

RABL-YOLOv8n: 轻量级夜间行人检测算法^①



李晓莉^{1,2}, 李加强^{1,2}, 陈彦林^{1,2}, 赵龙庆^{1,2}, 何超^{1,2}

¹(西南林业大学 机械与交通学院, 昆明 650224)

²(云南省高校高原山区机动车环保与安全重点实验室, 昆明 650224)

通信作者: 赵龙庆, E-mail: 1955247264@qq.com

摘要: 针对夜间低照度场景下行人检测中存在的目标模糊、特征弱化以及小尺度目标漏检等问题, 本文提出了一种轻量化检测算法 RABL-YOLOv8n. 首先, 设计一个轻量化 RGCSPELAN 模块, 通过优化特征提取过程, 显著增强了对小目标的捕捉能力, 同时有效减少不必要的计算和存储开销; 其次, 在骨干网络的第 10 层引入细粒度分类注意力 (attention for fine-grained classification, AFGC) 机制, 利用多分支局部感知策略提升行人服饰纹理等细粒度特征的可辨识度; 然后, 在特征融合层采用双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN) 结构, 并结合自适应特征加权策略, 进一步强化多尺度特征的交互能力; 最后, 用 LSCD 检测头替换原有检测头, 通过解耦定位与分类任务并引入轻量级上下文感知模块, 显著提升小目标检测的精度. 实验结果表明, 在自建 NightPerson 数据集上, 本算法相较于基线 YOLOv8n 模型, $mAP@50$ 提升了 0.3%, 精确度仅下降 0.013, 而召回率上升了 0.009, 参数量和浮点计算量分别减少了 58% 和 42%. 与 YOLOv5n、YOLOv6n、YOLOv10n 等模型对比, 该算法在检测精度与模型轻量化之间实现了较好的均衡.

关键词: 夜间行人检测; RGCSPELAN; 细粒度分类注意力机制; 双向特征金字塔网络; LSCD; 轻量化

引用格式: 李晓莉, 李加强, 陈彦林, 赵龙庆, 何超. RABL-YOLOv8n: 轻量级夜间行人检测算法. 计算机系统应用, 2026, 35(1): 188-196. <http://www.c-s-a.org.cn/1003-3254/10064.html>

RABL-YOLOv8n: Lightweight Algorithm for Nighttime Pedestrian Detection

LI Xiao-Li^{1,2}, LI Jia-Qiang^{1,2}, CHEN Yan-Lin^{1,2}, ZHAO Long-Qing^{1,2}, HE Chao^{1,2}

¹(School of Mechanical and Transportation, Southwest Forestry University, Kunming 650224, China)

²(Key Laboratory of Motor Vehicle Environmental Protection and Safety in Plateau Mountainous Areas of Yunnan Province, Kunming 650224, China)

Abstract: This study proposes a lightweight detection algorithm, RABL-YOLOv8n, to address the problems of target blur, feature weakening, and small-scale target omission in pedestrian detection under low-illumination nighttime scenes. First, a lightweight RGCSPELAN module is designed, which significantly enhances the ability to capture small targets by optimizing the feature extraction process, while effectively reducing unnecessary computational and storage overhead. Second, attention for fine-grained classification (AFGC) mechanism is introduced in the 10th layer of the backbone network, which utilizes a multi-branch local perception strategy to enhance the recognizability of fine-grained features such as pedestrian clothing texture. Then, a bidirectional feature pyramid network (BiFPN) structure is adopted in the feature fusion layer, combined with an adaptive feature weighting strategy to further enhance the interaction capability of multi-scale features. Finally, the LSCD detection head is used to replace the original detection head. By decoupling the localization and classification tasks and introducing a lightweight context-aware module, the accuracy of small-object detection is significantly improved. The experimental results show that on the self-built NightPerson dataset, compared

① 基金项目: 云南省高层次人才项目 (YNWR-QNBJ-2018-066, YNQR-CYRC-2019-001)

收稿时间: 2025-06-09; 修改时间: 2025-07-07, 2025-07-21; 采用时间: 2025-09-01; csa 在线出版时间: 2025-11-26

CNKI 网络首发时间: 2025-11-27

with the baseline YOLOv8n model, $mAP@50$ increases by 0.3%, precision decreases by only 0.013, recall increases by 0.009, while parameter count and floating point operations are reduced by 58% and 42%, respectively. Compared with YOLOv5n, YOLOv6n, YOLOv10n and other models, the proposed algorithm achieves the best balance between detection accuracy and model lightweighting.

Key words: nighttime pedestrian detection; RGCSPELAN; attention for fine-grained classification (AFGC); bidirectional feature pyramid network (BiFPN); LSCD; lightweight

夜间行人检测在提高道路安全方面具有重要意义。由于夜间光线较暗,驾驶员视线受限,行人更难被及时发现,容易发生交通事故,通过夜间行人检测系统,可以实时监测道路上的行人,提前警示驾驶员,从而减少事故发生的风险。此外,这种技术也有助于城市智能交通系统的优化,提高交通效率和行人安全保障。

随着深度学习技术的迅猛发展,利用深度学习手段解决夜间车辆检测问题^[1]已逐渐成为主流趋势。在众多基于深度学习的目标检测算法中, YOLO^[2]系列算法尤为突出。YOLO (you only look once) 算法首次于2016年提出,以其出色的实时检测性能而备受关注。后续的YOLOv8版本在保持高效检测速度的同时,进一步提升了检测精度^[3,4]。自YOLO算法问世以来,基于该算法框架的各类目标检测模型不断涌现。具体而言,熊俊涛等人^[5]提出了Des-YOLOv3模型,成功应用于夜间环境下柑橘的识别任务。何自芬等人^[6]则设计了一种轻量化的夜间红外图像行人检测神经网络——YOLO-Person,通过引入MobileNetV2^[7]网络结构实现了模型的轻量化设计。张文龙等人^[8]提出了一种轻量级行人检测算法,该算法通过增加特征增强模块,并采用通道注意力机制替代传统下采样层,提升了检测性能,同时降低了模型的空间复杂度。刘振兴等人^[9]则针对拥挤场景下的行人检测难题,提出了一种改进的特征金字塔结构,并结合新的数据增强策略,有效解决了行人多尺度检测问题。随着研究的深入,行人检测算法在速度与精度的平衡与提升方面取得了显著进展。然而,在夜间行人检测这一特定任务中,现有算法仍面临检测精度不足、识别效果欠佳以及参数量庞大等挑战。

针对前人研究的局限性与现存问题,本文提出一种基于YOLOv8n改进的优化行人检测算法。基于Ghost-Net理念,我们融合了高效层聚合网络 (efficient layer aggregation network, ELAN) 架构与重参数化卷积模块

(reparameterized convolution, RepConv),设计了一种轻量化模块——RGCSPELAN。该模块在强化特征提取效能与梯度传输效率的同时,实现了模型结构的轻量化。添加细粒度分类的注意力机制,通过对特征对比度的增强,使得行人目标在视觉上更具辨识度,进一步提升了YOLOv8n在夜间行人检测中的性能;此外,我们在颈部网络中引入双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN),旨在进一步提升算法的检测性能与效率;最后设计了一种检测头LSCD,通过共享卷积机制显著降低了参数量。为解决不同检测头所负责的目标尺度差异问题,我们采用Scale层^[10]对特征进行自适应缩放,从而在保持较低参数量和计算成本的同时,最大程度地减少检测精度的损失。

1 算法原理

1.1 YOLOv8n 算法

YOLOv8n是YOLOv8^[11]系列中的一个轻量级目标检测模型,其设计目标是实现高效的实时目标识别。与其他版本的模型相比, YOLOv8n在保持较高检测精度的同时,进行了网络结构的简化,并减少了模型的参数量。通过这些优化, YOLOv8n显著提高了模型的处理速度和计算效率,从而能够更好地满足实时应用的需求。

YOLOv8n算法是一种端到端的目标检测方法^[12]。该算法的网络结构由3个主要部分组成,分别是骨干网络 (Backbone)、特征融合网络 (Neck) 及头部网络 (Head)。完整的网络结构图如图1所示。

该算法在继承YOLOv5架构的基础上进行了改进,骨干网络部分延续了跨阶段局部网络 (cross stage partial network, CSP) 设计模式,通过引入C2f模块替代YOLOv5中的C3模块,构建了多路径跳接与特征分割机制,增强了梯度传播路径的多样性^[13],从而在保持实时性前提下提升了检测精度。特征融合层针对

YOLOv5 的 PAN-FPN (路径聚合特征金字塔网络) 架构进行优化, 移除了上采样阶段的卷积层, 在保证多尺度特征融合能力的同时有效降低了计算复杂度. 检测头部分采用解耦式双分支结构, 分别针对目标类别概

率与边界框参数进行独立建模, 并采用无锚框检测方式, 通过 WiseIoUv1 损失函数将边界框定位问题转化为概率分布预测任务, 有效缓解了传统锚框机制下的边界模糊现象.

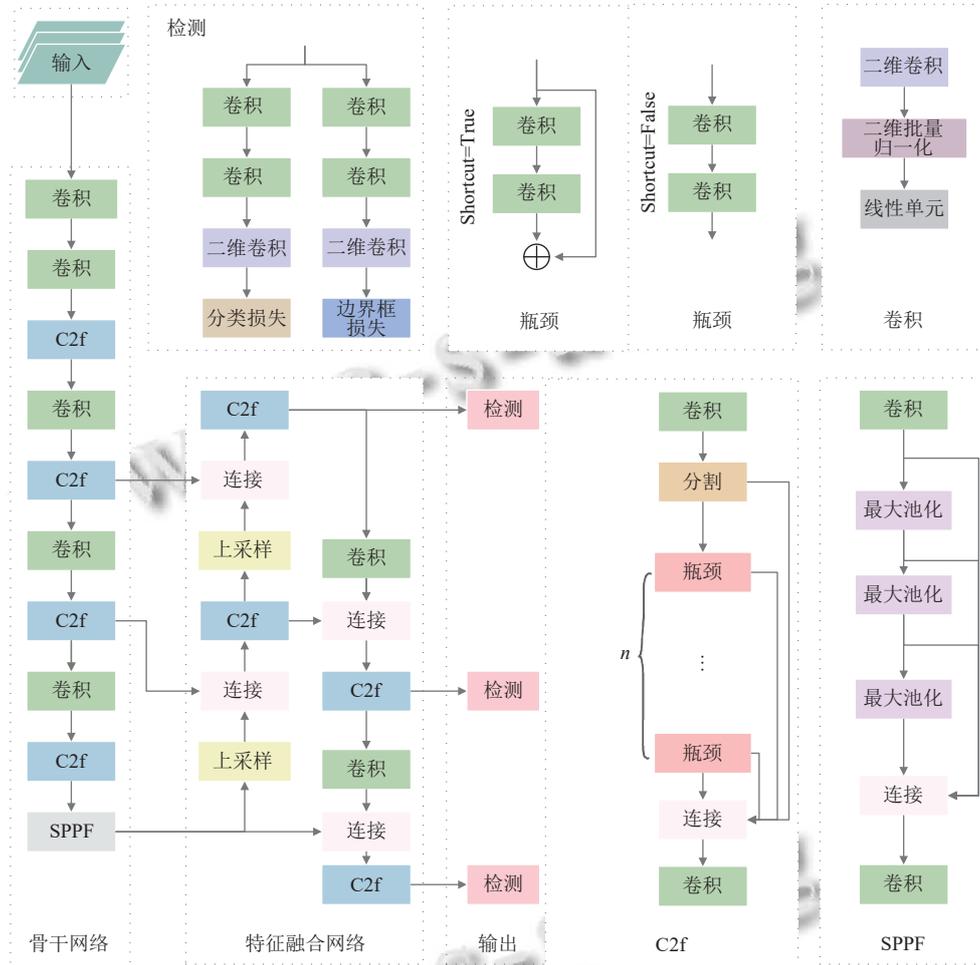


图1 YOLOv8n 网络结构

1.2 RGCSPELAN 轻量化模块

在夜间行人检测任务中, 由于目标尺寸较小且背景复杂, 传统的特征提取方法往往无法有效捕捉夜间环境中小目标的细节特征, 进而影响检测性能. 特别是在低照度和动态噪声的影响下, 现有方法难以充分发挥其特性, 导致检测精度的下降. 为了解决这一问题, 并在保证模型轻量化的同时提升性能, 本文提出了 RGCSPELAN 模块. RGCSPELAN 模块结构示意图如图 2 所示. 该模块通过优化特征提取过程, 增强了对小目标的捕捉能力, 特别是在复杂背景下的细节还原, 同时通过精简网络结构, 减少了不必要的计算和存储开销.

轻量化模块 RGCSPELAN 融合了 GhostNet 网络

的特征冗余压缩技术、ELAN 结构的高效梯度路径设计以及重参数化策略. GhostNet 是一种轻量级神经网络架构, 通过创新的特征复用机制, 优化了计算效率. 与传统的卷积神经网络 (CNN) 通过多个卷积层生成高维特征图不同, GhostNet 采用生成少量基特征图的方式, 通过廉价的线性变换衍生出更多的特征图. 这一方法有效减少了冗余特征的计算, 降低了计算复杂度, 并在提升网络表达能力的同时, 保持较高的参数和计算效率. ELAN 结构的设计理念与 C3 和 C2f 模块相似, 均通过层次化特征聚合与多分支结构, 有效捕获不同层次的特征信息. 这种结构化的特征处理方式能够实现不同层次特征的融合, 从而提升模型对复杂模式的

表达能力. 除此之外, ELAN 结构在设计上进行了优化, 尤其是在分支间的交互方式与计算图的优化方面, 进一步增强了梯度流的优化效果, 促进了动态参数共享机制的应用. RepConv 模块是近年来在深度学习, 特别是卷积神经网络中提出的一个重要结构优化手段. 其主要目的是通过对卷积操作的重新参数化, 提升卷积神经网络在推理阶段的速度和效率, 同时尽量减少推理时的计算开销. RepConv 的结构设计采用训练与推理的双阶段解耦策略, 以优化计算效率并提升模型性能. 在训练阶段, RepConv 采用异质性多分支结构, 其中包括 3 个并行分支: 3×3 卷积作为主分支, 负责捕捉局部空间特征; 1×1 卷积用于建模跨通道交互, 弥补固定卷积核感受野的限制; 恒等连接分支则保留输入特征图的原始信息, 有助于缓解梯度消失问题. 具体的数学表达式为式 (1):

$$y_{\text{train}} = f_{3 \times 3}(x) + f_{1 \times 1}(x) + x \quad (1)$$

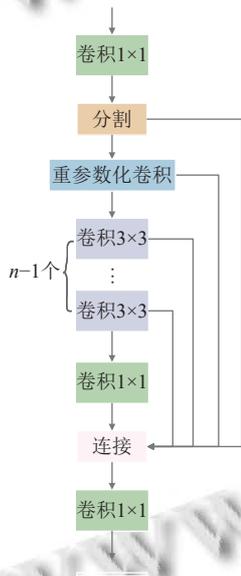


图2 RGCSPELAN 结构示意图

模型的输出 y_{train} 等于 3 个分支的输出之和, 分别为空间特征 $f_{3 \times 3}(x)$ 、通道交互 $f_{1 \times 1}(x)$ 和输入特征图 x 的恒等映射. 该设计通过多路径梯度反向传播联合优化参数, 显著增强模型的特征融合能力. 在推理阶段, RepConv 基于结构重参数化技术, 将多分支结构等价转换为单一 3×3 卷积操作. 具体实现依赖卷积运算的线性叠加性: 首先, 将 1×1 卷积核通过零填充扩展至 3×3 尺寸, 并将恒等连接映射等效为单位矩阵的 1×1 卷积 (同样填充对齐); 随后, 将各分支的卷积核及偏

置项分别叠加, 形成融合后的参数, 计算公式如式 (2) 所示:

$$W_{\text{fused}} = W_{3 \times 3} + \text{pad}(W_{1 \times 1}) + \text{pad}(I), b_{\text{fused}} = b_{3 \times 3} + b_{1 \times 1} \quad (2)$$

其中, $\text{pad}(\cdot)$ 表示零填充操作, I 对应恒等映射的单位矩阵. 此过程严格遵循计算图等价性原则, 确保融合后的单分支卷积输出与原始多分支结构一致, 从而在维持模型性能的同时, 显著降低推理时的计算冗余与内存访问开销. 该机制的可行性源于卷积操作的线性特性与参数空间的有限性质, 使得多分支动态特征学习与单路径静态部署需求得以高效统一. RepConv 结构如图 3 所示.

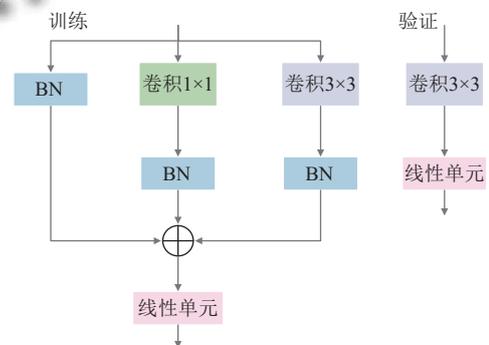


图3 RepConv 结构

RGCSPELAN 模块融合了多种网络结构的设计: 首先采用 GhostNet 的卷积策略生成初始特征图, 并通过分层架构实现多尺度特征提取; 同时借鉴 ELAN 的分支处理思想, 将初始特征经 split 模块拆分为双路径结构——主路径延续多层特征递进处理, 辅路径则直接与主路径输出特征融合, 经卷积整合后输出特征结果.

在模块优化方面, 该架构摒弃了 YOLOv8 中常规使用的 BottleNeck 组件, 转而通过重参数化技术弥补结构调整带来的性能影响. 具体而言, 在梯度传导分支引入 RepConv 模块, 该模块在训练阶段维持复合卷积结构以增强特征提取能力, 推理阶段则通过重参数化转化为等效单卷积, 在保持模型精度的同时实现计算加速与结构简化. 这种动态调整机制既保留了深层特征表达能力, 又降低了模型复杂度.

1.3 细粒度分类的注意力机制 (AFGC)

注意力机制是深度学习领域中一种模拟人类视觉注意力的技术. 该技术使模型能够聚焦于输入数据中的关键区域, 提高计算效率并增强模型的性能. 核心原理是一个可学习的自动加权求和过程. 通过为不同的

输入特征分配不同的注意力权重,模型能够自动识别并关注数据中更为重要的部分。

AFGC技术能够有效聚焦图像中与行人相关的关键区域,从而减少背景噪声对检测过程的干扰。这种优化提升了模型在复杂夜间环境中的识别能力。此外,AFGC结合了多尺度特征融合策略,能够有效应对不同尺度的行人目标,提高了YOLOv8在不同距离和不同亮度条件下的检测精度。在特征生成与校正方面,AFGC通过自适应机制生成高质量的多尺度特征图,增强了模型在低对比度和噪声干扰下的表现。特征校正模块进一步优化了生成的特征,使得行人目标在低光照条件下的检测更加精准。通过增强特征对比度,AFGC使得行人目标在视觉上更加易于辨识,进一步提升了YOLOv8在夜间行人检测中的整体性能。

1.4 双向特征金字塔网络 BiFPN

BiFPN是一种高效的多尺度特征融合模块,旨在解决传统特征金字塔网络(feature pyramid network, FPN)在目标检测任务中存在的特征冗余与信息流失问题。在YOLOv8n中,BiFPN通过双向跨尺度连接与可学习的加权特征融合机制,提升了模型对不同尺度

目标的检测能力,尤其是小目标的识别精度。BiFPN摒弃传统FPN的单向信息流模式(如自上而下或自下而上),引入双向路径聚合机制。具体而言,相邻层级的特征图通过自顶向下(高层语义特征向底层传递)和自底向上(底层细节特征向高层传递)的双向路径交互,形成闭环信息流。这种设计允许特征在不同分辨率层级间多次融合,从而增强多尺度特征的上下文关联性。传统特征融合(如拼接或相加)默认各层级特征贡献均等,而BiFPN通过引入可学习的归一化权重参数,动态调整不同层级特征的融合权重。例如,对于输入特征图 P_i 与 P_j ,其融合公式可表示为式(3):

$$P_{\text{fused}} = \frac{w_i \cdot P_i + w_j \cdot P_j}{w_i + w_j + \epsilon} \quad (3)$$

其中, w_i 与 w_j 为训练过程中优化的权重系数, ϵ 为数值稳定性常数。此机制使模型能够自适应地强化重要特征层,抑制噪声或冗余信息。

BiFPN模块不仅提升了模型的多尺度目标检测性能(尤其是小目标场景),还通过轻量化^[14]设计维持了实时推理效率,成为平衡精度与速度的关键模块。BiFPN网络结构如图4所示。

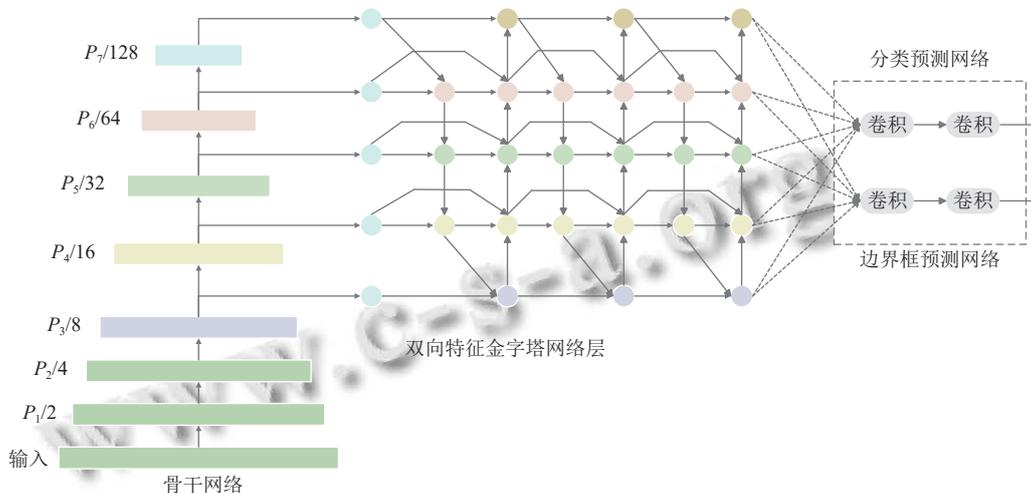


图4 BiFPN结构图

1.5 LSCD检测头

在目标检测任务中,特别是在复杂场景下,网络必须处理来自不同尺度和密集特征图的信息。这种处理要求网络能够有效地融合多尺度特征。然而,传统的卷积解码方法在执行多尺度特征融合时,会产生大量冗余信息。这种冗余信息的存在使计算开销显著增加。此外,在处理复杂图像场景时,如何从高维特征空间中有

效提取有用信息,仍然是一个待解决的难题。随着网络深度的增加,计算和内存消耗也会显著上升,从而严重影响推理速度和整体效率。

LSCD模块通过引入可学习的稀疏卷积机制,有效解决了上述问题。该模块采用稀疏卷积操作,在特征图中通过选择性地对稀疏位置进行卷积计算,减少了冗余计算,并提升了计算效率。稀疏卷积不仅能够有效保

本实验参数设置如表2所示。

表2 实验参数

参数	配置
optimizer	SGD
img-size	640×640
epochs	200
batch-size	8

2.3 评价指标

由于本研究仅涉及夜间行人的单一识别目标,因此属于二分类问题。在模型评估时,选择了精确度(Precision)、召回率(Recall)、平均精度($mAP@50$)、模型参数量、浮点计算量(FLOPs)和每秒帧数(FPS)这6个指标,以全面衡量模型的精度与计算效率。

精确度是分类任务中衡量模型预测结果中正类样本的准确性的指标,精确度高意味着模型预测为正类的样本中,真正正类样本的比例较高。召回率是另一种用于评估分类模型的指标,它反映了模型识别出的正类样本占有所有实际正类样本的比例,召回率高意味着模型能够识别出更多的正类样本,尽管可能也会增加误报(即更多的假阳性)。在目标检测和多标签分类等任务中,平均精度(mean average precision, mAP)被广泛采用,作为综合性能评估指标,特别是在精确度与召回率之间的平衡问题上。 $mAP@50$ 通常表示在交并比(intersection over union, IoU)阈值为0.5的情况下计算的平均精度。该指标主要用于评估目标检测任务中各个类别的检测精度,并提供对模型整体性能的一个概览。 mAP 值的提高表明模型在处理多类别检测任务时能展现出更为优越的性能。模型的参数量指的是构成神经网络的所有权重和偏置的总和,它是衡量模型复杂度的重要指标之一。参数量通常与模型的存储需求、计算能力以及推理速度密切相关。网络的参数量越大,通常意味着模型具有更高的表达能力,但是,这也可能增加过拟合(overfitting)的风险,尤其是在训练数据有限的情况下。浮点计算量(floating point operations, FLOPs)是评估模型在执行一次前向传播或反向传播时所需计算资源的常用指标,其单位为10亿次浮点运算,该指标可以反映模型的计算复杂度,与推理速度和能效存在紧密联系。FLOPs值较低的模型通常会有更快的推理速度,并且在运算过程中能降低能量消耗。使用FPS来测试检测速度,它能够直接影响实时目标检测任务的响应能力和效率。其具体公式如式(4)–式(7):

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

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

$$mAP@50 = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

$$FLOPs = H' \times W' \times C_{out} \times K^2 \times C_{in} \quad (7)$$

其中, TP (true positives) 表示正确预测为正类的样本数量, FP (false positives) 表示错误预测为正类的样本数量, FN (false negatives) 表示将实际正类样本预测为负类的样本数量, AP_i 是针对每个类别的平均精度, N 是类别数, $H' \times W'$ 是输出特征图的尺寸, C_{out} 是输出通道数, K^2 是卷积核的大小, C_{in} 是输入通道数。

3 结果与分析

3.1 消融实验

为了验证本文算法中的关键模块与改进对目标检测效果的影响,开展了消融实验,结果见表3。可以看出,采用原始YOLOv8n模型分类的平均精度值 $mAP@50$ 为0.923,精确度和召回率分别为0.930、0.822,参数量和浮点计算量分别为3.006M和8.1 GFLOPs。与原始YOLOv8n模型相比,用RGCSPELAN模块替代C2f模块(方案1)使得基线模型在牺牲较小检测精度的同时,大幅度降低了模型的大小与计算成本, $mAP@50$ 降低0.2%,精确度降低0.013,召回率上升0.002,参数量和浮点计算量分别减少26.9%和25.9%。引入AFGC注意力机制(方案2)后, $mAP@50$ 上升0.2%,精确度降低0.028,召回率上升0.017,参数量减少,浮点计算量未变。采用BiFPN替换Neck中的PANet模块后(方案3),受到骨干网络中的池化操作和卷积作用的影响, $mAP@50$ 上升0.4%,精确度降低0.028,召回率上升0.017,参数量和浮点计算量分别减少33.7%和12.3%。把YOLOv8n的检测头替换成了LSCD检测头(方案4), $mAP@50$ 降低0.3%,精确度降低0.015,召回率降低0.008,参数量和浮点计算量分别减少21.4%和19.7%。方案5是RGCSPELAN模块、AFGC注意力机制、BiFPN模块相结合, $mAP@50$ 上升0.1%,精确度降低0.028,召回率上升0.030,参数量和浮点计算量分别减少45.4%和27.1%。方案6是RGCSPELAN模块、AFGC注意力机制、LSCD检测头相结合,

$mAP@50$ 降低 0.4%，精确度降低 0.032，召回率上升 0.012，参数数量和浮点计算量分别减少 46.1% 和 44.4%。方案 7 是 BiFPN 模块、AFGC 注意力机制、LSCD 检测头相结合， $mAP@50$ 上升 0.4%，精确度降低 0.018，召回率上升 0.016，参数数量和浮点计算量分别减少 43.7% 和 25.9%。方案 8 添加了所有的改进方案的模块，相较于原始 YOLOv8n 模型， $mAP@50$ 上升 0.3%，精确度降低 0.013，召回率上升 0.009，参数数量和浮点

计算量分别减少 58% 和 42%。即方案 8 在保持平均精度、精确度和召回率变化较小的同时，显著减少了参数数量和浮点计算量，成功实现了模型的轻量化。从 FPS 数据来看，改进后的 RABL-YOLOv8n 模型虽然没有显著提高 FPS，但其精度优化和结构增强可能对特定应用场景具有更高的适应性。整体而言，RABL-YOLOv8n 在推理速度和性能平衡方面展现了更为优越的表现。

表 3 消融实验结果

编号	改进方法				参数数量 (M)	FLOPs (G)	精确度	召回率	$mAP@50$ (%)	FPS (f/s)
	RGCSPPLAN	AFGC	BiFPN	LSCD						
YOLOv8n	×	×	×	×	3.006	8.1	0.930	0.822	92.3	96
方案 1	√	×	×	×	2.197	6.0	0.917	0.824	92.2	82
方案 2	×	√	×	×	3.072	8.1	0.902	0.839	92.5	73
方案 3	×	×	√	×	1.991	7.1	0.902	0.839	92.7	93
方案 4	×	×	×	√	2.362	6.5	0.915	0.814	92.0	76
方案 5	√	√	√	×	1.639	5.9	0.883	0.852	92.4	88
方案 6	√	√	×	√	1.620	4.5	0.898	0.834	91.9	82
方案 7	×	√	√	√	1.692	6.0	0.912	0.838	92.7	80
方案 8	√	√	√	√	1.274	4.7	0.917	0.831	92.6	96

注: √表示原始模型YOLOv8n中相应模块被替换, ×表示原始模型YOLOv8n相应模块未被替换

3.2 对比实验

为了更直观地展示 RABL-YOLOv8n 的优势, 本文设计了一些对比实验, 所有实验均使用相同的数据集、设备和参数, 并选择了几种经典的 YOLO 模型与 RABL-YOLOv8n 进行比较。由表 4 可以看出 YOLOv3t 参数数量和浮点计算量都极高, 精确度、召回率、 $mAP@50$ 比 YOLOv8n 低; YOLOv5n 与 YOLOv8n 相比参数数量和浮点计算量分别降低了 16.7% 和 12.3%, 但与改进的 RABL-YOLOv8n 相比降低数值还远远不够, 且精确度、召回率、 $mAP@50$ 都低于 RABL-YOLOv8n; YOLOv6n 与 RABL-YOLOv8n 相比参数数量和浮点计算量大幅上升, 精确度、 $mAP@50$ 下降, 召回率略微上升; YOLOv10n 的参数数量和浮点计算量与 YOLOv8n 相比下降 24.7% 和 19.8%, 但与改进后的 RABL-YOLOv8n 远不能比, 且精确度、召回率、 $mAP@50$ 也不及 RABL-YOLOv8n。因此, 本文提出的改进模型 RABL-YOLOv8n, 具有较高的识别精度和更优的识别效率, 更适合应用于嵌入式设备。通过比较不同版本的 YOLO 模型, 可以观察到随着架构优化和轻量化设计的实施, 模型的推理速度普遍得到提升。YOLOv5n 和 YOLOv6n 在一定程度上保持了较高的效率。YOLOv8n 和 YOLOv10n 则在保持较高 FPS 的同时进一步优化了模型架

构, 体现了在目标检测领域提高模型推理速度与精度之间的良好平衡。改进后的 RABL-YOLOv8n 与原 YOLOv8n 在推理速度上的相似性说明了改进方法对性能的保持作用, 并且在其他任务上有所增强。

表 4 对比实验结果

模型	参数数量 (M)	FLOPs (G)	精确度	召回率	$mAP@50$ (%)	FPS (f/s)
YOLOv3t	12.128	18.9	0.901	0.762	85.6	159
YOLOv5n	2.503	7.1	0.911	0.822	92.3	71
YOLOv6n	4.234	11.8	0.906	0.833	92.2	92
YOLOv10n	2.265	6.5	0.909	0.814	92.5	93
YOLOv8n	3.006	8.1	0.930	0.822	92.3	96
RABL-YOLOv8n	1.274	4.7	0.917	0.831	92.6	96

3.3 模型泛化性验证

为了验证 RABL-YOLOv8n 算法的泛化能力, 本文在两个复杂天气数据集下将该模型与原始模型进行了对比实验。表 5 数据集为雾天道路数据集, 包含行人、自行车、摩托车、汽车、公共汽车这 5 类; 表 6 数据集为恶劣天气 (雨天、雪天、雾天等) 道路数据集, 包含行人、骑手、汽车、卡车、公共汽车、火车、摩托车、自行车这 8 类。由表 5、表 6 可以看出, 该算法与原始模型相比, 参数数量和浮点计算量分别减少 58% 和 42%, 而精确度、召回率、 $mAP@50$ 变化不明显, 而且改进后模型的 FPS 与原模型相比变化不大, 都保持较

高水平,这一结果充分证明了 RABL-YOLOv8n 算法的有效性及其优良的泛化能力。

表5 在雾天道路数据集上的检测结果对比

模型	参数量 (M)	FLOPs (G)	精确度	召回率	mAP@50 (%)	FPS (f/s)
YOLOv8n	3.006	8.1	0.774	0.634	71.3	93
RABL-YOLOv8n	1.275	4.7	0.749	0.615	69.4	86

表6 在恶劣天气道路数据集上的检测结果对比

模型	参数量 (M)	FLOPs (G)	精确度	召回率	mAP@50 (%)	FPS (f/s)
YOLOv8n	3.006	8.1	0.334	0.124	8.9	89
RABL-YOLOv8n	1.275	4.7	0.326	0.16	7.7	95

4 结论

(1) 本文在 YOLOv8n 模型的基础上,设计轻量化模块 RGCSPELAN,在骨干网络的第 10 层增加细粒度分类的注意力 (AFGC) 机制,用 BiFPN 模块代替 Neck 中的 PANet 模块, LSCD 检测头替换原有检测头,构建基于 YOLOv8n 的改进模型——RABL-YOLOv8n 模型. 通过使用自建数据集进行对比实验,结果表明改进后的模型有效解决了夜间低照度场景中行人检测的目标模糊、特征弱化和小尺度漏检问题,同时减少了冗余信息、模型参数和浮点计算量,提升了训练速度和识别精度,成功实现了夜间行人的轻量化识别。

(2) 消融实验结果表明,不同改进模块对模型的参数量、浮点计算量、精确度、召回率和平均精度产生了不同的影响. 综合采用 4 个模块后,模型的参数和浮点计算量分别比原始模型减少了 58% 和 42%,而精确度、召回率和平均精度变化较小,效果最佳. 与其他模型的对比结果也显示,改进后的 RABL-YOLOv8n 模型在减少参数和浮点计算量方面表现突出,且能保持精确度、召回率和平均精度几乎不变. 这些结果均表明 RABL-YOLOv8n 模型在夜间行人检测中表现出色. 最后通过泛化实验,结果充分证明了 RABL-YOLOv8n 算法的有效性及其优良的泛化能力。

参考文献

- 1 余利君,刘军清. 夜间车辆检测研究综述. 长江信息通信, 2023, 36(2): 105-107.
- 2 Girshick R, Donahue J, Darrell T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the 27th IEEE Conference on Computer Vision and Pattern Recognition, 2014. 580-587.
- 3 Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017. 6517-6525.
- 4 Redmon J, Farhadi A. YOLOv3: An incremental improvement. arXiv:1804.02767, 2018.
- 5 熊俊涛,郑镇辉,梁嘉恩,等. 基于改进 YOLOv3 网络的夜间环境柑橘识别方法. 农业机械学报, 2020, 51(4): 199-206.
- 6 何自芬,陈光晨,陈俊松,等. 多尺度特征融合轻量化夜间红外行人实时检测. 中国激光, 2022, 49(17): 130-139.
- 7 徐丽,刘星星,屈立成. 基于 YOLOv4 的夜间车辆检测模型轻量化研究. 计算机技术与发展, 2022, 32(3): 84-89.
- 8 张文龙,南新元,徐明明,等. 基于通道注意力的轻量行人检测算法. 现代电子技术, 2022, 45(16): 133-138.
- 9 刘振兴,宋晓宁. 融合上下文及空间信息的拥挤行人检测算法. 小型微型计算机系统, 2023, 44(9): 2017-2022.
- 10 Zhou P, Ni BB, Geng C, *et al.* Scale-transferrable object detection. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 528-537.
- 11 魏陈浩,杨睿,刘振丙,等. 具有双层路由注意力的 YOLOv8 道路场景目标检测方法. 图学学报, 2023, 44(6): 1104-1111.
- 12 戴林华,黎远松,石睿. 基于改进 YOLOv8 的带钢表面缺陷检测算法. 制造技术与机床, 2024(11): 139-148.
- 13 Sun Z, Zhu LX, Qin S, *et al.* Road surface defect detection algorithm based on YOLOv8. Electronics, 2024, 13(12): 2413. [doi: 10.3390/electronics13122413]
- 14 Tie J, Zhu CG, Zheng L, *et al.* LSKA-YOLOv8: A lightweight steel surface defect detection algorithm based on YOLOv8 improvement. Alexandria Engineering Journal, 2024, 109: 201-212. [doi: 10.1016/j.aej.2024.08.087]

(校对责编:李慧鑫)