

DOI:10.13382/j.jemi.B2508248

隧道超前钻探下的围岩裂隙检测算法

郭乙龙^{1,2} 陈春梅^{1,2} 朱宏伟³ 汪顶攀⁴ 李明俊⁴ 张婷^{1,2}

(1. 西南科技大学信息与控制工程学院 绵阳 621010; 2. 特殊环境机器人技术四川省重点实验室 绵阳 621010;
3. 西南科技大学环境与资源学院 绵阳 621010; 4. 四川振通检测股份有限公司 绵阳 621000)

摘要:在隧道钻探地质超前预报中,为了更好地指导隧道掘进作业,需对钻探岩层内壁上存在的缺陷、裂隙和渗漏情况进行检测。在真实工程环境中采集了超前钻探岩层内壁图像,通过针对性处理,形成了钻孔内壁缺陷数据集,并提出一种基于YOLOv8n的孔洞内壁缺陷检测模型。首先,提出一种融合坐标注意力机制的坐标通道-空间卷积模块(CSCM),通过建立通道维度与空间坐标的交互关系,以增强模型特征提取能力;其次,设计快速空间金字塔池化卷积模块,以提升网络浅层特征与深层特征融合传递的能力;最后,引入幻影卷积算子改进C2f模块,采用残差连接结构提升多尺度特征提取的效果,以进一步提高模型检测性能,并实现模型轻量化。验证结果表明,相比于原始的YOLOv8n模型,改进后的算法在自制钻孔数据集的检测精度提升了5.5%,而计算负载降低了0.1 GFLOPs,相较于YOLOv11、RT-DETR等主流检测模型,平均检测精度提升了7%。改进后算法有效提升了检测精度,实现了实时高效超前预报,展现出良好的工程应用前景。

关键词:地质超前预报;围岩缺陷检测;YOLOv8n;CSCM注意力机制

中图分类号: TP391; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Detection algorithm of surrounding rock defects under tunnel advance drilling

Guo Yilong^{1,2} Chen Chunmei^{1,2} Zhu Hongwei³ Wang Dingpan⁴ Li Mingjun⁴ Zhang Ting^{1,2}

(1. School of Information and Control Engineering, Southwest University of Science and Technology, Mianyang 621010, China;
2. Robot Technology Used for Special Environment Key Laboratory of Sichuan Province, Mianyang 621010, China;
3. School of Environment and Resource, Southwest University of Science and Technology, Mianyang 621010, China;
4. Sichuan Zhentong Inspection Co. Ltd., Mianyang 621000, China)

Abstract: In tunnel advance drilling for geological forecasting, the detection of defects, cracks, and seepage within borehole walls is crucial to guide safe and efficient tunneling operations. This study addresses this challenge by constructing a borehole wall defect dataset from real-world drilling images and proposing an optimized YOLOv8n-based detection model. The technical advancements are threefold: Firstly, coordinate channel-spatial convolutional module with attention mechanism; A novel module integrating coordinate attention is designed to enhance feature extraction by establishing interdependencies between channel dimensions and spatial coordinates. Secondly, rapid spatial pyramid pooling convolutional module; A lightweight hierarchical architecture is developed to improve the fusion and transmission of shallow and deep network features. Lastly, ghost convolution-enhanced C2f module; A residual-connected C2f structure incorporating ghost convolution operators is proposed to refine multi-scale feature extraction while achieving model lightweighting. Experimental results demonstrate that the proposed algorithm achieves a 5.5% improvement in mean average precision (mAP) over the baseline YOLOv8n model on the custom dataset, with a computational load reduction of 0.1 GFLOPs. Compared to state-of-the-art models such as YOLOv11 and RT-DETR, it exhibits a 7% superiority in average detection accuracy. The improved algorithm effectively enhances detection accuracy, enabling real-time, efficient, and advance forecasting, demonstrating promising prospects for engineering applications.

Keywords: geological advance prediction; surrounding rock defect detection; YOLOv8n; CSCM attention mechanism

0 引言

岩体的稳定性与其内部裂隙的发育情况密切相关,岩体中的节理、裂隙及断层可能导致围岩变形和隧洞坍塌等灾害^[1-2]。因此,在地下施工作业过程中,需要对围岩结构开展超前钻探预报。基于机器视觉的岩层超前钻探设备具有实时性、连续性和非接触式的特点,能够便捷地获取岩体内部图像,让施工人员提前掌握围岩状态,为隧道安全施工提供了可靠指导。

目前,通过物探法与超前水平钻探结合的检测方式,虽可通过视频采集分析岩体缺陷、裂隙及突水特征^[3],但传统图像处理依赖人工特征提取,检测精度高度依赖操作人员专业水平,存在主观性强、量化程度低的缺陷^[4],导致特征表达能力有限且效率低下。而基于神经网络结构缺陷检测与分割模型的提出,则是解决了传统缺陷检测中人为主观判断的劣势,并且更加准确和高效。黄振宇等^[5]通过结合神经网络与 Softmax 回归层模型,构建了判别式深度置信网络模型,通过仿真测试,实现了对智能电缆隧道缺陷检测。Cheng 等^[6]在 U-Net 神经网络模型中加入距离变换损失函数,并将其用于裂缝检测,提高了模型分割的准确性。房昱纬等^[7]提出了一种基于神经网络的钻探测试数据智能分析和地层识别方法,并通过隧道开挖后所揭示地层对分析方法进行了验证。然而神经网络在面对复杂无序的数据时,常面临特征提取困难和泛化能力不足的问题。而深度学习与缺陷检测任务的有效结合则是解决了使用单一神经网络存在的问题,并且基于深度学习的缺陷检测方法逐渐成为主流趋势^[8],通过端到端的特征学习,在复杂地质图像中实现了像素级缺陷定位,显著提升检测结果的准确性和效率,并已有学者将其应用于裂隙缺陷检测任务中。Attard 等^[9]采用 Mask R-CNN 模型对隧道衬砌裂缝进行目标检测和实例分割,并同时定位裂缝并生成像素级掩码,实验结果表明,该方法在复杂隧道环境下的裂缝检测精度显著优于传统方法,但其对细小特征提取能力有限,且双阶段模型计算资源和时间需求大。Duan 等^[10]通过 YOLOv5 结合数据增强、上下文编码(SCE)和细节保留编码(DPE)得到了隧道衬砌裂缝实时检测模型,在低光、低对比度和高噪声环境中保持较高精度和准确度的裂纹检测,但未针对隧道衬砌不同类型裂缝的特征差异做出针对改进。朱磊等^[11]通过骨架提取和函数拟合的裂缝几何特征计算方法,调整算法参数,根据裂缝狭长弯曲的特性,获得适用于隧道裂缝检测的 Mask R-CNN 模型,但其针对的裂缝数据相对单一,模型处理复杂数据能力不足。彭鸿瑞等^[12]通过在原有的 YOLOv8 网络模型上增加小目标检测层和 SPD-Conv 卷积块结合的 SimAM 注意力机制,

以及多尺度特征双向融合改善模型对小缺陷的检测效果,但不断堆叠的模块极大的增加了模型计算量,难以满足实际部署和实时检测要求。

综上所述,超前钻探围岩缺陷检测任务中仍存在如下问题:围岩缺陷(缺陷、裂隙和渗漏)尺度差异大,其中裂隙和渗漏在围岩内壁常呈现狭长特性,而缺陷则呈现宽大特性;且缺陷区域与周围正常岩层在特征层上区分不明显,模型在检测多尺度缺陷时需要较强的特征提取能力和泛化能力以有效识别不同形态的缺陷;目前大部分研究仅针对围岩裂隙,未能涵盖钻探围岩所有可能存在的缺陷部分,限制了模型在超前钻探围岩缺陷检测算法在工程实际检测场景下的应用。针对上述问题,通过实地采集真实超前钻探围岩数据,根据渗漏、裂隙和缺陷图像构建隧道钻孔围岩缺陷数据集,提出一种基于 YOLOv8n 网络模型改进的隧道超前钻探内壁缺陷检测算法。首先,结合坐标注意力机制提出一种坐标通道-空间卷积注意力模块(coordinate channel-space convolution module, CSCM)融入到主干中,聚焦于任务最重要的特征;其次,改进空间金字塔池化模块,提升模型的多尺度特征定位提取能力;然后,引入幻影卷积改进 C2f 模块融入模型,在保证有效捕捉图像不同尺度的特征时,丰富特征的表达能力;最后,探究了在模型中的不同位置放置模块,对模型整体性能的影响。

1 超前钻探围岩缺陷检测算法

1.1 YOLOv8 网络

YOLOv8 网络模型作为兼具性能和效率的基准模型,为适应多样化的视觉任务需求,提供了一种灵活的网络架构设计方法。该模型通过调整网络的深度和宽度参数,提供了 n、s、m、l、x 共 5 种不同配置型号。其中,n 型号参数最少、推理速度最快,优化了检测精度与鲁棒性之间的平衡,适合对实时性要求较高的计算场景。

YOLOv8 采用端到端的一阶段检测架构,主要由 Backbone、Neck 和 Head 这 3 个部分组成^[13]。Backbone 部分通过卷积模块、C2f 模块与快速空间金字塔池化层(spatial pyramid pooling fast, SPPF)结构实现对输入图片的多尺度特征提取,生成不同层次的特征图;Neck 部分接收这些特征图,采用特征金字塔网络(feature pyramid network, FPN) + 路径聚合网络(path aggregation network, PAN)的结构,FPN 从主干网络自上而下传递深层语义特征,PAN 自下而上传递浅层空间特征,构建双向特征金字塔结构,融合不同尺度的特征图,检测不同大小的目标,实现融合深浅层特征以增强语义与空间信息表达能力^[14];Head 部分采用任务解耦策略,通过独立的分支分别处理目标分类与边界框回归任务,并基于无锚

相互耦合导致的优化冲突,实现增强特征重标定的协同效应。

在组通道注意力块 (group channel attention model, GCAM) 部分,利用分治策略对输入特征进行通道维度的动态重组,其结构如图 2 所示。具体而言,模块将输入特征沿通道维度均等分割为两个互补子空间;前半通道保留原始特征以维持基础表征能力;后半通道则通过分组空间注意力机制进行重标定。分组策略将通道划分为多个子组,每组内部独立进行空间维度的长程依赖建模^[17]。通过高度方向的自适应平均池化与宽度方向的池化操作,模块分别提取空间维度的全局上下文信息,随后将压缩后的特征拼接并通过轻量化的 1×1 卷积进行跨维度融合。这种设计将传统的二维空间注意力分解为高度与宽度的独立建模,显著降低了计算复杂度^[15]。融合后的特征通过 Sigmoid 函数生成注意力权重,与原始子空间特征进行重组,形成通道维度的动态特征增强。与此同时,模块并行计算全局通道注意力权重,利用全局平均池化与全连接层生成通道注意力系数图,最终通过逐元素乘法实现全局与局部特征的协同优化。GCAM 通过分组计算与维度解耦策略,在降低计算复杂度的同时实现多尺度特征的精细化调整。模块最终输出 Y 如式 (1) 所示。

$$Y = \text{concat}(Y_0^{\text{group}}, A_{\text{spatial}}) \odot A_{\text{channel}} \quad (1)$$

式中: Y_0^{group} 为一半原始特征图; A_{spatial} 为另一半特征图经过空间维度建模融合后的注意力权重; A_{channel} 为全局通道注意力权重图; \odot 表示通道维度广播的逐元素乘法。

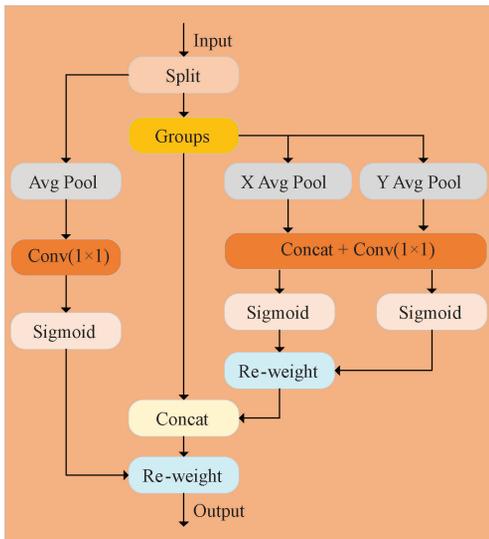


图 2 GCAM 结构示意图

Fig. 2 Architecture of the GCAM module

而空间注意力部分引入空间注意力块 (spatial attention module, SAM) 机制,通过双路特征压缩增强模型

鲁棒性。SAM 结构如图 3 所示。首先沿通道维度分别计算均值与最大值统计量,捕捉特征图中不同位置的显著性差异^[16]。平均池化反映了特征的空间平滑性,而最大池化则强调局部区域的突出响应,两者的结合能够平衡全局背景与局部细节的信息表达^[18]。随后,通过 7×7 的卷积层对拼接后的双路特征进行空间关系建模,利用局部感受野捕捉空间上下文依赖。最后通过 Sigmoid 函数生成的二维空间注意力图,以元素相乘的方式作用于特征图,实现对关键空间区域的聚焦与冗余信息的抑制。

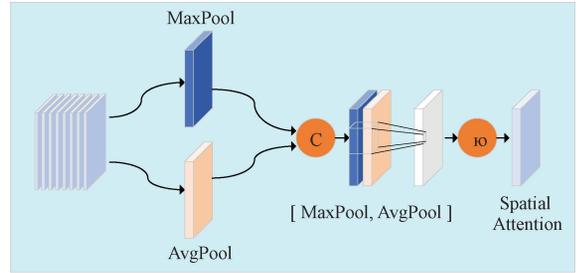


图 3 SAM 结构示意图

Fig. 3 Architecture of the SAM module

CSCM 模块通过通道分组与空间维度解耦策略,在保持注意力机制有效性的同时,降低添加模型带来的计算成本。分组机制将通道计算复杂度从传统的平方级降至线性级,而高度-宽度分离建模则使空间注意力的参数量减少^[19]。先通过通道注意力强化重要通道的特征表达,再经由空间注意力细化关键区域的定位,避免了混合注意力中通道与空间权重相互耦合导致的优化冲突,从而提升模型的性能。CSCM 模块的输出表达式如下:

$$Y_{\text{Output}} = \mathcal{F}_{\text{spatial}} \circ \mathcal{F}_{\text{channel}}(x) \quad (2)$$

式中: $x \in R^{B \times C \times H \times W}$ 为输入特征图; $\mathcal{F}_{\text{channel}}(\cdot)$ 为通道注意力函数; $\mathcal{F}_{\text{spatial}}(\cdot)$ 为空间注意力函数; \circ 表示两个函数的组合运算。

2) SPPFC (SPPF Conv) 模块

SPPF 是 YOLOv8 模型中用于多尺度特征融合的关键模块,利用多个串联的最大池化层,以此实现多尺度特征定位于融合。但随着网络深度的增加,目标特征也更加抽象,不同尺度缺陷特征的充分融合困难,进而对模型检测目标的准确性以及稳定性产生一定的影响^[20]。因此,本文在 SPPF 模块上通过在最大池化后增加卷积块,以增强局部细节表达改进 SPPF 模块。改进后的 SPPFC 模块结构如图 4 所示,替换 SPPF 模块以提升模型对钻探围岩缺陷特征定位与融合的能力。

通过在选定特定最大池化后加入 3×3 标准卷积模块进一步提炼目标特征,利用非线性激活函数 ReLU,增强模型对局部细节特征捕捉能力。原始 SPPF 输出仅为拼

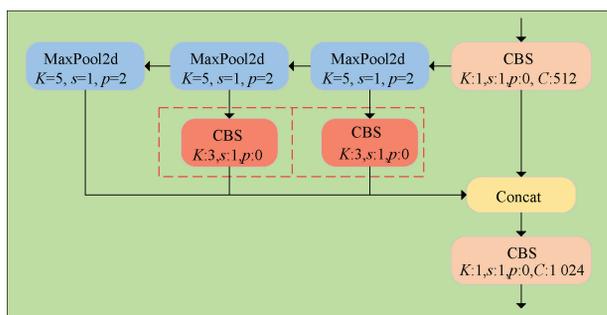


图 4 SPPFC 结构示意图

Fig. 4 Architecture of the SPPFC module

接池化后的结果,而对最大池化的特征进行卷积处理后,使拼接融合的特征包含更多的语义和细节信息;增强了多尺度特征的表达能力,对边缘细节的捕捉更优异。多阶段池化加卷积的组合能更好的适应复杂背景和目标形变,可以有效的关注隧道钻孔内裂隙的位置。

3) C2f_G 多尺度特征提取模块

钻孔内壁缺陷类别尺度差异较大,针对不同尺度的特征提取时,较大尺度特征在经过深层卷积层后还能保留,而较小尺度特征则被逐渐卷积采样稀释后导致特征提取不平衡^[21]。针对钻孔内壁裂隙检测中多尺度特征提取与计算效率的双重需求,通过引入幻影卷积(GhostConv)重构 C2f 模块,以构建轻量化多尺度特征提取架构 C2f_G 模块。重构后的 C2f_G 模块如图 5 所示。

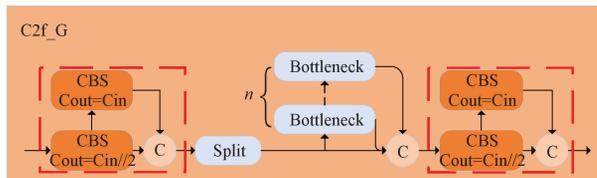


图 5 C2f_G 结构示意图

Fig. 5 Architecture of the C2f_G module

Ghost 卷积通过线性变换生成冗余特征图以降低计算量,C2f 模块则通过跨阶段特征融合保留丰富的梯度信息。融合后的 C2f_G 模块包含特征解耦层与动态融合块。为了减轻模型的重量,并将不同尺度的特征图更好的融合在一起,输入特征首先通过 Ghost 卷积层生成冗余特征图,再经逐通道线性变换扩展特征维度;随后在多尺度分支中,通过不同扩张率的卷积核提取特征,并将各分支输出与原始特征进行跨阶段连接;最终通过可学习的注意力权重动态聚合多尺度特征。在减少参数量的情况下,仍能通过通道重组机制保留小尺度缺陷的细节特征,同时利用跨层连接强化大尺度特征的语义信息表达。在保持模型表达能力的同时实现了显著的参数压缩,有效的平衡计算效率与特征表达能力。

2 实验与结果分析

2.1 实验环境

本文用于模型训练和测试的硬件配置和软件环境如表 1 所示。在模型训练过程中,输入图像尺寸大小固定为 640×640,训练轮数为 300,学习率动量为 0.937,初始学习率为 0.01,批次为 16。

表 1 硬件配置与软件环境

Table 1 Hardware and software configuration

硬件配置及软件环境	配置名及版本
处理器(CPU)	Intel Core i7-13700k (32 GB)
显卡(GPU)	NVIDIA GeForce RTX4070TiSuper (16 GB)
操作系统	Windows 11
运算平台	CUDA 12.1
深度学习框架	PyTorch 2.3 + python 3.8

2.2 数据集构建

在隧道掘进现场,利用数字式钻孔摄像设备进行钻孔围岩可视化操作。通过对整个钻孔围岩内部画面进行采集和保存,结合钻头旋进过程中的实时参数分析,选择真实有效且人为破坏不大的片段处理。通过实地采集的隧道超前钻探孔洞视频,利用视频抽去关键帧获取图像,并人工筛选出图像清晰、成像质量高且参考价值高的包含所需目标类别的图像保留。

采集到清晰图像共计 3 246 张图像,分别包含孔壁裂隙、缺陷及渗漏 3 个目标类别,各类别典型缺陷如图 6 所示。由于数据集规模有限,直接训练可能导致模型过拟合或欠拟合,因此需对数据集进行随机扩展。通过对图像亮度、饱和度及翻转效果等条件随机调整,将数据集扩展至 4 094 张图像。使用 Labelimg 对孔洞裂隙图片进行手工标注,将缺陷的类别、位置和大小信息存储在标签文件中。为预防各类别数据分布不均衡的问题,将图片和标签数据按照 8 : 2 比例均衡划分训练集和测试集,构成隧道超前钻探围岩缺陷数据集(TD_dataset)。

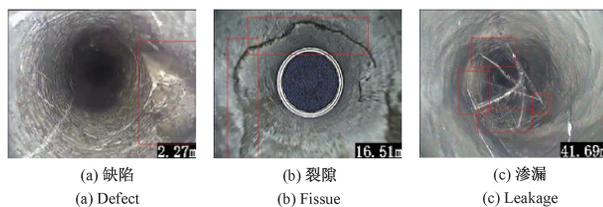


图 6 主要类别示意图

Fig. 6 Main category diagram

图 6 红色框选出的 3 种类型是本文需要的检测对象。裂隙与缺陷大多是地下岩层中随着地质运动、不同

岩层间产生空隙而来;而渗漏区域则是由于地下水层的存在,随着钻孔隧道的深入破碎岩层而产生的泄漏。

2.3 评价指标

为了更准确的评估模型在隧道超前钻孔内壁缺陷检测任务中的效果,本文采用精确度-召回率 (precision-recall, P-R)、模型参数量 (Params)、平均精度 (average precision, AP) 和平均检测精度 (mean average precision, mAP)、平均交并比 (mean intersection over union, mIoU) 和模型浮点计算量 (floating point operations, FLOPs) 作为进行对象检测的评估指标。其公式如式(3)~(7)所示。

$$P = \frac{T_p}{T_p + F_p} \quad (3)$$

$$R = \frac{T_p}{T_p + F_N} \quad (4)$$

$$AP = \int_0^1 P(R) dR \quad (5)$$

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{T_p}{F_N + F_p + T_p} \quad (6)$$

$$mAP = \frac{1}{C} \sum_j^c AP_j \quad (7)$$

式中: T_p 为正却预测的缺陷数; F_p 为错误预测的缺陷数; F_N 为未被预测的缺陷数; C 为缺陷种类数, AP_j 表示第 j 类缺陷的 AP 值。

mIoU 量化了目标检测中预测框与真实框的空间匹配程度,其值为两者重叠面积占它们总面积的比例,是衡量检测框定位精度的标准。浮点计算量用于衡量模型的计算复杂度和计算资源的需求,表示模型的计算强度。较低的浮点计算量和参数计数通常对应于较快的速度。

2.4 模型对比实验

为了验证改进后的 YOLOv8n 模型的检测性能优势,将改进模型与近年来目标检测中的 SOTA 模型进行对比验证,其中包括 YOLOv5、YOLOv8、YOLOv11、Faster-RCNN^[22] 和 RT-DETR^[23] 等主流检测模型,对比实验在相同的数据集和实验环境下进行,训练参数均相同。表 2 为不同模型比较的实验结果。

表 2 模型对比实验结果

Table 2 Models comparison experiment results

模型	Params/($\times 10^6$)	P/%	R/%	mIoU/%	mAP@0.5/%	计算量/GFLOPs
YOLOv5n	1.76	66.5	84.0	49.4	54.6	4.2
YOLOv8n	3.01	90.3	69.7	56.9	61.2	8.2
YOLOv8s	11.3	89.8	66.1	55.2	60.6	28.7
YOLOv11n	2.59	91.4	63.3	56.1	59.4	6.4
Faster-RCNN	136.57	50.5	53.1	47.1	50.3	368.6
RT-DETR	32.8	69.6	56.7	57.9	59.4	100.9
本文	3.07	94.9	73.1	60.7	66.7	8.1

从表 2 可以看出,在单阶段检测器中 SOTA 模型中,改进的模型相较于 YOLOv5、YOLOv11 而言,平均检测精确度 (mAP) 提高了 12.1% 和 7.3%;与双阶段的 Faster-RCNN 相比,mAP 提高了 16.4%;RT-DETR 作为结合了 Transformer 和 DETR 两种检测框架的端到端的检测模型,在检测钻探内壁缺陷时,mAP 仅为 59.4%,并且计算需求过大,难以在部署在实际场景中。而 YOLOv8n 的 mAP 为 61.2%,相较于其他检测模型精度更高;YOLOv8s 的网络结构更深,参数更多,但 mAP 值却比 YOLOv8n 降低了 0.06%。改进后模型与 YOLOv8n 相比,虽然参数量提升了 0.06×10^6 ,但模型检测精度提升 5.5%,同时 mIoU 值相较于原模型也提升了 3.8%,但计算需求却比 YOLOv8n 降低 0.1 GFLOPs,证明提出的改进模型能够在提高检测性能的同时,降低对计算资源的需求,能够兼顾检测精度和实时检测性能,满足钻孔隧道缺陷检测任务的需求。

为了强调本文提出的注意力模型用于检测隧道钻孔图像数据集的准确性,在 YOLOv8n 模型中分别加入现阶

段较为流行的注意力模块与本文提出的 CSCM 注意力模块进行对比验证。如表 3 所示。

表 3 YOLOv8n 模型融合不同注意力实验结果

Table 3 Baseline add attention models experimental results

模型	Baseline	Params/($\times 10^6$)	mAP@0.5/%
		3.01	61.2
CBAM		3.08	63.1
CA	YOLOv8n	3.02	63.8
EMA		3.02	63.5
CSCM		3.07	64.7

分别以未做处理的 YOLOv8n 模型,和在主干部分分别加入 CBAM、CA、EMA^[19] 和本文提出的 CSCM 注意力模块进行比较,对比数据集与参数设置均一致。表 3 结果表明,注意力机制可以有效增强 YOLOv8n 模型对钻孔围岩缺陷的检测精度,但不同的注意力机制作用方式不同,其对模型性能提升效果也不同。CBAM 模块在参数量增加最高的情况下,模型检测精度只提升 1.9%,而

CA、EMA 虽参数量增加最小,但模型的检测精度分别只提升 2.6%、2.3%。CSCM 模块相比原模型提升 3.5%,证明可以在不显著增加参数量的情况提升模型的检测性能。

2.5 消融实验

在消融分析中,为了验证各改进点是如何影响模型整体性能的,并验证改进 YOLOv8n 模型的有效性。设计了以下两组实验。

首先,为了探究各改进点在不同位置对模型整体性能的影响,确定最佳的替换位置,设置了以下两组消融实验,通过对不同部分引入不同模块分别探究其性能表现如何。验证结果如表 4 所示。在 YOLOv8 模型中加入 CSCM 注意力机制模块;将原模型中 C2f 模块替换为改进的幻影卷积 C2f_G 模块,分别将两个模块添加到 Backbone 和 Neck 网络中。在 Backbone 部分添加 CSCM 注意力机制相较于其他部分,模型性能提升幅度更大;C2f_G 模块不仅在提升模型性能时,也通过卷积层策略

减少了模型参数量,但其在 Neck 部分中表现好于在 Backbone 部分表现。

表 4 模块位置实验结果

Table 4 Module position experiment results

模型	Backbone	Neck	mAP@0.5/%	计算量/GFLOPs
CSCM	✓		64.7	8.3
		✓	63.6	8.3
	✓	✓	63.0	8.4
C2f_G	✓		61.7	8.2
		✓	62.4	7.8
	✓	✓	62.1	7.7

其次,为了验证各改进点对模型整体性能的影响,设置了 8 组消融实验,通过逐步引入 CSCM 注意力机制模块、快速空间金字塔池化卷积 SPPFC 模块和 C2f_G 模块,分析每个改进点单独和相互组合后对模型整体性能的影响。实验结果如表 5 所示。

表 5 消融实验

Table 5 Ablation experiment results

序号	CSCM	SPPFC	C2f_G	P/%	R/%	Params/($\times 10^6$)	mAP@0.5/%	计算量/GFLOPs
1				90.3	69.7	3.01	61.2	8.2
2	✓			92.3	71.3	3.07	64.7	8.3
3		✓		92.1	69.3	3.16	62.9	8.4
4			✓	91.7	69.1	2.85	62.4	7.8
5	✓	✓		92.5	70.8	3.22	65.1	8.5
6	✓		✓	91.4	72.4	2.92	65.6	7.9
7		✓	✓	92.7	69.3	3.00	63.7	8.1
8	✓	✓	✓	94.9	73.1	3.07	66.7	8.1

从表 5 结果可以看出,添加 CSCM 注意力机制后,模型的 mAP 提升了 3.1%,表明 CSCM 模块有效的增强了模型的检测性能。在隧道超前钻探内壁缺陷检测任务中,各缺陷形态差异较大,同时背景信息等杂乱,要求模型需要针对不同特征对特征图中的显著区域更为关注,同时抑制了背景等不相关信息,CSCM 模块通过通道分组建模与空间双分支融合特征实现了模型对特征的有效关注。单独添加 SPPFC 模块,mAP 值相较于原模型增加 1%,表明空间金字塔池化卷积在内壁缺陷检测任务中多尺度特征提取更加有效,增强模型对不同尺寸目标的检测能力。添加 C2f_G 模块时,mAP 值提升 1.2%,并且参数量与计算量均有所下降,说明该模块在检测任务中不仅有效增强了模型的多尺度特征提取能力,并且通过通道拆分优化了模型参数量,验证了 C2f_G 的有效性和轻量化。

在融合 CSCM 模块和 SPPFC 模块后,模型 mAP 值提升了 3.5%,也证明了两个模块的相互作用,增强了模型对多尺度特征的关注度和提取能力,并不会影响模型检

测性能,进一步提升了模型的检测能力。

同时引入 CSCM 注意力模块、SPPFC 模块和 C2f_G 模块后的模型,与基准模型相比,mAP 提升了 5.5%,模型性能达到最高,同时模型参数量与计算量相较于原模型,并未有过大提升,维持在轻量化水平,也证明了改进方法对隧道超前钻探内壁缺陷检测任务的有效性。

为了更直观的展示改进后模型的实际性能,通过对比 YOLOv8 原模型检测效果和改进后模型检测效果验证改进模型的性能表现如何。检测效果如图 7 所示。

从图 7 可以看出,改进后的 YOLOv8n 算法对每类目标的检测效果均有提升,平均检测置信度也提高 20%。检测框定位也更贴近类别边界。检测效果的提升表明了改进后的 YOLOv8n 算法模型在隧道超前钻探围岩缺陷检测任务上的表现更加优异。

3 结论

本文针对隧道超前钻探围岩缺陷检测任务提出了基

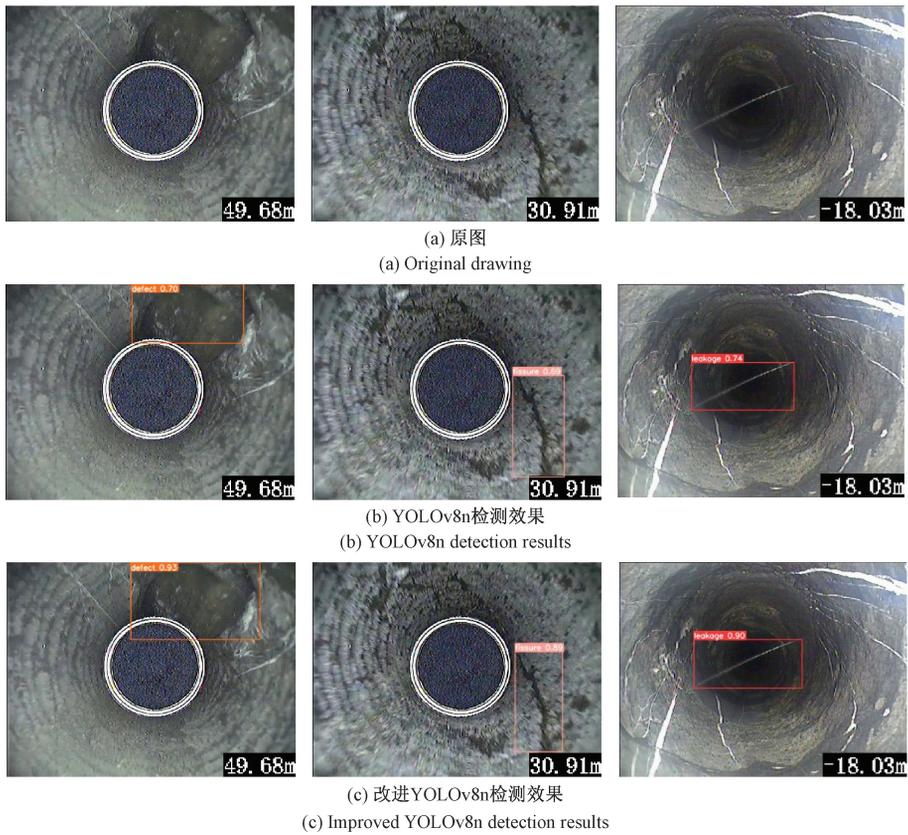


图 7 检测效果对比

Fig. 7 Comparison of detection results

于改进的 YOLOv8n 检测模型的缺陷检测算法,旨在解决超前钻探围岩缺陷尺度差异大,检测类别单一的问题,这有助于对地质超前预报做出更加客观的判断。针对钻探内壁缺陷特征提取困难的问题,基于坐标注意力机制设计了 CSCM 注意力模块,增强模型对重点特征的关注度,增强模型的特征提取能力;其次,为解决多尺度特征难以定位提取的问题,改进快速空间金字塔池化模块,通过加入标准卷积提炼目标局部特征,有效的提升模型的多尺度特征定位提取能力;为强化 Neck 部分中多尺度特征融合能力,利用幻影卷积和残差连接连接机制,融合多尺度语义信息,在提升模型性能的同时也减小模型参数。实验结果表明,改进后的算法模型,在自制的钻探围岩缺陷数据集上的检测精度达到了 66.7%,高于改进前的算法以及其他主流检测模型,同时参数量相较于原模型,仅增加 0.06×10^6 ,适用于隧道超前钻探围岩缺陷检测任务中。未来的研究需要进一步优化模型结构。此外,通过不同的成像仪器,采集图像扩展数据集,有助于提升模型的泛化能力。

参考文献

[1] 郑程程,贺鹏,王刚,等. 隧道裂隙岩体结构信息译解与危石垮塌空间展布规律研究[J]. 岩石力学与工程

学报,2022,41(3):515-532.

ZHENG CH CH, HE P, WANG G, et al. Structure information interpretation of fractured rock mass and spatial distribution law of dangerous rock collapse in tunnels [J]. Chinese Journal of Rock Mechanics and Engineering, 2022,41(3):515-532.

[2] XING Y, KULATILAKE W P H S, SANDBAK L A. Investigation of rock mass stability around the tunnels in an underground mine in USA using three-dimensional numerical modeling [J]. Rock Mechanics and Rock Engineering, 2018,51:579-597.

[3] 孙斌. 综合超前地质预报技术在隧道断层破碎带中的应用[J]. 江西建材,2023(1):139-140,147.

SUN B. Application of comprehensive advance geological prediction technology in tunnel fault fracture zone prediction [J]. Jiangxi Building Materials, 2023(1):139-140,147.

[4] 黄亚斌. 岩溶隧道超前钻探孔内成像施工技术研究[J]. 建筑技术开发,2024,51(2):65-67.

HUANG Y B. Research on construction technology of in-hole imaging in karst tunnel over-drilling [J]. Building Technology Development, 2024,51(2):65-67.

- [5] 黄振宁,赵永贵,许志亮,等. 基于判别式深度置信网络的智能电缆隧道缺陷检测技术研究[J]. 电子设计工程, 2022,30(20):103-107.
HUANG ZH N, ZHAO Y G, XU ZH L, et al. Fault detection technology for smart cable tunnel based on discriminant deep belief network[J]. *Electronic Design Engineering*, 2022,30(20):103-107.
- [6] CHENG J, XIONG W, CHEN W, et al. Pixel-level crack detection using U-net [C]. 2018 IEEE Region 10 Conference. New York: IEEE Press, 2018:462-466.
- [7] 房昱纬,吴振君,盛谦,等. 基于超前钻探测试的隧道地层智能识别方法[J]. 岩土力学, 2020, 41(7):2494-2503.
FANG Y W, WU ZH J, SHENG Q, et al. Intelligent recognition of tunnel stratum based on advanced drilling tests[J]. *Rock and Soil Mechanics*, 2020,41(7):2494-2503.
- [8] CHEN J Y, ZHOU M L, HUANG H W, et al. Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning [J]. *International Journal of Rock and Mining Sciences*, 2021, 142:104745.
- [9] ATTARD L, DEBONO C J, VALENTINO G, et al. Automatic crack detection using Mask R-CNN [C]. 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA), 2019:152-157.
- [10] DUAN S Q, ZHANG M H, QIU S L, et al. Tunnel lining crack detection model based on improved YOLOv5 [J]. *Tunnelling and Underground Space Technology*, 2024, 147:105713.
- [11] 朱磊,李东彪,闫星志,等. 基于改进 Mask R-CNN 深度学习算法的隧道裂缝智能检测方法[J]. 图学学报, 2023, 44(1):177-183.
ZHU L, LI D B, YAN X ZH, et al. Intelligent detection method of tunnel cracks based on improved Mask R-CNN deep learning algorithm[J]. *Journal of Graphics*, 2023, 44(1):177-183.
- [12] 彭鸿瑞,杨桂华. 基于改进 YOLOv8 的 SOP 芯片缺陷检测研究[J]. 电子测量技术, 2023, 47(12):71-82.
PENG H R, YANG G H. Research on defect detection of SOP chip based on improved YOLOv8 [J]. *Electronic Measurement Technology*, 2023,47(12):71-82.
- [13] 方涛涛,王池社,王洁,等. 基于 YOLOv8n 的探地雷达图像管线定位方法[J]. 国外电子测量技术, 2023, 42(11):170-177.
FANG T T, WANG CH SH, WANG J, et al. Ground penetrating radar image pipeline location based on YOLOv8n [J]. *Foreign Electronic Measurement Technology*, 2023, 42(11):170-177.
- [14] 曾勇杰,范必双,杨涯文,等. 改进 YOLOv8 算法在风机叶片缺陷检测上的应用[J]. 电子测量与仪器学报, 2024,38(8):26-35.
ZHENG Y J, FAN B SH, YANG Y W, et al. YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications [J]. *Journal of Electronic Measurement and Instrumentation*, 2024,38(8):26-35.
- [15] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design [C]. *Conference on Computer Vision and Pattern Recognition*, 2021.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. *Proceedings of the European Conference on Computer Vision*, 2018:3-19.
- [17] SAINING X, GIRSHICK R, DOLLAR P. Aggregated residual transformations for deep neural networks [C]. *Conference on Computer Vision and Pattern Recognition*, 2017.
- [18] ZAGORUYKO S. KOMODAKIS N. Paying more attention to attention: Improving the performance of convolutional neural networks via attention transfer [C]. *Conference on Computer Vision and Pattern Recognition*, 2017.
- [19] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning [C]. *IEEE International Conference Acoustics, Speech and Signal on Processing*, 2023:1-5.
- [20] 郭志聪,张雷. 基于改进 YOLOv8 的低照度煤矿传送带异物识别算法[J]. 电子测量技术, 2024, 47(21):188-196.
GUO ZH C, ZHANG L. Foreign object recognition algorithm of low-light coal mine conveyor belt based on improved YOLOv8 [J]. *Electronic Measurement Technology*, 2024,47(21):188-196.
- [21] 童小钟,魏俊宇,苏绍璟,等. 融合注意力和多尺度特征的典型水面小目标检测[J]. 仪器仪表学报, 2023, 44(1):212-222.
TONG X ZH, WEI J Y, SU SH J, et al. Typical small target detection on water surfaces fusing attention and multi-scale features [J]. *Chinese Journal of Scientific Instrument*, 2023,44(1):212-222.
- [22] REN SH O, HE KM, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39 (6): 1137-1149.
- [23] 刘亚蒙,赵友全,孙振涛,等. 构建改进 RT-DETR 算法检测隐形眼镜环状波纹缺陷[J]. 电子测量与仪器学

报, 2024, 38(5): 1-9.

LIU Y M, ZHAO Y Q, SUN ZH T, et al. Constructing an enhanced RT-DETR algorithm for detecting annular ripple defects in contact lenses[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(5): 1-9.

作者简介



郭乙龙, 2022 年于四川大学锦江学院获得学士学位, 现为西南科技大学硕士研究生, 主要研究方向为机器视觉、目标检测。

E-mail: 1536427800@qq.com

Guo Yilong received his B. Sc. degree from Sichuan University Jinjiang College in 2022. Now he is a M. Sc. candidate at Southwest University of Science and Technology. His main research interests include machine vision and object detection.



陈春梅(通信作者), 2000 年于西南科技大学获得学士学位, 2010 年于西南科技大学获得硕士学位, 2020 年于中国工程物理研究院获得博士学位, 现为西南科技大学副教授, 主要研究方向为人工智能和机器视觉。

E-mail: ccm@mails.swust.edu.cn

Chen Chunmei (Corresponding author) received her B. Sc. degree from Southwest University of Science and Technology in 2000, M. Sc. degree from Southwest University of Science and Technology in 2010 and Ph. D. degree from China Academy of Engineering Physics in 2020, respectively. Now she is an associate professor in Southwest University of Science and Technology. Her main research interests include artificial intelligence and computer vision.