

基于改进 YOLOv11n 的复杂路况下道路病害检测算法

李志龙¹, 王靖岳¹, 黄理程¹, 于文泰²

(1. 沈阳理工大学汽车与交通学院, 沈阳 110159; 2. 辽宁理工学院汽车与机械工程学院, 辽宁 锦州 121007)

摘要: 道路目标检测实验在复杂路况下非常容易出现漏检、误检和重复检测。针对在复杂路况下的道路实时检测, 提出一种基于 YOLOv11 的改进算法。设计了一种高效的新型分组提取卷积替换原 YOLOv11n 模型中特征提取网络的卷积, 显著扩大了模型感受野, 增强了对小尺度目标的检测能力; 针对复杂路况中图像光影关系不明显, 容易出现光线暗淡和阴影重叠等问题; 引入 C2DyBRA 模块强化模型对特征细节的捕捉, 进而优化边界框预测的准确性与匹配度; 最后改进上采样方式使用新型上采样算子 DySample 增强目标与背景的对比度, 同时有效提升了对密集道路病害目标的定位精度。实验结果表明, 改进后的算法在保持原基准模型轻量的基础上, mAP@0.5 相较于原基准模型提高了 9.8%, 召回率提升了 7.7%。显著提升了检测精度的同时满足实时性的要求, 表现出了更出色的检测效果。

关键词: 目标检测; YOLOv11; 复杂路况; 道路病害

中图分类号: U49; TP39

文献标志码: A

Improved YOLOv11n Road Damage Detection Algorithm for Complex Road Conditions

LI Zhilong¹, WANG Jingyue¹, HUANG Licheng¹, YU Wentai²

(1. School of Automotive and Transportation, Shenyang Ligong University, Shenyang 110159, China; 2. School of Automobile and Mechanical Engineering, Liaoning Institute of Science and Engineering, Jinzhou 121007, Liaoning Province, China)

Abstract: Road object detection experiments in complex road environments are prone to missed detections, false alarms, and repeated detections. To address real-time road damage detection under complex road conditions, this paper proposes an improved algorithm based on YOLOv11. An efficient novel grouped extraction convolution is designed to replace the convolutions in the feature extraction network of the original YOLOv11n model, significantly expanding the model's receptive field and enhancing its detection capability for small-scale targets. To tackle issues such as weak illumination relationships, low light, and shadow overlaps in complex road scenarios, the upsampling method is improved by using the novel DySample upsampling operator to enhance the contrast between targets and the background, while effectively improving the localization accuracy for densely distributed road distress. Finally, the C2DyBRA module is introduced to strengthen the model's ability to capture feature details, thereby optimizing the accuracy and matching degree of bounding box predictions. Experimental results show that the improved algorithm, while maintaining the lightweight nature of the original baseline model, achieves a 9.8% increase in mAP@0.5 and a 7.7% improvement in recall compared to the original baseline model. It significantly enhances detection accuracy while meeting real-time requirements, demonstrating superior detection performance.

Keywords: target detection; YOLOv11; complex road conditions; road distress

收稿日期: 2025-12-13

修回日期: 2026-06-05

基金项目: 国家重点研发计划项目(2018YFB0105004); 辽宁省教育厅高校基本科研项目(LJ212510144037); 辽宁理工学院开放合作科研课题(LNLGKFH203)

第一作者: 李志龙(2000—), 男, 江苏泰州人, 硕士研究生, 主要研究方向为车辆检测与电子控制。E-mail: 1102235042@qq.com

通讯作者: 王靖岳(1978—), 男, 辽宁铁岭人, 教授, 工学博士, 主要研究方向为车辆系统动力学与控制。E-mail: abswell@126.com

公共交通设施作为现代社会运作的命脉,其建设与维护水平直接影响着社会的经济发展。截至2022年底,中国公路总里程已经突破535万km,然而在温度循环、重载交通、材料老化等多种因素作用下,道路普遍出现裂缝、坑槽、网裂等道路病害。据交通运输部统计,因道路破损导致的交通事故占比达23.6%,其中坑洼引发的车辆失控

事故年均增长率达8.7%,这几项数据凸显了道路病害检测与预防性道路养护工作的重要性和紧迫性。除此以外,仍然有许多破损道路、乡村土路等条件恶劣的路况难以被检测和识别道路病害类型。本文聚焦于此类复杂的道路情况,通过改进算法模型检测复杂路况下的道路病害。

传统道路检测主要依赖人工巡检与专业检测车检测,前者主要存在检测效率低、检测成本高且由于主观性强易导致检测精度下降等问题;后者虽配备了激光断面仪和雷达等精密设备,但单次作业成本核算后高达每公里3~5万元,难以满足我国公路里程长、检测频率高的现实需求。现在随着计算机视觉技术的突破,基于深度学习的智能检测方法为破解这一难题提供了新的思路。当前基于深度学习的目标检测算法主要分为双阶段与单阶段两类技术路线。其中以 Girshick 等^[1]提出的 R-CNN 和 Girshick^[2]提出的 Faster-R-CNN 为代表的双阶段算法首先需要生成候选区域进行特征提取,再通过卷积神经网络完成目标分类与定位,其中 Faster-R-CNN 最核心的创新就是 Zhang 等^[3]提出的区域建议网络(region proposal network, RPN),虽然双阶段算法的多步骤处理机制能够显著提升检测的精度,但是处理速度慢的缺点导致其难以在需要实时传输数据的动态环境中进行有效应用;而以文献[4-7]提出的 YOLO 系列、Liu 等^[8]提出的 SSD 和 Lin 等^[9]提出的 RetinaNet 为代表的单阶段算法,则是通过端到端的架构直接在特征图上进行目标预测。由于省去了候选框生成环节,此类单阶段算法不仅减少了候选区域产生的扰动,更将推理速度提升至传统双阶段算法的数倍,尤其适配自动驾驶等实时性要求较为苛刻的场景。“你只看一次”(you only look once, YOLO)系列模型作为单阶段算法中的一种,在检测精度与检测速度等指标上都达到了较高的水平,且在不同场景下拥有良好的泛化性,正是基于以上优势,YOLO 系列已成为目标检测领域的主流算法,并在 COCO 等基准数据集上持续刷新性能记录。

近些年的研究中,针对小目标检测问题,丛玉华

等^[10]提出了一种轻量的小目标检测网络 CSPBiA-YOLO,通过引入空间金字塔池化(spatial pyramid pooling, SPP)模块,优化了网络的特征提取的能力,在 VisDrone 数据集上在获得较高检测精度的同时保持了良好的检测速度,并且该模型在嵌入式设备上同样有很高的适用性。季顺帆等^[11]提出一种基于改进 YOLOv8n 的检测算法 YOLO-SGCF,该模型在主干网络引入空间深度转换卷积(Space-to-Depth Convolution, SPDConv),有效保留空间信息并增强多尺度特征表达能力,提升了模型对小目标的检测精度。王晓红等^[12]提出了一种基于 YOLOv7-w6 的改进网络 EMT-ECoTNet。该网络引入 CoT 模块与 MA-ECA 通道注意力机制,构建 ECoT Block 以增强小目标特征提取能力;同时采用 M-SPPF、CSPC 结构及 EIoU 损失函数,进一步提升检测精度与收敛速度。在 VisDrone 数据集上的实验表明,EMT-ECoTNet 的 mAP@0.5 达到 62.8%,相比原始 YOLOv7-w6 提高了 3.2 个百分点。曹利等^[13]提出了一种基于 YOLOv8n 改进的航空小目标检测模型 ASOD-YOLO。该模型将原有的特征金字塔结构的自上而下部分替换为低层的信息分发结构,在减少特征损失的同时增强不同尺度间信息融合的能力;相较于基线模型,在 mAP@50 指标上提升了 4.1 个百分点,在 mAP@50:95 指标上提升了 2.3 个百分点,有效完成了小目标检测任务。Sami 等^[14]提出了一种改进 YOLOv7 的目标检测算法。该方法通过增设小目标检测层增强对小目标的特征学习能力;采用 K-means++对先验框进行了重聚类,使其更贴合真实目标分布,提升定位精度;引入 WIoU 损失函数并且在颈部与检测头嵌入协调坐标卷积(CoordConv),提升对特征图位置信息的定位和感知能力。实验结果表明,该算法在华为 SODA10M 数据集上的 mAP 达到 64.8%,较原模型提升 2.6 个百分点,但是未能平衡好准确率和检测速度之间的差值。Dai 等^[15]开发了一种名为门控跨域协作网络(GCC-Net)的模型,该网络借助实时图像增强策略,并结合特征跨域交互与多源特征融合模块,有效提升了图像中低对比度区域的视觉可辨识性。不过由于在某些情况下存在过度增强的问题,部分关键细节特征反而被削弱,导致在目标发生遮挡的区域仍可能出现误检测的情况。Fan 等^[16]利用编码器、解码器和基于残余注意力模块的图像频率关系对路面裂缝进行检测,然而由于裂缝分布密集且尺度差别很大,导致检测的效果一般。

在改进轻量化模型方面,赵贺等^[17]提出一种基

于 YOLOv5 的轻量级目标检测模型 GSC-YOLO, 该模型在主干网络引入了幻影卷积并且采用 Cluster_NMS 算法和独特的注意力模块, 达到了减少参数数量和模型体积的同时提升检测性能的目的。相较于基准模型, 赵等人提出的 GSC-YOLO 平均精度提高了 3.1%, 模型参数量下降了 82.1%, 模型体积降低了 77.4%。梁龙学等^[18]提出了一种独特的双路径特征金字塔网络, 这种机制通过其新模型的双向交互特征提升了对检测区域缺陷的识别准确度。实验结果表明, 该算法的平均精度为 83.7%, 同时将推理模型的参数规模降低至 5.7M, 实时检测速度高达每秒 143.4 帧, 满足了检测精度与实时性的双重需求。

以上现有的模型在保持轻量化的基础上, 对普通道路情况下的道路病害检测已经具备较好的效果, 比如李欣等^[19]提出的双核卷积路面裂缝检测算法, 该算法融合多维度特征, 加入三支注意力机制, 运用跨维度交互技术构建通道、高度与宽度维度间的相互依赖性, 使模型具备多维度特征提取能力; 接着, 用双核卷积替代传统卷积以达成模型轻量化; 此外, 采用改进的 MPDIou 边界框回归函数取代 CIoU 边界框回归函数, 加快模型收敛速度。相较于基准模型 YOLOv8, 在 RDD2022 数据集上, F1 和 mAP 分别提升了 7.5% 和 5.3%, 参数量与计算量分别减少了 0.2% 和 0.7%。罗晖等^[20]改进了 YOLOv4 算法用于公路病害检测, 该模型在 DC 模块和 FL 模块的联合驱动下, 降低了网络参数量并解决了网络训练过程中正、负样本不平衡而导致的检测精度较低的问题, 同样具有一定的先进性。

然而当将此类算法应用于复杂路况下的道路病害检测时仍面临显著挑战: 一方面, 坑洼目标具有尺度差异大(从毫米级裂缝到米级凹陷)、形变不规则等特性, 另一方面, 现有道路病害数据集规模有限, 难以充分表征复杂路面场景中的阴影反光、修补痕迹等干扰因素, 导致模型易出现漏检与误检。因此本文借鉴郭中华等^[21]的模型改进思想, 该改进模型对传统时间序列模型的局限性进行深入分析, 研究了一种融合全连接层和 KAN 网络的双路径设计, 在原模型基础上融入了多尺度卷积和高效通道注意力机制, 从而提升了模型的准确性和鲁棒性, 展现出较强的预测能力。

基于对以上文献的学习和总结, 针对复杂路况下道路病害检测面临的小目标漏检、阴影干扰、特征边缘模糊三大核心挑战, 本文提出一种基于 YOLOv11n 的改进算法, 主要创新点如下: 1) 提出分组提取卷积模块 C3K2-GEC。针对传统卷积感受野受限导致小尺

度裂缝、坑槽难以捕获的问题, 设计非对称分组提取卷积, 通过放射状感受野扩增策略, 减少了 22.2% 的参数量, 同时显著增强模型对小目标的方位敏感表征能力。2) 引入动态双路注意力模块 C2DyBRA。针对复杂光影环境下病害特征被阴影、反光干扰难以辨识的问题, 借鉴 BiFormer 双层路由机制, 构建区域级稀疏注意力, 使模型在计算复杂度降低的同时, 自适应聚焦病害关键区域, 有效抑制背景噪声。3) 采用轻量化上采样算子 DySample。针对密集病害群中边缘模糊、定位不准的问题, 以点采样替代动态卷积, 在不增加计算负担的前提下实现对网状裂缝、龟裂等密集病害的精确定位。上述三项改进在保持 YOLOv11n 轻量特性的同时, 在自建 SDR 数据集上实现 mAP@0.5 提升 9.8%、召回率提升 7.7% 的显著效果, 验证了本文方法在复杂路况下的有效性与鲁棒性。

1 YOLOv11 算法概述

YOLOv11 是 Ultralytics 团队于 2024 年 9 月 30 日推出的新一代目标检测模型, 作为该系列最新的迭代版本, 和 YOLO 系列的经典版本如 YOLOv1、王婉婷等^[22]提出的 YOLOv3、程擎等^[23]提出的 YOLOv4、YOLOv5 和 YOLOv8 对比, YOLOv11 在模型架构与计算效率方面实现了突破性升级, 其具体的结构如图 1 所示。

该结构采用 C3K2 模块替代传统 C2f 结构, 并在 SPPF 后引入 C2PSA 注意力模块以增强全局特征建模能力, 该模块通过融合改进型 C2f 架构与 PSA 注意力机制, 集成多头注意力单元和前馈神经网络, 既能并行处理多维特征信息, 又能通过高维映射捕捉复杂非线性特征, 配合可选的残差连接有效优化了梯度流动效率。检测头采用深度可分离卷积与解耦头结构, 在保持精度的同时降低计算负载。YOLOv11 架构提供了五种不同规格的模型, 按参数量与计算复杂度由低至高依次为 n、s、m、l 和 x。这种梯度化的设计旨在适配从计算资源受限到追求精度的多样化检测任务需求, 本文选择的基准模型为精度和模型体积比较均衡的轻量化版本 YOLOv11n, 此模型通过精简网络层级和参数规模, 相较于前代 YOLOv10n 实现 2% 的推理加速与计算资源优化, 其平衡性能与效率的特性使其成为资源受限场景下实时检测任务的理想选择。在此基础上, 该模型还采用 PAN-FPN 结构强化深浅层特征融合能力, 配合改进的空间金字塔池化策略, 全面提升了多尺度目标的定位精度与特征表征多样性。




图 1 YOLOv11 网络结构

Fig. 1 YOLOv11 network structure

2 YOLOv11 算法改进

为提升复杂路况下道路病害的检测效能,本研究提出了一种基于YOLOv11n的改进模型,整体架构如图2所示。

该模型主要包含三项核心改进: 首先, 在网络主干部分原有的 C3K2 模块中使用一种新颖的卷积结

构替代标准卷积,以显著扩大模型感受野,从而增强对小尺度目标的检测能力;其次,采用 C2DyBRA 模块替换原模型中的 C2PSA 模块,以强化模型对特征细节的捕捉,进而优化边界框预测的准确性与匹配度;最后,在颈部网络的特征融合阶段引入新型上采样算子 DySample,通过增强目标与背景的对比度,有效提




图 2 YOLOv11 改进网络结构

Fig. 2 Improved YOLOv11 network structure

升了对密集病害目标的定位精度。

2.1 改进主干网络 C3K2 结构

针对 YOLOv11n 中传统卷积对特征信息微弱的小目标很难被检测到的问题,本研究设计了一种高效

的新型卷积结构称为分组提取卷积(grouped extraction convolution, GEC)用于替换原主干网络低层 C3K2 模块中的卷积,得到新模块 C3K2-GEC, GEC 模块的结构如图 3 所示。




图 3 GEConv 结构原理图

Fig. 3 Schematic diagram of GEConv structure

GEC 作为一种新颖的卷积模块,与标准卷积在结构设计、感受野扩展和特征提取机制上存在较大区别。标准卷积通常采用对称的方形卷积核(如 \$3 \times 3\$)在空间维度上进行均匀的滑动窗口操作,其数学形式可表示为: $Y = X \otimes W$, 其中 X 为输入特征图, W 为卷积核权重, $\otimes$ 表示卷积运算。这种设计虽然简单高效,但忽略了目标的空间分布特性,相比之下,分组提取卷积通过其独特的分组提取机制实现了创新:首先,它将输入特征图($X^{(h_1, w_1, c_1)}$),在通道维度上隐式分组,其中 h_1 、 w_1 、 c_1 表示输入张量 $X^{(h_1, w_1, c_1)}$ 的高度、宽度和通道大小,同时并行施加多个方向的非对称卷积核(如 1×3 和 3×1),每个核辅以不对称填充策略(例如,填充参数 $P(1,0,0,3)$ 表示左、右、上、下方向的像素填充数),使卷积核从中心向外围呈放射状扩散。其工作原理可形式化描述为:对于每个分支(i),输出特征图计算为

$$X_i^{(h', w', c')} = \text{SiLU}(\text{BN}(X_{P(\dots)}^{(h_1, w_1, c_1)} \otimes W_i^{(k_h, k_w, c')})) \quad (1)$$

式中: W_i 为方向特异性卷积核, BN 表示批归一化, SiLU 为激活函数;

为了提高训练的稳定性和速度,我们在每次卷积

后应用批归一化(BN)和激活函数(SiLU)。第一层 PConv 执行并行卷积如下:

$$\begin{aligned} X_1^{(h', w', c')} &= \text{SiLU}(\text{BN}(X_{P(1,0,0,3)}^{(h_1, w_1, c_1)} \otimes W_1^{(1,3, c')})), \\ X_2^{(h', w', c')} &= \text{SiLU}(\text{BN}(X_{P(0,1,0,3)}^{(h_1, w_1, c_1)} \otimes W_2^{(3,1, c')})), \\ X_3^{(h', w', c')} &= \text{SiLU}(\text{BN}(X_{P(0,1,0,3)}^{(h_1, w_1, c_1)} \otimes W_3^{(1,3, c')})), \\ X_4^{(h', w', c')} &= \text{SiLU}(\text{BN}(X_{P(3,0,1,0)}^{(h_1, w_1, c_1)} \otimes W_4^{(3,1, c')})). \end{aligned} \quad (2)$$

第一层交织卷积后的输出特征图的高度 h' 、宽度 w' 和通道数 c' 与输入特征图的关系如下:

$$h' = \frac{h_1}{s} + 1, w' = \frac{w_1}{s} + 1, c' = \frac{c_2}{4} \quad (3)$$

式中: c_2 为来自 PConv 模块的最终输出特征图的通道数, s 为卷积步长。

随后,各分支输出被拼接为

$$X^{(h', w', 4c')} = \text{Cat}(X_1, X_2, X_3, X_4) \quad (4)$$

最终通过一个融合卷积层生成输出 $Y^{(h_2, w_2, c_2)}$:

$$Y^{(h_2, w_2, c_2)} = \text{SiLU}(\text{BN}(X^{(h', w', 4c')} \otimes W^{(2,2, c_2)})) \quad (5)$$

式中:

$$h_2 = h' - 1 = \frac{h_1}{s} \quad (6)$$

$$w_2 = w' - 1 = \frac{w_1}{s} \quad (7)$$

这种分组提取架构不仅更贴合小目标的空间分布规律,还能通过分组并行计算大幅提升特征提取的效率。其核心优势在于,通过分组提取策略,在较少的参数增加下实现了感受野的显著扩大。感受野的有效性向外减弱,类似于高斯型分布。此外,目标越小,其特征变得越集中,这突出了中心特征的重要性。图 3 的左下角显示了 GEConv($k=3$)的感受野是 25,卷积的数量从中心向外递减,类似于高斯分布。值得注意的是,GEConv 利用分组卷积显著增加了接受野,同时将参数量降到了最低。Conv 的参数量计算方法为下式:

$$\text{Conv}_{\text{params}} = c_2 \times c_1 \times k \quad (8)$$

式中: k 为卷积核大小。如果输出通道数 c_2 等于输入通道数 c_1 ,则 Conv 的参数为 $9c_1^2$,我们的 PConv 的参数计算如下:

$$\begin{aligned} \text{GEConv}_{\text{params}} &= 4 \times \left(\frac{c_2}{4} \times c_1 \times 3 \times 1 \right) + \\ &4c_2c_1 = 7c_2c_1 = 7c_1^2 \end{aligned} \quad (9)$$

与 Conv 的参数量 $9c_1^2$ 相比,GEConv 减少了 22.2% 的参数量。更重要的是,这种机制使网络能够从不同方向分别捕获特征响应,最后通过特征拼接和融合,形成具有方位感知能力的特征表示,这既减少了计算冗余,又实现了类似注意力机制的特征选择效果,能够自适应地强化目标区域响应。

分组提取卷积的优越性主要体现在三个方面:首先,在特征提取能力上,其分组定向提取机制能更精准地匹配小目标的高斯分布特性,增强目标与背景的分度;其次,在参数效率上,通过分组并行计算实现了感受野的指数级扩展,而参数量仅线性增长,优于传统扩张卷积的粗放式扩展;最后,在工程实用性上,该模块可显著提升小目标检测的精度和鲁棒性。实验验证表明,在小目标检测任务中,分组提取卷积在 mAP50 和 IoU 等关键指标上均优于标准卷积及其他变体,体现了其在困难检测场景中的有效性和优越性。

为检验分组提取卷积在道路病害检测任务中的优势,把优化后的模型与原模型进行了热力图可视化对比,如图 4~6 所示,展示了不同道路病害下原图和热力图可视化的结果。其中,图 4(a)、图 5(a)和图 6(a)为不同道路病害的原图;图 4(b)、图 5(b)和图 6(b)为运用标准卷积的 C3K2 模块的 YOLOv11n 的可

视化热力图;图 4(c)、图 5(c)和图 6(c)为使用分组提取卷积的 C3K2-GEC 模块的 YOLOv11n 的可视化热力图。




图 4 裂缝道路病害热力图

Fig. 4 Heatmap of crack road damage




图 5 坑槽道路病害热力图

Fig. 5 Heatmap of pothole road damage




图 6 开裂道路病害热力图

Fig. 6 Heatmap of alligator crack road damage

各图中高亮的区域代表模型所关注的重点部分,可以明显看出各图(c)都比各图(b)关注重点更加集中在道路病害中心区域,即使用分组提取卷积能够提高模型对道路病害目标的关注度。

2.2 引入 C2DyBRA 模块

目前主流的注意力机制有 SE 通道注意力、CBAM 混合注意力及 Transformer 全局自注意力,然而在复杂的道路病害检测任务中 SE 缺乏空间建模能力;CBAM 虽引入空间注意力,但局部卷积感受野受限,难以捕捉跨度较大的裂缝病害;Transformer 全局自注意力虽然能够补完以上注意力机制的短板,但计算复杂度为 $O((HW)^2)$,无法满足实时检测需求。在复杂道路场景中,传统卷积神经网络在特征提取过程中往往难以有效捕捉长距离依赖关系和全局上下文信息,导致对小尺度病害目标和部分遮挡目标的检测性能受限。为解决此问题,本文借鉴 Zhu 等^[24]提出的 BiFormer 模块中的双层路由注意力思想,设计了动态路由特征增强模块(c2f with dynamic bi-level routing attention, C2DyBRA),

该模块通过双层级路由机制实现特征的自适应聚焦,显著提升模型对关键区域的特征提取能力。

C2DyBRA 模块的核心由区域路由和特征增强两个子模块组成。给定输入特征图 $X \in R^{H \times W \times C}$, 模块首先将其划分为 $S \times S$ 个非重叠区域, 每个区域包含 $\frac{HW}{S^2}$ 个特征向量。此模块的区域路由机制通过构建区域级亲和力图实现关键区域筛选:

$$A^r = Q^r (K^r)^T \quad (10)$$

式中: $Q^r, K^r \in R^{S^2 \times C}$ 分别为区域级查询和键向量, 通过区域平均池化获得。路由索引矩阵通过 Top-K 选择生成:

$$I^r = \text{topkIndex}(A^r) \quad (11)$$

此模块的特征增强机制为在路由区域基础上执行细粒度特征提取公式为

$$O = \text{Attention}(Q, K^s, V^s) + \text{DWConv}(V) \quad (12)$$

式中: $K^s = \text{gather}(K, I^r)$ 和 $V^s = \text{gather}(V, I^r)$ 为基于路由索引聚集的键值对, DWConv 为深度卷积提供的局部上下文增强。

C2DyBRA 模块的复杂度可表示为

$$O(\text{C2DyBRA}) = O\left(S^4 C + k \frac{(HW)^2}{S^2} C\right) \quad (13)$$

式中: k 为路由区域数量。通过合理设置 S , 模块复杂度可优化至 $O((HW)^{4/3})$, 在保持全局感知能力的同时显著降低计算用量。

本文将 C2DyBRA 模块嵌入到 YOLOv11n 骨干网络的深层特征提取阶段, 替换原有的 C2PSA 模块。该设计使模型能够在保持轻量级特性的同时, 自适应地聚焦于图像中的关键区域, 有效提升了对小尺度病害和复杂背景下目标的检测精度。

2.3 改进上采样方式

传统上采样方法如双线性插值、最近邻插值计算过程较为简单, 但无法学习内容自适应特征; CARAFE、FADE 等动态上采样虽性能优异, 但需额外卷积生成动态核或偏移, 计算量较大。本文采用 Liu 等^[25]提出的 DySample 模块替换原模型中的 Upsample 模块, DySample 开创了一种新的上采样方法, 其核心在于规避传统的动态卷积操作, 转而利用点采样机制来提升整体模型效能。在基准 YOLOv11n 架构中, 常规的上采样技术往往伴随较高的计算成本, 这在一定程度上

制约了模型在资源受限的边缘设备上的应用潜力。针对拍摄的复杂路况下的路面病害检测任务, 所获取的图像普遍面临检测目标尺寸微小和像素失真等问题, 同时为了防止细节特征的流失, 故引入此模块减小特征提取的复杂性。该模块通过引入内容感知的偏移学习策略, 动态调整采样位置, 不仅增强了对小尺度病害区域的辨识精度, 还能有效适应条件恶劣道路图像的低质量特性。相较于传统方法, DySample 在显著减少计算资源需求的同时, 实现了图像分辨率的优化, 从而在效率和性能之间取得了良好平衡。

3 实验与分析

3.1 数据集

为系统验证本文提出的模型在恶劣道路场景下的适应能力, 研究采用自行构建的严重劣化道路 (severely deteriorated road, SDR) 数据集进行实验验证。该数据集的基础样本来源于 Roboflow 平台的公开道路图像资源, 在完成初步数据收集后, 通过实施数据扩充处理以增强样本多样性, 并采用 Labelimg 标注工具对各类道路病害区域进行精细标注生成标签文件。本数据集共分成八类典型道路病害: 鳄鱼裂缝、边缘开裂、横向裂缝、纵向裂缝、骨料剥落、车辙变形、标线磨损及坑槽。在数据划分策略上, SDR 数据集遵循 8 : 2 : 1 的比例配置, 将全部 4 413 张有效图像划分为三个独立子集: 训练集包含 3 208 张样本, 验证集配置 803 张样本, 测试集保留 402 张样本, 以此确保模型评估的严谨性与可靠性。数据集分布如图 7 所示。




图 7 数据集分布散点图

Fig. 7 Dataset distribution scatter plot

3.2 实验设备

3.2.1 硬件配置

相关硬件配置如表 1 所列。

3.2.2 软件配置

相关软件配置如表 2 所列。

表 1 实验硬件配置

Tab. 1 Experimental hardware configuration

名称	相关配置
操作系统	Windows11
中央处理器	Core i5-14600KF
内存/G	16
图像处理器	NVIDIA RTX 5060Ti

表 2 实验软件配置

Tab. 2 Experimental software configuration

名称	相关配置
CUDA	12.8.0
Pytorch	2.8.0
Python	3.10.14
图像尺寸/像素	640×640
批样本大小/个	32
迭代轮次/轮	300

3.3 评价指标

本研究对模型性能评价指标主要包括平均精度均值(mean average precision, mAP)、模型参数量(parameters, Param)、计算复杂度(giga floating-point operations per Second, GFLOPs)和推理效率(frames per second, FPS)四项核心指标。在使用最为广泛的 mAP 指标中, mAP50 特指交并比阈值为 0.5 时的平均精度, 而 mAP50:95 则综合考量了阈值从 0.5 至 0.95 间隔 0.05 变化的平均精度, 能够更全面地反映模型在不同定位精度要求下的表现。模型可训练参数规模直接体现其结构复杂程度, 通常参数量与模型容量呈正相关。GFLOPs 用于衡量模型前向传播所需的计算资源, 其数值与运算负担成正比。FPS 作为效率指标, 表征单位时间内处理的图像数量, 其数值与推理速度成正比。

为系统评估模型改进效果, 实验引入六项验证指标: 精确率(precision, P)、召回率(recall, R)、平均精度均值(mAP)、F1 分数(F1-score)、计算复杂度(GFLOPs)和帧率(FPS)。各项指标定义与计算方式如下:

1) 精确率: 正确预测的正样本数占预测正样本总数的比例, 反映模型检测结果的可靠性, 计算公式为

$$P = \frac{TP}{TP + FP} \quad (14)$$

式中: TP 为正确检测的目标数量, FP 为误检为目标的背景数量。

2) 召回率: 正确识别的目标数占实际目标总数的

比例, 体现模型对真实目标的覆盖能力, 计算公式为

$$R = \frac{TP}{TP + FN} \quad (15)$$

式中: FN 为未被检出的真实目标数量。

3) 平均精度与平均精度均值: AP 通过精确率-召回率曲线下面积衡量单类别识别性能, mAP 则是对所有类别 AP 值的宏观平均, 计算公式分别为

$$AP = \int_0^1 P(r) dr \quad (16)$$

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \quad (17)$$

式中: C 为目标类别总数, i 为类别索引。

4) F1 分数: 精确率与召回率的调和平均数, 用于平衡二者之间的制约关系, 其计算式为

$$F1 = \frac{2 \times P \times R}{P + R} \quad (18)$$

5) GFLOPs: 表征模型计算复杂度的关键指标, 定义为十亿次浮点运算次数, 反映前向传播过程中的计算负载, 计算公式为

$$GFLOPs = \frac{FLOPs}{10^9} \quad (19)$$

式中: FLOPs 为模型处理单张输入图像所需的总浮点运算数。

6) 帧率: 表征模型推理速度的关键指标, 定义为

$$FPS = \frac{N}{T} \quad (20)$$

式中: N 为处理图像总数量, T 为对应的耗时总和。

3.4 实验对比

3.4.1 不同模型对比实验

为了验证本文所提方法的有效性, 将改进后的模型与目前几类主流模型在 SDR 数据集上进行实验对比, 具体模型为 Faster-R-CNN、YOLOv5、YOLOv8、YOLOv10、YOLO11, 实验结果如表 3 所列。

由表 3 数据可知, 本文算法在 SDR 数据集上的 mAP@0.5 达到 40.3%, 较基线 YOLOv11n 的 31.5% 提升 9.8%, 较 YOLOv8 的 31.4% 提升 8.9%; 召回率达到 40.3%, 较基线提升 7.7%, 较 YOLOv5 提升 10.1%。在模型轻量化方面, 本文算法参数量为 2.45M, 较基线的 2.58M 减少 5.0%, 计算量为 6.30 G, 与基线持平且低于 YOLOv8 和 YOLOv10。综合而言, 在本实验条

件下,本文算法在检测精度与模型效率之间实现了更优的平衡。

3.4.2 改进点消融实验

设置消融实验分析各个模块对 YOLO 模型性能的影响,评价指标分别为精确率、召回率、平均精度

均值、 $F1$ 分数、计算复杂度、帧率和模型参数量,实验结果如表 4 所列,表中打勾选中部分代表使用新模块替换原有模块,分别为使用 C3k2-GEC 替换 C3k2,使用 C2DyBRA 替换 C2PSA 以及使用 DySample 替换 UpSample。

表 3 不同模型对比实验

Tab. 3 Comparison experiments of different models

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5\sim0.95/\%$	$F1/\%$	GFLOPs	FPS/帧	Param/M
Faster- R-CNN	55.2	28.4	30.5	12.2	37.5	158.7	137	28.2
YOLOV5	62.2	30.2	31.2	12.6	45.6	7.1	630	2.50
YOLOV8	59.0	31.6	31.4	15.2	41.2	8.1	755	3.01
YOLOV10	57.8	28.7	30.9	14.1	38.4	8.2	546	2.69
YOLOV11	58.7	32.6	31.5	14.4	41.9	6.3	547	2.58
本文算法	61.5	40.3	40.3	18.4	48.7	6.3	416	2.45

表 4 在 SDR 数据集上的消融实验

Tab. 4 Ablation experiments on the SDR dataset

实验	YOLO11n	C3k2-GEC 替换 C3k2	C2DyBRA 替换 C2PSA	DySample 替换 UpSample	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@$ $0.5\sim0.95/\%$	$F1/\%$	GFLOPs	FPS/帧	Param/M
1	√				58.7	32.6	31.5	14.4	41.9	6.3	547	2.58
2	√	√			55.9	39.7	36.9	16.9	46.4	6.3	432	2.42
3	√		√		66.6	33.1	33.9	16.2	44.2	6.3	545	2.61
4	√			√	61.6	36.5	35.3	16.2	45.8	6.3	554	2.59
5	√	√	√		68.3	35.9	39.3	18.7	47.1	6.3	473	2.44
6	√	√	√	√	61.5	40.3	40.3	18.4	48.7	6.3	416	2.45

由上表可以看出以上模块对 $mAP@0.5$ 指标均有提升效果,在替换原 C3K2 模块为 C3K2-GEC 后 $mAP@0.5$ 提升了 5.4%,召回率提升了 7.1%,表明新型卷积对不同空间分布的捕捉更加细致,尤其是感受野扩大后对小目标的识别能力得到了明显增强。在此基础上分别替换 C2PSA 和 UpSample 为 C2DyBRA 和 DySample, $mAP@0.5$ 达到 40.3% 且 $F1$ 分数达到最高值 48.7%,足以说明此模型较原 YOLO 模型在复杂道路情况下有效提高了检测精度且更加稳定。

3.4.3 实验结果可视化分析

抽取测试集图片使用原模型和改进后模型进行检测并对比输出,结果如图 8-9 所示。图中不同颜色边界框表示检测出的不同种类道路病害,若是道路病害未出现边界框进行框选即为该目标未检出。通过对比可见基准模型和改进模型不同的检测结果。

其中图 8 是使用 Base 模型 YOLOv11n 的检测结果,图 9 是使用本文改进后的模型检测后的结果,其中不同颜色代表不同道路病害类别,对比两组图片可以发现,两种算法都可以检测出明显的裂缝和坑洞目

标,但对于目标较小或者阴影重叠的道路病害检测效果差别较大。对比图 8(a)和图 9(a),原模型未检出主干道裂缝和道路左侧细小裂缝,改进后模型都检测出来;对比图 8(b)和图 9(b),有一道横向裂缝和电线阴影有部分重合导致目标特征模糊,改进模型成功检测




图 8 YOLOv11n(Base)检测效果

Fig. 8 YOLOv11n (Base) detection results



图 9 本文模型检测效果

Fig. 9 Detection results of the proposed model

出来而原模型未检出; 对比图 8(c) 和图 9(c), 在道路病害合集的图片中原模型有多个形状复杂的裂缝未检出, 改进后模型检测出了其中大部分裂缝。

4 结论

本文针对复杂路况下由于阴影反光和重复修补等原因导致的道路病害特征提取困难、特征边缘模糊, 从而难以检测的问题。其中坑洼目标尺度差异大, 裂缝目标形变不规则, 导致模型容易出现漏检与误检。基于以上问题本文提出一种改进 YOLOv11n 的算法, 它快速精准定位目标缺陷。通过应用新型 GEC 卷积设计 C3K2-GEC 模块扩大感受野, 增强了对复杂背景的抗干扰能力; 在 Neck 部分替换新的动态上采样算子 DySample, 锐化图像边缘并且保留更多细节, 在轻量的基础上进一步增强对小目标的检测能力; 引入 C2DyBRA 模块优化了边界框精度, 提升了细节捕捉能力, 更好地识别裂缝的细微纹理、坑洼的边缘等关键细节, 使各个尺度进一步联系上下文, 动态关注全局关键信息。

实验结果表明, 在自建 SDR 复杂路况数据集和本实验条件下, 本文改进算法相较于基线 YOLOv11n 实现了 mAP@0.5 提升 9.8%、召回率提升 7.7% 的显著提高, 同时参数量降低 5.0% 并保持计算量持平, 验证了 GEC 卷积、C2DyBRA 注意力与 DySample 上采样三项改进在小目标感知、背景干扰抑制、边缘细节保持三个维度的有效性。与 Faster-R-CNN、YOLOv5、YOLOv8、YOLOv10 等主流检测器相比, 本文算法检测精度达 40.3% mAP, 并且模型参数为 2.45M, FPS 为 416 帧, 综合效率指标上表现最优, 证明了其在本研究所定义的复杂路况检测任务中的适用性。未来工作将探索模型剪枝与知识蒸馏等轻量化技术, 进一步优化推理速度。总的来说, 本文改进算法能够更加高效准确地对设定的道路病害目标进行检测, 降低了专业车检测的成本并且缓解了人工巡检的压力, 填补了部分复杂路况下道路病害检测算法的空白。

参考文献:

- [1] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Washington, DC: IEEE Computer Society, 2014: 580-587.
- [2] Girshick R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV). Washington, DC: IEEE Computer Society, 2015: 1440-1448.
- [3] Zhang Ruirui, You Jie, Lee J. Detecting pine trees damaged by wilt disease using deep learning techniques applied to multi-spectral images[J]. *IEEE Access*, 2022, 10: 39108-39118.
- [4] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Washington, DC: IEEE Computer Society, 2016: 779-788.
- [5] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Washington, DC: IEEE Computer Society, 2017: 7263-7271.
- [6] Redmon J, Farhadi A. YOLOv3: an incremental improvement [PP/OL]. V1. arXiv, (2018-04-08)[2026-06-10]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [7] Bochkovskiy A, Wang Chienyao, Liao Hongyuanmark. YOLOv4: optimal speed and accuracy of object detection [PP/OL]. V1. arXiv (2020-04-23)[2026-06-10]. <https://doi.org/10.48550/arXiv.2004.10934>.
- [8] Liu Wei, Anguelov D, Erhan D, et al. SSD: single shot multi-box detector[C]//Proceedings of the 14th European Conference on Computer Vision (ECCV). Cham: Springer, 2016: 21-37.
- [9] Lin T, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV). Washington, DC: IEEE Computer Society, 2017: 2999-3007.
- [10] 丛玉华, 何啸, 邢长达, 等. 基于无人机的轻量化小目标检测网络[J]. *弹箭与制导学报*, 2022, 42(6): 6-12, 155.
- [11] Cong Yuhua, He Xiao, Xing Changda, et al. Lightweight small target detection network based on UAV[J]. *Journal of Projectiles, Rockets, Missiles and Guidance*, 2022, 42(6): 6-12, 155.
- [12] 季顺帆, 吴岳忠, 陈天奇. 面向自动驾驶应用的改进 YOLOv8n 车辆小目标检测算法 [J]. *激光杂志*, 2026, 47(4): 43-53.
- [13] Ji Shunfan, Wu Yuezhong, Chen Tianqi. Improved YOLOv8n vehicle small target detection algorithm for autonomous driving applications[J]. *Laser Journal*, 2026, 47(4): 43-53.
- [14] 王晓红, 胡豫. 复杂背景下的无人机图像小目标检测 [J]. *计算机工程与应用*, 2023, 59(15): 107-114.
- [15] Wang Xiaohong, Hu Yu. Small object detection in UAV images under complex background[J]. *Computer Engineering and Applications*, 2023, 59(15): 107-114.

- [13] 曹利, 徐慧英, 谢刚, 等. ASOD-YOLO: 基于 YOLOv8n 改进的航空小目标检测模型 [J]. 计算机工程与科学, 2026, 48(1): 133-145.
- Cao Li, Xu Huiying, Xie Gang, et al. ASOD-YOLO: an improved aerial small object detection model based on YOLOv8n[J]. Computer Engineering & Science, 2026, 48(1): 133-145.
- [14] Sami A A, Sakib S, Deb K, et al. Improved YOLOv5-based real-time road pavement damage detection in road infrastructure management[J]. Algorithms, 2023, 16(9): 452.
- [15] Dai Linhui, Liu Hong, Song Pinhao, et al. A gated cross-domain collaborative network for underwater object detection [J]. Pattern Recognition, 2024, 149: 110222.
- [16] Fan Lili, Zhao Hongwei, Li Ying, et al. RAO-UNet: a residual attention and octave UNet for road crack detection via balance loss[J]. IET Intelligent Transport Systems, 2022, 16(3): 332-343.
- [17] 赵贺, 白天平, 冯越. 基于改进 YOLOv5 的轻量级航拍图像目标检测方法 [J]. 兰州交通大学学报, 2025, 44(4): 94-104.
- Zhao He, Bai Tianping, Feng Yue. Lightweight aerial image target detection method based on improved YOLOv5[J]. Journal of Lanzhou Jiaotong University, 2025, 44(4): 94-104.
- [18] 梁龙学, 袁桂花, 吴小所, 等. 基于轻量化改进 CenterNet 网络的光伏电池表面缺陷检测算法 [J]. 兰州交通大学学报, 2025, 44(4): 105-116.
- Liang Longxue, Yuan Guihua, Wu Xiaosuo, et al. Surface defect detection algorithm for photovoltaic cells based on lightweight improved CenterNet network[J]. Journal of Lanzhou Jiaotong University, 2025, 44(4): 105-116.
- [19] 李欣, 王锋, 刘启明. 多维度特征融合的双核卷积路面裂缝检测算法 [J]. 兰州交通大学学报, 2025, 44(2): 111-122.
- Li Xin, Wang Feng, Liu Qiming. Dual-kernel convolutional pavement crack detection algorithm with multi-dimensional feature fusion[J]. Journal of Lanzhou Jiaotong University, 2025, 44(2): 111-122.
- [20] 罗晖, 贾晨, 李健. 基于改进 YOLOv4 的公路路面病害检测算法 [J]. 激光与光电子学进展, 2021, 58(14): 336-344.
- Luo Hui, Jia Chen, Li Jian. Road pavement disease detection algorithm based on improved YOLOv4[J]. Laser & Optoelectronics Progress, 2021, 58(14): 336-344.
- [21] 郭中华, 李蕾蕾, 李小军, 等. 一种 BiLSTM-MCEP 融合模型的短期交通流量预测 [J]. 兰州交通大学学报, 2026, 45(1): 22-30, 51.
- Guo Zhonghua, Li Leilei, Li Xiaojun, et al. Short-term traffic flow prediction based on a BiLSTM-MCEP fusion model[J]. Journal of Lanzhou Jiaotong University, 2026, 45(1): 22-30, 51.
- [22] 王婉婷, 姜国龙, 褚云飞, 等. 从 RCNN 到 YOLO 系列的物体检测系统综述 [J]. 齐鲁工业大学学报, 2021, 35(5): 9-16.
- Wang Wanting, Jiang Guolong, Chu Yunfei, et al. A review of object detection systems from RCNN to YOLO series[J]. Journal of Qilu University of Technology, 2021, 35(5): 9-16.
- [23] 程擎, 范满, 李彦冬, 等. 无人机航拍图像语义分割研究综述 [J]. 计算机工程与应用, 2021, 57(19): 57-69.
- Cheng Qing, Fan Man, Li Yandong, et al. Review of semantic segmentation research on UAV aerial images[J]. Computer Engineering and Applications, 2021, 57(19): 57-69.
- [24] Zhu Lei, Wang Xinjiang, Ke Zhanghan, et al. BiFormer: vision transformer with bi-level routing attention[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Washington, DC: IEEE Computer Society, 2023: 10323-10333.
- [25] Liu Wenzhe, Lu Hao, Fu Hongtao, et al. Learning to upsample by learning to sample[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Washington, DC: IEEE Computer Society, 2023: 6027-6037.

(责任编辑: 马延麟)