

# 光电工程

## Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊  
Scopus CSCD

### 改进YOLOv8的路基边坡裂缝检测算法

牛晓富, 黄河, 张红民, 胥铁峰

#### 引用本文:

牛晓富, 黄河, 张红民, 等. 改进YOLOv8的路基边坡裂缝检测算法[J]. *光电工程*, 2024, 51(11): 240171.

Niu X F, Huang H, Zhang H M, et al. Improved YOLOv8 algorithm for detecting cracks in roadbed slopes[J]. *Opto-Electron Eng*, 2024, 51(11): 240171.

<https://doi.org/10.12086/oe.2024.240171>

收稿日期: 2024-07-20; 修改日期: 2024-10-24; 录用日期: 2024-10-24

### 相关论文

#### 无人机视角下的道路损伤检测算法MAS-YOLOv8n

王晓燕, 王禧钰, 李杰, 梁文辉, 牟建宏, 毕楚然

*光电工程* 2024, 51(10): 240170 doi: 10.12086/oe.2024.240170

#### 改进GBS-YOLOv7t的钢材表面缺陷检测

梁礼明, 龙鹏威, 卢宝贺, 李仁杰

*光电工程* 2024, 51(5): 240044 doi: 10.12086/oe.2024.240044

#### 基于改进YOLOv5s网络的斜拉桥拉索表面缺陷检测

王鹏峰, 李运堂, 黄永勇, 朱文凯, 林婕, 王斌锐

*光电工程* 2024, 51(5): 240028 doi: 10.12086/oe.2024.240028

#### 局部和全局特征融合的太阳能电池片表面缺陷检测

陶志勇, 何燕, 林森, 易廷军, 张尧晟

*光电工程* 2024, 51(1): 230292 doi: 10.12086/oe.2024.230292

更多相关论文见光电期刊集群网站 



<http://cn.ojournal.org/oe>



OE\_Journal



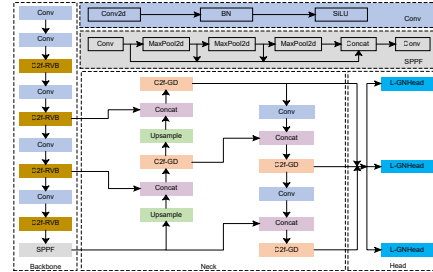
Website

# 改进 YOLOv8 的路基边坡裂缝检测算法

牛晓富<sup>1</sup>, 黄河<sup>1,2</sup>, 张红民<sup>1\*</sup>, 胥铁峰<sup>1</sup>

<sup>1</sup>重庆理工大学电气与电子工程学院, 重庆 400054;

<sup>2</sup>招商局重庆交通科研设计院有限公司, 重庆 400067



**摘要:** 针对现有路基边坡裂缝检测算法中检测精度低、泛化能力弱等问题, 提出了一种改进 YOLOv8 的路基边坡裂缝检测算法。首先, 在主干网络中嵌入重参数化模块和轻量化模型的同时捕获裂缝细节与全局信息, 提高模型的检测精度。其次, 设计 C2f-GD 模块实现模型特征高效融合, 增强模型的泛化能力。最后, 设计轻量级检测头 L-GNHead, 提高对不同尺度的裂缝检测精度, 同时采用 SloU 损失函数加速模型收敛。在自建的路基边坡裂缝数据集上的实验结果表明, 改进算法与原算法相比, mAP50 和 mAP50-95 分别提升了 3.3% 和 2.5%, 参数量和计算量分别降低了 46.6% 和 44.4%, 速度提高了 18 f/s。在数据集 RDD2022 的泛化性验证结果表明, 改进算法不仅达到更高的检测精度, 且检测速度更快。

**关键词:** YOLOv8; 边坡裂缝; 重参数化; C2f-GD; L-GNHead; SloU

**中图分类号:** TP391

**文献标志码:** A

牛晓富, 黄河, 张红民, 等. 改进 YOLOv8 的路基边坡裂缝检测算法 [J]. 光电工程, 2024, 51(11): 240171

Niu X F, Huang H, Zhang H M, et al. Improved YOLOv8 algorithm for detecting cracks in roadbed slopes[J]. *Opto-Electron Eng*, 2024, 51(11): 240171

## Improved YOLOv8 algorithm for detecting cracks in roadbed slopes

Niu Xiaofu<sup>1</sup>, Huang He<sup>1,2</sup>, Zhang Hongmin<sup>1\*</sup>, Xu Tiefeng<sup>1</sup>

<sup>1</sup>School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China;

<sup>2</sup>China Merchants Chongqing Transportation Research and Design Institute Limited, Chongqing 400067, China

**Abstract:** An improved YOLOv8 algorithm is proposed to address the problems of low detection accuracy and weak generalization ability in existing roadbed slope crack detection algorithms. Firstly, a reparameterization module is embedded in the backbone network to lighten the model while capturing crack details and global information, improving detection accuracy of the model. Secondly, the C2f-GD module is designed to achieve efficient fusion of model features and enhance the generalization ability of the model. Finally, the lightweight detection head L-GNHead is designed to improve the crack detection accuracy for different scales, while the SloU loss function is used to accelerate model convergence. The experimental results on the self-constructed roadbed slope crack dataset show that the improved algorithm improves mAP50 and mAP50-95 by 3.3% and 2.5% respectively, reduces parameters and computational costs by 46.6% and 44.4% respectively, and improves FPS by

收稿日期: 2024-07-20; 修回日期: 2024-10-24; 录用日期: 2024-10-24

基金项目: 国家重点研发计划 (2022YFC3002603); 重庆市自然科学基金面上项目 (cstc2021 jcyj-msxmX0525, CSTB2022NSCQ-MSX0786, CSTB2023NSCQ-MSX0911); 重庆市教委科学技术研究项目 (KJQN202201109)

\*通信作者: 张红民, hmzhang@cqut.edu.cn.

版权所有©2024 中国科学院光电技术研究所

18 frames/s compared with the original algorithm. The generalization validation results on the dataset RDD2022 show that the improved algorithm not only achieves higher detection accuracy, but also faster detection speed.

**Keywords:** YOLOv8; slope cracks; reparameterization; C2f-GD; L-GNHead; Siou

## 1 引言

随着我国公路交通网的持续优化和高速发展,公路边坡工程对于确保路基安全稳定愈发重要。裂缝作为大多数公路边坡病害的起初迹象,增加、扩展和演化是边坡失稳的最直观表现<sup>[1]</sup>。因此,及时准确地检测出路基边坡裂缝,对实现公路边坡灾害的自动监控和异常预警,进而保障公路交通畅通与安全有着非常重要的现实意义。

通常,一些公路边坡裂缝由于位置特殊很难通过人工巡检的方式直接检测且存在一定的高危性<sup>[2]</sup>,因此,人们逐渐采用传统的图像处理技术来识别和定位<sup>[3]</sup>。但是,该类技术通常需手动调整参数,同时对图像获取质量和环境条件敏感,难以应对多样化的裂缝形态及复杂场景。近年来,基于深度学习的目标检测算法因其高检测效率和准确性而成为公路裂缝检测领域的主流,此类算法大致可分为单阶段算法和两阶段算法。其中,两阶段算法<sup>[4-6]</sup>虽然具有不错的检测精度,但存在模型复杂度高、检测速度较慢和不易部署等诸多问题。相比而言,以 YOLO<sup>[7-9]</sup> 系列、SSD<sup>[10]</sup> 为代表的单阶段检测算法因在模型结构和实时性等方面具有明显优势,得到了广泛的应用。Liu 等<sup>[11]</sup> 提出一种 PeleeNet 与 YOLOv3 相结合的地表裂缝识别算法,通过引入 CBAM 注意力机制和深度可分离卷积,实现了模型的轻量化和良好的裂缝检测效果。Zhou 等<sup>[12]</sup> 利用 MobileNetV3 和深度可分离卷积替换 YOLOv4 的主干网络和普通卷积,满足了隧道衬砌裂缝实时检测时移动设备对帧率的要求。Hu 等<sup>[13]</sup> 改进 YOLOv5<sup>[14]</sup> 提出了一种结合导航信息进行快速定位边坡裂缝的方法,用于对路堑渠道边坡裂缝识别。Zhao 等<sup>[15]</sup> 基于 YOLOv5 设计双特征金字塔网络改进颈部网络,同时采用解耦头将回归和分类任务分开,取得了较高精度的钢筋表面缺陷检测结果。Ni 等<sup>[16]</sup> 基于 YOLOv7<sup>[17]</sup> 引入漏斗激活函数 F-ReLU 和多头自注意力机制,能够高效完成路面病害图像采集后的高精度识别,实现了对高速公路的损害程度评级。Xu 等<sup>[18]</sup> 基于隧道轨道检测车,利用 YOLOv8 算法实现隧道管片表面裂缝形态和宽度的识别,满足了更高准确度的应用要求。

这些裂缝检测算法虽能检测出裂缝所处区域,但往往局限于单一简单的裂缝场景。由于路基边坡裂缝形态多样、背景复杂和光照等影响,这些算法存在检测精度较低和模型泛化能力不足等问题。因此,本文提出了一种改进 YOLOv8 的路基边裂缝检测算法,主要创新点如下:

1) 在主干网络中嵌入重参数化模块,轻量化的同时有效提取裂缝细节特征和全局信息,提高模型的检测精度。

2) 在颈部网络中设计 C2f-GD 模块,实现裂缝特征的高效融合,增强模型的泛化能力。

3) 设计一种轻量级检测头 L-GNHead 以提高对不同尺度的裂缝检测精度,同时采用 Siou 损失函数加速模型收敛。

## 2 改进 YOLOv8 的裂缝检测算法

### 2.1 YOLOv8 模型

YOLOv8<sup>[19]</sup> 是单阶段目标检测算法之一,因其结构简洁、速度快、通用性等优点而被广泛应用于工业领域的目标检测、跟踪、分割等。YOLOv8 由 Input、Backbone、Neck 和 Head 组成,其中 Backbone 用于提取图像特征,由 Conv 模块、C2f 模块和 SPPF 模块组成;算法用 C2f 模块替换了 C3 模块,增加跳层连接和 Split 操作,丰富了模型的梯度流并提高了性能;Neck 采用路径聚合网络,用于对不同层次、不同尺度的特征进行融合和处理,其移除了 1×1 卷积的采样层,改用 C2f 模块;Head 部分采用解耦头结构,实现了分类和检测头的分离,提升了检测性能,并将 Anchor-Based 改为 Anchor-Free,通过直接预测目标的中心点来简化训练过程。YOLOv8 系列包括 n、s、m、l、x 五种不同大小模型,为在模型体积、检测性能和实际需求之间取得平衡,本文采用精度和实时性均衡的 YOLOv8n。

### 2.2 YOLOv8 模型改进策略

尽管 YOLOv8n 的性能优异,但在处理形态多变、尺寸不一且背景复杂的边坡裂缝时,因其细粒度裂缝



特征提取的能力受限, 导致检测精度较低以及泛化能力仍有所不足。此外, YOLOv8n 较高的计算复杂度使得它在需满足高实时性要求的移动设备上往往表现不佳。因此, 本文在主干网络中嵌入 RVB 模块, 增强网络提取边坡裂缝特征和全局信息的能力, 并添加 SE 注意力机制增强模型对边坡裂缝的关注度。其次, 在颈部网络中设计 C2f-GD 模块实现特征的高效融合, 增强模型的泛化能力。最后, 设计 L-GNHead 检测模块提高对不同尺度的边坡裂缝检测精度, 同时替换损失函数为 SiLU 加速模型收敛。改进的 YOLOv8 网络结构如图 1 所示, 具体描述如下。

### 2.2.1 C2f-RVB 模块

路基边坡裂缝的复杂背景、形态多变和长而窄的结构需要更长的依赖关系来获取全局上下文信息, 以确保模型能充分提取边坡裂缝特征。传统的 CNN (convolutional neural network) 通过多层卷积能够获取全局上下文信息, 但其既增加了模型复杂度, 又造成了局部信息过度聚合从而导致边坡裂缝关键特征丢失, 不能有效提取边坡裂缝特征。而 Transformer 能够建立特征图任意两点之间的长期依赖关系, 从而更加擅长提取整合边坡裂缝的全局上下文信息<sup>[20]</sup>。因此,

RepViT<sup>[21]</sup> (revisiting mobile CNN from ViT perspective) 网络同时结合了 CNN 和 Transformer 的优势, 更加擅长捕获全局上下文信息和局部细节特征, RVB (RepViT block) 结构如图 2 所示。

在传统的 MobileNetV3<sup>[22]</sup> 中  $1 \times 1$  卷积和  $3 \times 3$  深度卷积 (depthwise convolution, DW Conv) 共同处理通道和空间信息, 容易导致模型计算效率和表达能力不足。RVB 将这两个功能分离, 让  $3 \times 3$  深度卷积聚焦于提取空间特征,  $1 \times 1$  卷积则专注于通道间信息交互和整合, 这种设计有助于模型提取更丰富的全局信息, 同时保持 CNN 的局部信息处理能力。另外, RVB 在训练时增加了一个  $1 \times 1$  深度卷积, 增强了模型的学习能力, 而推理时被移除从而减少计算量和内存消耗。SE 层在 RVB 中是可选的, SE 注意力机制<sup>[23]</sup> 对输入的特征图进行压缩 (squeeze, Sq), 将高维特征图 ( $H \times W \times C$ ) 压缩成一维 ( $1 \times 1 \times C$ ), 从而充分提取全局特征信息; 然后对其进行激励 (excitation, Ex), 通过非线性变换学习获取各个通道的权重; 最后通过 Scale 将每个权重乘以原始输入图层, 使得模型更加专注于关键特征而削弱背景信息特征。图 3 为 SE 注意力机制结构图。

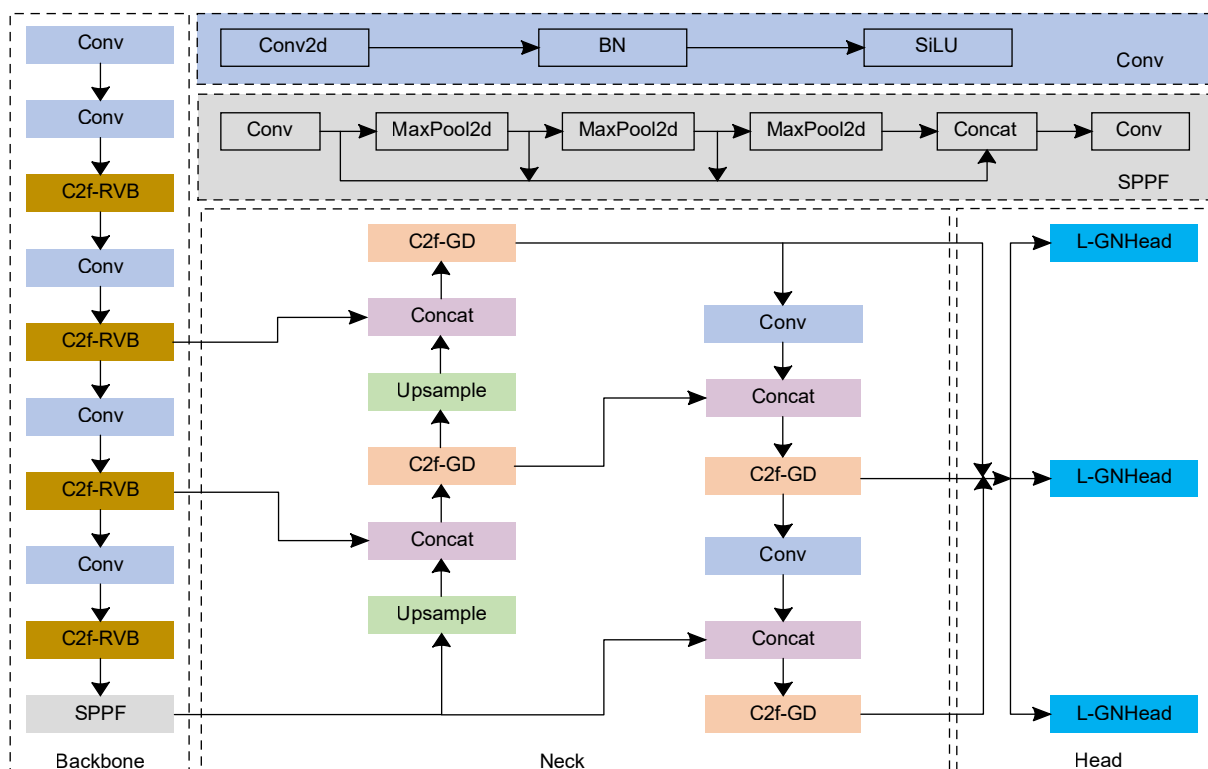


图 1 改进的 YOLOv8 网络结构

Fig. 1 Improved YOLOv8 network structure



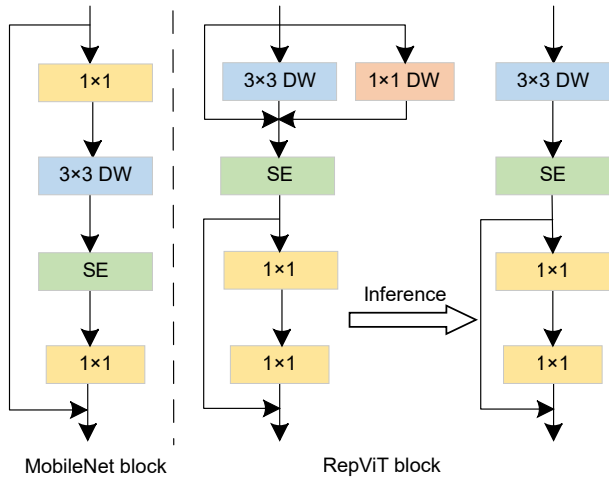


图 2 RepViT block 设计对比

Fig. 2 Comparison of RepViT block design

本文将 RVB 嵌入到主干网络的 C2f 模块中形成 C2f-RVB; 且经过实验验证后, 在第 2 层的 C2f-RVB 模块中不添加 SE 注意力机制, 以维持足够的局部信息处理能力; 而在第 4、6 和 8 层的 C2f-RVB 模块中添加 SE 注意力机制, 以增强模型对边坡裂缝特征的关注度。这种设计不仅降低了模型复杂度, 还实现了局部裂缝细节特征和全局上下文特征的高效提取, 尤其是增强了对长裂缝特征信息的学习和整合, 从而有效提高边坡裂缝的检测精度。

### 2.2.2 C2f-GD 模块

由于路基边坡裂缝的形状多样性和背景信息的复杂性, 网络模型在泛化到新场景时往往面临挑战; 此外, 原颈部网络难以对关键特征和背景信息做出有效区分, 不能高效地融合边坡裂缝特征。本文在颈部网络中引入 Ghost 模块和动态卷积, 以增强模型在复杂多变的边坡裂缝场景中的泛化能力。

Ghost 模块<sup>[24]</sup>是一种轻量级网络结构, 它通过 Primary-Conv 层生成初始局部特征图, 随后通过 Cheap-Operation 层以较低的计算成本生成剩余的幽灵

特征 (ghost features), 最后通过 Concat 操作将两者拼接, Ghost 模块结构如图 4 所示。这种设计在保持精度的同时降低了计算成本和减少了参数量。

动态卷积<sup>[25]</sup>可以增加网络参数量, 而几乎不会带来额外的 FLOPs (floating-point operations per second)。M 个动态专家 (dynamic experts) 的动态卷积可以写成式 (1):

$$\begin{cases} Y = X * W' \\ W' = \sum_{i=1}^M \alpha_i W_i \end{cases}, \quad (1)$$

其中:  $Y$  为输出张量, 输入张量  $X \in \mathbb{R}^{C_{in} \times H \times W}$  和权重张量  $W \in \mathbb{R}^{C_{out} \times C_{in} \times K \times K}$ ,  $W'$  为参数增强函数,  $*$  为卷积操作,  $W_i \in \mathbb{R}^{C_{out} \times C_{in} \times H \times W}$  是第  $i$  个卷积权重张量,  $\alpha_i$  为对应的动态系数, 动态系数  $\alpha_i$  是动态生成的。动态卷积通过引入动态系数  $\alpha_i$  来增加网络参数, 首先对输入张量  $X$  使用全局平均池化将信息融合成向量, 然后使用含有 softmax 的两层 MLP 模块生成动态系数, 如式 (2) 所示:

$$\alpha = softmax(MLP(Pool(X))), \quad (2)$$

其中:  $\alpha \in \mathbb{R}^M$  为动态系数,  $X$  为输入张量,  $softmax$  为激活函数,  $MLP$  为多层感知机。动态卷积通过实时调整卷积核的组合, 使其能够针对输入数据的不同特征进行实时优化响应, 进而显著增强模型的泛化能力。

受 ParameterNet<sup>[26]</sup> 启发, 本文设计了 C2f-GD 模块替换颈部网络中的 C2f 模块, C2f-GD 模块如图 5 所示。C2f-GD 模块将 Ghost 模块中的 Primary-Conv 层和 Cheap-Operation 层分别用两个不同特性的动态卷积替换, 其中第一个动态卷积负责高效整合边坡裂缝主要特征, 第二个动态卷积用于增加特征图维度, 通过 Concat 将两部分不同尺度的特征信息融合。这种设计因引入动态卷积使得该模块相较于原 Ghost 模




图 3 SE 注意力机制结构图

Fig. 3 Structure diagram of SE attention mechanism




图 4 Ghost 模块结构图

Fig. 4 Ghost module structure diagram

块增加了网络参数量, 在特征融合过程中能够掌握到更复杂的特征表示和融合方式, 进而实现模型特征的高效融合。同时, 由于动态卷积的权重是动态生成的, 模型可实时地调节图像中不同特征的关注度, 从而提升模型在复杂边坡裂缝检测的适应性和泛化性。

### 2.2.3 L-GNHead 模块

YOLOv8 检测头采用解耦头结构和 Anchor-Free, 但是解耦头结构带来了较大的参数量和计算量, 同时 Anchor-Free 依赖于所有位置进行预测, 这导致产生大量离目标中心较远的候选框, 这些低效的预测结果会降低检测精度且增加计算复杂度。

为解决 YOLOv8 检测头出现的问题, 本文引入 Group Norm<sup>[27]</sup> 来降低不同特征尺寸所带来的影响, 使得模型在训练过程中更加稳定。Group Norm 将卷积层的特征通道分为多个组, 对每个组内的特征进行归一化, 而不同组之间则独立进行归一化。该分组方式降低了因特征尺寸差异所带来的影响, 能够更好地适应不同尺寸和内容的图像, 增强了模型的稳定性和适应性。常见的归一化方法对比如图 6 所示, 每个子图显示了一个特征映射张量,  $N$  表示批 (batch) 维度,

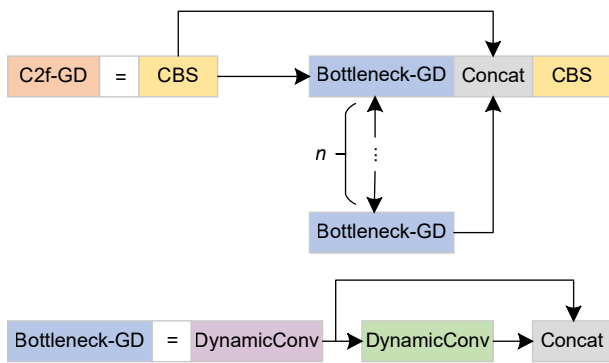


图 5 C2f-GD 模块结构图  
Fig. 5 C2f-GD module structure diagram

$C$  表示通道 (channel) 维度, 而  $(H, W)$  表示空间维度。

受 Group Norm 和共享卷积<sup>[28]</sup> 启发, 结合 YOLOv8 检测头和边坡裂缝检测的特性, 本文设计了轻量级检测头 (L-GNHead), L-GNHead 模块结构如图 7 所示。首先, 把经特征融合后的三个不同尺度特征图输入到检测头中, 通过两层共享卷积 GN-Conv 实现不同尺度的特征交互和参数共享, 这种设计不仅降低网络的复杂度, 同时提高特征表达能力。然后, 分别通过  $1 \times 1$  卷积得到分类和回归两部分。最后, 在回归部分后引入 Scale 层来动态调整边界框预测的尺度, 它能够根据不同尺度的输入特征图动态调整锚点和步长, 从而提高对不同尺度的裂缝检测精度。此外, L-GNHead 模块降低了模型复杂度, 使得其比较适合部署在资源有限的移动设备中, 提升了模型的实时性。

### 2.2.4 损失函数改进

CIoU<sup>[29]</sup> 在计算时综合了预测框和真实框之间的 IOU、中心点距离和宽高比, 但未涉及到真实框和预测框之间的向量角度, 无法充分考虑到裂缝的细微变化, 导致预测精度低和收敛速度慢。SIoU<sup>[30]</sup> 加入向量角度并重新设计损失函数, 更有效地推动预测框朝




图 6 归一化方法对比  
Fig. 6 Comparison of normalization methods

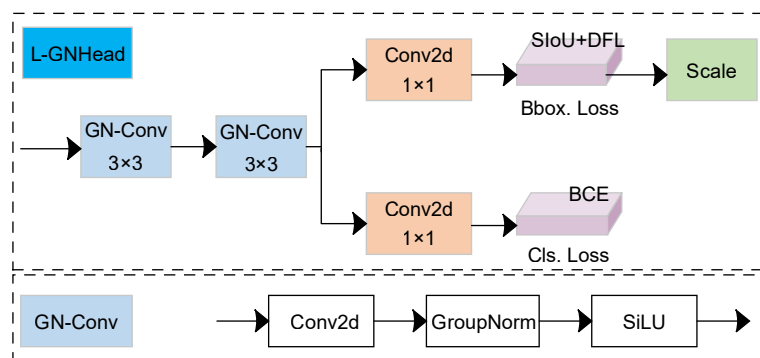


图 7 L-GNHead 模块结构图  
Fig. 7 L-GNHead module structure diagram

着真实框方向收敛, 加速模型收敛。

SIoU 损失函数包括四个部分: 角度损失、距离损失、形状损失、IoU 损失。SIoU 损失函数计算所涉及的参数如图 8 所示。




图 8 SIoU 损失函数计算示意图  
Fig. 8 SIoU loss function calculation diagram

角度损失的计算公式为

$$A = 1 - 2 \times \sin^2 \left( \arcsin x - \frac{\pi}{4} \right), \quad (3)$$

其中:

$$\begin{cases} x = \frac{c_h}{\sigma} = \sin \alpha \\ \sigma = \sqrt{(b_{c_x}^{\text{gt}} - b_{c_x})^2 + (b_{c_y}^{\text{gt}} - b_{c_y})^2} \\ c_h = \max(b_{c_y}^{\text{gt}}, b_{c_y}) - \min(b_{c_y}^{\text{gt}}, b_{c_y}) \end{cases}, \quad (4)$$

式中:  $\sigma$  为预测框与真实框的中心点的距离,  $c_h$  为预测框和真实框中心点的高度差;  $(b_{c_x}^{\text{gt}}, b_{c_y}^{\text{gt}})$  为真实框的中心坐标;  $(b_{c_x}, b_{c_y})$  为预测框的中心坐标。

距离损失的计算公式为

$$A = \sum_{t=x,y} (1 - e^{-\gamma \rho_t}), \quad (5)$$

其中:

$$\begin{cases} \rho_x = \left( \frac{b_{c_x}^{\text{gt}} - b_{c_x}}{c_w} \right)^2 \\ \rho_y = \left( \frac{b_{c_y}^{\text{gt}} - b_{c_y}}{c_h} \right)^2 \\ \gamma = 2 - A \end{cases}, \quad (6)$$

式中:  $c_w$  和  $c_h$  分别为真实框和预测框最小外接矩形的宽和高。

形状损失的计算公式为

$$\Omega = \sum_{t=w,h} (1 - e^{-w_t})^\theta, \quad (7)$$

其中:

$$\begin{cases} \omega_w = \frac{|w - w^{\text{gt}}|}{\max(w, w^{\text{gt}})} \\ \omega_h = \frac{|h - h^{\text{gt}}|}{\max(h, h^{\text{gt}})} \end{cases}, \quad (8)$$

式中:  $(w, h)$  为预测框的宽和高,  $(w^{\text{gt}}, h^{\text{gt}})$  为真实框的宽和高。  $\theta$  为对形状损失的关注度,  $\omega_w$  和  $\omega_h$  分别为预测框与真实框之间宽和高的拉伸程度。

IoU 损失的计算公式为

$$IoU = \frac{A}{B}, \quad (9)$$

其中:  $A$  为真实框与预测框的交集,  $B$  为真实框与预测框的并集。

因此, SIoU 损失的计算公式为

$$Loss_{\text{SIoU}} = 1 - IoU + \frac{A + \Omega}{2}. \quad (10)$$

### 3 实验结果与分析

#### 3.1 实验数据集

提出算法实验验证采用了两种数据集, 一是基于招商局重庆交通科研设计院有限公司自建的城市公路边坡裂缝数据集, 数据采集以广东省广州市白云区沈海高速公路边坡为主, 利用无人机自动化巡检获取图像, 无人机巡检开始时间为 2023 年 12 月 1 日。为了保证边坡裂缝数据集的有效性和完整性, 分别选取不同时间段和不同天气状态无人机采集的图像, 同时将图像裁切为 640 pixel×640 pixel 作为输入图像。数据集剔除了光照不足、裂缝遮挡严重和模糊的照片; 另外, 通过随机翻转、添加噪声和颜色扰动来扩充数据集, 并根据裂缝开裂程度进行不同数量的标注。该数据集共包含 2000 张图片, 其中训练集 1600 张、验证集 200 张、测试集 200 张。边坡裂缝图像示例如图 9 所示。二是全球道路损伤检测挑战赛的公开数据集 RDD2022<sup>[31]</sup>, 它包含了多种道路类型和环境条件下的图片, 从中选取 6171 张与国内路面场景相似的图片作为实验数据集, 按照 8:1:1 随机划分为训练集、验证集、测试集。此外, 为了更准确地聚焦于裂缝检测任务, 对数据进行了清洗和重新标注, 将不同裂缝类别统一标注为一类, 同时剔除了数据集中的其他类别。

#### 3.2 实验设备及评价指标

本文模型实验基于 Windows 11 系统下进行的, 硬件配置为 Intel Core i9-13900k、NVIDIA GeForce RTX4080 和 16 GB 显存。网络模型编译环境为



Python 3.11.5+Pytorch 2.1.0+Cuda 12.1。为确保实验的严谨, 不设置预训练权重, Epoch 为 250, Batchsize 为 16, 优化器为 SGD, Optimizer Momentum 为 0.937, 学习率为 0.01。为准确衡量模型改进效果, 采用平均精度均值 (mAP)、每秒帧数 (FPS)、模型参数量 (params) 和模型计算量 (FLOPs) 作为评价指标。当预测框与真实框的交并比 (intersection over union, IOU) 大于 0.5 时认为该目标被准确预测, 分别在 IOU 取值为 0.5 和 0.5 : 0.95 条件下计算平均精度 (mAP50, mAP50-95), 以此评估模型对不同尺度裂缝的检测精度。模型实时性评估则采用每秒钟能够检测图像的帧数。




图 9 边坡裂缝图像示例  
Fig. 9 Example of slope crack images

### 3.3 消融实验

为验证所提出的各改进模块在路基边坡裂缝检测中的有效性, 在自建数据集上进行了消融实验, 每一组实验设置相同的超参数, 确保相同的训练策略, 消融实验结果如表 1 所示, 其中“√”表示加入该模块, 粗体表示最佳性能。

由表 1 可知, 分别加入 C2f-RVB 模块和 C2f-GD

模块都在保证运行速度的同时提高了网络的检测精度, 且不同程度地降低了模型的参数量和计算量; 设计的 L-GNHead 模块使 mAP50 和 mAP50-95 分别提升了 1.0% 和 0.7%, 模型的参数量和计算量分别降低了 0.64 M 和 1.6 GFLOPs, 同时提升了检测速度, 验证了 L-GNHead 模块能有效提高对不同尺度的裂缝检测精度; SIoU 模块在保持模型参数量和计算量不变的情况下使 mAP50 提升了 0.6%。模型的检测精度和复杂度以及 FPS 会受到不同模块组合的影响而产生变化。最后, 各改进模块都组合起来的模型相较于原模型的 mAP50 和 mAP50-95 分别提升了 3.3% 和 2.5%, 参数量和计算量分别降低了 46.6% 和 44.4%, 并且 FPS 提升了 18 f/s, 有效地证明了改进模型在路基边坡裂缝检测中的有效性, 增强了模型的检测性能。

为直观展示改进模块在路基边坡裂缝检测中的有效性, 选取不同边坡图像分别进行 C2f-RVB 和 L-GNHead 的热力图对比, 对比结果如图 10 所示。可以看出分别引入不同的模块后对路基边坡裂缝的关注度都更为准确和细致, 减弱了边坡背景因素的干扰。因此, 验证了 C2f-RVB 和 L-GNHead 模块的引入有助于改善模型对边坡裂缝检测的性能。

### 3.4 对比实验

#### 3.4.1 不同算法对比

为进一步验证改进算法在路基边坡裂缝检测的优越性, 将改进算法与目标检测算法 SDD、Faster-RCNN、RT-DETR-L、YOLOv5n、YOLOv7tiny、YOLOv8n、YOLOv9s 和当前主流算法在自建数据集上进行对比实验, 不同算法的对比实验结果如表 2 所示, 其中粗体表示最佳性能。

由表 2 可知, SSD 和 Faster-RCNN 算法的平均精

表 1 消融实验结果

Table 1 Results of ablation experiments

| Model     | C2f-RVB | C2f-GD | L-GNHead | SIoU | mAP50/%     | mAP50-95/%  | Params/M    | GFLOPs     | FPS          |
|-----------|---------|--------|----------|------|-------------|-------------|-------------|------------|--------------|
| YOLOv8n   |         |        |          |      | 85.1        | 43.2        | 3.00        | 8.1        | 96.6         |
| YOLOv8n_1 | √       |        |          |      | 86.5        | 44.6        | 2.64        | 7.0        | 86.8         |
| YOLOv8n_2 |         | √      |          |      | 86.4        | 44.2        | 2.63        | 7.1        | 93.8         |
| YOLOv8n_3 |         |        | √        |      | 86.1        | 43.9        | 2.36        | 6.5        | 103.1        |
| YOLOv8n_4 |         |        |          | √    | 85.7        | 43.4        | 3.00        | 8.1        | 97.9         |
| YOLOv8n_5 |         | √      | √        | √    | 87.9        | <b>46.0</b> | 1.95        | 5.6        | 99.4         |
| YOLOv8n_6 | √       | √      |          |      | 87.2        | 43.1        | 2.24        | 6.1        | 106.9        |
| YOLOv8n_7 | √       | √      | √        |      | 87.6        | 45.3        | 1.60        | 4.5        | 104.0        |
| YOLOv8n_8 | √       | √      | √        | √    | <b>88.4</b> | 45.7        | <b>1.60</b> | <b>4.5</b> | <b>114.7</b> |




图 10 不同模块热力图对比

Fig. 10 Comparison of thermal maps with different modules

表 2 对比实验结果

Table 2 Comparison of the experimental results

| Model                     | mAP50/%     | mAP50-95/%  | Params/M    | GFLOPs     | FPS          |
|---------------------------|-------------|-------------|-------------|------------|--------------|
| SSD                       | 69.2        | 34.6        | 63.82       | 124.5      | 96.6         |
| Faster-RCNN               | 70.4        | 37.8        | 137.42      | 371.4      | 18.7         |
| RT-DETR-L <sup>[32]</sup> | 81.6        | 39.8        | 28.44       | 100.6      | 32.8         |
| YOLOv5n                   | 82.4        | 41.3        | 2.50        | 7.1        | 110.1        |
| YOLOv7tiny                | 81.5        | 39.5        | 6.12        | 12.4       | 109.8        |
| YOLOv8n                   | 85.1        | 43.2        | 3.00        | 8.1        | 96.6         |
| YOLOv9s <sup>[33]</sup>   | 87.9        | 44.6        | 7.33        | 26.8       | 64.7         |
| 文献[34]                    | <b>88.7</b> | 44.9        | 89.1        | 15.4       | —            |
| 文献[35]                    | 87.8        | 45.5        | 33.4        | —          | —            |
| Ours                      | 88.4        | <b>45.7</b> | <b>1.60</b> | <b>4.5</b> | <b>114.7</b> |

度不高, 检测速度慢和模型复杂度高。实时目标检测算法 RT-DETR-L 的 mAP50 为 81.6%, 而改进算法在更低的参数量和计算量下, mAP50 达到了 88.4%, 相比 RT-DETR-L 算法提升了 6.8%; 同时 mAP50-95 提升了 5.9%, FPS 也有显著的提升。与 YOLOv5n、YOLOv7tiny、YOLOv8n 和 YOLOv9s 相比, 改进算法在不同程度降低参数量和计算量的前提下, mAP50 分别提升了 6.0%、6.9%、3.3% 和 0.5%, 且参数量和计算量相较 YOLOv8n 分别降低了 46.6% 和 44.4%。文献 [34] 通过引入全局响应归一化 (GRN) 层, 增强了通道间的特征竞争。该方法虽然提升了模型的特征能力, mAP50 达到 88.7%, 但是其大幅增加了模型的参数量和计算量。文献 [35] 虽结合了局部图像信息和全局上下文表示, 但是边坡裂缝形态多变且背景复杂, 导致该模型的平均检测精度低于本文模型。综合分析, 改进算法不仅显著降低了模型参数量和计算量, 而且提高了模型检测精度和检测速度, 能够实现对路基边坡裂缝的高效检测。此外, 其轻量化设计使其能够嵌入到移动设备和无人机上, 实用性更强。

### 3.4.2 不同位置的 SE 注意力机制性能对比

主干网络中不同层捕获的特征具有不同的性质和用途, 为探究 C2f-RVB 模块中 SE 注意力机制在主干网络的不同层对路基边坡裂缝检测的效应。在自建数据集上进行性能对比实验, 实验结果如表 3 所示。其中:  $P$  表示准确率,  $R$  表示召回率; ①表示在主干网络的第 8 层添加 SE 注意力机制, ②表示在主干网络的第 4 层和第 8 层添加 SE 注意力机制, ③表示在主干网络的第 2 层、第 4 层和第 8 层添加 SE 注意力机制。

表 3 不同位置 SE 对比

Table 3 Comparison of SE at different positions

|         | $P$ /%      | $R$ /%      | mAP50/%     | Params/M |
|---------|-------------|-------------|-------------|----------|
| YOLOv8n | 90.2        | 83.0        | 85.1        | 3.00     |
| ①       | 89.5        | 82.9        | 84.9        | 2.64     |
| ②       | 88.5        | 81.7        | 82.1        | 2.64     |
| ③       | 88.4        | 81.1        | 85.8        | 2.64     |
| Ours    | <b>91.0</b> | <b>83.5</b> | <b>86.5</b> | 2.64     |

由表 3 可知, 在参数量相同的情况, 本文的改进模块相较于其它三种不同位置的改进表现出更优的检测性能。原因在于该改进方式使得主干网络重点关注了网络不同层的裂缝细节特征, 帮助模型更好地学习到边坡裂缝特征, 抑制复杂背景信息的干扰; 同时相比于 YOLOv8n, 改进模块在准确率、召回率和 mAP50 上分别提高了 0.8%、0.5% 和 1.4%, 从而验证了 C2f-RVB 模块的有效性。

### 3.4.3 C2f-GD 模块有效性对比

C2f-GD 模块通过将动态卷积融合到 Ghost 模块中, 使得网络能够实时地调整卷积核权重, 增强模型的泛化能力。为验证 C2f-GD 模块在检测路基边坡裂缝特征方面的有效性, 在自建数据集上选取两张图片进行热力图对比, C2f-GD 模块热力图对比如图 11 所示。

由图 11 可知, 通过引入 C2f-GD 模块改变了模型对边坡裂缝的预测概率, 同时对裂缝特征表现出高关注度和敏感性, 增强了模型对边坡裂缝细节信息的整合, 验证了 C2f-GD 模块具有增强模型泛

化能力的作用。

### 3.4.4 不同损失函数性能对比

不同损失函数对模型预测值与实际值之间差距的度量 and 优化方向不同, 为探究不同损失函数与模型性能之间的关系, 实验对比了 CIoU、EIoU<sup>[36]</sup>、WIoU<sup>[37]</sup> 和 SIoU 四种损失函数在自建数据集上的性能情况, 不同损失函数对比结果如表 4 所示。

由表 4 可知, 在参数量不变的情况下, 不同的损失函数对模型的检测性能造成轻微影响。改进模块的召回率和 mAP50 分别提升了 1.2% 和 0.6%, 表明 SIoU 可以提升模型的回归精度和平均精度, 有效降低了边坡裂缝的漏检和误检的情况。

不同损失函数收敛曲线对比图如图 12 所示, 由图 12 中可以看出, 模型采用 SIoU 后损失下降平滑且损失值达到最低, 表明模型在学习裂缝特征时更加稳定。这主要是因为 SIoU 损失函数涉及到真实框和预测框之间的形状和方向相似性, 为模型训练提供了更全面的损失度量, 有助于模型更快地调整到正确的预测方向上, 进而加速模型收敛。




图 11 C2f-GD 模块热力图对比

Fig. 11 Comparison of thermal maps with C2f-GD module

表 4 不同损失函数对比结果

Table 4 Comparison results of different loss functions

| Loss | P/%         | R/%         | mAP50/%     | Params/M |
|------|-------------|-------------|-------------|----------|
| CIoU | <b>90.2</b> | 83.0        | 85.1        | 3.0      |
| EIoU | 89.5        | 82.6        | 83.8        | 3.0      |
| WIoU | 89.9        | 84.1        | 84.2        | 3.0      |
| SIoU | 89.9        | <b>84.2</b> | <b>85.7</b> | 3.0      |




图 12 不同收敛曲线对比图

Fig. 12 Comparison of different convergence curves



### 3.5 实际检测结果对比

为了更具体地呈现改进算法在改进前后对路基边坡裂缝检测的效果, 在自建数据集上选取部分图片进行实际检测对比, 不同边坡场景裂缝检测结果对比如图 13 所示。

由图 13 可知, YOLOv8n 在检测不同场景的边坡裂缝时存在检测精度不高、漏检和误检的问题, 尤其针对复杂边坡场景时难以全面且高精度地识别裂缝。相比之下, 改进算法在检测性能上明显优于 YOLOv8n, 不仅检测精度更高且降低了误检情况。此外, 该算法在面对不同场景的边坡裂缝具备较强的适应性, 充分验证了改进算法对实际边坡裂缝检测的有效性和可靠性。

### 3.6 模型泛化性验证

为进一步验证改进算法对路基边坡裂缝检测的有效性和泛化性, 改进模型在公共数据集 RDD2022 上完成了训练, 并与 Baseline 模型进行了性能对比。具体而言, 改进模型与 Baseline 模型对比的损失收敛曲线和 mAP50 曲线分别如图 14(a) 和图 14(b) 所示。

由图 14(a) 可知, 改进模型的收敛效果更佳, 说明改进模型在训练过程中能够学习到全面的裂缝纹理特性, 具备更强的泛化性能。由图 14(b) 可知, 改进模型在迭代 180 次后平均精度趋于稳定且明显高于 Baseline; 此外, 改进模型没有出现过拟合现象, 表明其提升了模型的准确性和稳定性。

在公共数据集 RDD2022 上将改进算法与目标检测算法 Faster-RCNN、RT-DETR-L、YOLOv5n、YOLOv7tiny、YOLOv8n、YOLOv9s 和当前主流算法进行对比验证, 对比实验结果如表 5 所示, 其中粗体表示最佳性能。

由表 5 可知, 改进算法在不同目标检测算法中除 mAP50-95 略低于 YOLOv8n 和文献 [34] 外, 其余检测效果更优, 其中 mAP50 达到了 78.9%, 相比于 YOLOv8n 提升了 2.6%, 同时参数数量和计算量分别为 YOLOv8n 的 53.3% 和 55.5%, FPS 提升了 16 f/s。综合而言, 改进算法在公共数据集上具有良好的检测精度和检测效率。此外, 在公共数据集 RDD2022 上进行实际检测结果可视化, 部分实例检测结果对比如图 15

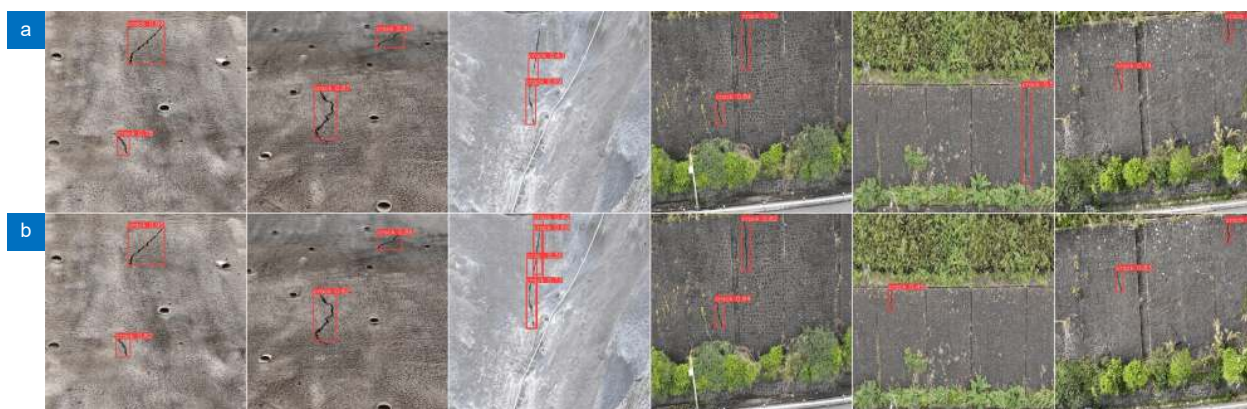


图 13 边坡裂缝检测结果对比。(a) YOLOv8n; (b) Ours

Fig. 13 Comparison of slope crack detection results. (a) YOLOv8n; (b) Ours

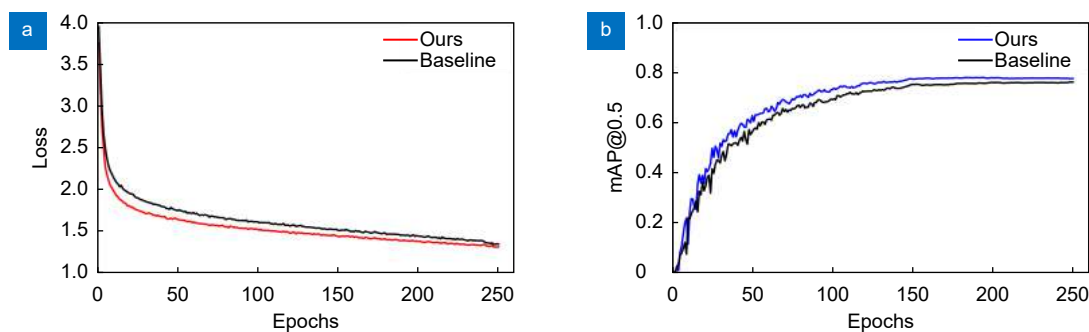


图 14 RDD2022 数据集上训练对比结果。(a) 损失收敛曲线图; (b) mAP50 曲线图

Fig. 14 Comparison results of training on RDD2022 dataset. (a) Loss convergence curve; (b) mAP50 curve

表 5 RDD2022 数据集对比实验结果

Table 5 Comparison of the experimental results on RDD2022 dataset

| Model                     | mAP50/%     | mAP50-95/%  | Params/M    | GFLOPs     | FPS          |
|---------------------------|-------------|-------------|-------------|------------|--------------|
| Faster-RCNN               | 63.1        | 34.5        | 137.42      | 371.4      | 18.2         |
| RT-DETR-L <sup>[32]</sup> | 73.1        | 40.4        | 28.44       | 100.6      | 32.4         |
| YOLOv5n                   | 75.9        | 44.2        | 2.50        | 7.1        | 107.8        |
| YOLOv7tiny                | 75.5        | 44.1        | 6.12        | 12.4       | 108.5        |
| YOLOv8n                   | 76.3        | 44.9        | 3.00        | 8.1        | 95.8         |
| YOLOv9s <sup>[33]</sup>   | 77.9        | 44.6        | 7.33        | 26.8       | 65.2         |
| 文献[34]                    | 78.4        | <b>45.1</b> | 89.1        | 15.4       | —            |
| 文献[35]                    | 78.1        | 44.5        | 33.4        | —          | —            |
| Ours                      | <b>78.9</b> | 44.7        | <b>1.60</b> | <b>4.5</b> | <b>111.6</b> |

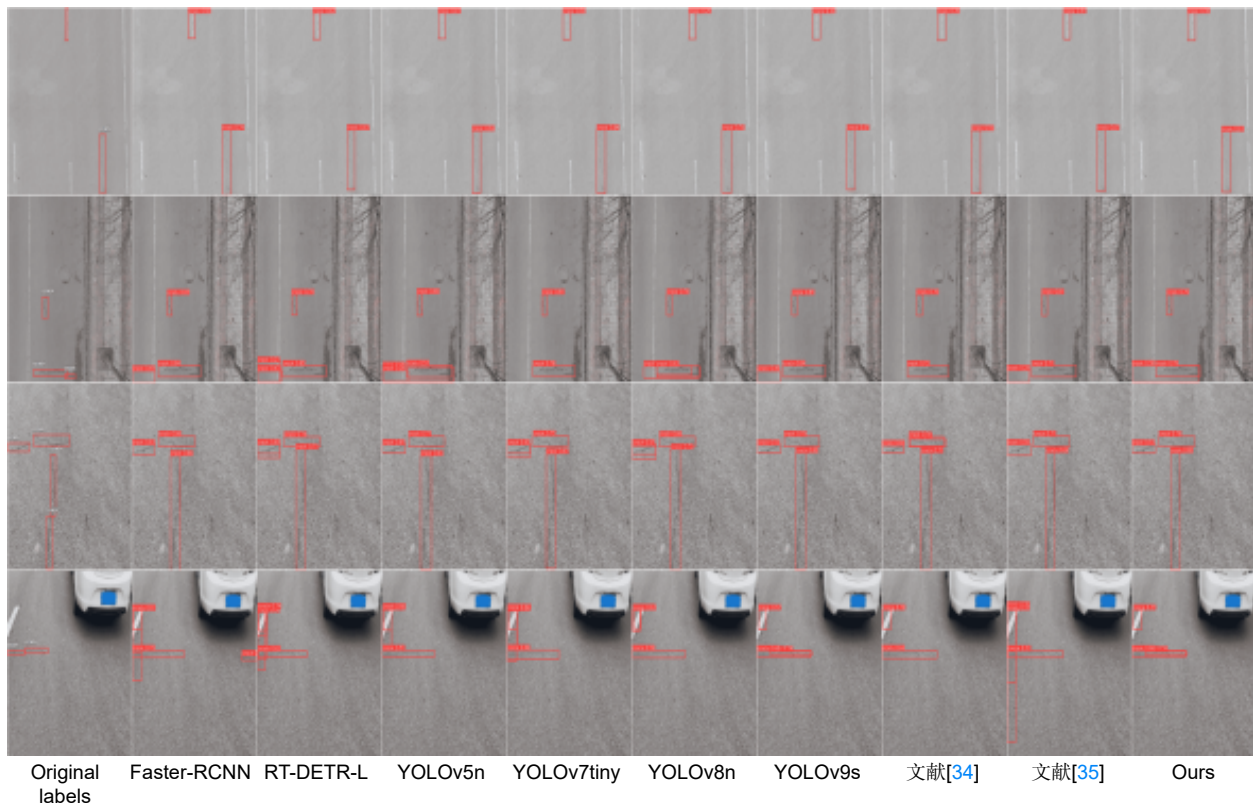


图 15 RDD2022 数据集不同算法检测结果对比

Fig. 15 Comparison of detection results of different algorithms on RDD2022 dataset

所示。由图 15 中可以看出，改进算法的检测框图与原标注的目标裂缝贴合性更好，同时检测精度优于其他的算法。另外，改进算法对于小目标裂缝和多条裂缝场景可以实现较好的检测效果，泛化性更强。

## 4 结论

本文提出了一种改进 YOLOv8 的路基边坡裂缝检测算法，有效缓解了现有路基边坡裂缝检测算法面

临的多尺度裂缝检测精度低和泛化能力不足等问题。首先在主干网络中引入 RVB 模块，提高网络的特征提取能力；然后构建 C2f-GD 模块轻量化模型的同时增强模型的泛化能力；最后设计轻量级检测头 L-GNHead 适应不同尺度的边坡裂缝检测，同时使用 SIoU 损失函数优化模型训练过程。改进算法在自建的路基边坡裂缝数据集上达到了更优的检测精度，有效减少了边坡裂缝的漏检和误检；同时模型的参数量

和计算量都得到了降低。在公开数据集 RDD2022 开展了泛化性实验, 改进算法取得了良好的检测性能, 且与其他算法相比能高效、准确地检测出不同尺度的裂缝。此外, 改进算法使得模型更为轻量化和高效, 有助于推动其在移动设备上的部署和工业应用。下一步工作重点是致力于模型在移动设备上的部署, 并基于实际检测性能进行深入探究, 以更好地满足高精度和实时性的应用需求。

## 参考文献

- [1] Phi T T, Kulatilake P H S W, Anka M L Y, et al. Rock mass statistical homogeneity investigation along a highway corridor in Vietnam[J]. *Eng Geol*, 2021, **289**: 106176.
- [2] Yan K, Zhang Z H. Automated asphalt highway pavement crack detection based on deformable single shot multi-box detector under a complex environment[J]. *IEEE Access*, 2021, **9**: 150925–150938.
- [3] Zhang X. Highway crack material detection algorithm based on digital image processing technology[J]. *J Phys Conf Ser*, 2023, **2425**(1): 012067.
- [4] Weng X X, Huang Y C, Li Y N, et al. Unsupervised domain adaptation for crack detection[J]. *Autom Constr*, 2023, **153**: 104939.
- [5] Yang Y T, Mei G. Deep transfer learning approach for identifying slope surface cracks[J]. *Appl Sci*, 2021, **11** (23): 11193.
- [6] Huang Z K, Chang D D, Yang X F, et al. A deep learning-based approach for crack damage detection using strain field[J]. *Eng Fract Mech*, 2023, **293**: 109703.
- [7] Zhu X K, Lyu S C, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision Workshops*, 2021: 2778–2788. <https://doi.org/10.1109/ICCVW54120.2021.00312>.
- [8] Li C Y, Li L L, Jiang H L, et al. YOLOv6: a single-stage object detection framework for industrial applications[Z]. arXiv: 2209.02976, 2022. <https://arxiv.org/abs/2209.02976>.
- [9] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 7464–7475. <https://doi.org/10.1109/CVPR52729.2023.00721>.
- [10] Gong L X, Huang X, Chao Y K, et al. Correction to: an enhanced SSD with feature cross-reinforcement for small-object detection[J]. *Appl Intell*, 2023, **53**(18): 21483–21484.
- [11] Liu X, Mo S T, Zhang J, et al. PeleeNet\_yolov3 surface crack identification with lightweight model[J]. *J Harbin Inst Technol*, 2023, **55**(4): 81–89.  
刘星, 莫思特, 张江, 等. 轻量化模型的 PeleeNet\_yolov3 地表裂缝识别[J]. *哈尔滨工业大学学报*, 2023, **55**(4): 81–89.
- [12] Zhou Z, Zhang J J, Lu S P. Tunnel lining crack detection algorithm based on improved YOLOv4[J]. *J China Railway Soc*, 2023, **45**(10): 162–170.  
周中, 张俊杰, 鲁四平. 基于改进 YOLOv4 的隧道衬砌裂缝检测算法[J]. *铁道学报*, 2023, **45**(10): 162–170.
- [13] Hu Q F, Wang P, Li S M, et al. Research on intelligent crack detection in a deep-cut canal slope in the Chinese South–North water transfer project[J]. *Remote Sens*, 2022, **14**(21): 5384.
- [14] Chen X, Peng D L, Gu Y. Real-time object detection for UAV images based on improved YOLOv5s[J]. *Opto-Electron Eng*, 2022, **49**(3): 210372.  
陈旭, 彭冬亮, 谷雨. 基于改进 YOLOv5s 的无人机图像实时目标检测[J]. *光电工程*, 2022, **49**(3): 210372.
- [15] Zhao C, Shu X, Yan X, et al. RDD-YOLO: a modified YOLO for detection of steel surface defects[J]. *Measurement*, 2023, **214**: 112776.
- [16] Ni C S, Li L, Luo W T, et al. Disease detection of asphalt pavement based on improved YOLOv7[J]. *Comput Eng Appl*, 2023, **59**(13): 305–316.  
倪昌双, 李林, 罗文婷, 等. 改进 YOLOv7 的沥青路面病害检测[J]. *计算机工程与应用*, 2023, **59**(13): 305–316.
- [17] Liang L M, Long P W, Lu B H, et al. Improvement of GBS-YOLOv7t for steel surface defect detection[J]. *Opto-Electron Eng*, 2024, **51**(5): 240044.  
梁礼明, 龙鹏威, 卢宝贺, 等. 改进 GBS-YOLOv7t 的钢材表面缺陷检测[J]. *光电工程*, 2024, **51**(5): 240044.
- [18] Xu X Q, Li Q, Li S E, et al. Crack width recognition of tunnel tube sheet based on YOLOv8 algorithm and 3D imaging[J]. *Buildings*, 2024, **14**(2): 531.
- [19] Talaat F M, Zaineldin H. An improved fire detection approach based on YOLO-v8 for smart cities[J]. *Neural Comput Appl*, 2023, **35**(28): 20939–20954.
- [20] Beyene D A, Tran D Q, Maru M B, et al. Unsupervised domain adaptation-based crack segmentation using transformer network[J]. *J Build Eng*, 2023, **80**: 107889.
- [21] Wang A, Chen H, Lin Z J, et al. Rep ViT: revisiting mobile CNN from ViT perspective[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024. <https://doi.org/10.1109/CVPR52733.2024.01506>.
- [22] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*, 2019: 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>.
- [23] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2020, **42**(8): 2011–2023.
- [24] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 1577–1586. <https://doi.org/10.1109/CVPR42600.2020.00165>.
- [25] Chen Y P, Dai X Y, Liu M C, et al. Dynamic convolution: attention over convolution kernels[C]//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 1030–11039. <https://doi.org/10.1109/CVPR42600.2020.01104>.
- [26] Han K, Wang Y H, Guo J Y, et al. ParameterNet: parameters are all you need for large-scale visual pretraining of mobile networks[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024: 15751–15761. <https://doi.org/10.1109/CVPR52733.2024.01491>.
- [27] Wu Y X, He K M. Group normalization[C]//*Proceedings of the 15th European Conference on Computer Vision*, 2018: 3–19. [https://doi.org/10.1007/978-3-030-01261-8\\_1](https://doi.org/10.1007/978-3-030-01261-8_1).
- [28] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 936–944.



- <https://doi.org/10.1109/CVPR.2017.106>.
- [29] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: faster and better learning for bounding box regression[C]//*Proceedings of the 34th AAAI Conference on Artificial Intelligence*, 2020: 12993–13000. <https://doi.org/10.1609/aaai.v34i07.6999>.
- [30] Gevorgyan Z. SloU loss: more powerful learning for bounding box regression[Z]. arXiv: 2205.12740, 2022. <https://arxiv.org/abs/2205.12740>.
- [31] Arya D, Maeda H, Ghosh S K, et al. RDD2022: a multi-national image dataset for automatic road damage detection[Z]. arXiv: 2209.08538, 2022. <https://arxiv.org/abs/2209.08538>.
- [32] Zhao Y, Lv W Y, Xu S L, et al. DETRs beat YOLOs on real-time object detection[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024: 16965–16974. <https://doi.org/10.1109/CVPR52733.2024.01605>.
- [33] Shi Y G, Li S K, Liu Z Y, et al. MTP-YOLO: you only look once based maritime tiny person detector for emergency rescue[J]. *J Mar Sci Eng*, 2024, 12(4): 669.
- [34] Woo S, Debnath S, Hu R H, et al. ConvNeXt V2: co-designing and scaling ConvNets with masked autoencoders[C]//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 16133–16142. <https://doi.org/10.1109/CVPR52729.2023.01548>.
- [35] Subramanyam A V, Singal N, Verma V K. Resource efficient perception for vision systems[Z]. arXiv: 2405.07166, 2024. <https://arxiv.org/abs/2405.07166>.
- [36] Zhang Y F, Ren W Q, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146–157.
- [37] Tong Z J, Chen Y H, Xu Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[Z]. arXiv: 2301.10051, 2023. <https://arxiv.org/abs/2301.10051>.

## 作者简介



牛晓富 (1995-), 男, 硕士研究生, 主要研究方向为图像处理、深度学习目标检测。

E-mail: [3023345034@stu.cqut.edu.cn](mailto:3023345034@stu.cqut.edu.cn)



【通信作者】张红民 (1970-), 男, 博士, 主要研究方向为图像处理与模式识别。

E-mail: [hmzhang@cqut.edu.cn](mailto:hmzhang@cqut.edu.cn)



黄河 (1982-), 男, 博士, 主要研究方向为物联网技术的监控设备及成果工程化应用。

E-mail: [cqhuanghe@cmhk.com](mailto:cqhuanghe@cmhk.com)



胥铁峰 (1998-), 男, 硕士研究生, 主要研究方向为图像处理、计算机视觉。

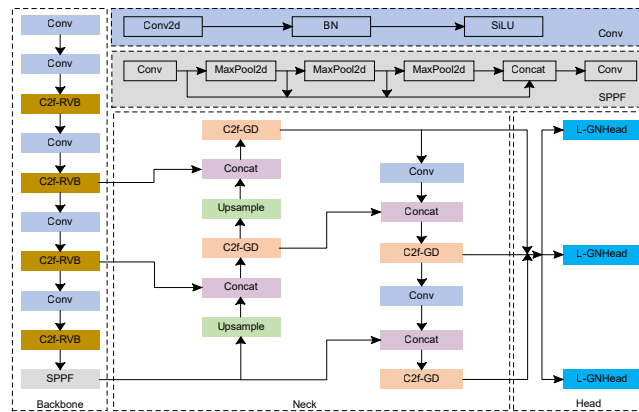
E-mail: [xtfjuzi@163.com](mailto:xtfjuzi@163.com)



扫描二维码, 获取PDF全文

# Improved YOLOv8 algorithm for detecting cracks in roadbed slopes

Niu Xiaofu<sup>1</sup>, Huang He<sup>1,2</sup>, Zhang Hongmin<sup>1\*</sup>, Xu Tiefeng<sup>1</sup>



Improved YOLOv8 network structure

**Overview:** The road transportation network in our country is constantly optimizing, and the slope engineering of highways is a key link to ensure the safety and stability of roadbeds, and its importance is becoming increasingly prominent. Cracks, as the initial signs of most highway slope diseases, their increase, expansion, and evolution are intuitive manifestations of slope instability. Therefore, timely and accurate identification of these roadbed slope cracks is the significant for real-time monitoring and warning of highway slope disasters, as well as ensuring smooth and safe traffic. Traditional slope crack detection mainly relies on manual inspection, resulting in high detection costs and low efficiency. In recent years, while deep learning based object detection algorithms can identify cracks, they tend to be limited to a single simple scene. However, due to differences in the shape of slope cracks, complex backgrounds, and lighting conditions, there are problems such as low detection accuracy, complex network models that are difficult to meet real-time requirements, and poor model generalization. In response to the problems in current slope crack detection algorithms, this paper proposes an improved YOLOv8 algorithm roadbed slope crack detection algorithm. Firstly, a reparameterization module is embedded in the backbone network to enhance the network's feature extraction ability and improve the detection accuracy of the model. Then, a lightweight C2f-GD module is built in the neck network, which enhances the generalisation ability of the model. In addition, the lightweight detection head L-GNHead is designed, which greatly reduces the complexity of the model and improves the detection accuracy of slope cracks at different scales. Finally, the SIOU loss function is used to accelerate the model convergence and improve the detection accuracy. The experiment results show that the improved algorithm improves mAP50 and mAP50-95 by 3.3% and 2.5% respectively on the self-constructed slope crack dataset, effectively reducing missed and false detections of slope cracks. At the same time, the number of parameters and computational complexity of the model is reduced by 46.6% and 44.4% respectively, and the FPS is improved by 18 frames/s. In addition, this paper conducts generalization validation on the public dataset RDD2022, and the comprehensive results show that the improved algorithm makes the model more lightweight and efficient, which helps promote deployment on edge devices. The next step focuses on the deployment of the model on mobile devices and in-depth exploration based on the actual detection performance to better meet the needs of high-accuracy and real-time applications.

Niu X F, Huang H, Zhang H M, et al. Improved YOLOv8 algorithm for detecting cracks in roadbed slopes[J]. *Opto-Electron Eng*, 2024, 51(11): 240171; DOI: [10.12086/oe.2024.240171](https://doi.org/10.12086/oe.2024.240171)

Foundation item: Project supported by National Key Research and Development Program (2022YFC3002603), Chongqing Natural Science Foundation Top Project (cstc2021 jcyj-msxmX0525, CSTB2022NSCQ-MSX0786, CSTB2023NSCQ-MSX0911), and Science and Technology Research Project of Chongqing Municipal Education Commission (KJQN202201109)

<sup>1</sup>School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China; <sup>2</sup>China Merchants Chongqing Transportation Research and Design Institute Limited, Chongqing 400067, China

\* E-mail: hmzhang@cqut.edu.cn