

基于改进 YOLOv8 的轨道板裂缝检测方法

付浩辰^{1,2}, 白堂博^{1,2}, 许贵阳^{1,2}

(1. 北京建筑大学 机电与车辆工程学院, 北京 100044;

2. 城市轨道交通车辆服役性能保障北京市重点实验室, 北京 100044)

摘要: 高铁轨道板裂缝严重危害车辆运行安全, 目前裂缝维护中存在无效修复的情况, 当前针对这一问题的研究较为缺乏。本文提出了 YOLOv8-DSC 模型不同类型裂缝分类方法, 在骨干网络引入动态蛇形卷积模块(Dynamic Snake Convolution, DSC), 基于此重新构造 C2f 中的 Bottleneck 结构, 建立为 C2f-v1 模块, 从而替换 YOLOv8 骨干网络的部分 C2f 模块, 提升无效裂缝多尺度细节特征的获取能力; 在颈部网络引入 CBAM 注意力机制, 增强模型对关键特征的关注度, 强化细小裂缝特征在神经网络中的传递; 在损失函数方面, 利用 SIOU 损失函数替换 CIOU, 削弱几何因素对模型的过度惩罚, 减少对模型训练的干预以增加模型的泛化能力; 最后从网络结构、裂缝数据、分类方法和环境条件四个方面对其进行了验证和评价。实验结果表明: YOLOv8-DSC 模型相较于 YOLOv8 原模型, 漏检误检情况得到明显改善, 平均精度均值及查全率分别提高了 4.6%、4.0%, 有效实现了轨道板无效修复裂缝的准确检测。

关键词: 高速铁路; 轨道板裂缝; YOLO; 裂缝检测; 图像处理

中图分类号: TP391.4

文献标志码: A

Crack detection of track slab based on YOLOv8

FU Haochen^{1,2}, BAI Tangbo^{1,2}, XU Guiyang^{1,2}

(1.School of Mechanical-Electronic and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;

2.Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicles, Beijing 100044, China)

Abstract: The severe cracking of high-speed rail tracks poses a significant threat to the safety of train operations. Currently, there are instances of ineffective repairs in track crack maintenance, and research addressing this issue is lacking. This paper proposes a YOLOv8-DSC model for classifying different types of cracks, incorporating a Dynamic Snake Convolution (DSC) module into the backbone network. The Bottleneck structure in C2f is redesigned and named C2f-v1, replacing certain C2f modules in the YOLOv8 backbone network to enhance the capability of capturing multi-scale detailed features. In the neck network, the CBAM attention mechanism is introduced to increase the model's focus on key features and strengthen the transmission of small target features in the neural network. Regarding the loss function, the SIOU loss function is utilized to replace CIOU, reducing the excessive penalty of geometric factors on the model and minimizing intervention in model training to improve generalization ability. Finally, the model is validated and evaluated from four aspects: net-

收稿日期: 2024-03-28

基金项目: 北京市自然科学基金资助项目(L211007, L221027)、国家自然科学基金资助项目(52272385)

Foundation item: Beijing Natural Science Foundation-funded projects (L211007, L221027), National Natural Science Foundation of China-funded project (52272385)

第一作者: 付浩辰(2000—), 男, 山东滨州人, 硕士研究生, 研究方向为轨道损伤检测. **email:** 823860257@qq.com.

通讯作者: 白堂博(1985—), 男, 山东泰安人, 副教授, 研究方向为机械设备状态监测与故障诊断. **email:** baitangbo@bucea.edu.cn.

work structure, crack data, classification method, and environmental conditions. Experimental results demonstrate that the YOLOv8-DSC model, compared to the original YOLOv8 model, exhibits significant improvements in false negatives and false positives, with an increase of 4.6% in mean Average Precision and 4.0% in recall. This effectively achieves accurate detection of invalid repair cracks in rail tracks.

Keywords: high speed railway; track slab cracks; YOLO; crack detection; image processing

目前,我国高铁运营里程 4.5 万公里^[1]位居世界第一。无砟轨道道床板等结构长期处于复杂的外界环境之中,致使其在服役期间不断出现开裂问题,且由于裂缝维护中普遍存在无效维护的现象,使得存在裂纹等病害的道床板即使进行了维护,也让高铁的运行存在一定的安全隐患。轨道板裂缝的无效维护不仅降低了铁路结构的承载能力,而且还可能造成扣件脱落和轨道移位,威胁高铁的运行安全。因此,开展高速铁路轨道板裂缝相关研究具有一定的科研价值与现实意义。

近年来,国内外学者开展了大量裂缝检测相关研究。Li 等^[2]基于红外成像对裂缝进行检测,当环境温度不低于 20°C 时,能够对裂纹进行较为精确的定位。马跃坤等^[3]采用基于多尺度积阈值红外图像增强算法的红外热成像检测方法对无砟轨道板裂缝进行检测。然而,基于红外成像的裂缝检测结果依赖于环境温度,温度对检测精度有较强的干扰性。

采用基于可见光图像处理的方法^[4]能够有效避免温度对检测结果的影响。张鑫鹏等^[5]提出一种微裂纹检测方法,通过阈值算法及 Canny 算子实现裂纹的粗提取,使用特征约束条件进行筛选,实现了裂纹的获取。姜会增等^[6]提出一种铁道桥梁表面裂缝检测方法,通过对图像中各点进行二值化阈值分割,滤除非裂缝成分,保留裂缝信息来实现裂缝检测。传统可见光图像处理算法进行裂缝检测能够取得良好的检测效果,但高速铁路轨道板图像具有低对比度及背景复杂的特点,裂缝特征不够明显,处理过程复杂,对算法性能及检测人员专业水平要求更高。

基于深度学习的方法能够充分提取目标深层特征,通常具有更好的检测效果。柴雪松等^[7]使用 ResNet18 网络对铁路隧道衬砌裂缝进行识别,识别精度达 94%。许贵阳等^[8]提出改进 Faster R-CNN 的 CRTSII 型轨道板裂缝检测方法,使用 Soft-NMS 算法,改善裂缝检测重叠状况,提高了检测效果。胡文博等^[9]使用 YOLOv3 网络进行裂缝区域提取,使用改进正交投影法判别裂缝边界,实现了宏微观耦合的深度学习裂缝精细化测量。

综上所述,现有高速铁路裂缝的研究中,主要针对现存裂缝的位置检测,缺乏针对无效修复裂缝的检测,为有效减少轨道板裂缝给高铁运行带来的安全隐患,优化对无效修复轨道板裂缝修补工作流程,亟需针对需要二次修复的裂缝进行有效检测。由于无砟轨道背景较复杂且拍摄环境不稳定,图像可能会存在大量的噪声,且裂缝标签种类的增加,会导致特征不明显的需要二次修复裂缝与小目标裂缝难以提取特征信息,使得轨道板裂缝检测存在精度差、召回率低等问题。为了解决以上问题,本文建立 C2f-v1 模块与 CBAM 注意力机制模块,利用其对 YOLOv8 进行优化,提高模型的精度,首次提出了一种基于 YOLOv8 的轨道板裂缝检测算法 YOLOv8-DSC,通过图像检测技术进行轨道板各类别裂缝识别,为列车运行和基础设施运维提供参考。

1 裂缝目标检测算法

1.1 YOLOv8模型

YOLOv8是Ultralytics公司于2023年1月10日发布的一种物体检测和图像分割的算法。相较于之前的版本,该算法进一步优化了模型轻量化结构,并提高了检测精度。本文提出了一种YOLOv8的改进方法,不仅提高了无砟轨道板裂缝的检测精度与召回率,而且实现了裂缝的高精度分类检测、模型尺寸最小化和对不同拍摄环境图像的鲁棒性和适应性的提高。

YOLOv8网络^[10]模型主要包含了输入(Input)、骨干网络(Backbone)、颈部网络(Neck)、检测头(Head)等4部分。

YOLOv8采用CSP-DarkNet作为骨干网络,该网络结合了Cross-Stage Partial Network(CSP)和DarkNet的特点。CSP模块通过将输入特征图分成两部分,其中一部分进行卷积处理,另一部分直接传递到输

出。这种设计可以有效地减少特征信息丢失，并提高特征提取的效果。在Neck模块中，YOLOv8采用了Path Aggregation Network(PAN)结构，实现了浅层和深层信息的融合。PAN结构通过自下而上和自上而下的路径，将浅层和深层特征进行融合，以提高物体检测的准确性和稳定性。此外，YOLOv8还采用面向任务的分配器实现动态样本分配，该分配器根据目标的难易程度动态分配样本给不同的训练阶段，从而使模型更加关注难以检测的目标，提高检测准确性和鲁棒性。YOLOv8网络结构如图1所示。




图 1 YOLOv8 网络结构

Fig.1 YOLOv8 Network Architecture

1.2 改进的YOLOv8模型

基于上述YOLOv8模型的改进，针对无砟轨道板裂缝的检测，提出全新的YOLOv8-DSC模型，模型结构如图2所示。




图 2 YOLOv8-DSC 网络结构

Fig.2 YOLOv8-DSC Network Architecture

1.2.1 动态蛇形卷积模块

在实际的无砟轨道板裂缝图像中，面临着不同类别裂缝特征不一，尺度差异大的问题。然而YOLO v8模型使用的是固定尺寸的卷积核，导致其对于不同尺寸、形态变化复杂的目标适应能力差，从而削弱了模型对尺度变化较大、边界信息不明显的裂缝的识别能力。为了缓解这一问题，本文提出使用动态蛇形卷积模块(Dynamic Snake Convolution, DSC)。

动态蛇形卷积的设计灵感来源于蛇形的形状，用于改善对目标形状和边界的敏感性^[11]。对于复杂的或不规则形状的目标，通过引入动态的、可变形的卷积核来帮助神经网络更好地捕捉目标的形状信息。这种可变形的卷积核能够根据目标的形状和边界信息进行调整，从而更好地适应目标的特定形状。由于已修复裂缝与需进行二次修复裂缝的特征存在都有修复物亮斑、且亮斑中都存在较为相似的暗型管状结构，导致传统的卷积操作在处理时存在一定的局限性，不仅识别精度较低而且很容易将两者进行误判，而动态蛇形卷积则能够通过自适应性地调整卷积核的形状和大小，更有效地捕获不同形态裂缝的具体特征，从而提高对该裂缝检测的准确性和鲁棒性，使整体模型在识别已修复裂缝与需进行二次修复裂缝时，减少误判，提高精度。

动态蛇形卷积提取特征图的过程如图3所示，首先对输入特征图利用卷积获得偏移量，同时根据输入特征图的特征和偏移量推导出输出特征图。




图 3 动态蛇形卷积特征提取过程

Fig.3 Dynamic Snake Convolution feature extraction process

为了应对在YOLOv8的C2f模块中使用普通卷积操作时出现的感受野范围限制问题，本文对该模块进行了重新构建，以提高其在无砟轨道板图像中捕捉裂缝几何形变的能力。具体而言，使用动态蛇形卷积来替换原有C2f模块的普通卷积操作，增强无砟轨道板图像中裂缝几何形变的适应能力。具体改进如图4所示。




图 4 基于动态蛇形卷积的 C2f-v1 模块

Fig.4 C2f-v1 based on Dynamic Snake Convolution

1.2.2 CBAM注意力机制模块

由于无渣轨道板拍摄环境不稳定，图像可能会存在噪声、模糊等不确定性问题，导致需进行二次修复裂缝与细小裂缝存在误检、漏检，为解决这一问题，本文在YOLOv8颈部网络中引入CBAM注意力机制，加权突出重要的通道和空间位置，增强模型对关键特征的关注度，强化小目标特征在神经网络中的传递，提高检测模型对于不同背景下各类别细小裂缝的特征提取能力。

目前许多学者正致力于研究关于注意力机制的相关主题，并取得了一定进展。如CA^[12]注意力机制、SE^[13]注意力机制。CA注意力机制通过全局平均池化和全连接层学习各通道间的特征关系，可以有效增强模型的特征学习能力和泛化能力，却忽略了图像中不同区域的空间关系。SE注意力机制通过神经网络自动学习的方式，利用特征图每个通道的重要程度去给不同特征赋予各自权重值，从而让神经网络重点关注某些特征通道，上述两种注意力机制都忽略了图像的空间关系，而在轨道板裂缝检测任务中，空间信息对于准确定位和检测裂缝是至关重要的。

针对以上注意力机制存在的问题，本文提出了CBAM注意力机制，其结构如图5所示。




图 5 CBAM 注意力机制结构

Fig.5 Structure of CBAM attention mechanism

CBAM注意力机制结合了空间注意力(Spatial Attention)和通道注意力(Channel Attention)两个方面，使检测模型可以更全面地捕捉图像的重要信息。

总的过程可以概括为：首先输入原始特征图先经过通道注意力机制识别，随后将获取的通道权重结果和输入原始特征图相乘后得到第一重信息，再将第一重信息输入到空间注意力机制进行二维卷积得到空间权重结果，将归一化后的空间权重结果和第一重信息相乘，得到最终加权后的特征图。

由于CBAM注意力机制的引进，使得YOLOv8模型在检测任务中具有综合考虑空间和通道注意力、网络可学习性强、全局上下文信息捕捉和多层级加权处理等优势，在识别多类别轨道板裂缝方面，解决了存在大量的噪声图像与图像亮度太高或太低时的细小裂缝存在误检、漏检的问题，提高了模型的性能和泛化能力。

1.2.3 SIoU损失函数

边界框回归的损失函数对于目标检测至关重要，它的良好定义将为模型带来显著的性能改进。YOLOv8中的边界框回归损失函数为CIoU。

原网络损失函数CIoU loss计算如式(1)、(2)、(3)所示：

$$L_{CloU} = 1 - I_{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (1)$$

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

$$\alpha = \frac{v}{(1 - I_{IoU}) + v} \quad (3)$$

其中： ρ 两中心点间欧氏距离； b 为预测框中心点； b^{gt} 为真实框中心点； c 为预测框与真实框最小包围区域的对角线长度； α 为权衡参数； v 为衡量长宽比一致性的参数； w^{gt} 为真实框宽度； h^{gt} 为真实框高度； w 为预测框宽度； h 为预测框高度。

不难看出，虽然CIoU损失函数综合考虑了预测框与真实框的长宽比、中心点位置以及重叠面积，提高了回归定位的准确性，但当真实框与预测框长宽比相同时，CIoU loss长宽比的惩罚项恒为0，较差的样本会对回归损失产生较大的影响，使得收敛过程波动相对较大。SIoU^[14]损失函数相比于CIoU损失函数，增加角度惩罚成本，有效减少损失函数的总自由度，削弱几何因素对模型的过度惩罚，减少对模型训练的干预以增加模型的泛化能力。因此，本文使用SIoU损失函数替换原CIoU损失函数。

在原损失函数基础上增加了角度成本与距离成本，降低了惩罚项为0的概率，使得收敛过程更加稳定，并且提高了推理精度。

2 现场实验与数据集建立

实验硬件环境为GTX4080显卡，显存容量16GB，处理器为i7-13700，运行环境为Python3.8.13，Torch1.12.0+cu116，Opencv-Python4.6.0。

2.1 实验前准备

2.1.1 数据采集

目前,关于高铁无砟轨道板表面裂缝检测研究缺乏相关的公共数据集。因此，本文进行了实际道路检测实验。

实验所用到的轨道板表面裂缝数据集图片是由北京某公司设计制造的新型轨道巡检车在夜间采集某高速铁路CTRSII型轨道板图像，图像分辨率为2048×2048，采集时通过激光线阵相机连续拍摄，图6为新型智能轨道巡检车。



图 6 智能轨道巡检车

Fig.6 Intelligent rail inspection vehicle

2.1.2 裂缝类别划分

现有研究通常根据图像中是否存在裂缝将样本图像划分为背景与裂缝，从图像块级别检测裂缝，而不考虑无效修复裂缝的信息。根据无砟轨道结构特点、无砟道床混凝土裂缝性质和裂缝伤损等级，

轨道板裂缝修补方法可分为表面封闭法和注浆法，两种方法的修补材料都采用合成树脂或聚合物水泥砂浆，在完成轨道板裂缝修补作业后，固化的修补材料会在修补处形成特征较为明显的修复区域。

由于裂缝是否修复完善对BTS的维护和服务方法以及服务状态的评估有着重要影响，本文提出了一种基于裂缝修复状态的分级标记方法。根据《高速铁路无砟轨道线路维护规程(试行)》(铁运[2012]83号)等规范对不同类型的裂缝进行划分。划分依据为，图像块中裂缝附近不存在修复物亮斑，则标记为未修复裂缝，数据标注时定义其标签为Unrepaired；图像块中裂缝存在修复物亮斑且不存在较为明显的裂缝，则标记为已修复裂缝，定义其标签为Repaired；图像块中裂缝存在修复物亮斑且在亮斑内部存在较为明显的裂缝，则标记为需进行二次修复裂缝，定义其标签为Re-repair。不同类别的裂缝示意图如图7所示。




图 7 裂缝病害类别划分图

Fig.7 Category classification diagram of crack diseases

2.1.3 数据集建立

本文所用数据集是由北京某公司设计制造的新型轨道巡检车在夜间采集某高速铁路CTRSII型轨道板图像，图像分辨率为2048×2048，共计2655个裂纹图像。

采用Labelimg工具进行标注，最后将数据集按照8:1:1的比例随机划分为训练集、测试集和验证集。该数据集的分类有三类，一类是Unrepaired(表未修复裂缝)，一类是Repaired(代表已修复裂缝)，一类是Re-repair(代表需进行二次修复裂缝)。

2.2 评价指标

为验证改进模型的性能，本文使用了以下评价指标：精准率 P (Precision)、召回率 R (Recall)、平均精度均值 mAP (mean Average Precision)、 $F1$ 分数。精确率和召回率是基本的评价指标，通过它们计算得出的 $F1$ -score和 mAP 作为最终的评价指标，用于衡量模型的识别准确率。

精确率是指预测为正样本且预测正确的结果占预测为正样本的比例。计算如式(4)所示：

$$P = \frac{T_p}{T_p + F_n} \times 100\% \quad (4)$$

召回率是指在实际为正样本的情况下，被正确预测为正样本的比例。计算如式(5)所示：

$$R = \frac{T_p}{T_p + F_p} \times 100\% \quad (5)$$

其中： T_p 为正确预测的裂缝结果； F_n 为未检测出的裂缝结果； F_p 为误判为裂缝的结果。

n 个类别的平均精确率计算如式(6)所示：

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P(R) d(R) \quad (6)$$

$F1$ -score综合考虑了准确率和召回率，较全面地反映算法的整体性能。取两个指标的谐波平均值计

算，如式(7)所示：

$$F1-score = 2 \frac{P \times R}{P + R} \quad (7)$$

3 结果分析

3.1 不同模型对比

为了评估改进算法在无砟轨道板裂缝检测上的性能，将本文算法模型和Faster R-CNN、YOLOv4、YOLOv5^[15]、YOLOv7^[16]等目前主流的目标检测算法进行比较，未修复裂缝、已修复裂缝、需二次修复裂缝的实验结果如表1所示。从表中可以看出本文算法在无砟轨道板检测上检测效果优于下表中的主流模型，改进后的YOLOv8算法由于加强了骨干网络与颈部网络的特征提取，与相比对原始YOLOv8模型，其 $mAP@0.5$ 上涨了3.5%， $F1-score$ 上涨了3.79%，且改进后的模型在对已修复裂缝、需二次修复裂缝的识别上，精度有了明显提升。

表 1 不同模型结果对比

Tab.1 Comparison of different model results

算法	AP/%			P/%	R/%	Map@0.5/%	F1-score/%
	未修复裂缝	已修复裂缝	需二次修复裂缝				
Faster-RCNN	88.1	71.2	86.0	83.7	88.2	91.4	85.89
YOLOv4	78.5	66.2	83.9	76.3	86.1	90.1	80.90
YOLOv5	81.9	66.7	84.0	79.6	87.3	90.5	83.27
YOLOv7	84.1	69.6	84.9	80.7	86.2	90.5	83.36
YOLO8	86.8	71.4	85.2	82.7	90.1	91.7	86.25
本文模型	90.2	77.9	91.1	87.3	94.1	95.3	90.55

3.2 损失函数对比

在同种实验条件下，对改进模型损失函数收敛性进行验证。两种损失函数在训练过程中随迭代次数的变化曲线如图8所示。




图 8 损失函数对比

Fig.8 Loss function comparison

从图中可以看出，随着迭代次数的增加，模型损失基本收敛，使用 L_{Siou} 替换边界框损失函数 L_{Ciou} 后，目标框的损失函数值有所降低，而且从损失趋势上来看， L_{Siou} 收敛速度更快；因此，使用Siou作

为改进模型的损失函数使得模型损失更低，预测效果更好，对模型性能的提升具有重要意义。

3.3 消融实验

为了验证提出的改进模型每个模块的有效性，在YOLOv8的基础上对各个模块进行消融实验。将YOLOv8-DSC中添加的所有模块删除得到的基础网络记为A，在A上依次加入DSC模块、C2f-v1模块、CBAM模块、Siou损失函数，将得到的网络模型依次记为B、C、D、E，实验结果如表2所示。

可以看出，在加入动态蛇形卷积模块后， P 、 R 、 $mAP@0.5$ 、 $F1-score$ 相比较YOLOv8分别提升了1.7%、1.4%、2.8%，特别是在对已修复裂缝与需二次修复裂缝的检测精度上，B模型分别提升了3.7%、4.7%。之后通过在颈部网络中引入CBAM注意力机制模块，最大化保留细小的特征信息，同时加权突出重要的通道和空间位置，增强模型对关键特征的关注度，使得模型 $F1-score$ 提升了3.09%。最后，使用Siou损失函数代替CIoU损失函数，增加角度惩罚成本，减少了损失函数的总自由度，以此削弱几何因素对模型的过度惩罚，减少对模型训练的干预以增加模型的泛化能力。

综合上述分析，可以得到融合的改进模型极大地提升了模型的检测能力。对未修复裂缝、已修复裂缝、需二次修复裂缝的 $mAP@0.5$ 分别提高了2.4%、4.3%、6.5%。

表 2 消融实验结果

Tab.2 Results of ablation experiment

检测模型	AP/%			P /%	R /%	$Map@0.5$ /%	$F1-score$ /%
	未修复裂缝	已修复裂缝	需二次修复裂缝				
A	86.8	71.4	85.2	82.7	90.1	91.7	86.25
B	86.9	75.1	89.9	84.4	91.5	93.5	87.81
C	87.7	74.4	89.8	84.7	92.2	92.9	88.29
D	89.7	77.4	91.0	86.8	94.0	95.1	90.27
E	90.2	77.9	91.1	87.3	94.1	95.3	90.55

3.4 不利环境条件下分类结果的一致性

为了探索YOLOv8-DSC模型的鲁棒性和适应性，本文从原始测试集中选取了600幅图像(每类标签包含200幅图像)，进一步测试融合改进的模型在不利环境条件下的分类效果，包括背景噪声干扰、光照强度影响和人为因素造成的图像模糊三种情况。在原始图像中加入不同程度的椒盐噪声，模拟背景噪声的干扰，如图9(a)改变图像的亮度值，模拟自然环境中光线的影响，如图9(b)、(c)所示；对图像进行高斯模糊处理，模拟图像采集时对焦误差造成的图像模糊，如图9(d)所示。从指标 $F1-score$ 对三种类型的裂缝图像进行分析和评估。




图 9 三种不利环境条件

Fig.9 Three adverse environmental conditions

1) 图片背景噪声

椒盐噪声是数字图像中常见的一种噪点。它可以通过在图像中随机添加黑色或白色像素来模拟背景噪声的干扰。信号噪声率(SNR:数值范围0-1)用于测量图像中的噪声。信噪比越小，图像中的噪声比例越大。

2)光照强度

通过增减图像中每个像素的亮度值(范围0-255)来模拟自然环境条件下的光线变化。

3)图像模糊

通过对原始图像进行卷积运算，模拟因人为聚焦误差而采集到的模糊图像。卷积运算的数学表达式如下：

$$F(r) = \frac{1}{\sqrt{2\pi\sigma^2}^N} e^{-r^2/(2\sigma)^2} \quad (8)$$

其中， σ 是正态分布的标准偏差； r 是高斯核，高斯核的标准差决定了模糊的程度，标准差越大，模糊效果越明显。

如图10(a)所示,对于未修复裂缝和已修复裂缝，图像背景噪声对其 $F1$ -score的影响较小；对于需二次修复裂缝，图像背景噪声对其 $F1$ -score影响较大；如图10(b)所示，图片亮度的适当提高或降低在一定程度上会增加各类别裂缝的 $F1$ -score，但随着光照强度的持续增加或降低，都会导致裂缝识别度的降低；如图10(c)所示，当图像的模糊程度较小时，容易将需二次修复裂缝误判为已修复裂缝，导致需二次修复裂缝的 $F1$ -score大幅下降，已修复裂缝的 $F1$ -score小幅水平上升；随着图像模糊度的增加，已修复裂缝与需二次修复裂缝之间的差异逐渐缩小,识别精度与召回率都收到较大影响，而未识别裂缝仍有一定的识别度,这使得已修复裂缝和需二次修复裂缝的 $F1$ -score下降，未修复裂缝的 $F1$ -score变化不大。

综上所述，在背景噪声和光照强度的影响下，YOLOv8-DSC模型对未修复裂缝与已修复裂缝仍能保证较好的一致性，其 $F1$ -score分别能保持在80%与70%以上。但对于模糊图像，裂缝分类的准确率和 $F1$ -score都明显下降。这说明YOLOv8-DSC模型对背景噪声和光照强度的影响具有良好的鲁棒性和适应性，但对模糊轨道板裂缝图像的认识效果有待提高。




图 10 三种不利环境条件下 F1 分数的变化趋势

Fig.10 The change trend of $F1$ -scores under three adverse environmental conditions

3.5 模型改进效果的对比图

针对轨道板裂缝的复杂情况，本文选取部分轨道板图片进行预测，原模型与本文模型预测结果如图11、12所示。相较于YOLOv8网络模型，本文模型对各类裂缝特征更加敏感，能有效提高裂缝的分类精度，如图11、12所示；能够显著有效减少误检率，如图13所示；可以明显提高细小裂缝的检出率，如图14所示。




图 11 裂缝识别分类对比(a)

Fig.11 Comparison of classification in crack detection(a)




图 12 裂缝识别分类对比(b)

Fig.12 Comparison of classification in crack detection(b)




图 13 裂缝识别误判对比

Fig.13 Comparison of false positives in crack detection




图 14 细小裂缝识别对比

Fig.14 Comparison of fine cracks in crack detection

4 结论

1)通过不同环境对比实验可知，即使轨道板图像在采集时存在光源不足、图像噪声多等环境问题，本文提出的模型仍然可以较为准确的对三种类别裂缝做出识别与区分。相比Faster R-CNN及YOLOv8等方法，本方法具有更高的识别精度与召回率，最终精确度为87.3%，召回率为94.1%，mAP@0.5为95.3%，F1-score为90.55%。

2)针对传统算法对需进行二次修复裂缝识别精度低且易被误判为已修复裂缝的问题，通过在YOLOv8骨干网络引入自建C2f-v1模块得到解决，该模块与动态蛇形卷积(Dynamic Snake Convolution, DSC)相结合，可以自适应地关注细长和曲折的局部结构来准确捕获裂缝结构的特征，提高了算法的检测精度与鲁棒性。

3)通过对消融实验与不利环境条件下的结果分析可得，在YOLOv8颈部网络中引入CBAM注意力机制模块，增强了小目标特征在神经网络中的传递，同时提高了对模糊图像与不同亮度图像下细小裂缝的特征收集能力。

4)本文提出的YOLOv8-DSC模型不仅能够替代现有轨道板裂缝检测，而且还能够解决轨道板维护中无效修复裂缝识别的难题，为高铁各类别轨道板裂缝的识别提供可靠的预测结果。

参考文献(References):

- [1] 发展和改革委员会.中国国家铁路集团有限公司 2023 年统计公报[N].人民铁道, 2024-02-17(002).
- [2] Li Z W, Liu X Z, Lu H Y, et al. Surface crack detection in precasted slab track in high-speed rail via infrared thermography[J]. Materials, 2020, 13(4837):1-10.
- [3] 马跃坤,李再伟,赵彦旭等.无砟轨道板表面裂缝的红外热成像检测方法[J].铁道科学与工程学报, 2022, 19(03): 579-587. Ma Yuekun, Li Zaiwei, Zhao Yanxu, et al. Infrared thermal imaging detection method for surface cracks of ballastless track slab [J]. Journal of Railway Science and Engineering, 2022, 19(03): 579-587.(in Chinese)
- [4] 云艳,高红俐,沈姗姗.基于机器视觉技术的疲劳裂纹自动检测实验系统[J].机电工程, 2012, 29(02): 183-187. Yun Yan, Gao Hongli, Shen Shanshan. Experimental system for automatic detection of fatigue cracks based on machine vision technology[J]. Mechanical and Electrical Engineering, 2012, 29(02): 183-187.
- [5] 张鑫鹏,魏立峰,苑玮琦等.基于机器视觉的板式换热器板片微裂纹检测方法研究[J].机电工程, 2020, 37(07):856-860. Zhang Xinpeng, Wei Lifeng, Yuan Weiqi, et al. Research on Micro-Crack detection method of plate heat exchanger plates based on machine vision[J]. Mechanical and Electrical Engineering, 2020, 37(07): 856-860.(in Chinese)
- [6] 姜会增.基于数字图像处理的铁路桥梁裂缝检测技术[J].铁道建筑, 2016, 15(05): 82-86. Jiang Huizeng. Railway bridge crack detection technology based on digital image processing[J]. Railway Construction, 2016, 15(05): 82-86. (in Chinese)
- [7] 柴雪松,朱兴永,李健超等.基于深度卷积神经网络的隧道衬砌裂缝识别算法[J].铁道建筑, 2018, v.58; No.532(06): 65-70. Chai Xuesong, Zhu Xingyong, Li Jianchao, et al. Crack recognition algorithm for tunnel lining based on deep convolutional neural network[J]. Railway Construction, 2018, v.58; No.532(06): 65-70.(in Chinese)

- [8] 许贵阳,张诗泉,白堂博.基于改进 Faster R-CNN 的 CRTSII 型轨道板裂缝检测方法[J].中国铁道科学, 2023, 44(1): 106-113.
Xu Guiyang, Zhang Shiquan, Bai Tangbo. Crack detection method for CRTSII type track slab based on improved Faster R-CNN[J]. China Railway Science, 2023, 44(1): 106-113.(in Chinese)
- [9] 胡文博,王卫东,汪雯娟等.基于宏微观耦合深度学习的高速铁路无砟轨道板表面裂缝精细化测量[J].中南大学学报(自然科学版), 2022, 53(5): 1965-1975.
Hu Wenbo, Wang Weidong, Wang Wenjuan, et al. Fine measurement of surface cracks on ballastless track slab of high-speed railway based on Macro-Micro coupled deep learning[J]. Journal of Central South University (Natural Science Edition), 2022, 53(5): 1965-1975.(in Chinese)
- [10] 李松,史涛,井方科.改进 YOLOv8 的道路损伤检测算法[J].计算机工程与应用, 2023, 59(23): 165-174.
Li Song, Shi Tao, Jing Fangke. Road damage detection algorithm based on improved YOLOv8[J]. Computer Engineering and Applications, 2023, 59(23): 165-174. (in Chinese)
- [11] Qi L , Yang L , Da L. Revolutionizing target detection in intelligent traffic systems: YOLOv8-SnakeVision[J]. Electronics, 2023, 12(24):4970.
- [12] LI G , SHI G , JIAO J. YOLOv5-KCB: A new method for individual pig detection using optimized K-Means, CA attention mechanism and a Bi-Directional feature pyramid network[J]. Sensors, 2023, 23(11):5242.
- [13] ZHOU T , HUANG B , LI R , et al. An attention based deep learning model for citywide traffic flow forecasting[J]. International Journal of Digital Earth, 2022, 15(1):323-344.
- [14] Cha Y J , Choi W , Buyukozturk O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [15] Zhu X , Lyu S , Wang X , et al. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]// Proceedings of the IEEE/CVF international conference on computer vision. Montreal, 2021: 2778-2788.
- [16] 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

作者简介：

付浩辰^{1,2}，白堂博^{1,2}，许贵阳^{1,2}

(1. 北京建筑大学 机电与车辆工程学院，北京 100044；

2. 城市轨道交通车辆服役性能保障北京市重点实验室，北京 100044)

FU Haochen^{1,2}, BAI Tangbo^{1,2}, XU Guiyang^{1,2}

(1.School of Mechanical-Electronic and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China ;

2. Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicles, Beijing 100044, China)