

文章编号: 1007-2780(2025)09-1369-12

CORM-YOLO: 低照度环境下交通行人检测算法

王 栋¹, 罗亚波¹, 张 峰^{1*}, 黄 随²

(1. 武汉理工大学 机电工程学院, 湖北 武汉 430070;

2. 湖北天威汽车有限公司, 湖北 随州 441300)

摘要:洒水车在夜间或凌晨等低照度环境下频繁作业,然而传统目标检测算法在此类场景中的表现普遍较差,极易出现行人漏检或误检问题,带来误洒水和碰撞等安全隐患。这是由于低照度条件下图像整体亮度不足,目标边缘模糊,颜色和纹理等关键信息退化,导致检测模型难以提取有效特征;同时,噪声信号相对增强,也进一步干扰了模型的判断准确性。为提升洒水车在低照度条件下的行人检测能力,本文提出了一种改进的轻量级检测算法 CORM-YOLO。CORM-YOLO 算法是在 YOLOv8n 的基础上进行结构优化,引入了 CPA-Enhancer 作为特征提取网络,显著增强低照度图像的语义与纹理信息表达能力;采用 OREPA 优化主干网络卷积模块,有效压缩模型参数与计算成本;利用 RepHead 替代传统检测头,提高了小目标检测的鲁棒性与精度;同时引入 MGD Loss 知识蒸馏机制,通过引导轻量模型学习教师模型的判别特征,进一步提升模型整体性能。实验结果表明,CORM-YOLO 在低照度行人检测任务中的 mAP@50 达到 0.845,较 YOLOv8n 提升 3.6%,mAP@50:95 达到 0.504,提升 1.8%,且推理速度满足实际部署要求。该方法在保障低照度作业安全性方面具有重要应用价值,可广泛用于智慧城市和智能交通领域。

关键词:低照度行人检测;深度学习;YOLOv8;重参数化;知识蒸馏

中图分类号: TP391 **文献标识码:** A **doi:** 10.37188/CJLCD.2025-0104 **CSTR:** 32172.14.CJLCD.2025-0104

CORM-YOLO: Pedestrian detection algorithm in low-light conditions for traffic environments

WANG Dong¹, LUO Yabo¹, ZHANG Feng^{1*}, HUANG Sui²

(1. School of Mechanical and Electronic Engineering, Wuhan University of Technology,

Wuhan 430070, China;

2. Hubei Tianwei Automobile Co. Ltd., Suizhou 441300, China)

Abstract: Sprinkler trucks frequently operate during nighttime or early morning hours, when ambient illumination is extremely low. Under such conditions, traditional object detection algorithms often perform poorly, leading to frequent pedestrian missed detections or false positives, which in turn may result in unintended spraying or even safety hazards such as collisions. This performance degradation is primarily due to the insufficient brightness, blurred object edges, and weakened color and texture information in low-light images, which hinder effective feature extraction by detection models. Additionally, increased noise levels

收稿日期: 2025-05-20; 修订日期: 2025-07-17.

基金项目: 湖北省科技厅项目 (No.[2023]58; No.2023DJC082)

Supported by Department of Science and Technology Project of Hubei Province (No.[2023]58; No.2023DJC082)

*通信联系人, E-mail: zhangfengie@whut.edu.cn

further compromise the accuracy of model inference. To address these challenges, this paper proposes a lightweight and improved detection algorithm, CORM-YOLO, based on YOLOv8n. The algorithm introduces CPA-Enhancer as a feature extraction network to enhance semantic and texture representation in low-light images; OREPA is employed to optimize convolution modules in the backbone, reducing computational complexity and parameter count; RepHead replaces the traditional detection head to improve robustness and accuracy for small object detection; and MGDLoss is introduced as a knowledge distillation mechanism to enable the lightweight model to learn discriminative features from a teacher model, thus enhancing overall performance. Experimental results show that CORM-YOLO achieves an mAP@50 of 0.845, 3.6% improvement over YOLOv8n, and an mAP@50:95 of 0.504, with 1.8% gain, while maintaining real-time inference speed suitable for onboard deployment. The proposed method demonstrates strong applicability in ensuring safe operation of sprinkler trucks under low-light conditions and holds promising potential for broader applications in smart city and intelligent transportation systems.

Key words: low-light pedestrian detection; deep learning; YOLOv8; re-parameterization; knowledge distillation

1 引言

近年来,深度学习的快速发展极大推动了行人检测技术的演进,使其在诸如安防监控、自动驾驶及智能交通等多个领域中得到实际应用^[1]。然而,大多数传统检测方法对光照条件较为依赖。在低光环境中,图像往往模糊、对比度低且噪声较多,严重影响检测的准确性与稳定性,使行人检测面临巨大挑战。目前,行人检测的方法主要分为两类:一种是基于传统图像处理的方法,如 Haar 特征、HOG 特征及 SVM 分类器,依赖手工设计的特征进行检测;另一种是基于深度学习的方法,如 Faster R-CNN、Mask R-CNN、YOLO 系列和 SSD,这些方法在良好的光照条件下表现优异,但在低光环境下,检测性能会大幅下降^[2-3]。低光条件下性能下降的原因主要有以下几点:(1)图像在低照度下亮度与对比度偏低且噪声较多,可用视觉信息显著减少;(2)弱光环境使得行人边缘轮廓与纹理细节难以分辨,从而削弱了基于外观特征的检测效果;(3)复杂背景干扰与低光条件叠加,不仅增加了检测难度,也对实时处理性能提出了更高的计算资源要求^[4]。

为应对低照度环境下行人检测的难题,当前深度学习方法主要采取两类优化策略:其一是通过模型训练使其能够更好地理解和适应弱光图像中的特征分布;其二是构建针对性更强的网络架构,以挖掘低亮度场景中的细微信息。此外,

也有部分研究聚焦于更具鲁棒性的损失函数,提升模型在复杂光照条件下的泛化能力,以解决低照度场景中可能出现的标注误差问题^[5]。为缓解低照度图像中亮度不足、对比度低和细节丢失等问题^[6],2021年,赖坤城等^[7]首次在 Mask R-CNN 框架中引入 MSRCR-IF 模块,同时,改进了特征金字塔网络与区域建议网络,为提升低光环境下的行人检测精度与效率提供了有效方案。2023年,龚安等^[8]提出夜间监控场景下的改进检测算法 NSPDet,创新性地融合 Zero-DCE 低光增强模块和邻近感知模块(NOH),在复杂夜间场景中展现出更强的检测鲁棒性与适应性。2025年,徐广平等^[9]设计了 RetinaHA-YOLOv8,将 RetinexFormer 图像增强与 HAT 特征融合机制相结合,并引入在线重参数化卷积,建立了一个兼顾精度与实时性的低照度行人检测体系。尽管已有诸多研究在低照度行人检测领域取得了显著成果,但仍存在一些不足与挑战。例如,一些方法在提升检测精度的同时往往带来模型结构的复杂化,难以满足资源受限设备上的实时部署需求;此外,部分增强模块存在过度增强或引入伪影的风险,可能干扰检测模型对真实目标的识别与定位,降低在复杂低光环境中的鲁棒性。

本文提出了一种基于 YOLOv8 改进的低光行人检测算法 CORM-YOLO。算法中,CPA-Enhancer 链式思考网络通过链式提示机制自适应地提取低光图像中的关键特征,显著提高了低光

图像中特征的提取能力;在线重参数化的卷积结构 OREPA 被用于替代 YOLOv8 中部分常规卷积模块,有效加快了模型的推理过程,提高了推理速度,从而更好地满足实时检测的需求;重参数化检测头 RepHead 通过优化检测头结构,进一步提升了检测精度,同时减少了计算复杂度^[10-14];MGDLoss 知识蒸馏通过将教师模型的知识传递给学生模型,弥补了模块调整可能带来的性能损失,进一步提升了模型在低光环境下的表现^[15]。与现有低照度检测方法相比,CORM-YOLO 在保持轻量级结构的同时,有效融合了图像增强、特征提取优化、推理加速与知识蒸馏等多重策略,形成了一个兼具鲁棒性与效率的检测框架^[16]。其中,CPA-Enhancer 提升了弱光图像的可辨识度,OREPA 和 RepHead 显著降低了推理延迟与计算开销,MGDLoss 则确保了模型精度在结构压缩下的稳健性。正是这种模块间的协同融合,使 CORM-YOLO 在面对弱纹理、强噪声与实时处理要求并存的低照度行人检测场景中,展现出优于其他方案的综合性能。

2 YOLOv8 及其改进算法

2.1 YOLOv8

实时目标识别技术被广泛应用于安防监控、无人驾驶及智慧交通等多个场景中,具有重要意义,尤其是在行人检测方面。在低照度条件下,传统检测方法常因图像质量下降而导致识别效果不佳。为应对这一问题,研究者逐步引入深度学习策略提升检测性能。YOLO 系列因兼具速度与准确性,已被广泛应用于行人识别任务,其中的模型 YOLOv8 在该领域中展现出更优表现,其通过创新的网络结构进一步提升了检测性能。

YOLOv8 结构包括输入层、主干网络(Backbone)、颈部网络和检测头,具体特点如下:

(1)输入层:通过 Mosaic 数据增强和 MixUp 策略,提升低光环境下的鲁棒性,增强了模型对不同光照条件的适应性。

(2)主干网络:采用 CSPDarknet 结构,通过 CSP 提高特征重用性,结合 C2f 模块优化低光图像中的细节提取,SPPF 模块增强多尺度特征提取能力。

(3)颈部网络:结合 PANet 和 C2f 模块,优化

了多尺度特征融合,提升了小目标在低光环境中的检测精度。

(4)检测头:采用 Anchor-Free 机制和 Decoupled Head 结构,直接预测目标边界框,避免任务间干扰,提高了检测精度,特别在低光下表现优异。

这些改进使得 YOLOv8 在低照度行人检测中表现出色,能在低对比度和高噪声环境下保持高检测准确性,并满足实时检测需求。

2.2 改进的 YOLOv8 算法

本文介绍一种基于 YOLOv8 改进的低照度行人检测算法 CORM-YOLO,其模型架构如图 1 所示。

针对低光条件下图像质量退化的问题,本文在 YOLOv8 主干网络中集成了 CPA-Enhancer 链式思考网络,以增强特征表达能力并提升整体检测性能。CPA-Enhancer 基于链式思考机制,通过引导式提示自适应调节图像亮度与对比度,同时保留关键细节信息。该模块采用多阶段特征优化策略,在提升图像可见性与对比度的同时,有效增强了目标特征的可区分性,尤其在弱光条件下表现出显著优势。

为降低 CPA-Enhancer 带来的计算开销,算法进一步引入在线重参数化卷积模块(OREPA),用于替代主干网络中的部分卷积操作。具体而言,保留了主干网络前两层的卷积块,同时对所有 C2f 模块中的瓶颈层(Bottleneck)结构的第二个卷积层进行重构。该设计在保证特征提取能力和网络通用性的基础上,有效压缩了计算复杂度,加快了推理速度,实现了精度与效率的良好平衡。此外,浅层结构主要承担初级特征提取任务,保留该部分可提升网络对图像底层信息的敏感性,同时增强模型在不同数据集和任务中的迁移适应能力。

在检测头部分,本文将 YOLOv8 原有检测头替换为重参数化检测头 RepHead。RepHead 采用多分支结构以捕获更丰富的特征表达,在推理阶段通过结构融合将多分支转化为单分支卷积,有效降低了计算复杂度。该优化设计不仅提升了推理效率,还增强了边界框回归与类别预测的准确性,从而显著提升整体检测精度。

为进一步提升网络性能并减缓结构变更带来的精度损失,本文引入 MGDLoss 知识蒸馏策略,通过将教师模型的知识迁移至学生模型,实




图1 CORM-YOLO 网络结构图
Fig. 1 Diagram of CORM-YOLO network structure

现对关键判别特征的继承与强化。该策略显著提升了学生模型在低光环境下的检测能力,在保持模型轻量化设计的同时,确保了检测精度与推理效率的协同优化。

2.2.1 CPA-Enhancer 链式思考网络

CPA-Enhancer 引入了链式思考 (CoT) 提示机制,用于自适应增强图像,特别是在未知退化条件下,其网络结构如图 2 所示。

CPA-Enhancer 的核心思想是通过 CoT 提示动态分析图像退化特性,进而调整增强策略,提高物体检测效果。CoT 提示生成模块 (CGM) 能够根据图像退化的不同情况,生成相关的上下文信息,帮助模型自动识别并适应不同退化类型。内容驱动提示块 (CPB) 增强了输入特征与 CoT 提示之间的交互,使模型根据图像退化类型调整增

强策略。该模块可以与目标检测器一起进行端到端训练,避免了需要额外预训练的过程和监督信号。将 CPA-Enhancer 集成到 YOLOv8 中,能够有效改善低光照和复杂场景中的图像质量,确保在这些环境下行人检测仍能提取到清晰可靠的特征。模块的插件式设计使其能够轻松集成到现有框架中,为解决各种退化条件下的目标检测问题提供了一种高效且通用的方案。特别是在低光照和低对比度的环境中,CPA-Enhancer 显著提升了行人检测性能,增强了模型的鲁棒性。

CPA-Enhancer 在 YOLOv8 上的低照度行人检测中设立了新的性能基准,提升了检测精度并优化了推理速度。该模块增加的参数量非常少,仅为 0.35M,并不会影响实时性。在复杂环境下,CPA-Enhancer 为提升模型的鲁棒性和泛化




图2 CPA-Enhancer网络结构图

Fig. 2 Diagram of CPA-Enhancer network structure

能力提供了有效的解决方案。

2.2.2 在线重参数化卷积 OREPA

OREPA 采用两阶段流程、线性缩放层和优化策略来提升模型性能,其块结构如图3所示。

首先,OREPA 采用在线优化与压缩训练相结合的方式实现结构重构。在常规卷积网络中,BN (Batch Normalization)层需对每个通道单独计算标准差,阻碍了多分支路径的统一融合,进而增加了计算开销。但BN中的缩放参数对于保持分支间的梯度多样性至关重要,这一点对重参数化效果

具有决定性作用。因此,OREPA 在在线阶段引入线性缩放替代传统的非线性BN,既简化了分支整合过程,也保留了必要的性能调节能力。线性缩放层不仅能合并计算、提高训练效率,还能引导多个分支朝不同方向优化,保留模型特征表达能力。OREPA 在压缩训练阶段将复杂模块简化为单一卷积操作,并通过归一化层优化性能。通过替换传统卷积模块,OREPA 减少了计算开销,采用轻量化设计,确保模型满足实时处理需求,同时保留了强大的特征表达能力。




图3 OREPA块结构

Fig. 3 OREPA block structure

2.2.3 重参数化检测头 RepHead

RepHead 通过在每个检测层中嵌入双 Rep-Conv 模块对特征进行增强处理,然后将其输出

分别送入分类头和回归头,实现了重参数化卷积与检测任务的有机结合。该检测头由重参数化模块 RepConv 组成,在增强特征学习能力的同时仅

略微增加 GFLOPs,从而保持了较快的推理速度和较高的性能,确保较高的 FPS 能力。它利用 RepConv 的重参数化特性,在训练时采用多分支辅助训练的策略,推理阶段转化为串行高效的单分支结构。RepConv 的结构如图 4 所示。




图 4 RepConv 网络结构

Fig. 4 RepConv network structure

训练阶段通过 RepVGG 模块的多分支拓扑结构(包括 1×1 卷积、 3×3 卷积及恒等映射)实现多样化特征学习,推理阶段通过重参数化将其融合为单个等效的 3×3 卷积层,以大幅提升计算效率和速度。在低光行人检测中,RepHead 的高效特征增强机制能够在复杂光照条件下提取更具辨识度的目标特征。同时,其优化的推理性能确保了在实时监控场景中快速准确地检测低光环境中的行人,从而显著提升模型的鲁棒性和适应性。

2.2.4 MGDLoss 知识蒸馏

我们通过知识蒸馏方法进一步提升改进后 YOLOv8 模型在低光环境下的检测精度。知识蒸馏通过使学生模型(小模型)模仿教师模型(大模型)的行为以传递知识,改善学生模型的泛化能力和精度。为了实现这一目标,选择 YOLOv8l 作为教师模型,它经过 Nightowls 数据集的训练,能够在复杂的低光场景下有效地提取特征。为了确保学生模型在不同尺度下提取特征图时与教师模型一致,采用适当的尺度匹配策略,模型图如图 5 所示。

首先,定义了知识蒸馏中的损失函数,它结




图 5 MGDLoss 知识蒸馏模型

Fig. 5 MGDLoss knowledge distillation model

合了传统的目标检测损失和蒸馏损失。我们在损失函数中引入了教师模型的输出,并通过最小化学生模型输出与教师模型输出之间的差异来引导学生模型的学习。具体来说,损失函数包括以下几个部分:

(1) 目标检测损失 (L_{det})。这部分损失与标准的 YOLO 目标检测损失一致,包括定位损失(如均方误差)和分类损失(如交叉熵损失):

$$L_{\text{det}} = \lambda_{\text{coord}} L_{\text{coord}} + \lambda_{\text{conf}} L_{\text{conf}} + \lambda_{\text{cls}} L_{\text{cls}}, \quad (1)$$

其中: L_{coord} 为定位损失, L_{conf} 为置信度损失, L_{cls} 为分类损失, λ_{coord} 、 λ_{conf} 、 λ_{cls} 是相应的权重系数。

(2) 蒸馏损失 (L_{distill})。蒸馏损失通过计算教师模型和学生模型输出之间的差异进行优化。常见的蒸馏损失包括基于 Softmax 输出的 Kullback-Leibler (KL) 散度和基于特征图的均方误差 (MSE)。本模型采用基于特征图的 MSE 来引导学生模型学习教师模型的特征图表示:

$$L_{\text{distill}} = \sum_i \left(\left\| F_{\text{teacher}}^{(i)} - F_{\text{student}}^{(i)} \right\|^2 \right), \quad (2)$$

其中, $F_{\text{teacher}}^{(i)}$ 和 $F_{\text{student}}^{(i)}$ 分别表示教师模型和学生模型在第 i 层输出的特征图。

(3) 最终的损失函数 (L_{final})。最终的损失函数是目标检测损失和蒸馏损失的加权和:

$$L_{\text{final}} = L_{\text{det}} + \alpha L_{\text{distill}}, \quad (3)$$

其中, α 是蒸馏损失的权重超参数,它控制了教师模型与学生模型之间的知识传递强度。通过优化该损失函数,我们能够使学生模型在保持高效性的同时,借鉴教师模型的精度。

在训练过程中,学生模型通过最小化总损失函数 (L_{final}) 学习教师模型的知识,从而在检测精度上得到提升。通过这种方法,使模型在低光环境

下的检测精度和鲁棒性得到了显著提高,验证了知识蒸馏在YOLOv8模型中应用的有效性。

3 数据集与评价标准

3.1 数据集

本研究选用NightOwls数据集作为实验验证平台。该数据集专注于低照度环境下的行人检测,图像采集自真实的夜间场景,如街道、停车场等,具备高度还原的弱光条件与复杂背景。与白天场景相比,夜间行人检测因受光照变化、图像模糊、反光干扰及对比度不足等因素影响,具有更高的挑战性。

NightOwls共包含约27.9万帧图像,来源于40个不同的视频序列,采集自3个国家,涵盖多个季节与天气条件。所有图像均来自连续视频帧,具备完整的边界框标注信息,并包含遮挡情况、目标姿态、检测难度及跨帧跟踪信息,为多帧目标识别与评估提供了全面支持。

由于原始数据集数据量大、帧间冗余度高,为提高数据处理效率并减少过拟合风险,我们对数据进行了清洗与筛选。具体策略如下:

从训练集中每隔3帧抽取1帧,剔除未包含任何标注信息的图像,以确保每张样本图像至少包含一个目标实例。按照7:2:1的比例将清洗后的数据划分为训练集、验证集与测试集,最终得到共计10450张图像,其中训练集7270张,验证集2180张,测试集1000张。该数据准备流程确保了样本的代表性与多样性,为后续的模型训练与性能评估提供了坚实基础。

3.2 评价标准

本实验采用6个指标评估模型性能:准确率(Precision, P)、召回率(Recall, R)、mAP@50、mAP@50:95、模型大小(M)、每秒处理帧数(FPS)和浮点运算次数(GFLOPs)。

(1)准确率(P):用于评估模型在预测为行人的样本中,有多少属于真实的正类。其计算方式为:将真正例(TP)与预测为正的总数(TP+FP)进行比值运算,表达式如式(4)所示:

$$P = \frac{TP}{TP + FP} \quad (4)$$

(2)召回率(R):表示在所有实际的行人中,有多少被模型正确检测出来,其计算公式如式(5)

所示:

$$R = \frac{TP}{TP + FN} \quad (5)$$

(3)mAP@50:是一种用于多类别目标检测任务的性能评估指标。该指标在设定IoU阈值为0.50的条件下,对每个类别分别计算 P - R 曲线下的面积AP,然后对所有类别的AP取平均值,最终得到mAP。

(4)mAP@50:95:是一种更全面的mAP衡量方法,考虑多个IoU阈值范围。通常,IoU范围为0.50~0.95,以0.05为间隔进行计算。这种方式可以更全面地评估模型在不同IoU阈值下的表现。

(5)帧率(FPS):在如自动驾驶或安防监控等对实时性要求较高的应用中,算法的处理效率至关重要。每秒可处理图像帧数通常作为衡量实时性能的重要指标。

(6)计算量(GFLOPs):反映模型运算复杂度的常用度量标准。若GFLOPs过高,可能会限制模型在算力有限的设备上的部署与运行效率。

4 实验结果与分析

4.1 设备搭建及实验参数设定

4.1.1 设备搭建

为实现洒水车的行人检测与洒水控制功能,搭建了相应的行人检测设备。该设备结构包括移动主板控制系统、洒水车、双目相机、洒水装置等,如图6所示。




图6 环境搭建示意图

Fig. 6 Schematic diagram of environment setup

通过相机实时采集洒水车前方经过的行人图像,并将其传输至移动主板进行分析,获取行人的速度、距离和运动轨迹信息。随后,控制系统根据分析结果调节阀门电流,从而控制洒水装

置实现对行人的避让。

4.1.2 实验参数设定

本实验在 Windows11 操作系统下进行,使用的 CPU 为 14 代 Intel(R) Core(TM) i7-14700 HX, GPU 为 NVIDIA GeForce RTX 4070 Laptop GPU。深度学习环境为 Python3.11、PyTorch2.0.1 和 CUDA11.8。训练过程中,共训练 200 个 epoch, batch_size 设置为 4, workers 为 4,使用的优化器是 SGD(初始学习率为 0.01,动量因子为 0.9),使用自动混合精度(Automatic Mixed Precision, AMP)训练。

4.2 蒸馏式模型优化实验

实验表明,蒸馏权重系数对最终效果具有显著影响。基于教师模型 YOLOv8l 与学生模型的组合,评估了不同蒸馏权重设定下的性能变化。如图 7 所示,当权重系数设为 2.0 时,模型在蒸馏后




图 7 不同权重系数下的模型性能

Fig. 7 Model performance with different weight coefficients

获得了较优的检测精度, mAP@50 和 mAP@50:95 分别达到 81.7% 和 49.5%。随着权重的变化,精度与召回率曲线出现一定波动,模型对低照度行人特征关注度随之变化。而平均精度整体维持在较高水平,进一步验证了蒸馏过程对提升检测能力的有效性。

4.3 消融实验

为深入探讨各个模块的加入对模型性能的影响,设置了一系列消融实验,旨在评估每个模块对模型整体性能带来的具体影响。实验基于本文处理后的 NightOwls 数据集,采用 YOLOv8 作为基准模型,选取 P、R、mAP@50、mAP@50:95 和 GFLOPs 等关键指标进行评估。

进行融合所有模块的消融实验,结果如表 1 所示。由于本系统需部署于洒水车上,因此在模型设计中需兼顾检测性能与计算成本,以确保其能够在移动主板设备上稳定运行。综合考虑性能与计算成本,在使用 OREPA 替换部分传统卷积时,能够在几乎不降低检测精度的前提下,显著减少 GFLOPs 值,有效缓解 CPA-Enhancer 与 RepHead 检测头带来的额外计算开销。为了进一步弥补轻量化卷积带来的精度下降,本文引入知识蒸馏对模型进行辅助训练,在不增加模型参数的情况下提升检测精度。当同时使用 4 个模块时, Precision、Recall、mAP@50 和 mAP@50:95 分别达到 0.852、0.771、0.845 和 0.504,均达到最高水平,验证了所提出模型的有效性与可行性。

表 1 消融实验

Tab. 1 Ablation experiments

Experiments	CPA-Enhancer	RepHead	OREPA	蒸馏	Precision	Recall	mAP@50	mAP@50:95	GFLOPs
1					0.830	0.753	0.809	0.486	8.2
2	✓				0.832	0.758	0.826	0.495	21
3	✓	✓			0.846	0.759	0.835	0.497	21.2
4	✓	✓	✓		0.851	0.769	0.833	0.496	18
5	✓	✓	✓	✓	0.852	0.771	0.845	0.504	18

4.4 对比实验

为全面验证所提方法在低照度行人检测场景下的表现,本文开展了多组对比实验。实验依托本文处理后的 NightOwls 数据集,其具有代表性的低照度环境,为算法效果评估提供了良好基础。对比对象包括 YOLOv8 系列中的 YOLOv8n

与 YOLOv8s,以及多种当前主流的低照度行人检测方法,具体模型如下:

PE-YOLOv3:对 YOLOv3 进行优化以适应低照场景,借助专用模块提升暗光环境下的检测性能;Faster R-CNN:经典的两阶段检测网络,以高精度见长;YOLOv5:具备优秀检测速度与性

能的单阶段目标检测模型;SSD:以实时检测能力闻名的单阶段模型;DETR:基于 Transformer 的端到端目标检测方法;YOLOv8:最新版本的 YOLO 系列模型,融合了改进的检测能力与灵活性;YOLOv10:新一代的实时目标检测模型,提供更高效的端到端检测;YOLOv11:轻量化的 YOLOv11 系列模型,适合资源受限场景;YOLOv12:提出了一种以注意力为中心的 YOLO 框架,与之前基于 CNN 的 YOLO 框架的速度相匹配,同时利用了注意力机制的性能优势。

评价指标选用 mAP50 和 FPS,以全面评估各模型的精度与速度表现,对比实验结果如表 2 所示。本文提出的模型在精度方面显著优于其他方法,说明增强低光图像的亮度与对比度对提升检测效果有明显作用。在检测速度方面,单阶段算法整体优于双阶段方法,其中 SSD 以每秒帧率(FPS)61.5 表现最快。尽管本文模型在帧率上略低于 SSD,但依然超过实时处理的基本门槛(约 30 FPS),同时在检测精度方面表现最优。

表 2 对比实验		
Tab. 2 Comparative experiments		
Models	MAP@50	FPS
YOLOv8n	0.809	59.8
YOLOv8s	0.826	46.2
Faster R-CNN	0.802	16.4
PE-YOLOv3	0.832	45.9
YOLOv10	0.828	56.4
SSD	0.772	61.5
DETR	0.785	51.4
YOLOv12	0.832	57.3
YOLOv11	0.826	56.2
YOLOv5	0.803	53.7
Ours	0.845	49.6

此外,图 8 所示的 Precision-Recall(P - R)曲线进一步验证了本文方法的优越性。与其他对比模型相比,本文模型在各召回率水平下均能保持较高的精度,曲线整体更贴近右上角,表明其在高召回率下仍具备稳定的识别精度。曲线下的面积更大,也反映了模型的整体检测性能更强,进一步佐证了本文改进策略在低照度环境中的有效性。




图 8 不同目标检测模型在 NightOwls 数据集下的 P - R 曲线对比

Fig. 8 Comparison of P - R curves of different object detection models on the NightOwls dataset

4.5 检测结果分析

如图 9 与图 10 所示,在 NightOwls 数据集上,YOLOv8n 与 CORM-YOLO 的检测效果存在显著差异。图 9 展示了 YOLOv8n 的检测结果,图 10 为改进后的 CORM-YOLO 在相同样本上的检测表现。本文选取了 4 种不同的场景,按从左至右的顺序,光照条件依次由低到高。可以观察到,在这 4 个场景中,改进后的 CORM-YOLO 模型在检测效果上均优于原始 YOLOv8n。

这一结果表明,所提出的改进模型在应对遮挡、模糊和边缘目标检测方面具有更好的鲁棒性和泛化能力,尤其在夜间等复杂光照环境中展现



图 9 YOLOv8n 检测结果 1

Fig. 9 Detection results 1 of YOLOv8n

5 结 论

本文针对低照度行人检测问题,基于YOLOv8n提出了CORM-YOLO模型,通过CPA-Enhancer网络增强低光图像的亮度与对比度,并采用OREPA卷积替换传统卷积,在降低计算量同时保持精度,重参数化检测头RepHead和

MGDLoss知识蒸馏的结合进一步提升了模型的检测准确性和效率。实验结果表明,CORM-YOLO相比YOLOv8n在NightOwls低光行人数据集上取得了显著提升,MAP@50提高至0.845,FPS达到49.6,满足实时视频处理需求。CORM-YOLO模型大小仅为10.33M,适用于移植部署到嵌入式设备中,适合在洒水车上安装部署,有效解决洒水车低照度环境作业的安全问题。

参 考 文 献:

- [1] 吕佳铭,张峰,罗亚波. 基于改进YOLOv5s的烟梗物料目标检测算法[J]. 浙江大学学报(工学版),2024,58(12): 2438-2446.
LV J M, ZHANG F, LUO Y B. Improved YOLOv5s based target detection algorithm for tobacco stem material [J]. *Journal of Zhejiang University (Engineering Science)*, 2024, 58(12): 2438-2446. (in Chinese)
- [2] 李宝兵,符长友. 基于改进YOLOv8的低光照行人检测算法[J]. 西华大学学报(自然科学版),2025,44(3):29-36.
LI B B, FU C Y. Low light pedestrian detection algorithm based on improved YOLOv8 [J]. *Journal of Xihua University (Natural Science Edition)*, 2025, 44(3): 29-36. (in Chinese)
- [3] 罗志聪,何陈涛,陈登捷,等. 基于轻量化YOLOv8s-GD的自然环境下百香果快速检测模型[J]. 农业机械学报, 2024,55(8):291-300.
LUO Z C, HE C T, CHEN D J, *et al.* Passion fruit rapid detection model based on lightweight YOLO v8s-GD [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(8): 291-300. (in Chinese)
- [4] 宋建坤,孙扬,李韵鹏. 复杂光照场景下的自动驾驶汽车行人检测[J]. 计算机应用与软件,2025,42(1):102-107,188.
SONG J K, SUN Y, LI Y P. Pedestrian detection in self-driving cars in complex lighting scenes [J]. *Computer Applications and Software*, 2025, 42(1): 102-107, 188. (in Chinese)
- [5] 郑雁文. 基于YOLOv7的夜间行人检测算法研究[D]. 成都:成都理工大学,2023.
ZHENG Y W. Research on night pedestrian detection algorithm based on YOLOv7 [D]. Chengdu: Chengdu University of Technology, 2023. (in Chinese)
- [6] 刘瀚文,王红霞,周奎,等. YOLOv4-tiny网络夜间行人检测算法研究[J]. 重庆邮电大学学报(自然科学版),2023, 35(5):908-915.
LIU H W, WANG H X, ZHOU K, *et al.* Research on nighttime pedestrian detection algorithm for YOLOv4-tiny network [J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2023, 35(5): 908-915. (in Chinese)
- [7] 赖坤城,赵津,王超,等. 改进Mask R-CNN算法在低光道路环境下行人检测研究[J]. 重庆理工大学学报(自然科学),2021,35(7):154-160.
LAI K C, ZHAO J, WANG C, *et al.* Improved Mask R-CNN algorithm for pedestrian detection in low-light road conditions [J]. *Journal of Chongqing University of Technology (Natural Science)*, 2021, 35(7): 154-160. (in Chinese)
- [8] 龚安,李中浩,梁辰宏. 夜间多场景的邻近感知实时行人检测算法[J]. 中国图象图形学报,2023,28(9):2693-2705.
GONG A, LI Z H, LIANG C H. NSPDet: real-time nearby-aware pedestrian detection algorithm for multi-scene surveillance at night [J]. *Journal of Image and Graphics*, 2023, 28(9): 2693-2705. (in Chinese)
- [9] 徐广平,徐慧英,朱信忠,等. 基于改进YOLOv8的低光行人检测算法[J/OL]. 计算机工程与科学,2024:1-11[2025-02-27]. <http://kns.cnki.net/kcms/detail/43.1258.TP.20240908.1720.002.html>.
XU G P, XU H Y, ZHU X Z, *et al.* Improved low-light pedestrian detection algorithm based on YOLOv8 [J/OL]. *Computer Engineering & Science*, 2024: 1-11 [2025-02-27]. <http://kns.cnki.net/kcms/detail/43.1258.TP.20240908.1720.002.html>. (in Chinese)
- [10] CHEN J W, ZHANG W C, WEI D Y, *et al.* Visual inertial localization method assisted by pedestrian motion

- features [J]. *Measurement*, 2025, 240: 115593.
- [11] WEI F C, WANG W J. SCCA-YOLO: a spatial and channel collaborative attention enhanced YOLO network for highway autonomous driving perception system [J]. *Scientific Reports*, 2025, 15(1): 6459.
- [12] JUNG M, CHO J. Enhancing detection of pedestrians in low-light conditions by accentuating Gaussian-Sobel edge features from depth maps [J]. *Applied Sciences*, 2024, 14(18): 8326.
- [13] WANG S, SHIBGHATULLAH A S, KEOY K H, *et al.* Pedestrian mask-wearing detection based on YOLOv5 and DeepSORT [J]. *Neural Computing and Applications*, 2025, 37(15): 9169-9192.
- [14] LIU Q, LI Z M, ZHANG L, *et al.* MSCD-YOLO: a lightweight dense pedestrian detection model with finer-grained feature information interaction [J]. *Sensors*, 2025, 25(2): 438.
- [15] WANG Z D, YANG S Q, QIN H F, *et al.* CCW-YOLO: a modified YOLOv5s network for pedestrian detection in complex traffic scenes [J]. *Information*, 2024, 15(12): 762.
- [16] ZHANG F F, LEONG L V, YEN K S, *et al.* An enhanced lightweight model for small-scale pedestrian detection based on YOLOv8s [J]. *Digital Signal Processing*, 2025, 156: 104866.

作者简介:



王 栋,男,硕士研究生,2023 年于中南林业科技大学获得学士学位,主要从事机器视觉与行人检测方面的研究。E-mail:1471340309@qq.com



张 峰,男,博士,讲师,2012 年于重庆大学获得博士学位,主要从事机器视觉与生产调度等方面的教学与科研工作。E-mail:zhangfengie@whut.edu.cn