directional Feature Enhancement (ADFE) module is incorporated at the decoder input stage. By employing large-kernel strip convolutions to expand the directional receptive field, the module reduces the effect of local dark noise on edge features and improves the perception of geometric boundaries preserved by reflective materials. Experimental results on the CNTSSS nighttime traffic sign dataset demonstrate that the proposed model reduces the number of parameters and computational cost by 30.7% and 27.8%, respectively, while improving mAP@50 by 2.1% to 90.2%. The proposed method achieves

收稿日期：2026－05－12.

基金项目：国家自然科学基金项目(62465006)；2026年贵州省基础研究计划重点项目(QKHJCZD[2026]110)；贵州省科技计划项目(黔科合平台SSYS[2025]重大005,006,QKH[2025]ZD021).

* **通信作者：**孟奥运

favorable performance in nighttime traffic sign detection tasks.

Key words: object detection; low-light; traffic signs; RT-DETR; feature extraction

0 引言

随着智能辅助驾驶系统的快速发展,交通标志检测是驾驶系统环境感知的关键任务,直接关系决策准确性与行车安全[1]。现有自动驾驶算法在白天良好光照下性能优异,而在夜间低光照环境下,其对交通标志的检测识别精度较低。

与白天场景相比,夜间图像存在亮度不足、噪声增加和局部对比度下降等问题。虽然交通标志表面通常覆盖逆反射材料,但受环境光不足与成像噪声影响,交通标志内部纹理容易退化,目标特征减弱。同时,交通标志尺度小、远距离像素有限,低光照下更易漏检误检。此外,夜间道路中车辆灯光、霓虹灯以及高亮反射区域还会进一步干扰模型对真实目标区域的定位,增加检测任务的难度。针对低光照交通标志检测问题,目前研究主要围绕图像增强与检测网络优化两个方向展开。Lin等[2]提出一种专为低光照环境设计的端到端实时交通标志检测算法(YOLO-LLTS),该算法通过先验引导增强模块改善图像质量,并结合多分支特征交互网络,从而保留了远距离微小标志的关键信息,在多个夜间数据集上取得了最优结果。Luo等[3]设计了一个基于Retinex理论的图像自适应增强模块,该模块通过参数估计网络自动调整Retinex图像增强算法的关键超参数,以实现对低光照图像的自适应增强。Wang等[4]提出一种结合低光图像增强与小目标检测的交通标志检测方法,并针对轻量级交通标志检测模型的需求及不同图像质量,调整了模型结构。He等[5]提出一种基于改进YOLOv5的夜间交通标志检测方法NTS-YOLO,该方法使用无监督夜间图像增强技术预处理交通标志数据集,然后引入CBAM注意力机制和OTA损失函数,以增强模型在复杂背景和光照不均条件下的感知能力。Mishra等[6]提出自适应图像增强与多模态图推理相结合的夜间交通标志识别方法,该方法结合了联合光照校正与标志定位的检测阶段以及基于视觉-语言特征融合的分类阶段,并针对夜间光照条件多变的需求及对不同图像视觉噪声的适应性引入了动态预处理模块与跨模态注意力机制。上述研究在一定程度上改善了夜间交通标志检测效果,但仍存在一些不足。部分方法较为依赖图像预增强过程,在复杂噪声条件下容易引入额外伪特征;部分检测网络虽然提高了精度,但模型规模与计算量较大,不利于车载平台部署;另外,现有方法对于低光照条件下目标边界弱化、方向结构信息退化等问题关注不足,导致模型在暗背景场景中仍容易出现目标响应不稳定的情况。

近年来,实时端到端目标检测器(RT-DETR)作为一种端到端实时目标检测框架,在检测精度与推理速度之间取得了较好的平衡。其通过高效混合编码器与IoU感知查询机制降低了传统Transformer检测器的计算开销,在实时检测任务中表现出较好的应用潜力。然而,RT-DETR原始结构主要面向常规视觉场景设计,对于低光照条件下的弱纹理、小目标以及方向性边界特征缺乏针对性建模,导致其在夜间交通标志检测任务中仍存在特征表达不足的问题。

针对上述问题,对RT-DETR网络进行改进。首先,引入轻量化RepViT重构主干网络,以增强模型对低分辨率与模糊目标的特征提取能力;其次,设计低光照小目标增强模块(LSEM),通过通道-空间协同方式对低光照条件下的有效特征进行增强,并抑制背景噪声干扰;最后,进一步构建非对称方向特征增强(ADFE)模块,利用非对称卷积对交通标志结构方向信息进行建模,以提高模型对弱边界目标的感知能力。

1 RT-DETR网络结构

RT-DETR[7]是一种兼顾高精度与高推理速度的端到端目标检测模型。其网络核心主要由主干网络、高效混合编码器与带有查询选择机制的解码器构成。主干网络输出的多尺度特征首先进入高效混合编码器。该编码器通过仅在最高层特征进行尺度内交互(AIFI),结合基于CNN的跨尺度双向融合(CCFM),大幅降低了自注意力的计算开销。解码阶段采用IoU感知查询选择,筛选高质量的编码特征作为初始查询以取代随机初始化。最终,查询向量经Transformer解码后直接输出预测结果,在加速模型收敛的同时保障了端到端的实时推理性能。本文选用RT-DETR-R18作为基线模型,其结构如图1所示。

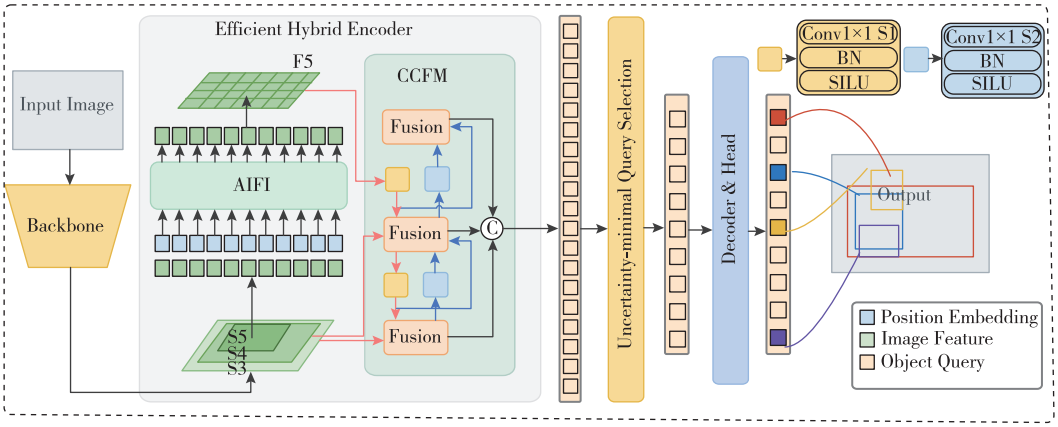


图 1　RT-DETR-R18 模型结构图

2　改进 RT-DETR 模型

2.1　RepViT 网络

在低光照条件下，由于入射光子数量减少，图像信噪比下降，交通标志内部纹理细节与边缘梯度响应减弱，采用 RepViT[8] 对主干网络进行重构。该网络借鉴视觉 Transformer 的设计思路，对传统纯卷积结构进行了重新组织，整体由初始卷积模块、四个特征提取阶段以及独立的下采样层构成。RepViT 结构图如图 2 所示。

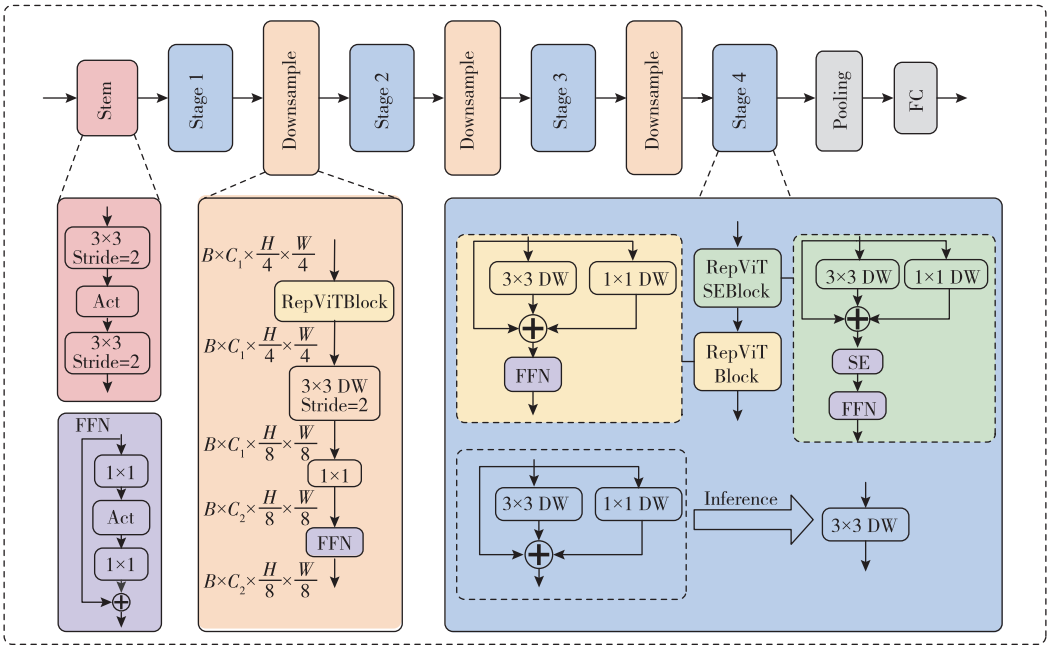


图 2　RepViT 网络结构图

在特征提取过程中，Stem 模块优先保留输入图像中的浅层边缘和纹理信息，为后面模糊目标的辨识提供基础。各阶段中的 RepViT Block 将空间建模与通道交互拆分处理，再结合结构重参数化[9]，使网络在推理开销变化不大的情况下，仍能提升对低分辨率目标的感知能力。跨层加入的 SE[10] 注意力机制会重新分配不同通道的响应强度，与目标相关的区域更加突出。下采样部分采用相对缓和的压缩方式，尽量保留降维过程中的局部细节，因此对模糊交通标志的检测效果有所改善。

2.2　LSEM 设计

夜间交通标志存在通道响应分布不均衡的问题，导致背景大面积偏暗。本文构建的 LSEM 如图 3 所示，从通道和空间两个层面对特征进行提取，以提高复杂光照环境下交通标志的检测稳定性。模块整体由“通道级光照特征筛选”和“空间级多尺度上下文建模”两部分组成，首先，输入特征被送入光照感知通道注意力（IACA）子模块，不同于传统的

ECA模块仅依赖全局平均池化，该部分采用全局平均池化与最大池化并行提取特征，一方面描述整体光照分布，另一方面保留局部高响应区域的信息；随后，通过共享多层感知机（MLP）和Sigmoid函数生成对应的通道权重。经过这一过程，不同通道的重要性被重新分配，与交通标志相关的高响应通道得到强化，同时减弱暗背景区域带来的噪声干扰。调整后的特征进一步进入多尺度上下文特征（MSCF）子模块。该模块设置4个并行分支，包括1个1×1卷积分支以及3个空洞率分别为1，2，3的3×3空洞卷积分支，在保持特征图分辨率不变的情况下扩大感受范围，从不同尺度提取目标本身及其周围环境信息。最后，将各分支输出进行拼接，并通过1×1卷积完成特征融合，使夜间场景中原本较弱的小目标表征得到补偿，从而提升检测阶段对低光照交通标志的识别能力。

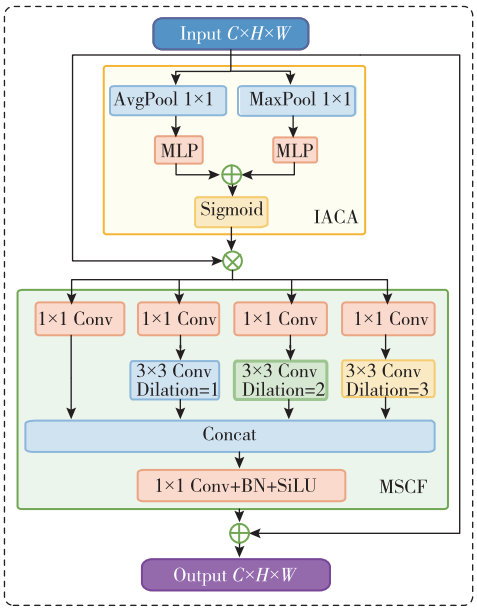


图3 LSEM结构图

2.3 ADFE模块设计

在低光照交通标志检测中，图像边缘模糊容易使交通标志的方向性特征被暗背景掩盖。RT-DETR在特征提取阶段主要依赖对称感受野，对弱高频细节的保留能力有限，容易使细小结构在传递过程中被平滑，影响解码器对目标细节的识别。

为改善该问题，本文在RT-DETR检测头解码器输入端设计ADFE模块，其结构如图4所示。该模块先对颈部网络输出的特征分别施加1×7和7×1的条形卷积，以横向和纵向两个方向对局部信息进行建模。由于这种卷积形式与交通标志中箭头、边框等细长结构在空间上的延展方式更为接近，能够在特定方向上建立更长的局部关联范围，从而减弱随机噪声对连续边缘响应的破坏。在此基础上，模块进一步利用动态注意力门控机制对不同方向的特征进行自适应融合，并在二维特征展平为序列前，将方向信息提前注入解码器输入中，使解码器在目标查询过程中能更稳定关注具有结构判别性的区域，降低低光照条件下弱边界目标的漏检率。

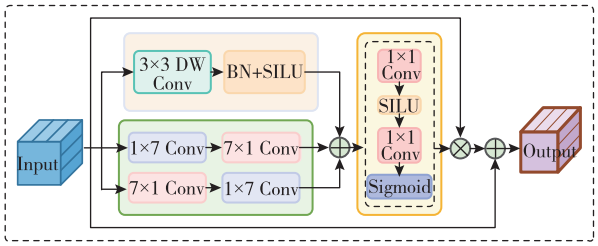


图4 ADFE模块结构图

给定输入特征图$X\in\mathbb{R}^{C\times H\times W}$，其中$C$，$H$，$W$分别代表通道数、高度和宽度。ADFE模块首先通过三个并行的分支对进行处理，以分别捕捉基础上下文、水平方向先验和垂直方向先验。

上下文分支：使用3×3深度可分离卷积[11]来保留局部空间上下文信息：

$$F_{\mathrm{ctx}}=\mathcal{B}\left[\mathrm{Conv}_{3\times3}^{dw}(X)\right] \tag{1}$$

水平条形分支：利用1×7和7×1的非对称深度卷积序列，专门捕获沿水平方向延伸的细粒度特征：

$$F_{\mathrm{h}}=\mathcal{B}\left\{\mathrm{Conv}_{7\times1}^{dw}\left\{\mathcal{B}\left[\mathrm{Conv}_{1\times7}^{dw}(X)\right]\right\}\right\} \tag{2}$$

垂直条形分支：利用相反顺序的卷积序列，专门捕获沿垂直方向延伸的特征：

$$F_{\mathrm{v}}=\mathcal{B}\left\{\mathrm{Conv}_{1\times7}^{dw}\left\{\mathcal{B}\left[\mathrm{Conv}_{7\times1}^{dw}(X)\right]\right\}\right\} \tag{3}$$

为了让网络自适应地选择重要特征并抑制背景噪声，将上述三个分支提取的特征进行逐元素相加融合，随后送入由1×1点卷积构成的瓶颈结构中，生成空间-方向联合注意力图$A\in\mathbb{R}^{C\times H\times W}$：

$$F_{\mathrm{agg}}=F_{\mathrm{ctx}}\oplus F_{\mathrm{h}}\oplus F_{\mathrm{v}} \tag{4}$$

$$A=\sigma\left\{W_2\delta\left[\mathcal{B}(W_1F_{\mathrm{agg}})\right]\right\} \tag{5}$$

式中，$\mathcal{B}(\cdot)$代表批量归一化；$\oplus$表示逐元素相加操作；$W_1\in\mathbb{R}^{\frac{C}{2}\times C}$为降维点卷积的权重矩阵；$W_2\in\mathbb{R}^{C\times\frac{C}{2}}$为升维点卷积的权重矩阵；$\delta(\cdot)$代表SiLU（Swish-1）激活函数；$\sigma(\cdot)$代表Sigmoid激活函数，用于将注意力权重归一化到（0，1）区间。

2.4　改进 RT-DETR 网络结构

在 RT-DETR-R18 的基础上进行改进，主要包含三项关键的网络结构优化：其一，采用轻量化的 RepViT 架构对主干网络进行替换与优化，以提升特征提取的效率；其二，在高效混合编码器中引入 LSEM，增强底层多尺度特征在进入跨尺度特征融合模块之前的空间表达能力；其三，在编码器与解码器之间设计 ADFE 特征增强模块，用于对多尺度融合后的特征进行深度的整合与提炼。具体架构如图 5 所示。

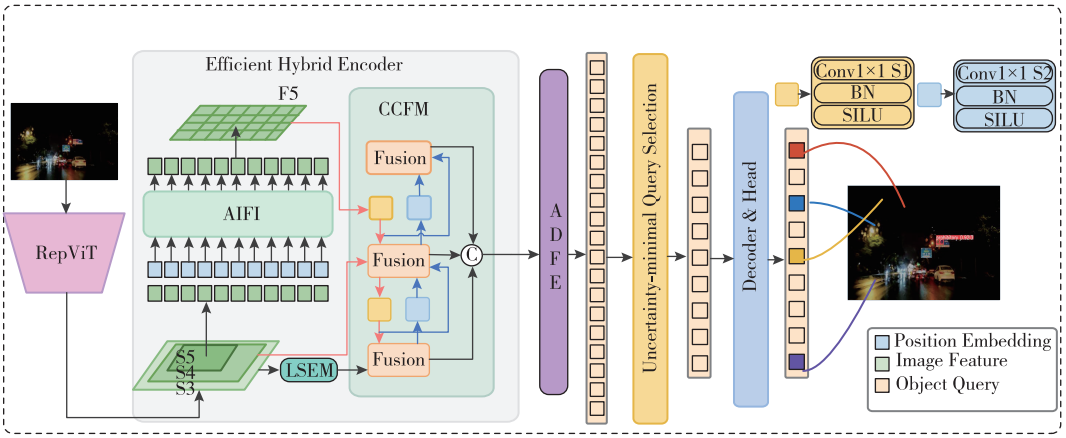


图 5　改进 RT-DETR-R18 模型结构图

3　实验结果与分析

3.1　数据集

CNTSSS 数据集[2]是国内研究团队采集的夜间低光照交通标志数据集，覆盖中国 17 个城市，场景类型包括城市道路、高速公路、乡村道路等，共计 4 062 张高质量的夜间交通标志图像，其中数据集交通标志的划分依据见图 6。实验按照 8∶1∶1 的比例将数据集划分为训练集、验证集、测试集。

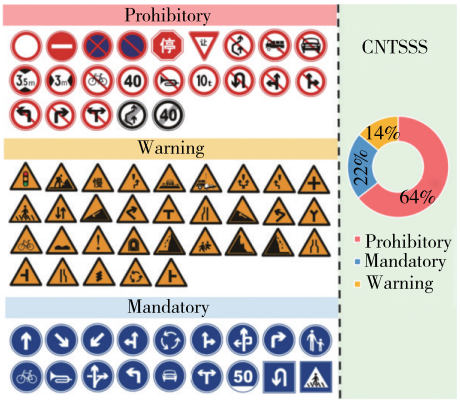


图 6　CNTSSS 三类交通标志

3.2　实验环境与参数设置

采用 Windows11 的操作系统，CPU 为 13th Gen Intel（R）Core（TM）i9-13900K，GPU 为 NVIDIA GeForce RTX4080，开发环境为 Pycharm，编译环境为 Python 3.9，Pytorch 1.13.1 和 CUDA 11.7。训练的相关参数有训练轮数为 150，批次大小为 8，线程数为 4，输入图像分辨率大小为 640×640，初始学习率为 0.01，采用 AdamW 优化器。

3.3　评价指标

采用精确率（P）、召回率（R）、平均精度均值（mAP@50/mAP@50-95）、参数量（Parameters）、计算量（GFLOPs）和帧率作为对交通标志检测识别的指标。参数量用于评估模型的存储占用，精确率、召回率和平均精度均值越接近 1，说明模型检测准确率越高，相应的计算公式如下：

$$P=\frac{TP}{TP+FP} \tag{6}$$

$$R=\frac{TP}{TP+FN} \tag{7}$$

$$AP=\int_0^1 P(R)\mathrm{d}R \tag{8}$$

$$mAP=\frac{1}{N}\sum_{N}^{i=1}AP_i \tag{9}$$

式中，TP 是模型正确预测为正类别的样本数，FP 模型错误预测为正类别的样本数，FN 是错误预测为非目标的样本数，N 是类别的总数。

3.4　消融实验

为验证各模块对模型整体性能的贡献，本文以 RT-DETR-R18 为基准模型开展了系统性的消融实验，并详细分析了不同模块组合对各项性能指标的具体影响，结果如表 1 所示。由表可知，使用 RepViT 替换原模型的主干网络后，虽然 mAP@50

下降了0.5%，但模型参数量由19.9 M下降至约13.3 M，计算量减少到36.8 GFLOPs，帧率由73.42 FPS提升至80.57 FPS，模型推理效率得到了提升。在加入ADFE模块后，模型特征融合效果得到了改善，mAP@50提升至89.8%。在加入LSEM后，模型的特征表达能力得到了提升，mAP@50提升至89.3%。当RepViT与ADFE组合使用时，有效弥补了精度损失，mAP@50达到89.2%。最后，将RepViT，ADFE与LSEM同时引入RT-DETR-R18后，模型参数量和计算量相比基准网络分别降低30.7%和27.8%，同时mAP@50提升至90.2%，较原模型提高2.1%，帧率虽略低于原模型，但仍满足实时检测需求。结果表明，各改进模块之间具有较好的互补性，在控制模型复杂度的同时能够有效提升检测性能。图7的折线图反映改进前后的mAP@50的变化。

表1 消融实验

Model	RepViT	ADFE	LSEM	*P*/%	*R*/%	*mAP@50*/%	*GFLOPs*	*Parameters*	帧率
RT-DETR-R18				93.4	84.3	88.1	57.2	19.9	73.42
	√			91.3	84.6	87.6	36.8	13.3	80.57
		√		93.9	85.2	89.8	60.3	20.1	69.84
			√	94.5	84.6	89.3	58.5	20.1	68.91
	√	√		93.5	86.4	89.2	40.0	13.6	72.36
	√	√	√	94.7	85.7	90.2	41.3	13.8	70.94

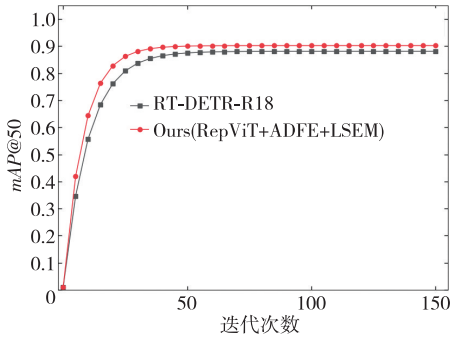


图7 改进前后mAP@50折线图

3.5 对比实验

为评估改进模型的性能，将其与目前主流的目标检测模型与改进模型对比，实验结果如表2所示。

表2 不同模型的实验结果

Model	*P*/%	*R*/%	*mAP@50*/%	*GFLOPs*	*Parameters*
SSD[12]	90.9	37.9	78.5	62.7	26.3
Faster R-CNN[13]	33.4	72.4	57.4	156.0	41.0
YOLOv5m	91.0	83.4	89.6	64.0	25.0
YOLOv8m	88.4	83.8	89.2	78.7	25.8
YOLO11m	89.2	83.8	88.9	67.7	20.0
YOLOv12m	91.0	83.4	88.8	67.1	20.1
YOLO26m[14]	92.0	78.7	85.6	67.9	20.4
YOLO-LLTS[2]	91.1	86.5	90.7	191.1	9.9
YOLO-TS[15]	92.9	87.0	90.5	148.5	15.7
RT-DETR-R18	93.4	84.3	88.1	57.2	19.9
本文	94.7	85.7	90.2	41.3	13.8

由表可知，本文模型在检测精度与轻量化之间取得平衡。在精度上，其精确率达到全组最高的94.7%，整体表现优于多数YOLO系列及RT-DETR-R18模型。尽管在mAP@50上低于YOLO-LLTS和YOLO-TS，但本文模型在计算量上具有优势：其GFLOPs仅为41.3，是所有对比模型中最低的，较传统算法SSD和Faster R-CNN分别减少了151.8和109.2，且参数量保持在13.8 M。综上，改进模型以较小的计算代价换取了高定位精度与识别能力，更适合部署在车载计算资源受限的检测场景中。

3.6 泛化实验

为进一步验证所提方法在不同交通标志场景中的适应性与泛化能力，本文选取CCTSDB2021数据集[16]作为外部测试数据集开展泛化实验。该数据集包含雨雾天气等照明不良情况下的图片，更适合验证模型在不同情况下的性能。

实验结果表明，改进模型在CCTSDB2021数据集的各项指标均有所提升，结果如表3所示。mAP@50达到98.2%，相比基准模型提升了0.5%；mAP@50-95提升了0.9%。同时，模型参数量与计算量均明显下降，说明在面对多种复杂道路环境下的交通标志目标时，改进模型依然可以保持较好的检测效果。

表3 泛化实验结果

Model	*P*/%	*R*/%	*mAP@50*/%	*mAP@50-95*/%	*GFLOPs*	*Parameters*
RT-DETR-R18	96.0	96.3	97.7	76.9	57.2	19.9
本文	96.1	96.7	98.2	77.8	41.3	13.8

3.7 识别结果

为直观评估算法的实际应用效果，本文对比了RT-DETR-R18与改进模型在实际夜间低光照场景下的视觉识别结果，如图8所示。从结果可以看出，在低光照条件下，基线模型容易漏检特征模糊的标志，置信度也偏低。改进模型则提升了这些目标的置信度，还补检了一些漏掉的暗弱标志，说明改进后

的模型对低光特征感知更准，抗干扰能力更强。



（a）RT-DETR-R18　　（b）本文

图 8　RT-DETR-R18 与改进模型在实际低光照场景下的视觉识别图

5　结论

针对低光照条件下，噪声干扰强造成关键特征丢失导致交通标志检测精度下降的问题，本文提出一种改进 RT-DETR 的低光照交通标志检测识别算法。首先，采用 RepViT 替换原始主干网络，在减少模型参数和计算量的同时，提高网络对低分辨率模糊目标的特征表达能力。其次，构建 LSEM，将通道重标定与空间多尺度特征提取结合起来，在增强亮区域响应的同时减弱暗背景噪声的影响。最后，在解码器输入前加入 ADFE 模块，通过大核条形卷积加强方向性信息，使反光区域形成的几何边界能够被更稳定地保留下来。在 CNTSSS 夜间交通标志数据集上的实验表明，改进后的模型参数量和计算量分别下降 30.7% 和 27.8%，平均精度均值提升 2.1%。实际低光照场景下的实验结果表明，改进后的模型在夜间低光照场景下对交通标志边缘和弱纹理区域具有更稳定的响应能力。后续工作中会进一步研究模型蒸馏等技术，以提升推理效率。

参考文献：

[1] Chen Z. Research on road traffic sign detection and recognition technology[J]. GBP Proceedings Series, 2025, 1: 39-46.

[2] Lin Z, Wu Y, Ma Y, et al. YOLO-LLTS: real-time low-light traffic sign detection *via* prior-guided enhancement and multibranch feature interaction [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 5043518.

[3] Luo P, Lin Y, Yang H. Traffic sign detection algorithm based on adaptive enhancement of low-illumination images[J]. Proc. of SPIE, 2025,13709: 137091E.

[4] Wang T, Qu H, Liu C, et al. LLE-STD: traffic sign detection method based on low-light image enhancement and small target detection[J]. Mathematics, 2024, 12(19): 3125.

[5] He Y, Guo M, Zhang Y, et al. NTS-YOLO: a nocturnal traffic sign detection method based on improved YOLOv5[J]. Applied Sciences, 2025, 15(3): 1578.

[6] Mishra A, Agarwal A, Lone H R. Benchmarking nighttime traffic sign recognition with illumination-adaptive detection and semantic attribute reasoning [EB/OL]. 2026: arXiv: 2511.17183. . https://arxiv.org/abs/2511.17183.

[7] Zhao Y, Lü W, Xu S, et al. DETRs beat YOLOs on real-time object detection [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

[8] Wang A, Chen H, Lin Z, et al. Rep ViT: revisiting mobile CNN from ViT perspective[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 15909-15920.

[9] Ding X, Zhang X, Ma N, et al. RepVGG: making VGG-style ConvNets great again [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13728-13737.

[10] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.

[11] Sandler M, Howard A, Zhu M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.

[12] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]//Computer Vision - ECCV 2016, 2016: 21-37.

[13] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[14] Chakrabarty S. YOLO26: an analysis of NMS-free end to end framework for real-time object detection [EB/OL]. 2026: arXiv: 2601.12882. https://arxiv.org/abs/2601.12882

[15] Chen J, Huang H, Zhang R, et al. YOLO-TS: real-time traffic sign detection with enhanced accuracy using optimized receptive fields and anchor-free fusion[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 26(11): 19995-20011.

[16] Zhang J M, Zou X, Kuang L D, et al. CCTSDB 2021: a more comprehensive traffic sign detection benchmark [J]. Human-centric Computing and Information Sciences, 2022, 12: 23.

作者简介：

孟奥运（1999—），男，河南省周口市人，硕士研究生，主要研究方向为图像处理；

陈世国（1967—），男，贵州省铜仁市人，教授，硕士研究生导师，主要研究方向为图像处理（人脸识别、图像融合）。