



M-YOLO:基于多尺度特征融合的轻量级恶劣天气目标检测模型

应雨洁, 丁飞, 余耀元, 曾宇, 吉韵

引用本文:

应雨洁, 丁飞, 余耀元, 等. M-YOLO:基于多尺度特征融合的轻量级恶劣天气目标检测模型[J]. 智能系统学报, 2026, 21(5): 1292-1299.

YING Yujie, DING Fei, YU Yaoyuan, et al. M-YOLO: a lightweight multi-scale feature fusion-based model for adverse weather object detection[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1292-1299.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202601011>

您可能感兴趣的其他文章

多视角数据融合的特征平衡YOLOv3行人检测研究

Research on multi-view data fusion and balanced YOLOv3 for pedestrian detection
智能系统学报. 2021, 16(1): 57-65 <https://dx.doi.org/10.11992/tis.202010003>

隔级融合特征金字塔与CornerNet相结合的小目标检测

Small target detection based on a combination of feature pyramid and CornerNet
智能系统学报. 2021, 16(1): 108-116 <https://dx.doi.org/10.11992/tis.202004033>

基于注意力机制的显著性目标检测方法

Salient object detection method based on the attention mechanism
智能系统学报. 2020, 15(5): 956-963 <https://dx.doi.org/10.11992/tis.201903001>

基于路网结构的城市交通事故短期风险预测方法

A short-term risk prediction method for urban traffic accidents based on road network
智能系统学报. 2020, 15(4): 663-671 <https://dx.doi.org/10.11992/tis.201910002>

基于反卷积和特征融合的SSD小目标检测算法

SSD small target detection algorithm based on deconvolution and feature fusion
智能系统学报. 2020, 15(2): 310-316 <https://dx.doi.org/10.11992/tis.201905035>

一种基于雨线主方向自适应的全局稀疏去雨模型

A global sparse rain removal model based on rain streaks main direction adaptation
智能系统学报. 2020, 15(2): 271-280 <https://dx.doi.org/10.11992/tis.201809042>

DOI: 10.11992/tis.202601011

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260709.1703.005>

M-YOLO: 基于多尺度特征融合的轻量级恶劣天气目标检测模型

应雨洁^{1,2}, 丁飞^{1,2}, 余耀元^{1,2}, 曾宇^{1,2}, 吉韵^{1,2}

(1. 南京邮电大学 江苏省宽带无线通信和物联网重点实验室, 江苏 南京 210003; 2. 南京邮电大学 物联网学院, 江苏 南京 210003)

摘要: 为提高复杂气象环境下智能交通系统的交通目标识别精度, 提出基于多接入边缘计算 (multi-access edge computing, MEC) 架构的增强型 YOLOv5 模型 (a lightweight multi-scale feature fusion-based model for adverse weather object detection, M-YOLO)。设计双阶段图像增强机制, 实现雾/雨/雪多源气象特征的融合; 引入通道与空间协同的卷积块注意力机制 (convolutional block attention module, CBAM) 以提升模型在复杂背景下的目标识别和定位能力; 在 YOLOv5 架构基础上新增 P2/4 小目标检测层, 提高对小尺寸目标的检测精度; 同时, M-YOLO 还采用了 MPDIoU (minimum point distance intersection over union) 损失函数优化边界框回归。最后, 通过 Foggy-Cityscapes、Rain-Cityscapes 和 Snow-Cityscapes 数据集进行实验验证, 结果表明 M-YOLO 均表现出更优的平均检测精度。在混合天气条件下, M-YOLO 模型的 mAP50 达到 0.485, 相比于基准模型 (0.415) 大幅提高, 为边缘计算环境下的实时交通监控提供了高效解决方案。

关键词: YOLOv5; 目标检测; 多接入边缘计算; 注意力机制; 智慧交通; 图像增强; 轻量级模型; 恶劣天气

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1673-4785(2026)05-1292-08

中文引用格式: 应雨洁, 丁飞, 余耀元, 等. M-YOLO: 基于多尺度特征融合的轻量级恶劣天气目标检测模型 [J]. 智能系统学报, 2026, 21(5): 1292-1299.

英文引用格式: YING Yujie, DING Fei, YU Yaoyuan, et al. M-YOLO: a lightweight multi-scale feature fusion-based model for adverse weather object detection[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1292-1299.

M-YOLO: a lightweight multi-scale feature fusion-based model for adverse weather object detection

YING Yujie^{1,2}, DING Fei^{1,2}, YU Yaoyuan^{1,2}, ZENG Yu^{1,2}, JI Yun^{1,2}

(1. Jiangsu Key Laboratory of Broadband Wireless Communications and Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; 2. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: To improve the traffic target recognition accuracy of intelligent transportation systems in complex meteorological environments, an enhanced YOLOv5 model (M-YOLO) based on multi-access edge computing (MEC) architecture is proposed. A two-stage image enhancement mechanism was designed to realize the fusion of fog/rain/snow multi-source meteorological features; a channel and spatial synergistic Convolutional Block Attention Mechanism (CBAM) was introduced to enhance the model's target recognition and localization ability in complex backgrounds; a P2/4 small-target detection layer was added based on the YOLOv5 architecture to improve the detection accuracy of small-sized targets; meanwhile, M-YOLO also adopted the MPDIoU loss function to optimize the bounding box regression. Finally, experimental validation was performed with Foggy-Cityscapes, Rain-Cityscapes, and Snow-Cityscapes datasets, and the results show that M-YOLO exhibits better average detection accuracy. Under mixed weather conditions, the mAP50 of the M-YOLO model reaches 0.485, which represents a significant improvement over the benchmark model (0.415), providing an efficient solution for real-time traffic monitoring in edge computing environments.

Keywords: YOLOv5; target detection; multi-access edge computing; attention mechanism; intelligent transportation; image enhancement; lightweight model; adverse weather

收稿日期: 2026-01-06. 网络出版日期: 2026-07-10.

基金项目: 工业和信息化部产业技术基础公共服务平台项目 (2019-00892-3-1); 江苏省高等学校基础科学 (自然科学) 研究重大项目 (25KJA510003); 江苏省研究生科研创新计划项目 (SJCX24_0336); 江苏省大学生创新创业训练计划项目 (2024I0293166Y).

通信作者: 丁飞. E-mail: dingfei@njupt.edu.cn.

随着城市化进程的加速与智能交通系统的深入渗透, 道路作为交通流的重要组成部分, 其安全性与通行效率已成为城市交通管理的核心挑战。尤其在暴雨、大雾、降雪等恶劣天气条件下,

传统视觉感知系统受限于图像退化、目标模糊等问题,导致车辆与行人检测精度显著下降,严重威胁交通安全。在此背景下,如何通过深度学习技术实现复杂气象条件下的高精度目标检测,成为智能交通领域亟待突破的关键课题。

近年来,多接入边缘计算(multi-access edge computing, MEC)凭借其低延迟、高实时性的优势,为交通目标检测提供了新的技术路径。MEC通过将计算资源下沉至路侧边缘节点(如摄像头、信号灯),能够实现交通数据的本地化处理,有效规避云端传输延迟^[1]。研究表明,MEC框架可通过多节点协同计算优化资源分配^[2],并在隐私保护方面展现潜力(如结合联邦学习实现车牌、人脸等数据脱敏^[3])。然而,恶劣天气导致的图像质量退化(如雾霾遮蔽、雨雪噪声)与边缘设备的有限算力之间的矛盾,对现有检测模型提出了双重挑战:一方面,需提升模型对低质图像的鲁棒性;另一方面,需在精度与计算效率间取得平衡。

在目标检测算法层面,以YOLO系列^[4]为代表的单阶段检测器因其实时性优势,被广泛用于交通场景。然而,复杂道路场景中普遍存在小目标密集(如远处车辆)、目标遮挡及光照突变等问题,传统YOLO模型易出现漏检与误检^[5]。

针对上述问题,现有研究主要从以下三方面展开:

1) 数据增强与图像修复技术,通过模拟或修复恶劣天气图像提升模型泛化性。Chen等^[6]提出多师生架构的两阶段知识学习机制,同步修复雾、雨、雪3类天气退化图像;Fu等^[7]设计无监督低光增强网络LE-GAN(light exposure generative adversarial network),显著改善低光照检测性能。Jose等^[8]提出一种基于Transformer的端到端模型TransWeather,仅使用一组编码器和鉴别器修复受损图像。王新蕾等^[9]提出基于提示学习的跨层注意力加权图像去噪分支,利用退化提示重构清晰图像。但此类方法存在两大局限:一是合成数据与真实场景存在域偏移^[10],二是修复模块常导致推理延迟增加,难以实现实时处理效果^[11]。

2) 注意力机制优化,采用动态权重分配强化关键特征响应,包括通道注意力机制、空间注意力机制和混合注意力机制等。通道注意力模块如SENet(squeeze-and-excitation networks)^[12]通过动态调整特征通道权重增强小目标响应;GE-Net(gather-excite network)^[13]则利用空间注意力来更好地挖掘特征之间的上下文信息;空间-通道协

同注意力,如CBAM(convolutional block attention module)^[14],进一步融合多尺度特征,缓解目标重叠问题。许云峰等^[15]提出了一种轻量级的空间位置注意力模块SLAM(spatial location attention module),聚焦于空间位置信息对跨维度交互的重要性。但此类方法常伴随计算复杂度的增加,难以适配MEC架构下的边缘设备。

3) 模型轻量化设计,为适配MEC架构,轻量化设计成为研究热点。知识蒸馏技术通过迁移教师模型至轻量化学生模型,可在压缩参数数量的同时保持精度^[16]。例如,Zhao等^[17]提出基于响应标度的蒸馏方法,以 2.77×10^6 参数量实现检测效率与精度的平衡。Dong等^[18]基于蒸馏提出的轻量级算法可将模型体积压缩9倍,精度损失仅为0.1%。此外,模型剪枝技术可去除多余参数,提升模型泛化性能。李昂等^[19]基于模型剪枝和稀疏训练,在模型大小减小9.7 MB的情况下实现了检测速度和精度的提高。杨睿宁等^[20]对于改进模型进行模型剪枝,在模型体积减小5.7 MB的基础上检测速度达到了89帧/s。在尽管如此,现有方法仍存在两大局限:其一,多数研究仅针对单一气象条件优化,缺乏对混合天气场景的泛化能力;其二,模型改进常以牺牲实时性为代价,难以满足边缘计算场景的低延迟需求。

针对上述问题,本文聚焦于监控摄像头图像中交通目标的识别问题,提出基于MEC架构的增强型YOLOv5模型(a lightweight multi-scale feature fusion-based model for adverse weather object detection, M-YOLO),设计双阶段图像增强机制,实现雾、雨、雪多源气象特征融合,提升模型对混合天气的适应性;轻量化注意力优化,在YOLOv5中嵌入CBAM,通过动态权重分配强化关键区域特征;多尺度检测增强,新增P2/4高分辨率检测层与MPDIoU损失函数,兼顾小目标检测精度与边界框回归效率,最后依托Foggy-Cityscapes、Rain-Cityscapes等合成数据集验证模型性能。

1 M-YOLO 模型设计

在智能网联交通系统中,路侧边缘平台包括路侧单元(road side unit, RSU)、路侧基础设施(摄像头、交通信号灯等),云端网络则涵盖云计算系统和云存储系统。本研究面向恶劣天气环境下道路的交通目标检测任务,基于多接入边缘计算(MEC)架构的平衡精度-速度的部署需求^[21],提出M-YOLO,其结构与应用框架如图1所示。M-YOLO的训练过程主要依托于云端强大的计算

资源和存储能力,提供可靠的模型参数;检测过程则部署于路侧的边缘平台,以满足智能交通系统对于实时性和高可靠性的要求。




图 1 基于 MEC 架构的 M-YOLO 模型框架

Fig. 1 M-YOLO model framework based on MEC architecture

M-YOLO 分为图像增强网络和目标检测网络。图像增强网络通过双阶段学习策略实现天气适应性提升: TT(teacher teach) 阶段基于多对一教师-学生架构,采用特征对齐模块 (feature alignment module, FAM) 实现学生网络轻量化知识继承; SL(student learn) 阶段则重点依赖真实图像提高学生网络图像增强能力。目标检测网络在 YOLOv5 基础上嵌入 CBAM 注意力机制,通过通道-空间协同权重调整强化关键区域特征响应,同时新增 P2/4 高分辨率检测层以捕捉微小目标细节,并采用 MPDIoU 损失函数优化边界框回归精度。

1.1 图像增强网络

该网络采用了两阶段的学习架构,包括教师教授 (TT) 阶段和学生自学 (SL) 阶段。

1.1.1 教师教授 (TT) 阶段

在 TT 阶段,本文构建了一个多教师知识蒸馏框架,采用动态知识融合策略指导学生网络 S 进行跨域特征学习。该框架包括 m 个预训练好的教师模型 T , 其中 T_i 是针对第 i 种恶劣天气进行专门优化的模型。为了有效解决多教师特征空间异构性问题,本文创新性地设计了特征对齐模块 FAM, 结构如图 2。

FAM 的核心构成是一个双路映射结构,该结构包括特征投影模块 (feature projection module, FPM) 和逆向特征投影模块 (inverse feature projection module, IFPM), 两者共同形成了一个闭合的

特征适配环路。FPM 作用是将教师网络和学生网络的特征投影到一个共同的特征空间中,以便进行特征对齐。FPM 由多个卷积块组成,每个卷积块的步幅为 1,并使用 ReLU(rectified linear unit) 激活函数。其损失函数为:

$$\mathcal{L}_{\text{FPM}} = \sum_j \|\varphi(\mathbf{F}_{T_i}^j) - \varphi(\mathbf{F}_S^j)\|_1$$

式中: $\mathbf{F}_{T_i}^j$ 和 $\mathbf{F}_S^j$ 分别表示教师 T_i 和学生 S 编码器第 j 层提取的特征, $\varphi(\cdot)$ 为 VGG(visual geometry group)^[22] 特征提取操作。




图 2 FAM 的结构

Fig. 2 Structure of FAM

IFPM 的功能在于,通过将教师网络的特征投影回原始输入空间,并计算投影特征与原始特征之间的差异,对学习过程施加约束。具体来说,IFPM 使用 FPM 的逆向操作,把投影特征映射回原始输入空间,进而计算该投影与原始特征的差异。上述过程有助于保障投影特征的有效性,从而提升 FAM 过程的鲁棒性。

$$\mathcal{L}_{\text{IFPM}} = \sum_j \|\rho(\mathbf{F}_{T_i}^j) - \mathbf{F}_{T_i}^{j'}\|_1$$

式中: $\mathbf{F}_{T_i}^j$ 和 $\mathbf{F}_S^j$ 分别表示教师 T_i 和学生 S 编码器第 j 层提取的特征, $\rho(\cdot)$ 为 IFPM 特征逆投影操作, $\mathbf{F}_{T_i}^{j'}$ 为图像第 j 层真实特征。

因此,特征对齐模块 FAM 的损失定义为

$$\mathcal{L}_{\text{FAM}} = \mathcal{L}_{\text{FPM}} + \mathcal{L}_{\text{IFPM}} = \sum_j \|\varphi(\mathbf{F}_{T_i}^j) - \varphi(\mathbf{F}_S^j)\|_1 + \sum_j \|\rho(\mathbf{F}_{T_i}^j) - \mathbf{F}_{T_i}^{j'}\|_1$$

为进一步缩小学生网络和教师网络的决策差距,本文还引入了 InfoNCE(information noise-contrastive estimation) 损失^[23]。InfoNCE 损失是一种基于对比学习的损失函数,其核心思想是最大化正样本对之间的相似度,同时最小化负样本对之间的相似度。

$$\mathcal{L}_{\text{InfoNCE}}(q, k_+, k_-) = -\frac{1}{N} \sum_{i=1}^N \log \left(\frac{\exp\left(\frac{q_i, k_{i+}}{\tau}\right)}{\sum_{j=1}^N \exp\left(\frac{q_i, k_{j-}}{\tau}\right)} \right)$$

式中: N 为样本数量。 τ 是温度系数, 用于调节相似度得分的分布, 较小的 τ 值会使相似度得分的分布更加尖锐, 突出正样本对的相似度; 较大的 τ 值则会使分布更加平滑, 增加负样本对的影响。 q 为目标网络的预测结果。 k_+ 、 k_- 分别为基准网络的正样本和负样本。

因此, TT 阶段的损失函数定义为

$$\mathcal{L}_{TT} = \mathcal{L}_{TPixel} + \alpha_1 \mathcal{L}_{FAM} + \alpha_2 \mathcal{L}_{InfoNCE}(z_s, z_{t+}, z_{t-})$$

式中: $\mathcal{L}_{TPixel}$ 是教师网络预测结果与学生网络预测结果之间的 L1 损失, $\mathcal{L}_{FAM}$ 是特征对齐损失, $\mathcal{L}_{InfoNCE}(z_s, z_{t+}, z_{t-})$ 是学生网络和教师网络预测结果之间的 InfoNCE 损失, α_1 、 α_2 为平衡系数。

1.1.2 学生自学 (SL) 阶段

在 TT 阶段结束后, 学生模型已经基本掌握了教师网络的图像增强知识, 因此可以迈入学生自学阶段。 SL 阶段内, 学生模型不再依赖教师网

络的指导, 而是通过使用真实图像来进一步提高其鲁棒性和判别能力。 此时损失函数定义为

$$\mathcal{L}_{SL} = \mathcal{L}_{GPixel} + \alpha_3 \mathcal{L}_{InfoNCE}(z_s, z_+, z_-)$$

式中: $\mathcal{L}_{GPixel}$ 是学生网络预测结果与真实图像之间的 L1 损失, $\mathcal{L}_{InfoNCE}(z_s, z_+, z_-)$ 是学生网络预测结果和真实图像之间的 InfoNCE 损失, α_3 为平衡系数。

与文献 [8, 24] 等现有的先修复、再检测的两阶段图像恢复工作相比, 本文设计的核心区别在于, 不以人类视觉的绝对清晰为导向, 而是保留最有利于后续目标检测头的鲁棒表征, 从而在计算效率与检测增益之间取得了更优的平衡。

1.2 目标检测网络

原始图片在经过训练后的学生模型进行图像增强后, 输入基于 YOLOv5 的目标检测模型中进行检测, 目标检测网络具体结构如图 3 所示。




图 3 M-YOLO 目标检测网络架构

Fig. 3 M-YOLO object detection network architecture

1.2.1 CBAM 注意力机制

本模型在 YOLOv5m 架构中嵌入了卷积块注意力模块 (CBAM), 通过通道与空间注意力协同工作机制优化特征提取过程。在骨干网络末端及特征金字塔各融合节点后引入 CBAM 模块, 其通道注意力子模块采用全局平均池化与最大池化的双路特征压缩, 生成通道权重向量以强化关键特征响应; 空间注意力子模块则通过卷积层构建空间权重矩阵, 突出目标区域的空间显著性。

1.2.2 小目标检测层

针对小目标特征易丢失问题, 本模型在 YOLOv5

模型原有的 3 层检测头基础上新增 P2/4 高分辨率检测头, 构建了四尺度检测层体系, 结合浅层特征跨层融合与自适应锚框优化策略, 强化细粒度特征提取能力。该检测头通过双线性插值上采样将深层语义特征与浅层高分辨率特征进行跨层连接, 采用通道拼接后接 C3 模块的策略实现特征融合, 利用 1/4 下采样率的特征图保留微小目标的细节信息。

1.2.3 MPDIoU

现有边界框回归损失函数大多在预测框与实际框的宽高比相同, 但宽度和高度值完全不同

时,无法被优化。为了解决上述问题,本文采用了基于最小点距离的边界框相似度比较度量 MPDIoU^[25], MPDIoU 中包含了现有损失函数中考虑的所有相关因素,例如重叠或非重叠面积、中心点距离以及宽度和高度的偏差,同时简化了计算过程。

$$\mathcal{L}_{\text{MPDIoU}} = 1 - R_{\text{IoU}} + \frac{d_1^2 + d_2^2}{\omega^2 + h^2}$$

式中: R_{IoU} 表示预测边界框与真实边界框的交并比, d_1 和 d_2 分别表示预测边界框和真实边界框的左上角和右下角点之间的欧氏距离, ω 和 h 分别表示真实边界框的宽度和高度。

2 实验结果及分析

2.1 实验设置

本文使用的深度学习框架为 torch2.0.1+cu117, 输入图像尺寸为 640×640, 初始学习率为 0.1, 学习率动量为 0.937, 优化器为 SGD, 训练轮次设置为 100 轮, batchsize 设置为 16, 使用官方提供的预训练权重 yolov5m.pt 作为预训练模型。

2.1.1 评估指标

本文采用准确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP) 等性能评价指标, 对 M-YOLO 模型的检测性能进行评价。评价指标计算式分别为

$$P = \frac{T_p}{T_p + F_p}$$

$$R = \frac{T_p}{T_p + F_n}$$

$$I_{\text{AP}} = \int_0^1 P(R) dR$$

$$I_{\text{mAP}} = \frac{1}{N} \sum_{i \in N} I_{\text{AP}}^i$$

式中: T_p 、 F_p 、 F_n 分别表示正确预测的正例、错误预测的正例和错误预测的负例。mAP50 表示 IoU 阈值为 0.50 时计算出的 mAP, mAP50-95 表示在一系列 IoU 阈值 (从 0.50 开始, 以 0.05 为步长一直到 0.95) 下分别计算 mAP 并求平均得到的值。

2.1.2 数据集

该模型使用了多个城市道路场景下的恶劣天气数据集进行训练和测试。

Foggy-cityscapes^[26]: 基于 Cityscapes^[27] 数据集扩展而成的合成雾天场景数据集, 包含 3 种不同能见度等级的各 2 975 张合成雾训练集图像和 500 张验证集图像, 本研究采取能见度最低的版本 ($B=0.02$)。Cityscapes 是一个专注于城市街道场

景语义理解的高质量图片数据集, 包含多个城市的道路目标信息。

Rain-cityscapes^[28]: 基于 Cityscapes 数据集的合成雨图像数据集, 包含不同降雨程度和类型的合成雨图像。

Snow-cityscapes^[8]: 基于 Cityscapes 数据集的合成雪数据集, 包含 16 000 张合成雪图像。

实验采用标注类别分为 8 类, 包括 bus、bicycle、car、motorcycle、person、rider、train、truck。

2.2 实验结果

2.2.1 不同恶劣天气下的对比实验

图 4 给出了雾/雨/雪等恶劣天气条件下 M-YOLO 模型识别的可视化对比结果, 可以看出, 所提 M-YOLO 模型在不同恶劣天气下均具有更优的识别性能, 主要表现在更多图像细节的有效提取, 包括更多地关注小尺寸交通目标如行人、远处车辆, 和更有效的抗噪声干扰能力。




图 4 雾/雨/雪条件下 M-YOLO 模型识别的对比结果
Fig. 4 Comparison results of M-YOLO model recognition under fog/rain/snow conditions

同时, 本文对雾/雨/雪条件下 M-YOLO 模型的性能进行了定量评估。雾天条件下选用的基准模型包括 YOLOv5、SWDA^[29]、R-YOLO^[29], 雨天条件下基准模型包括 YOLOv5、PDA^[28]、R-YOLO, 雪天条件下基准模型包括 YOLOv5、CST-DA^[30]、CTBL^[31], 其中 YOLOv5 均选择中等参数量的 YOLOv5m 版本。这些模型均为恶劣天气目标检测的经典算法, 同时其轻量化的架构特征与本文面向的低算力场景更适配, 能够更客观地评估本文方法的实际表现, 实验结果如表 1 所示。

表 1 不同恶劣天气数据集上的定量结果

Table 1 Quantitative results on different severe weather datasets

天气类型	方法	P	R	mAP50	mAP50-95
雾天	YOLOv5	0.720	0.358	0.403	0.238
	SWDA	0.576	0.321	0.343	0.195
	R-YOLO	0.783	0.378	0.436	0.255
	M-YOLO	0.781	0.431	0.501	0.282

续表 1

天气类型	方法	<i>P</i>	<i>R</i>	mAP50	mAP50-95
雨天	YOLOv5	0.451	0.312	0.338	0.156
	PDA	0.682	0.320	0.361	0.207
	R-YOLO	0.622	0.386	0.428	0.217
	M-YOLO	0.694	0.428	0.486	0.295
雪天	YOLOv5	0.638	0.388	0.426	0.230
	CST-DA	0.646	0.328	0.360	0.197
	CTBL	0.699	0.410	0.402	0.246
	M-YOLO	0.715	0.429	0.478	0.261

注: 加粗表示最优结果。

雾天场景下图像退化特征是大气散射导致目标与背景对比度显著降低, 目标边缘虚化严重, 尤其小尺寸目标 (如 person、bicycle) 的特征信号易被忽略。M-YOLO 虽在精确度上稍低于 R-YOLO, 但却以 0.501 的 mAP50 优于 R-YOLO(0.436), 其召回率 (0.431) 显著高于 SWDA(0.321), 证明 M-YOLO 的有效性。

雨天场景下图像退化主要表现为雨线形成的密集噪声干扰及运动目标的拖影效应。M-YOLO 的 mAP50(0.486) 较 PDA(0.361) 提升 34.6%, 模型性能较为突出。

雪天场景下图像退化主要由雪花密集遮挡与雪地反射导致的亮度不均引起, M-YOLO 在精确率 (0.715) 与 mAP50(0.478) 上均领先 CTBL (0.402)。综上, M-YOLO 在雾、雨、雪 3 类恶劣天气下均表现优异。

2.2.2 混合数据集上的对比实验

为评价模型在真实环境下, 同时面对多种恶劣天气的场景, 本研究从 Foggy- cityscapes、Rain- cityscapes 和 Snow- cityscapes 中随机抽取 1 000 张图像, 合并成一个混合训练集。在测试阶段, 使用 3 种数据集的测试集合并成一个混合测试集。将本文模型与其他 4 种对比模型进行对比实验, 在混合训练集上进行训练并在混合测试集上验证实验效果, 得到表 2。

表 2 混合数据集上的定量结果

Table 2 Quantitative results on mixed datasets

方法	<i>P</i>	<i>R</i>	mAP50	mAP50-95
PDA	0.576	0.352	0.365	0.186
SWDA	0.650	0.320	0.367	0.190
YOLOv5	0.829	0.357	0.415	0.233
R-YOLO	0.662	0.418	0.455	0.243
M-YOLO	0.695	0.428	0.485	0.294

注: 加粗表示最优结果。

如表 2, M-YOLO 以 0.485 的 mAP50 超越 R-YOLO(0.455) 和 YOLOv5(0.415), 表明其通过多天气特征融合与轻量化设计, 在复杂多变环境下具备更强的泛化能力。然而, YOLOv5 在精确率 (0.829) 上的优势提示, M-YOLO 在高置信度目标检测中可能存在阈值优空间。

2.2.3 消融实验

在 Foggy-cityscapes 数据集上, 本研究进行了消融实验以评价模型各个模块的作用, 如表 3。

表 3 消融实验结果

Table 3 Results of ablation experiment

设置	实验模块					实验结果			
	YOLOv5	图像增强网络	CBAM	MPDIoU	小目标检测层	<i>P</i>	<i>R</i>	mAP50	mAP50-95
Baseline	√					0.720	0.358	0.403	0.238
C1	√	√				0.725	0.430	0.473	0.273
C2	√	√	√			0.742	0.435	0.485	0.283
C3	√	√	√	√		0.756	0.439	0.492	0.290
M-YOLO	√	√	√	√	√	0.781	0.441	0.501	0.282

注: 加粗表示最优结果。

消融实验结果表明, 各模块对检测性能的贡献呈现显著的阶段性特征: 引入图像增强网络 (C1) 后, 模型召回率 (*R*) 从 0.358 跃升至 0.430, 验证了其对样本多样性的增强作用; 叠加 CBAM 注意力机制 (C2) 使精确率 (*P*) 提升至 0.742, 表明特征权重优化有效抑制了背景误检; MPDIoU 损失函数 (C3) 进一步将 mAP50-95 提高至 0.290, 凸显了边界框回归优化对多尺度定位精度的增益。最终, M-YOLO 通过引入小目标检测层, 以 0.781

的精确率和 0.501 的 mAP50 达到最优综合性能, 但其 mAP50-95 的轻微下降 (0.290→0.282) 说明高分辨率层关注到小目标同时也放大了雨雪噪声, 这会干扰定位框的精准度, 揭示了高分辨率特征图在增强小目标检测时对多尺度平衡的挑战, 体现了模型改进中的精度-鲁棒性权衡。

3 结束语

本文针对道路复杂天气条件下的交通目标检

测难题,提出了一种基于 MEC 架构的改进 YOLOv5 模型 (M-YOLO),借助多模块协同优化,实现了检测精度与效率的平衡。所提 M-YOLO 模型采用了两阶段增强策略,显著增强了模型对雾、雨、雪等恶劣天气的适应性。实验显示,在引入图像增强模块后,于 Foggy-cityscapes 数据集上的召回率提升了 20.1%,有力验证了特征对齐模块 (FAM) 在整合多天气特征方面的促进作用。通过嵌入 CBAM 注意力模块,模型精确率提高至 0.742,有效抑制了背景噪声干扰;采用 MPDIU 损失函数后, mAP50-95 指标达到 0.290,表明边界框回归优化增强了多尺度目标定位的精度。在小目标检测性能改进方面,新增的 P2/4 高分辨率检测头,使模型在密集小目标场景下的精确率提升至 0.781,但 mAP50-95 出现了轻微下降 (从 0.290 降至 0.282)。此外,新增 P2/4 检测层虽然导致了微小的计算量增加,但该模块对于恶劣环境下模糊小目标的识别效用具有重要作用,后续可通过动态特征融合策略优化计算效率,更好地平衡多尺度检测的鲁棒性以及检测性能与计算效率之间的平衡。

参考文献:


- [1] HU Yunchao, PATEL M, SABELLA D, et al. Mobile edge computing—a key technology towards 5G[J]. ETSI white paper, 2015, 11(11): 1–16.
- [2] YANG H F, CAI Jiarui, LIU Chenxi, et al. Cooperative multi-camera vehicle tracking and traffic surveillance with edge artificial intelligence and representation learning[J]. Transportation Research Part C: Emerging Technologies, 2023, 148: 103982.
- [3] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]//Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. Fort Lauderdale: PMLR, 2017, 54: 1273–1282.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 779–788.
- [5] GAO Chenqiang, MENG Deyu, YANG Yi, et al. Infrared patch-image model for small target detection in a single image[J]. IEEE transactions on image processing, 2013, 22(12): 4996–5009.
- [6] CHEN Weiting, HUANG Zhikai, TSAI C C, et al. Learning multiple adverse weather removal *via* two-stage knowledge learning and multi-contrastive regularization: toward a unified model[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 17632–17641.
- [7] FU Ying, HONG Yang, CHEN Linwei, et al. LE-GAN: Unsupervised low-light image enhancement network using attention module and identity invariant loss[J]. Knowledge-based systems, 2022, 240: 108010.
- [8] JOSE VALANARASU J M, YASARLA R, PATEL V M. TransWeather: transformer-based restoration of images degraded by adverse weather conditions[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 2343–2353.
- [9] 王新蕾, 王硕, 翟嘉政, 等. 多任务联合学习下的复杂天气航拍图像目标检测算法[J]. 计算机工程与应用, 2025, 61(2): 97–111.
WANG Xinlei, WANG Shuo, ZHAI Jiazheng, et al. Object detection algorithm of aerial image in complex weather based on multi-task joint learning[J]. Computer engineering and applications, 2025, 61(2): 97–111.
- [10] 董中华, 刘恒. 基于域适应的真实场景图像超分辨率方法[J]. 计算机科学与应用, 2023, 13(6): 1279–1288.
DONG Zhonghua, LIU Heng. Real-world image super-resolution method based on domain adaptation[J]. Computer science and application, 2023, 13(6): 1279–1288.
- [11] 王珏, 洪敏轩, 夏叶桐, 等. 基于条件生成对抗网络的低照度彩色图像增强算法[J]. 红外与激光工程, 2024, 53(11): 20240238.
WANG Jue, HONG Minxuan, XIA Yetong, et al. Low-light color image enhancement algorithm based on conditional generative adversarial network[J]. Infrared and laser engineering, 2024, 53(11): 20240238.
- [12] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132–7141.
- [13] HU Jie, SHEN Li, ALBANIE S, et al. Gather-excite: exploiting feature context in convolutional neural networks[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018: 9423–9433.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Computer Vision—ECCV 2018. Cham: Springer, 2018: 3–19.
- [15] 许云峰, 刘畅达, 梅卫, 等. 一种轻量级空间位置注意力模块及其在图像分类网络中的应用[J]. 信息与控制, 2025, 54(2): 321–335, 352.
XU Yunfeng, LIU Changda, MEI Wei, et al. Lightweight spatial location attention module and its application to image classification networks[J]. Information and control, 2025, 54(2): 321–335, 352.
- [16] HINTON G, VINYALS O, DEAN J. Distilling the know-

- ledge in a neural network[EB/OL]. (2015-03-09)[2026-01-06]. <https://doi.org/10.48550/arXiv.1503.02531>.
- [17] ZHAO Liang, WEI Zhengjie, LI Yanting, et al. SEDG-Yolov5: a lightweight traffic sign detection model based on knowledge distillation[J]. *Electronics*, 2023, 12(2): 305.
- [18] DONG Chenhang, PANG Chengxin, LI Zhengwei, et al. PG-YOLO: a novel lightweight object detection method for edge devices in industrial Internet of Things[J]. *IEEE access*, 2022, 10: 123736-123745.
- [19] 李昂, 孙士杰, 张朝阳, 等. 改进 YOLOv5s 的轨道障碍物检测模型轻量化研究[J]. *计算机工程与应用*, 2023, 59(4): 197-207.
- LI Ang, SUN Shijie, ZHANG Zhaoyang, et al. Research on lightweight of improved YOLOv5s track obstacle detection model[J]. *Computer engineering and applications*, 2023, 59(4): 197-207.
- [20] 杨睿宁, 惠飞, 金鑫, 等. 改进 YOLOv5s 的复杂交通场景路侧目标检测算法[J]. *计算机工程与应用*, 2023, 59(16): 159-169.
- YANG Ruining, HUI Fei, JIN Xin, et al. Roadside target detection algorithm for complex traffic scene based on improved YOLOv5s[J]. *Computer engineering and applications*, 2023, 59(16): 159-169.
- [21] 李子姝, 谢人超, 孙礼, 等. 移动边缘计算综述[J]. *电信科学*, 2018(1): 87-101.
- LI Zishu, XIE Renchao, SUN Li, et al. A survey of mobile edge computing[J]. *Telecommunications science*, 2018(1): 87-101.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10)[2026-01-06]. <https://doi.org/10.48550/arXiv.1409.1556>.
- [23] VAN DEN OORD A, LI Yazhe, VINYALS O. Representation learning with contrastive predictive coding [EB/OL]. (2019-01-22)[2026-01-06]. <https://doi.org/10.48550/arXiv.1807.03748>.
- [24] SAITO K, USHIKU Y, HARADA T, et al. Strong-weak distribution alignment for adaptive object detection[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 6949-6958.
- [25] MA Siliang, XU Yong. MPDIoU: a loss for efficient and accurate bounding box regression[EB/OL]. (2023-07-14)[2026-01-06]. <https://doi.org/10.48550/arXiv.2307.07662>.
- [26] SAKARIDIS C, DAI Dengxin, VAN GOOL L. Semantic foggy scene understanding with synthetic data[J]. *International journal of computer vision*, 2018, 126(9): 973-992.
- [27] CORDTS M, OMRAN M, RAMOS S, et al. The cityscapes dataset for semantic urban scene understanding[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 3213-3223.
- [28] SINDAGI V A, OZA P, YASARLA R, et al. Prior-based domain adaptive object detection for hazy and rainy conditions[C]//Computer Vision-ECCV 2020. Cham: Springer, 2020: 763-780.
- [29] WANG Lucai, QIN Hongda, ZHOU Xuanyu, et al. R-YOLO: a robust object detector in adverse weather[J]. *IEEE transactions on instrumentation and measurement*, 2023, 72: 5000511.
- [30] ZHAO Ganlong, LI Guanbin, XU Ruijia, et al. Collaborative training between region proposal localization and classification for domain adaptive object detection[C]// Computer Vision-ECCV 2020. Cham: Springer, 2020: 86-102.
- [31] WANG Kunpeng, CAI Jingxiang, YAO Juan, et al. Co-teaching based pseudo label refinery for cross-domain object detection[J]. *IET image processing*, 2021, 15(13): 3189-3199.

作者简介:



应雨洁, 硕士研究生, 主要研究方向为车联网、智能网联交通。E-mail: b22080607@njupt.edu.cn。



丁飞, 教授, 博士, 主要研究方向为群智感知计算、混合信息物理系统。E-mail: dingfei@njupt.edu.cn。



余耀元, 硕士研究生, 主要研究方向为人工智能与智能控制。E-mail: 1822393465@qq.com。