

贺泳超,陈秋南,程家杰.基于改进 YOLOv7 算法的隧道衬砌裂缝智能识别[J].湖南科技大学学报(自然科学版),2024,39(2):35-43.doi:10.13582/j.cnki.1672-9102.2024.02.005

HE Y C, CHEN Q N, CHENG J J. Intelligent Identification of Tunnel Lining Cracks Based on Improved YOLOv7[J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2024, 39(2): 35-43. doi: 10.13582/j.cnki.1672-9102.2024.02.005

基于改进 YOLOv7 算法的隧道衬砌裂缝智能识别

贺泳超¹,陈秋南^{2*},程家杰²

(1.湖南科技大学 资源环境与安全工程学院,湖南 湘潭 411201;

2.湖南科技大学 岩土工程稳定控制与健康监测湖南省重点实验室,湖南 湘潭 411201)

摘要:为了克服传统人工目测法的缺陷,提出针对隧道衬砌裂缝特征的改进 YOLOv7 算法模型 TLC-YOLO (Tunnel Lining Crack-YOLO).对比 4 类骨干网络对隧道衬砌裂缝的检测效果,认为复杂环境下的裂缝检测存在强背景干扰、训练样本质量不平衡等问题,使用轻量级卷积 GSConv 和 Slim-neck 架构,嵌入动态稀疏注意力模块 BiFormer 加强通道信息传输,提高 TLC-YOLO 模型的实时反应速度和检测精度,实现更灵活的计算分配和内容感知.为较好地训练样本分配梯度和抑制较差的训练实例,采用 Wise-IoU v3 作为坐标回归损失函数来提高模型的泛化能力.结果表明:通过自建隧道衬砌裂缝数据集训练之后,与 YOLOv7 相比,在多组试验中 TLC-YOLO 模型能同时提高隧道裂缝检测结果的准确率、召回率、F1 值和 mAP@0.5 值,证明 TLC-YOLO 模型在隧道衬砌裂缝智能识别中具有更好的检测和分类能力.

关键词:隧道衬砌裂缝;深度学习;目标检测;GSConv;BiFormer;Wise-IoU v3 损失

中图分类号:U457

文献标志码:A

文章编号:1672-9102(2024)02-0035-09

Intelligent Identification of Tunnel Lining Cracks Based on Improved YOLOv7

HE Yongchao¹, CHEN Qiunan², CHENG Jiajie²

(1. School of Resources, Environment and Safety Engineering, Hunan University of Science and Technology, Xiangtan 411201, China;

2. Hunan Provincial Key Laboratory of Geotechnical Engineering Stability Control and Health Monitoring,

Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: In order to overcome the inconvenience of the traditional manual visual inspection method, this paper proposes Tunnel Lining Crack-YOLO (TLC-YOLO), an improved YOLOv7 algorithm model for tunnel lining crack characteristics. This paper compares the detection effect of four types of backbone networks on tunnel lining cracks, and concludes that crack detection in complex environments has problems such as strong background interference and imbalance in the quality of training samples. By using lightweight convolutional GSConv and Slim-neck architectures in the TLC-YOLO model, and by embedding a dynamic sparse attention module, BiFormer, and by enhancing the transmission of channel information, we can improve the real-time response speed and detection accuracy of the model, enabling more flexible computation allocation and content awareness.

收稿日期:2023-02-06

基金项目:国家自然科学基金资助项目(52078211);湖南省交通运输厅科技进步与创新项目(202308)

*通信作者,E-mail: nmmwm1@163.com

Wise-IoU v3 is used as a coordinate regression loss function to improve the generalization ability of the model by assigning gradients to better training samples and suppressing poorer training instances. Results show that after training through the tunnel crack dataset, the TLC-YOLO model simultaneously improves the accuracy, recall, and F1 values, and mAP@0.5 values of the detection results for tunnel crack lesions in multiple sets of experiments compared to YOLOv7, proving that TLC-YOLO has a better ability to detect and classify tunnel lining cracks.

Keywords: tunnel lining cracks; deep learning; target detection; GSConv; BiFormer; Wise-IoU v3 loss

隧道衬砌裂缝作为隧道的表观损伤,是隧道衬砌破坏的主要影响因素,具有极大的危害.传统的隧道衬砌状态评估主要依靠专业管养团队开展人工目视检查,为了改善传统人工目视检查在隧道衬砌表面裂缝检测中存在的成本高、危险系数大且结果不准确的缺点^[1-2],学者们尝试借助信息采集设备,基于图像处理技术开展隧道衬砌表面裂缝的自动化研究,包括阈值分割法^[3-4]、边缘检测算法^[5-6]、基于区域生长的裂缝分割^[7-8]以及基于聚类的分割算法^[9-10]等.这些分割算法各有其局限性和弊端,存在应用场景受限、难以选择合适的特征提取方法以及检测效果较差等缺陷.

近年来,随着机器学习技术的发展,学术界和工业界开始将基于深度学习的图像识别思想融入裂缝检测^[11-12].作为两阶段的典型算法,R-CNN, SPP-Net等自出现以来,极大地促进了目标检测模型在隧道衬砌检测中的研究.张跃飞等^[13]使用自适应带权重的损失函数以及新的比例预测分支来训练神经网络,解决Mask R-CNN算法在复杂场景下裂缝掩码拟合质量不高的问题;LAU等^[14]使用预训练的ResNet34神经网络及“单周期”训练计划来加快收敛速度,增加空间和通道挤压与激励(SCSE)模块,使其只需要较少的特征工程技术.两阶段算法具有较高的检测精度,但计算量较大,实际应用速度较慢,因此,一些学者尝试将改良后的单阶段目标检测算法应用于裂缝检测.CHEN等^[15]将CBAM注意力模块与MobileNetV3-Large主干网络结合,极大地提升裂缝的识别精度;CUI等^[16]通过混凝土侵蚀试验建立深度学习数据集,修改YOLOv3的损失函数、激活函数及插入CSP模块,得到更高的准确率、精度和映射率;YU等^[17]提出基于剪枝算法简化网络的深度学习模型YOLOv4-FPM,使用焦点损失来优化损失函数,加快检测速度的同时增强模型的鲁棒性;何铁军等^[18]基于YOLOv5提出PD-YOLO模型,使用space-to-depth(SPD)层、SPPFCSPC模块和ASFF模块来改进算法,增强模型的检测能力.

虽然深度学习方法在隧道衬砌裂缝智能识别和分类中得到了推广,但是仍然存在一系列问题,如隧道衬砌裂缝的样本分布可能不平衡,即某些类别的裂缝数量明显少于其他类别;隧道环境的光照和视角可能受到限制,使得图像中的裂缝在不同条件下呈现出各种变化;隧道内可能存在各种噪声和干扰,如灰尘、水珠和涂料剥落等,这些可能被模型错误地识别为裂缝,增加误判的风险.目前的单阶段目标检测算法通常使用PascalVOC, MS-COCO等图像数据集进行训练,数据集类别主要为人、动物、车辆、家具和食品等.裂缝检测作为一项特定的目标检测任务,具有尺寸不规则、多方向性和纹理复杂性等检测难点,将目标检测算法在裂缝数据集上进行迁移学习往往难以取得较好的效果.本文在YOLOv7算法的基础上进行改进,提出针对隧道衬砌裂缝特征的改进YOLOv7算法模型TLC-YOLO(Tunnel Lining Crack-YOLO),结果表明:TLC-YOLO模型能降低训练样本数据质量的要求并提升不同环境下隧道衬砌的表面裂缝检测识别精度.

1 隧道衬砌裂缝检测算法

1.1 GSConv 卷积和 Slim-neck 架构

YOLOv7在很多检测任务上都有很强的表现,但在隧道衬砌裂缝的智能识别中,YOLOv7仍存在问题,如精度不够高和计算速度慢等.这是因为YOLO中的馈送图像会在骨干网络中经历空间信息逐步向通道传输的转换过程,并且每次特征图的空间(宽度和高度)压缩和通道拓展都会导致部分语义信息的丢失.根据文献[19]可知:在YOLOv7的网络中保持标准骨干网络而仅在颈部网络使用GSConv的Slim-neck架构能更好地处理特征图,减少冗余重复信息,在添加注意力模块之后,还能加强其工作性能.GSConv的网络结构如图1所示.

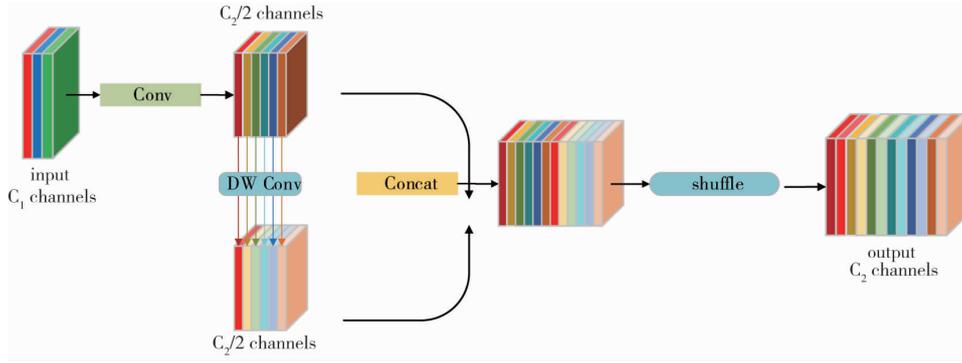


图 1 GSConv 的网络结构

1.2 动态稀疏注意力模块 BiFormer

由于在实际的应用场景中,隧道衬砌裂缝图像往往具有复杂且丰富的语义信息,因此,本文采用动态稀疏注意力模块 BiFormer^[20]过滤不关键的键值对,然后在剩余的候选区域集中应用细粒度的特征关注,便于有效特征的提取.

首先构筑双层路由注意力(Bi-Level Routing Attention, BRA),双层路由注意力工作示意如图 2 所示.图 2 中, $K^g, V^g \in \mathbf{R}^{S^2 \times \frac{HW}{S^2} \times C}$ 为键值张量, Q 为查询张量, A 为邻接矩阵, O 为键值对.对于给定的二维隧道衬砌图像 $X \in \mathbf{R}^{H \times W \times C}$, 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,即重塑 X 为 $X' \in \mathbf{R}^{S^2 \times \frac{HW}{S^2} \times C}$. 然后通过线性映射导出 Q, K, V 这三个权值矩阵, $Q, K, V \in \mathbf{R}^{S^2 \times \frac{HW}{S^2} \times C}$:

$$Q = X' W^Q, K = X' W^K, V = X' W^V. \tag{1}$$

式中: H 为高度,即纵坐标值; W 为宽度,即横坐标值; C 为通道数; $W^Q, W^K, W^V \in \mathbf{R}^{C \times C}$ 分别为 Q, K, V 的投影权重.

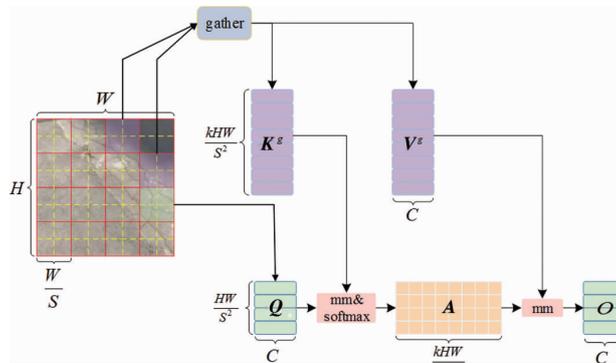


图 2 双层路由注意力工作示意图

使用四层金字塔结构,以 BRA 为基本构筑块,构建通用视觉转换器 BiFormer, BiFormer 结构如图 3 所示.

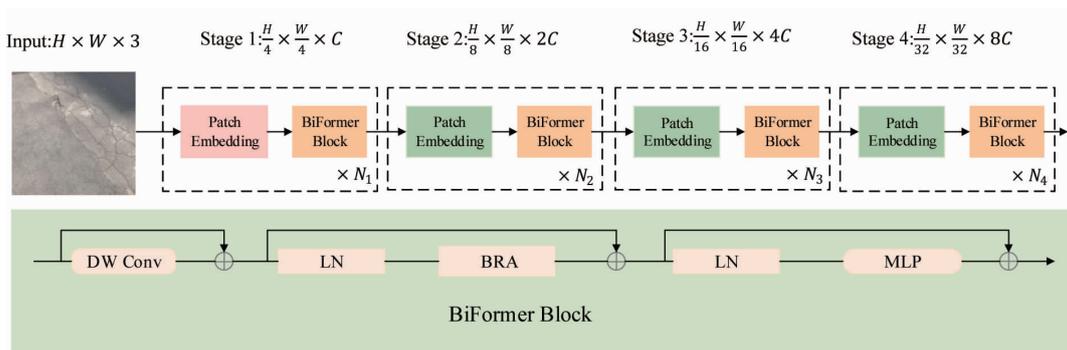


图 3 BiFormer 结构

1.3 Wise-IoU v3 损失函数

YOLOv7 使用 CIoU 来衡量边界框的损失, CIoU 考虑真实框和预测框的重叠程度、位置偏移和长宽比的一致性,可以更准确地表示目标框和预测框之间的重叠程度. CIoU 损失函数的定义如下:

$$L_{\text{IoU}} = 1 - \text{IoU}, \text{IoU} = \left| \frac{A \cap B}{A \cup B} \right|; \quad (2)$$

$$\mathcal{L}_{\text{CIoU}} = 1 - \text{IoU} + \frac{d^2}{c^2} + \alpha v; \quad (3)$$

$$\alpha = \frac{v}{(1 - \text{IoU}) + v}; \quad (4)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2. \quad (5)$$

式中: L_{IoU} 为 IoU 损失; IoU 为预测框和真实框相交区域面积和合并区域面积的比值; A 为预测框; B 为真实框; $\mathcal{L}_{\text{CIoU}}$ 为 CIoU 损失; α 为权重函数; v 用来度量宽高比的一致性; d 为预测框与真实框中心点的距离; c 为预测框和真实框最小外接矩形的对角线长度; w, h 为预测框的宽和高; $w^{\text{gt}}, h^{\text{gt}}$ 为真实框的宽和高.

边界框回归的 CIoU 损失如图 4 所示, 图 4 中的 D 为预测框和真实框的最小外接矩形.

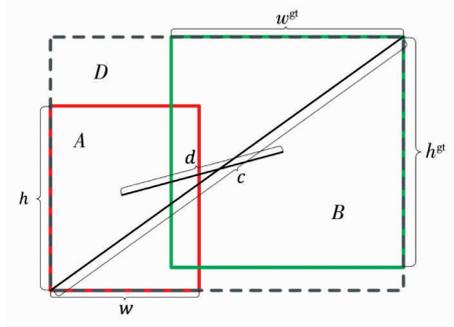


图 4 边界框回归的 CIoU 损失

CIoU 损失综合边界框回归的重叠面积、中心点距离和纵横比等因素,消除了训练过程中可能出现的梯度消失现象,但是通过式(5)反映的是纵横比的相对值差异,存在一定的模糊,且未协调样本的难易问题.考虑隧道衬砌裂缝数据的采集难度和标注工作量,训练集中会不可避免地存在低质量实例,几何因素(如距离和纵横比)将加重对低质量实例的惩罚,从而降低模型的泛化性能.为了解决训练样本质量不平衡的问题,首先根据距离度量构建距离注意力机制 Wise-IoU v1,然后定义离群度 β 来描述锚框质量,对离群度小的高质量锚框分配一个小的梯度增益 F ,使边界框回归聚焦到普通质量的锚框上,对离群度较大的低质量锚框分配较大的梯度增益,有效防止低质量实例产生的有害梯度.尽管需要增加聚焦系数的计算成本,但是由于不需要计算纵横比,算法的计算速度更快.采用 Wise-IoU v3^[21] 替代 YOLOv7 原模型的 GIoU 损失函数,定义如下:

$$\mathcal{L}_{\text{WIoUv1}} = \exp \left[\frac{d^2}{(c^2)^*} \right] \mathcal{L}_{\text{IoU}}; \quad (6)$$

$$\beta = \frac{\mathcal{L}_{\text{IoU}}^*}{\mathcal{L}_{\text{IoU}}} \in [0, +\infty); \quad (7)$$

$$F = \frac{\beta}{\delta \mu^{\beta \delta}}; \quad (8)$$

$$\mathcal{L}_{\text{WIoUv3}} = r \mathcal{L}_{\text{WIoUv1}}. \quad (9)$$

式中:上标 * 为防止 $\mathcal{L}_{\text{WIoUv1}}$ 产生阻碍收敛的梯度而将 W_g 和 H_g 从计算图中分离的操作; $\mathcal{L}_{\text{IoU}}^*$ 为单调聚焦系数; $\overline{\mathcal{L}_{\text{IoU}}}$ 为动量为 m 的滑动平均值; μ, δ 为超参数, $\mu = 1.9, \delta = 3$.

1.4 整体网络结构

针对隧道衬砌裂缝的复杂形态,引入 GSCConv 替代颈部的标准卷积层,以提高模型的学习效率和检测

速度.为了更好地捕捉图像中的裂缝要素,采用 Wise-IoU v3 损失函数来解决优劣样本间的边框回归平衡问题,最终得到兼具检测精度、分类准确度和训练速度的轻量化隧道衬砌裂缝检测模型 TLC-YOLO.表 1 为改进前后模型的轻量化对比,TLC-YOLO 模型的网络结构如图 5 所示,其中黑色方框处为 GSConv 替代标准卷积层的位置.

表 1 模型轻量化对比

名称	参数/M	运算次数/G	模型尺寸/MB
Baseline (YOLOv7)	37.2	105.2	71.4
TLC-YOLO	32.7	95.7	62.8

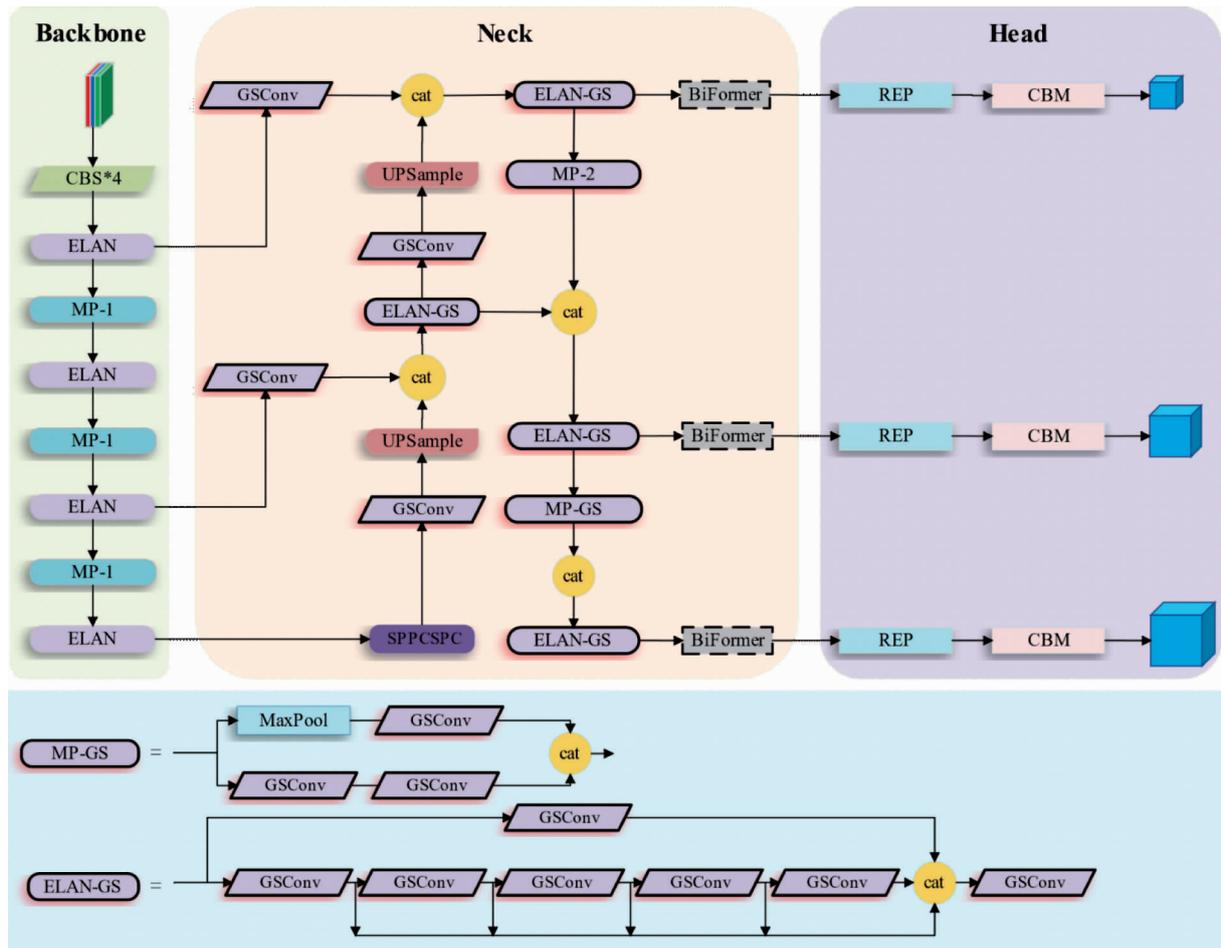


图 5 TLC-YOLO 模型的网络结构

2 模型训练和测试

2.1 数据集介绍

本文模型在自建隧道衬砌裂缝数据集上训练,通过分类纵向裂缝①D00、横向裂缝②D01、纵向拼接缝③D10、横向拼接缝④D11 和网状裂缝⑤D20,使用随机方法将数据集分为训练集和验证集,训练集和验证集的比例为 8 : 2.各裂缝类型如图 6 所示,各类型数据集的数量如表 2 所示.考虑现实的复杂环境条件,本文使用强弱扰动结合的图像干扰技术对数据集进行处理.在 YOLOv7 自带的 Mosaic 和 Mixup 数据增强的基础上,原有采集图像通过图像翻转,模拟光照条件强弱的对比度和亮度调整以及模拟检测设备抖动的运动模糊数据增强,经过剪裁拼接形成新的训练元素,并以一定比例混合生成新图像,最终形成新的数据集.对训练数据集 Self-built Dataset 使用空

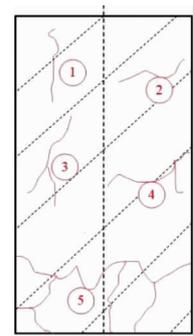


图 6 各裂缝类型

间几何变换,其空间倾斜角度小于 30° ,以保证不改变裂缝的走向特征.图像增强方法示例如图 7 所示.

表 2 各类型数据集数量

裂缝类型	标签	训练集	验证集
纵向裂缝	①D00	3 000	750
横向裂缝	②D01	2 500	625
纵向拼接缝	③D10	1 000	250
横向拼接缝	④D11	500	125
网状裂缝	⑤D20	2 800	700

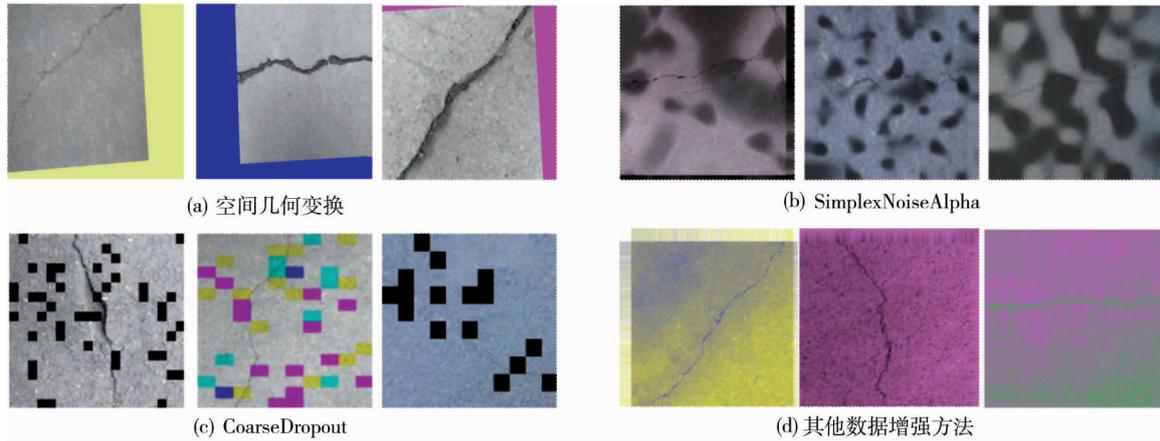


图 7 Self-built Dataset 图像增强方法示例

2.2 试验环境

本模型基于开源深度学习框架 PyTorch,开发语言主要为 Python.实例配置处理器为 15 vCPU Intel(R) Xeon(R) Platinum 8358P,2.60 GHz,GPU 选用 NVIDIA 的 RTX3090,24 G 显存.学习率设置为 0.01,训练次数设置为 100.

2.3 评价指标

本试验中,评价指标采用准确率(Pr)、召回率(Re)、F1 值和各类别 AP 均值(mAP@0.5).准确率为正确判定的裂缝数占所有检测到的裂缝数的比例;召回率也称为查全率,指在所有真实属于某个裂缝类别的样本中,被模型正确地判定为该类别的样本所占的比例;F1 值为准确率和召回率的加权平均,该值综合考虑准确率和召回率的信息,比单独使用任何一个指标更能反映模型的性能;mAP@0.5 指的是将 IoU 阈值设为 0.5 时,多个类别平均精度(AP)值的平均值,该值考虑多个实例的检测效果,体现了目标检测网络的综合性能.

$$Pr = \frac{T_p}{T_p + F_p}; \quad (10)$$

$$Re = \frac{T_p}{T_p + F_N}; \quad (11)$$

$$F1 = \frac{2 \times Pr \times Re}{Pr + Re}; \quad (12)$$

$$mAP = \frac{1}{n} \sum_n \int_0^1 P(R) dR. \quad (13)$$

式中: T_p 为被网络找到并正确分类的裂缝; F_N 为属于裂缝但是没有被正确检出的裂缝数; F_p 为被错误识别成裂缝的背景区域数目; n 为检测对象类别的数量.

3 试验结果分析

本文各项对比试验训练周期为 100 轮,使用训练过程中在验证集上表现最好的模型权重进行测试.

3.1 不同骨干网络改进 YOLOv7 模型对比试验

为了判断基于 PascalVOC, MS-COCO 等图像数据集改良的网络结构是否能适用于隧道衬砌裂缝识别与分类,本文进行对比试验,结果如表 3 所示.以 YOLOv7 为基础,以 MobileNetV3 为骨干网络的算法称为 YOLO-a,以 MobileNetXt 为骨干网络的算法称为 YOLO-b,以 ShuffleNetV2 为骨干网络的算法称为 YOLO-c.

表 3 不同骨干网络在 Self-built Dataset 下的试验结果对比

数据集	网络	Pr/%	Re/%	F1 值/%	mAP@ 0.5/%
Self-built Dataset	YOLOv7	85.6	83.2	84.4	82.2
	YOLO-a	83.2(-2.4)	83.1(-0.1)	83.2(-1.2)	80.0(-2.2)
	YOLO-b	85.7(+0.1)	80.3(-2.9)	82.9(-1.5)	81.6(-0.6)
	YOLO-c	84.2(-1.4)	82.6(-0.6)	83.4(-1.0)	83.8(+1.6)

由表 3 可知:将 YOLOv7 骨干网络替换成 MobileNetV3 时,模型对裂缝的检测准确率在数据集上均有所降低,说明此时的模型难以对检测出的裂缝进行准确分类,也有较大概率将背景信息误检为裂缝;将 YOLOv7 骨干网络替换成 MobileNetXt 时,模型对裂缝检测的召回率有所降低,这意味着出现裂缝误检;将 YOLOv7 骨干网络替换成 ShuffleNetV2 时,模型在数据集上的准确率、召回率及最重要的 F1 值均有所下降.此对比试验说明:动态拍摄设备和各类环境干扰使得研究者难以获得高质量、高分辨率的隧道衬砌裂缝图像数据样本,并且 YOLO 算法的标注非常耗费人力,存在训练数据匮乏,质量参差的情况.主流的骨干网络改进对于裂缝信息提取的表现难以令人满意,这主要是因为它们以各类形状清晰、高质量的训练样本为基础.因此,本文提出 TLC-YOLO 模型,以求解决上述各类问题.

3.2 消融实验

通过消融实验验证本文提出的 Slim-neck 架构范式和 Wise-IoU v3 计算对于裂缝检测网络性能的影响.以 YOLOv7 网络为基础,使用轻量级卷积网络 GSConv 和 Slim-neck 架构得到的网络称为 YOLO- α ,以 Wise-IoU v3 作为损失函数的网络称为 YOLO- β ,在 YOLO- α 的基础上加入 BiFormer 模块得到的网络称为 YOLO- γ .消融实验的结果如表 4 所示.由表 4 可知:在 YOLOv7 颈部使用 GSConv,能够加强信息传送效率,丰富特征图的表达能力,使模型获取更完整的特征信息进行训练;以轻量级卷积 GSConv 和 Slim-neck 架构的网络与 YOLOv7 网络相比,在 Self-built Dataset 上的检测能力都有不同程度的提升,准确率由 85.6% 提升到 88.8%,召回率减小 2.3 个百分点,map@ 0.5 提升 2.8 个百分点;以 Wise-IoU v3 作为坐标回归损失函数的网络能增加优质样本的训练权重,将 BBR(Bounding Box Regression)集中在普通或者更高质量的锚盒上,实现更低的回归误差,F1 值和 map@ 0.5 也有一定程度提升.

表 4 消融实验结果对比

数据集	网络	Pr/%	Re/%	F1 值/%	mAP@ 0.5/%
Self-built Dataset	YOLOv7	85.6	83.2	84.4	82.2
	YOLO- α	88.8(+3.2)	80.9(-2.3)	84.7(+0.3)	85.0(+2.8)
	YOLO- β	89.2(+3.6)	80.8(-2.4)	84.8(+0.4)	86.3(+4.1)
	YOLO- γ	84.2(-1.4)	86.4(+3.2)	85.3(+0.9)	88.1(+5.9)
	TLC-YOLO	90.7(+5.1)	90.4(+7.2)	90.5(+6.1)	90.5(+8.3)

此外,通过消融实验分析可以发现:使用不同的策略对 YOLOv7 进行改进时,不同方法带来的改进效果并非数值上的简单叠加,通道信息的传输优化、键值对计算资源的灵活分配与 BBR 损失改良最终使得模型的准确率、召回率、F1 值和 map@ 0.5 的同时提升,证明改进模型的有效性,TLC-YOLO 模型在隧道衬砌裂缝检测上与其他算法相比具有更优越的性能.

3.3 实际应用检测评价

为评估本文所提出的 TLC-YOLO 模型在实际场景中的应用效果,使用采集的丽香铁路某隧道的 1 000 张衬砌裂缝图片作为测试集.在试验结果中,本文主要对 F1 值进行计算,F1 值为准确率和召回率的加权平均,该值综合考虑准确率和召回率的平衡,是最适合衡量模型精确性的指标之一.各类型隧道衬砌裂缝

的检测结果如表 5 所示.由表 5 可知:检测结果再次验证了 TLC-YOLO 模型在隧道衬砌裂缝检测中的优越性,其中,裂缝 D00, D01, D10, D11 和 D20 的 F1 值达到 87.3%, 77.0%, 89.0%, 81.7%, 89.4%,较原模型分别增长 6.0, 6.6, 6.5, 10.3, 13.0 个百分点.将 YOLOv7 和 TLC-YOLO 这 2 个网络在测试集中的具体检测效果进行对比,部分检测结果如图 8 所示.

表 5 各类型隧道衬砌裂缝检测结果

模型	裂缝	Pr/%	Re/%	F1 值/%
YOLOv7	D00	80.1	82.5	81.3
	D01	68.4	72.6	70.4
	D10	81.3	83.8	82.5
	D11	69.7	73.1	71.4
	D20	75.5	77.3	76.4
TLC-YOLO	D00	86.2	88.5	87.3
	D01	75.3	78.8	77.0
	D10	89.5	88.5	89.0
	D11	80.1	83.3	81.7
	D20	89.2	89.7	89.4

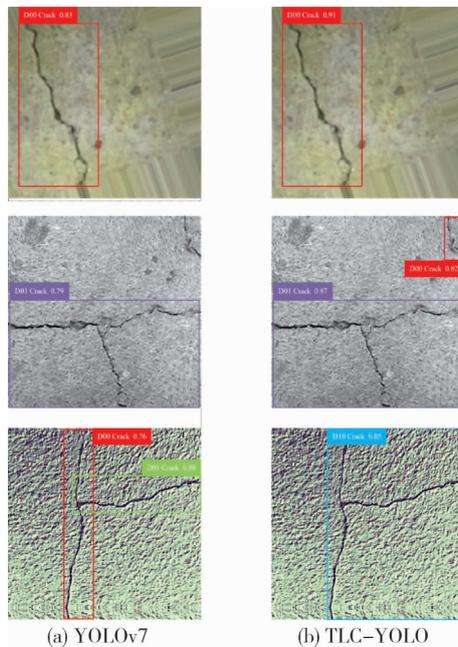


图 8 实际应用检测效果对比

对比分析可以发现,所提出的 TLC-YOLO 模型在实际应用中的性能优越性体现在以下 2 点:

1) 隧道衬砌裂缝的检测能力增强,裂缝误检率降低.在分辨率较低,背景噪声较复杂的场景下,TLC-YOLO 相较于 YOLOv7 表现出更强的特征学习能力,能从训练中学习更深层次的裂缝特征,对裂缝有更好的区分度,提高了隧道衬砌裂缝检测的准确性.

2) 检测目标的置信度增大.利用 Wise-IoU v3 损失函数对不同质量的训练样本的梯度进行分配,可以提高 TLC-YOLO 模型的特征提取能力和特征融合能力,相比 YOLOv7,各个场景下对裂缝检测的置信度都有所增加.

4 结论

1) 基于实际部署需求,在 YOLO 算法自带的 Mosaic 和 Mixup 数据增强基础上,综合运用各类形变尺度和随机噪声方法对训练集进行处理,增强模型的泛化能力和鲁棒性,使模型在训练过程中取得更为显著的性能增益,以满足实际场景的需求并提升算法的适用性.

2) TLC-YOLO 在颈部网络部分引入轻量级卷积 GSConv 和 Slim-neck 架构,同时嵌入动态稀疏注意力模块 BiFormer,在保留隧道衬砌裂缝图像在通道间的信息传递的同时,增强对低分辨率图像的多尺度特征提取能力.此外,考虑 YOLOv7 的 GIoU 损失函数存在的局限性,采用 Wise-IoU v3 损失函数,并通过梯度分配策略有选择性地训练样本,以加速收敛.消融实验结果证明以上改进的优越性.

3) 在自建隧道衬砌裂缝数据集测试下,TLC-YOLO 模型实现准确率、召回率、F1 值以及 mAP@0.5 值的同时提升,证明 TLC-YOLO 对于隧道衬砌裂缝具有更强的检测与分类能力,同时可以降低对训练样本质量的需求,不仅提升识别与分类的准确度,还减少人工标注的工作量,有利于模型的实际应用部署.

参考文献:

- [1] 乔雄,杨鑫.黄土隧道二次衬砌开裂原因及防治措施现状与发展[J].隧道建设(中英文),2023,43(10):1657-1676.
- [2] 刘德军,仲飞,黄宏伟,等.运营隧道衬砌病害诊治的现状与发展[J].中国公路学报,2021,34(11):178-199.
- [3] 张振海,贾争满,季坤.基于改进的 Otsu 法的地铁隧道裂缝识别方法研究[J].重庆交通大学学报(自然科学版),2022,41(1):84-90.
- [4] 刘渭宁,李文锋,李科,等.基于机器视觉的隧道衬砌表面病害检测技术研究进展[J].公路交通技术,2021,37(3):138-144.
- [5] 田贝乐,牛宏侠,刘义健.一种优化的 Canny 边缘检测算法[J].铁路计算机应用,2021,30(10):14-18.
- [6] WANG G C, TSE P W, YUAN M D. Automatic internal crack detection from a sequence of infrared images with a triple-threshold Canny edge detector[J]. Measurement Science and Technology, 2018, 29(2): 025403.
- [7] 王保宪,王哲,张宇峰,等.基于图像高维特征压缩映射的混凝土表面裂缝检测算法[J].北京理工大学学报,2019,39(4):343-351.
- [8] 龙学军,张杰,谭志国.基于视觉的隧道裂缝检测技术研究[J].现代计算机,2021,27(30):94-98.
- [9] 赵天玉,赵泉华.基于模糊聚类的黎曼流形空间遥感图像分割算法[J].无线工程,2021,51(8):738-741.
- [10] JU H Y, LI W, TIGHE S, et al. Illumination compensation model with k -means algorithm for detection of pavement surface cracks with shadow[J]. Journal of Computing in Civil Engineering, 2020, 34(1): 04019049.
- [11] 邓露,褚鸿鹄,龙砺芝,等.基于深度学习的土木基础设施裂缝检测综述[J].中国公路学报,2023,36(2):1-21.
- [12] 刘宇飞,樊健生,聂建国,等.结构表面裂缝数字图像法识别研究综述与前景展望[J].土木工程学报,2021,54(6):79-98.
- [13] 张跃飞,王敬飞,陈斌,等.基于改进的 MaskR-CNN 的公路裂缝检测算法[J].计算机应用,2020,40(S2):162-165.
- [14] LAU S L H, CHONG E K P, YANG X, et al. Automated pavement crack segmentation using U-net-based convolutional neural network[J]. IEEE Access, 2020, 8: 114892-114899.
- [15] CHEN L J, YAO H D, FU J Y, et al. The classification and localization of crack using lightweight convolutional neural network with CBAM[J]. Engineering Structures, 2023, 275: 115291.
- [16] CUI X N, WANG Q C, DAI J P, et al. Intelligent recognition of erosion damage to concrete based on improved YOLO-v3[J]. Materials Letters, 2021, 302: 130363.
- [17] YU Z W, SHEN Y G, SHEN C K. A real-time detection approach for bridge cracks based on YOLOv4-FPM[J]. Automation in Construction, 2021, 122: 103514.
- [18] 何铁军,李华恩.基于改进 YOLOv5 的路面病害检测模型[J].土木工程学报,2024,57(2):96-106.
- [19] LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[EB/OL]. 2022: arXiv: 2206.02424. <http://arxiv.org/abs/2206.02424>.
- [20] ZHU L, WANG X J, KE Z H, et al. BiFormer: vision transformer with Bi-level routing attention[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 10323-10333.
- [21] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. 2023: arXiv: 2301.10051. <http://arxiv.org/abs/2301.10051>.