

引用格式:陈逵,赵亚伟,王光明,等.基于SSG-YOLOv8n模型的砖砌墙体裂缝形态识别方法[J].工业建筑,2025,55(7):152-161. CHEN Kui,ZHAO Yawei,WANG Guangming,et al. A Method for Crack Pattern Recognition of Brick Walls Based on the SSG-YOLOv8n Model[J]. Industrial Construction,2025,55(7):152-161 (in Chinese). DOI:10.3724/j.gybzG25051205

# 基于SSG-YOLOv8n模型的砖砌墙体裂缝形态识别方法\*

陈逵<sup>1,2</sup> 赵亚伟<sup>1</sup> 王光明<sup>3</sup> 梁建国<sup>1</sup>

(1.长沙理工大学土木与环境工程学院,长沙 410000;2.长沙理工大学桥梁与建筑绿色建筑及维护湖南省重点实验室,长沙 410000;3.四川宏图都市设计咨询集团有限公司内蒙古设计咨询分公司,内蒙古鄂尔多斯 017200)

**摘要** 砖砌墙体裂缝的形成与发展是一个渐进过程,管理单位若在日常排查中忽视其动态变化,极易对人民生命财产安全构成威胁。针对传统人工检测方法存在的高风险、低效率、高成本等问题,提出一种改进的SSG-YOLOv8n模型。该模型在YOLOv8n基础架构上,通过引入SPD Conv卷积模块、增设小目标检测头并嵌入SAFM注意力机制模块,有效提升砖砌墙体裂缝形态的识别检测精度。试验数据显示,改进模型的mAP@50指标较原始YOLOv8n模型提升4.3%。为平衡检测精度提升与模型复杂度控制,进一步集成GhostNet轻量化模块,在保持精度优势的同时,显著降低浮点运算量、参数量及模型尺寸。试验结果表明:改进后的模型兼具检测精度与计算效率优势。

**关键词** 砖砌墙体裂缝;裂缝形态识别;YOLOv8;深度学习;智能检测

## A Method for Crack Pattern Recognition of Brick Walls Based on the SSG-YOLOv8n Model

CHEN Kui<sup>1,2</sup> ZHAO Yawei<sup>1</sup> WANG Guangming<sup>3</sup> LIANG Jianguo<sup>1</sup>

(1. School of Civil and Environmental Engineering, Changsha University of Science and Technology, Changsha 410000, China; 2. Hunan Provincial Key Laboratory of Green Construction and Maintenance of Bridges and Buildings, Changsha University of Science and Technology, Changsha 410000, China; 3. Sichuan Hongtu Urban Design & Consulting Group Limited Inner Mongolia Design & Consulting Branch Company, Ordos 017200, China)

**Abstract:** The formation and development of cracks in brick walls is a gradual process. If the management unit ignores dynamic changes during daily inspections, it is highly likely to pose a threat to the safety of people's lives and property. To address the problems of high risk, low efficiency, and high cost existing in traditional manual detection methods, this paper proposes an improved SSG-YOLOv8n model. Based on the basic architecture of YOLOv8n, this model significantly enhances the recognition and detection accuracy of the crack patterns of brick walls by introducing the SPD Conv convolution module, adding a small target detection head, and embedding the SAFM attention mechanism module. The experimental data showed that the mAP@50 index of the improved model was 4.3% higher than that of the original YOLOv8n model. To balance detection accuracy improvement and model complexity control, the GhostNet lightweight module was further integrated. While maintaining the accuracy advantage, it significantly reduced floating-point operations, parameter count, and model size. The experimental results indicated that the improved model achieved both high detection accuracy and computational efficiency, providing important technical support for automated crack pattern detection in brick walls.

\*长沙理工大学土木工程优势特色重点学科创新性项目(16ZDXK07)。

第一作者:陈逵,博士,硕士生导师,主要从事工程检测与加固改造。

通信作者:赵亚伟,2356096317@qq.com。

收稿日期:2025-05-12

**Keywords:** cracks in brick walls; crack pattern recognition; YOLOv8; deep learning; intelligent detection

随着我国经济持续发展与城镇化进程加速,住房需求呈现显著增长态势。统计数据显示,全国房屋竣工面积从1998年的17566.6万 $\text{m}^2$ 增至2023年的101999.09万 $\text{m}^2$ <sup>[1]</sup>。砖砌体因具备优异的隔热性能、较高抗压强度、材料易得性、坚固耐用性及经济成本优势<sup>[2]</sup>,成为城乡建筑墙体材料的主要选择。然而受施工不规范、材料性能不达标及长期使用等因素影响,大量砖砌体墙体出现开裂现象。墙体裂缝的形成是一个渐进发展过程,若在房屋服役期间未能及时监测其发育状态,极易对生命财产安全构成潜在威胁<sup>[3]</sup>。当前我国建筑墙体裂缝检测仍以人工巡检为主,该方法存在作业风险高、效率低下及成本高昂等固有缺陷<sup>[4]</sup>。深度学习技术的兴起为解决这一工程检测难题提供了科学可行的路径。

在过去的几年里,深度学习驱动的目标检测模型在计算机视觉领域展现出卓越的技术优势<sup>[5]</sup>。在此背景下,裂缝检测作为建筑安全评估的核心环节,吸引众多学者将深度学习模型引入该领域,有效提升裂缝识别的效率与准确性。例如,Thohari等<sup>[6]</sup>提出将深度学习特征提取与机器学习算法相结合的方法,不仅提升了检测精度,还实现了嵌入式设备部署,为建筑裂缝的检测提供了有效方案。Chen等<sup>[7]</sup>针对建筑外立面裂缝检测问题,提出基于深度学习的解决方案,提高了建筑裂缝检测的效率。Zhu等<sup>[8]</sup>改进了SSD模型用于混凝土裂缝检测,有效推动了深度学习在建筑安全评估领域的工程应用。

YOLO(You Only Look Once)作为深度学习领域极具开创性与影响力的目标检测模型,自2016年由Joseph Redmon等首次提出以来,历经多次迭代优化。目前YOLO模型普遍运用于道路、桥梁以及管道缺陷的检测。例如,Lan等<sup>[9]</sup>针对传统路面裂缝检测实时性差、精度低的问题,提出了YOLOv5s-attention模型,对道路裂缝形态图像的识别进行了出色的处理;Yao等<sup>[10]</sup>改进了YOLOv8模型用于道路目标检测,优化了模型参数并提高了检测精度;Liu等<sup>[11]</sup>提出一种结合深度卷积生成对抗网络(DCGAN)和YOLOv5的桥梁裂缝快速检测方法,提高了大型混凝土结构裂缝检测效率;Li等<sup>[12]</sup>改进了YOLOv8模型用于混凝土桥梁表面缺陷检测,提高

了坐标定位的准确性,降低了模型的复杂程度;凌同华等<sup>[13]</sup>改进YOLOv5模型,提出了YOLO-Pipe检测模型,实现了对排水管道缺陷更高精度的实时检测。上述模型的改进与优化,提高了检测的效率,节约了检测的成本。

砖砌墙体裂缝的形态学特征是评估建筑结构损伤程度的关键依据。尽管深度学习模型凭借强大的特征表征能力提升了检测效率,但其在复杂场景下的抗干扰能力不足,检测精度仍存在优化空间;同时,模型参数量过大导致计算资源消耗高,进一步限制了工程应用推广。YOLO系列模型以轻量化架构与高效检测性能的优势,为砖砌墙体裂缝形态识别提供了理想技术路径。已有研究表明,该模型在道路、桥梁及管道缺陷检测等领域展现出复杂环境适应性,但其在实际工程应用中仍面临多重技术瓶颈,具体表现为:1)裂缝作为典型小目标,在图像中占比小且语义特征模糊,易导致模型漏检;2)墙体周边复杂背景物件(如生活用品)的不规则轮廓与多样纹理形成强视觉噪声,增加特征判别难度;3)工程现场依赖便携式移动设备部署,有限算力资源对模型轻量化提出迫切需求。

针对上述关键问题,本文提出一种改进的SSG-YOLOv8n检测模型:首先在YOLOv8n基础架构上依次引入SPD Conv卷积模块、小目标检测头及SAFM注意力机制,通过增强特征提取能力与多尺度目标感知能力提升检测精度;继而集成GhostNet轻量化模块,在保证检测精度的同时显著降低浮点运算量、参数量及模型尺寸,形成精度与效率均衡的优化方案。

## 1 数据集构建

### 1.1 图像采集与标注

在深度学习模型训练与验证过程中,高质量的大规模样本数据是保障模型有效性与准确性的核心要素。然而当前针对砖砌墙体裂缝形态研究的公开可用标准化数据集相对匮乏,严重制约了相关领域的模型开发与优化工作。基于此,本文依托长沙市某小区检测项目及其他工程实践,系统采集并筛选典型裂缝形态图像,构建了适用于砖砌墙体裂缝形态研究的专用数据集。研究团队在实际检测

中累计获取 1273 张原始图像,针对当前学术界与工程领域尚未形成统一的裂缝形态量化分类标准的现状<sup>[14]</sup>,提出基于倾角的裂缝分类方法:将裂缝按倾角划分为 3 类,即  $0^{\circ}\sim 20^{\circ}$  定义为水平裂缝,  $20^{\circ}\sim$

$70^{\circ}$  为斜裂缝,  $70^{\circ}\sim 90^{\circ}$  为竖向裂缝。该分类体系紧密结合工程实际需求,所选 3 种典型裂缝形态可为建筑结构健康评估提供关键形态学依据,部分代表性裂缝图像如图 1 所示。

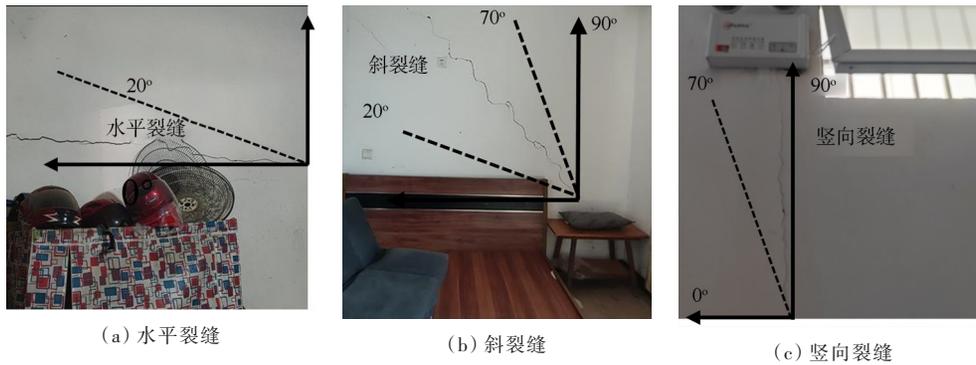


图 1 裂缝样本  
Fig. 1 Crack samples

本文使用 MakeSense (<https://www.makesense.ai/>) 网页对裂缝进行标注,通过在图像上画出矩形框来确定裂缝的范围以及裂缝形态,涵盖水平裂缝(C1)、斜裂缝(C2)以及竖向裂缝(C3)3种墙体常见的裂缝形态,获得了包含裂缝形态信息的TXT标注文件。

### 1.2 数据增强

在深度学习的过程中,训练数据样本的质量和数量对于模型的性能有着决定性的影响。通过数据增强技术,可以有效地丰富数据集样本,使模型在运行当中能发挥更好的效果。本文考虑到砖砌墙体裂缝形态的特征,使用了翻转、缩放、裁剪和色彩变换等数据增强操作,有效拓展了数据集,最终获得 4189 张裂缝形态图像。

将上述图像按照 8:1:1 的比例划分为训练集、验证集和测试集,分别包含了 3351、419、419 张图像。其中训练集中水平裂缝、斜裂缝和竖向裂缝数量分别为 1762、1518、1018 条,验证集中水平裂缝、斜裂缝和竖向裂缝数量分别为 227、212、105 条,测试集中水平裂缝、斜裂缝和竖向裂缝数量分别为 230、118、189 条。

## 2 研究方法

### 2.1 YOLOv8 模型

YOLOv8 是 Ultralytics 公司开发的一种深度学习网络模型<sup>[15]</sup>。YOLOv8 在精度和速度方面优于以前的型号,比如 YOLOv5 等。官网有 5 种配置,分别

是 n、s、m、l 和 x,本文综合考虑了精度和参数量,选用了参数量最小且精度表现良好的 YOLOv8n 模型。它的网络架构由 3 个不同的组件构成:Backbone、Neck 和 Head<sup>[10]</sup>。Backbone 模块是由 CBS、C2f、SPFP 三种模块组成,融合了 CSP 模块的设计理念,从输入图像中执行特征提取;Neck 模块执行特征融合处理,使模块能够获得 3 种不同尺寸的特征,与 YOLO5 不同的是,它删除了上采样阶段的卷积,并且将其中的 C3 模块替换为了 C2f 模块;Head 模块检测 3 种尺寸的特征并输出检测结果。

### 2.2 改进的 YOLOv8n 模型

在实际检测场景中,砖砌墙体裂缝检测面临多重技术挑战:1)作为典型小目标,裂缝在图像中像素占比低且边缘模糊,导致特征表征不充分;2)墙体周边复杂背景(如生活用品)的不规则轮廓与多样纹理形成强视觉噪声,严重干扰裂缝特征的有效提取;3)传统网络结构优化方法易导致参数量激增,难以满足移动终端对模型轻量化与实时检测的双重需求。这些问题直接造成原始 YOLOv8n 模型在实际应用中出现漏检率高、误检频繁及计算效率低下等现象。

针对上述技术瓶颈,提出一种融合多模块改进的 SSG-YOLOv8n 检测模型:首先,在骨干网络中嵌入 SPD Conv 卷积模块并增设小目标检测头,通过增强局部特征提取能力与多尺度特征融合策略,有效解决小目标特征模糊导致的检测失效问题;其次,在特征融合阶段引入 SAFM 注意力机制模块,通过

自适应抑制背景噪声干扰,显著提升模型对裂缝细节特征的捕捉能力;最后,针对模块叠加带来的参数冗余问题,采用GhostNet轻量化架构对模型进行

优化,在保证检测精度的同时大幅降低计算复杂度。改进后的网络结构如图2所示,红色标注区域为本文提出的关键改进模块。

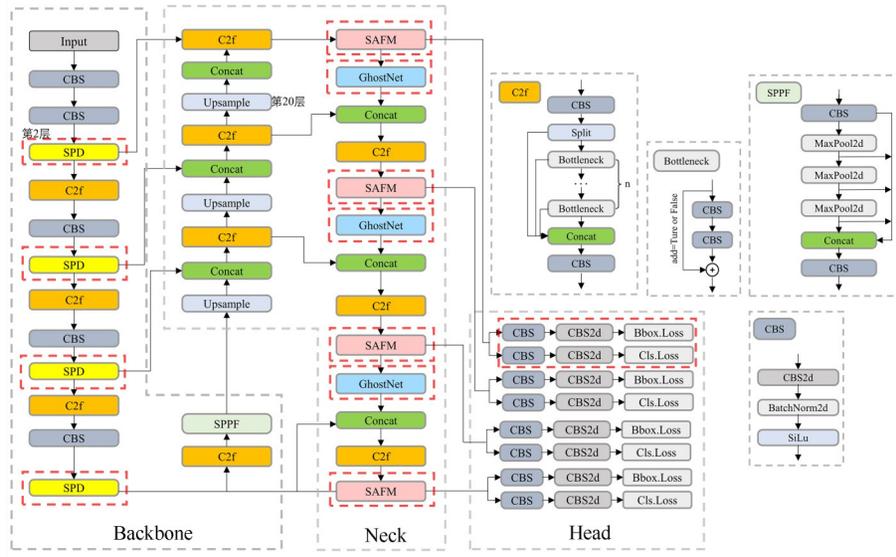


图2 SSG-YOLOv8n模型的结构示意

Fig. 2 Structural diagram of the SSG-YOLOv8n model

### 2.2.1 SPD Conv 卷积模块与小目标检测头

卷积神经网络(CNN)在图像分类和目标检测等领域中取得了巨大的成功。然而实际检测过程中,因图像采集快速,且裂缝在图像中占比较少,导致图像模糊,从而在卷积过程中获得较少的有用信息。传统上,大小目标的检测都被看成一个多尺度的目标检测问题,现有的改进此类问题的办法一般都是使用跨行卷积和最大池化,利用这些方法可能导致细粒度信息的丢失,压缩了有限的有效信息,从而进一步导致检测性能的降低<sup>[15]</sup>。

为了解决目标模糊方面的局限性,本文引入了SPD Conv 模块<sup>[16]</sup>,旨在提高网络的检测性能。SPD Conv 模块由空间到深度层与非跨步卷积层有机结合而成,其核心功能在于实现特征图的有效下采样,同时维持通道维度信息的稳定性。当输入图像数据特征 $X$ 的维度为 $S \times S \times C_1$ 时,该模块通过一系列精细化处理操作,可输出更为细致的子特征序列,计算公式如式(1)所示。

$$\begin{aligned} f_{0,0} &= X [0 : S : scale, 0 : S : scale] \\ f_{1,0} &= X [1 : S : scale, 0 : S : scale] \\ f_{scale-1,0} &= X [scale - 1 : S : scale, 0 : S : scale] \\ f_{0,1} &= X [0 : S : scale, 1 : S : scale] \\ f_{scale-1,1} &= X [scale - 1 : S : scale, 1 : S : scale] \end{aligned}$$

$$\begin{aligned} &\vdots \\ f_{0,scale-1} &= X [0 : S : scale, scale - 1 : S : scale] \\ f_{scale-1,scale-1} &= X [scale - 1 : S : scale, scale - 1 : S : scale] \end{aligned} \quad (1)$$

为了方便读者理解SPD Conv的处理流程,本文以 $scale=2$ 举例说明,处理的流程见图3。当输入特征图 $X$ 的维度为 $S \times S \times C_1$ 时,经过式(1)的处理,得到了4个子特征图,分别为 $f_{0,0}, f_{1,0}, f_{0,1}, f_{1,1}$ ,此时每个子特征图维度为 $(\frac{S}{2}, \frac{S}{2}, C_1)$ ,输入特征图 $X$ 被下采样为原来的一半。

之后,沿着通道维度按顺序将4个子特征映射进行连接,如图3(d)所示,此时特征图维度为 $(\frac{S}{2}, \frac{S}{2}, 4C_1)$ 。然后为其配备一个无跨步卷积层对连接后的特征图进行处理,该卷积层配备 $C_2$ 滤波器,Stride设定为1, $C_2$ 的维度应当小于 $C_1$ 的维度,得到了如图3(e)所示的特征图。此时通道数变为 $C_2$ ,高和宽被压缩到 $\frac{S}{scale}$ 。

在目标检测任务中,对于裂缝等小型目标物的检测精度提升是一个关键问题。内置小型物体检测头为解决该问题提供了有效的途径<sup>[17]</sup>。在构建小目标检测头时,通常是将不同尺度的特征进行拼接,随

后实施下采样操作。这种方式较为直接,仅仅是简单地  
将多尺度特征整合并进行下采样,全程无需开  
展任何额外的复杂处理,便能在一定程度上增强对  
小型目标物的检测能力。

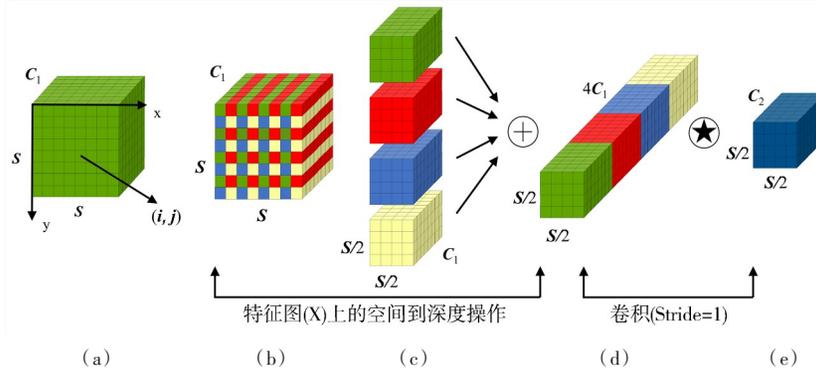


图3 SPD Conv 卷积说明图(scale = 2时)  
Fig. 3 Illustration of SPD Conv convolution ( scale = 2)

本文通过将小目标检测头与SPD Conv卷积模块集成来重新设计网络,如图2所示。第20层的分支被上采样后,采用拼接操作与第2层的特征图进行融合。最后合并来自两个分支的相同大小的特征图,创建一个新的小目标检测头。这个新的检测头与其他3个检测头一起形成一个四头检测结构。虽然这些改进使模型的计算量有所增加,但模型可以捕捉到更小的特征,从而可以大大提高模型的准确性,充分满足裂缝小目标检测任务的实际需求。

### 2.2.2 SAFM注意力机制模块

当前主流注意力机制如通道注意力SENet(Squeeze-and-Excitation Network)、高效通道注意力ECA(Efficient Channel Attention)及坐标注意力CA(Coordinate Attention)等,在提升模型特征表征能力的同时存在两方面局限性:其一,这类机制的引入会导致模型参数量显著增加,加剧计算复杂度;其二,针对砖砌墙体裂缝这类小目标检测任务,传统注意力机制主要聚焦于通道或全局空间的语义加权,缺乏对小目标局部细节特征的针对性强化,难以有效抑制复杂背景噪声的干扰。鉴于此,本文针对小目标检测场景的特殊性,选择SAFM注意力机制作为优化方案,其独特的特征融合与局部细节增强策略,能够在控制参数量增长的同时,显著提升模型对小目标特征的敏感度。

SAFM注意力机制模块<sup>[18]</sup>的网络体系结构如图4所示,实现的过程是首先将输入的特征划分为4块,并将它们输送到多尺度特征生成单元(MFGU)中生成不同尺度的特征,从而使得模型可以捕捉图像中不同大小区域的特征,其中的1块进行3×3的

深度卷积处理,其他3块通过池化操作单独采样,给定输入特征 $B$ ,计算公式见式(2):

$$[B_0, B_1, B_2, B_3] = \text{Split}(B)$$

$$\hat{B}_0 = \text{DW-Conv}_{3 \times 3}(B_0)$$

$$\hat{B}_i = \uparrow_p(\text{DW-Conv}_{3 \times 3}(\downarrow_{\frac{p}{2}}(B_i))) \quad 1 \leq i \leq 3$$

式中: $\text{Split}(\cdot)$ 对应通道分割操作; $\text{DW-Conv}_{3 \times 3}(\cdot)$ 是一个3×3的深度卷积; $\uparrow_p(\cdot)$ 表示通过最近的插值快速实现特定级别的上采样特征到原始分辨率 $p$ ; $\downarrow_{\frac{p}{2}}$ 表示将输入特征池化到 $\frac{p}{2}$ 的大小。

之后将被提取到的不同特征连接到通道维度上并执行1×1卷积,使得这些特征进行融合,计算公式见式(3):

$$\hat{B} = \text{Conv}_{1 \times 1}(\text{Concat}([\hat{B}_0, \hat{B}_1, \hat{B}_2, \hat{B}_3]))$$

式中: $\text{Concat}(\cdot)$ 表示连接操作; $\text{Conv}_{1 \times 1}(\cdot)$ 表示1×1卷积。

最后通过GELU函数对其进行归一化处理,从而估计注意力图,并根据估计的注意力智能自适应地调制输入,计算公式见式(4):

$$\bar{B} = \phi(\hat{B}) \odot B$$

式中: $\phi(\cdot)$ 表示GELU函数; $\odot$ 是元素积。

### 2.2.3 GhostNet轻量化模块

传统深度卷积神经网络在图像识别任务中展现出优异性能,但其特征映射存在显著冗余问题。这一缺陷极大地限制了神经网络在移动设备上的部署。

为了有效减少传统神经深度卷积网络的冗余,本文引入了GhostNet轻量化网络<sup>[19]</sup>。它的实现过

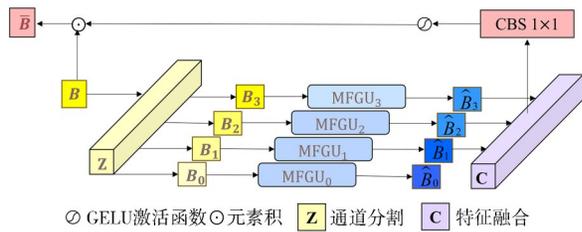


图4 SAFM注意力机制模块的网络体系结构图  
 Fig. 4 Network architecture diagram of the SAFM attention mechanism module

程见图5,假设原始的通道数是 $H \times W \times C$ ,首先在原始卷积的过程当中减少一半的通道数生成 $Y_1(H \times W \times 0.5C)$ 的特征映射;之后对上述得到的特征映射进行优化线性操作 $\Phi$ ,得到简洁有效的特征映射 $Y_2(H \times W \times 0.5C)$ ;最后沿着通道维数将得到的新映射 $Y_2$ 与第一步卷积得到的映射 $Y_1$ 进行拼接,得到完整的特征输出 $(Y_1, Y_2)$ 。

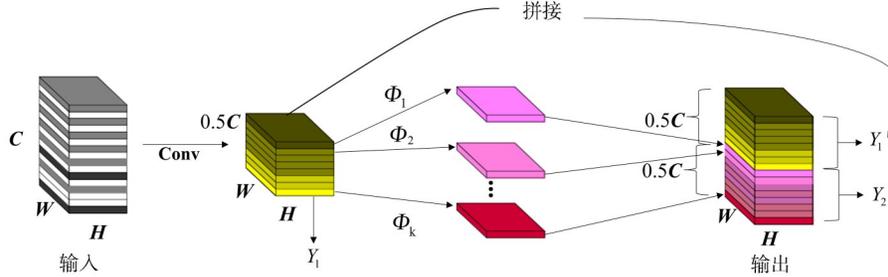


图5 GhostNet轻量化模块网络体系结构图  
 Fig. 5 Network architecture diagram of the GhostNet lightweight module

### 3 试验设计与分析

#### 3.1 试验环境

试验环境为 14 vCPU Intel(R) Xeon(R) Platinum 8362 CPU @ 2.80 GHz处理器, RTX 3090(24 GB) 显存, 45 GB 内存; Ubuntu22.04 操作系统, PyTorch 2.1.0, Cuda 12.1 和 Python 3.10。模型训练参数: 批次大小为 16, 初始学习率设为 0.01, 最终学习率为 0.0001, 优化器为 SGD, 开启 Mosaic 数据处理设置, 总迭代训练次数为 300 轮。

#### 3.2 评价指标

针对裂缝形态检测任务, 本模型采用参数量 (Parameters)、浮点运算量 (FLOPs)、模型大小 (Model size) 来评估模型轻量化程度, 并以平均精度均值 (mAP@50) 来衡量模型对砖砌墙体裂缝形态的识别精度, mAP@50 的交并比阈值取 0.5。其计算公式见式(5)。

$$AP = \int_0^1 Pr(R) dR$$

$$mAP@50 = \frac{1}{n} \sum_{i=1}^n AP_i \quad (5)$$

式中: AP 为平均精度, 其大小为 Pr-R 曲线下部分的面积; Pr 为精确度; R 为召回率; n 为类别的数量, 本文取 n=3。

#### 3.3 消融试验

为验证 YOLOv8n 模型添加的 SPD Conv 卷积模

块、小目标检测头、SAFM 注意力机制模块和 GhostNet 轻量化模块的有效性, 在自制的砖砌墙体裂缝数据集上, 以 YOLOv8n 原模型为基础, 设计消融试验, 分析模型的改进效果。试验结果如表 1 所示, 图 6 为损失曲线, 图 7 为 P-R 曲线, 图 8 为验证集在不同训练时期的 mAP@50 值。其中 A 代表 SPD Conv 卷积模块以及小目标检测头, B 代表 SAFM 注意力机制模块, C 代表 GhostNet 轻量化模块。

表 1 消融试验结果  
 Table 1 Results of ablation experiments

实验	模型	FLOPs/G	Parameters/ $10^6$	Model size/MB	mAP@50/%
1	YOLOv8n	6.9	2.7	5.4	89.9
2	YOLOv8n+A	14.7	3.1	6.2	92.8
3	YOLOv8n+A+B	15	3.2	6.4	94.2
4	YOLOv8n+A+B+C (SSG-YOLOv8n)	14.8	3.1	6.2	94.3

从图 6 中可以看出: 迭代训练次数达到 300 轮时, 4 种模型的损失曲线逐渐趋于稳定; SSG-YOLOv8n 模型在训练过程中展现出更优的损失下降表现, 有助于加快模型的收敛, 提升模型训练的效果。

从图 7 中可以看出, SSG-YOLOv8n 模型的 P-R 曲线整体处于更优位置, 表明该模型能在不同召回率下维持相对更高精确度, 有效提升了砖砌墙体裂缝形态识别检测的综合性能。

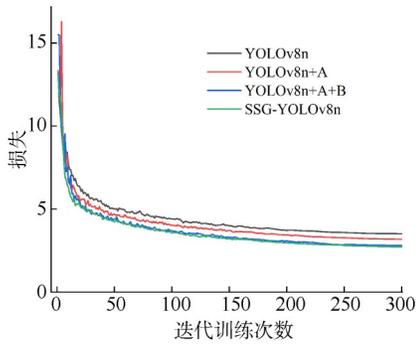


图6 损失曲线  
Fig. 6 Loss curves

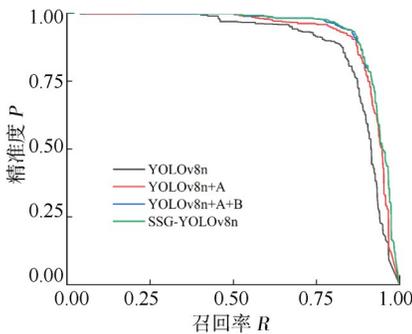


图7 P-R曲线  
Fig. 7 P-R curves

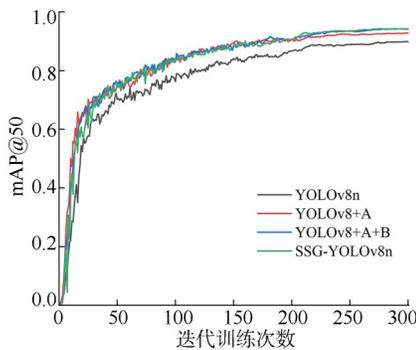


图8 不同训练时期的mAP@50的值  
Fig. 8 mAP@50 values in different training periods

从表1以及图8中可以看出,迭代训练次数达到300轮时:

1) 试验2在试验1(原模型)的基础上采用了SPD Conv卷积模块以及增加小目标检测头提高了计算精度,mAP@50指标较试验1提高了2.9%;

2) 试验3在试验2的基础上增加了SAFM注意力机制模块,从而进一步增加了模型的检测精度,mAP@50指标较试验2提高了1.4%;

3) 试验4在试验3的基础上引入了GhostNet轻量化模块,较试验3,在mAP@50提高的基础上,浮点运算量降至14.8 G,参数量减少至 $3.1 \times 10^6$ ,模型

大小减小至6.2 MB。试验4相较于试验1,mAP@50提高了4.4%,达到了94.3%。

### 3.4 对比试验

为进一步客观地验证本文提出的改进模型的性能,在自制的砖砌墙体裂缝形态数据集上以及在相同试验环境下,将SSG-YOLOv8n模型与YOLOv3 Tiny、YOLOv5n、YOLOv6n、Faster R-CNN(VGG)以及SSD(MobileNetv2)目标检测模型进行对比,结果见表2。可知:

表2 模型对比结果  
Table 2 Model comparison results

模型	FLOPs/G	Parameters/ $10^6$	Model size/MB	mAP@50/%
YOLOv3 Tiny	14.5	9.5	18.3	84.0
YOLOv5n	5.9	2.2	4.4	87.7
YOLOv6n	11.6	4.2	8.2	84.1
YOLOv8n	6.9	2.7	5.4	89.9
Faster R-CNN(VGG)	200.8	136.7	521.6	87.1
SSD(MobileNetv2)	3.1	3.8	14.5	78.5
SSG-YOLOv8n	14.8	3.1	6.2	94.3

1) SSG-YOLOv8n模型在检测精度上表现最优,mAP@50值达94.3%,较原始YOLOv8n模型(89.9%)提升4.4%,且显著高于对比的其他主流模型(均 $\geq 75%$ )。其中,相较于YOLOv3 Tiny、YOLOv5n、YOLOv6n、Faster R-CNN(VGG)和SSD(MobileNetv2),mAP@50分别提升10.3%、6.6%、10.2%、7.2%和15.8%,验证了SPD Conv卷积模块、小目标检测头及SAFM注意力机制对小目标特征提取能力的有效增强。2)在模型复杂度方面,SSG-YOLOv8n的浮点运算量为14.8 G,略高于YOLOv5n(5.9 G)和SSD(MobileNetv2)(3.1 G),但显著低于Faster R-CNN(VGG)(200.8 G);参数量为 $3.1 \times 10^6$ ,模型大小6.2 MB,均处于对比模型的中间梯队。尽管YOLOv3 Tiny的浮点运算量(14.5 G)稍低,但其参数量( $9.5 \times 10^6$ )和模型大小(18.3 MB)均高于SSG-YOLOv8n模型,且检测精度低10.3%。YOLOv5n虽在轻量化指标上表现优异,但其mAP@50较本文模型低6.6%,反映出传统模型在复杂背景下的小目标检测能力不足。3)值得注意的是,SSD(MobileNetv2)的浮点运算量最低(3.1 G),但检测精度仅78.5%,为所有对比模型中最差,表明单纯追求极低计算量会导致特征提取能力下降,难以满足裂缝检测的精度要求;而Faster R-CNN(VGG)

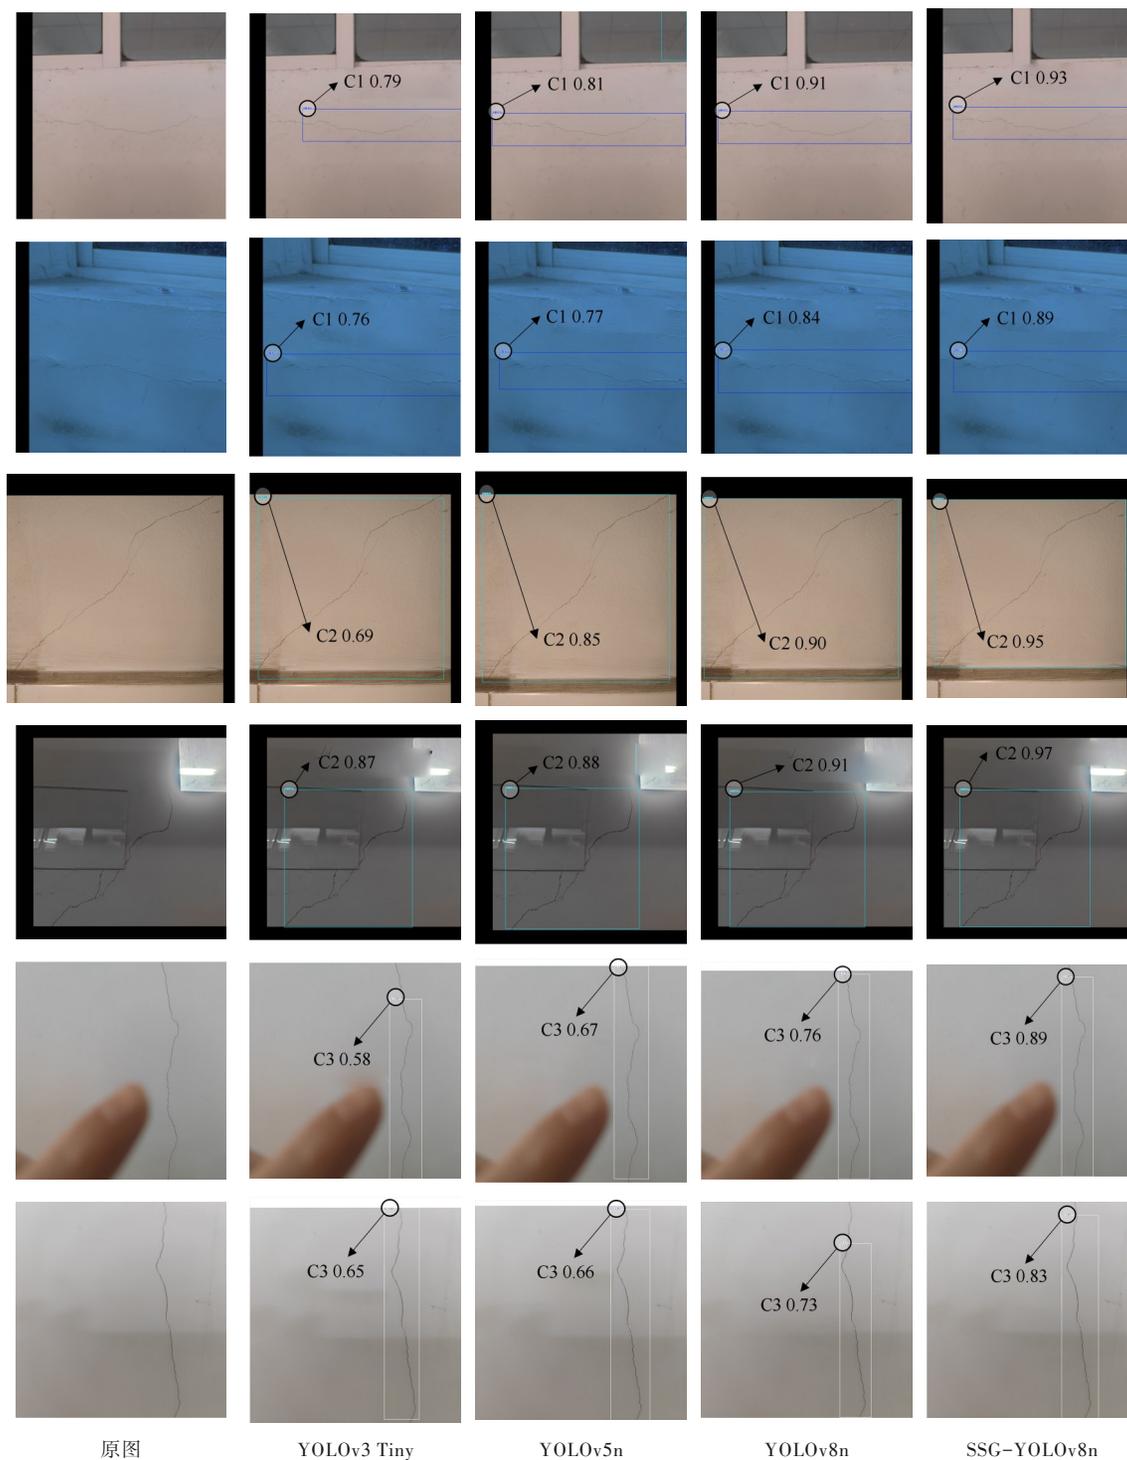


图9 砖砌墙体裂缝形态识别效果  
Fig. 9 Recognition results of crack patterns in brick walls

尽管采用复杂架构,但其浮点运算量、参数量和模型大小均为最高(分别为 200.8 G、 $136.7 \times 10^6$ 、521.6 MB),却未实现精度突破(87.1%),凸显了本文模型通过 GhostNet 轻量化模块平衡精度与效率的优越性。

综合表 2 数据对比可知,SSG-YOLOv8n 模型通

过多模块改进,在保持浮点运算量、参数量和模型大小处于中等复杂度的同时,实现了检测精度的显著提升(mAP@50 达 94.3%),有效解决了传统模型在小目标检测中精度与效率难以兼顾的问题。试验结果表明,该模型兼具高精度检测能力与工程部署适应性,为砖砌墙体裂缝形态的自动化实时检测

提供了高效可靠的技术方案。

### 3.5 效果验证

为更加直观地展示SSG-YOLOv8n模型对砖砌墙体裂缝形态识别的检测效果,选择测试集中的部分图像进行检测,效果如图9所示。可知:SSG-YOLOv8n模型可以识别出砖砌墙体裂缝形态的总体趋势以及范围;其次SSG-YOLOv8n模型对砖砌墙体裂缝形态识别检测的精度较高,普遍都达到了0.80以上,可以在日常的检测中发挥不错的效果。

## 4 结 论

本文针对砖砌墙体裂缝检测中的小目标特征模糊、复杂背景干扰及模型轻量化需求,提出一种改进的SSG-YOLOv8n检测模型,通过多模块协同优化实现了检测精度与计算效率的有效平衡,主要研究结论如下:

1)通过在YOLOv8n基础架构中引入SPD卷积模块、小目标检测头及SAFM注意力机制模块,构建多尺度特征增强与背景噪声抑制策略,有效解决了裂缝小目标特征表征不充分及复杂场景误检问题。消融试验表明,改进模型的mAP@50指标较原始YOLOv8n模型提升4.4%,达到94.3%,验证了多模块联合优化对小目标检测能力的强化作用。

2)针对模块叠加导致的参数量冗余问题,集成GhostNet轻量化架构对模型进行优化,在保持检测精度优势的同时,将浮点运算量控制在14.8 G、参数量 $3.1 \times 10^6$ 、模型大小6.2 MB,相较于传统改进方法,避免了因精度提升带来的计算复杂度激增,显著提升了模型在便携式设备上的部署适应性。

3)SSG-YOLOv8n模型的mAP@50指标分别高于YOLOv3 Tiny、YOLOv5n、YOLOv6n、Faster R-CNN(VGG)及SSD(MobileNetv2)模型10.3%、6.6%、10.2%、7.2%和15.8%,且浮点运算量、参数量和模型大小均处于对比模型的中间梯队,突破了传统模型“高精度-高计算量”或“轻量化-低精度”的技术瓶颈,为砖砌墙体裂缝形态的自动化实时检测提供了兼具工程实用性与技术先进性的解决方案。

### 参 考 文 献

- [1] 国家统计局. 中国统计年鉴[M]. 北京: 中国统计出版社, 2024.
- [2] SINGH S B, MUNJAL P. Bond strength and compressive stress-strain characteristics of brick masonry[J]. Journal of Building Engineering, 2017, 9: 10-16.
- [3] CAO X L, WEI X L, HUO X Q, et al. Self-powered retractable reel sensor for crack monitoring and warning in civil infrastructures[J]. Chemical Engineering Journal, 2023, 478, 147238.
- [4] CHEN W, CHEN C Y, LIU M, et al. Wall cracks detection in aerial images using improved mask R-CNN[J]. Computers, Materials & Continua, 2022, 73 (1). DOI: 10.32604/cmc.2022.028571
- [5] XIONG, C Q, ZAYED T, ABDELKADER E M. A novel YOLOv8-GAM-Wise-IoU model for automated detection of bridge surface cracks[J]. Construction and Building Materials, 2024, 414, 135025.
- [6] THOHARI A N A, KARIMA A, SANTOSO K, et al. Crack detection in building through deep learning feature extraction and machine learning approach[J]. Journal of Applied Informatics and Computing, 2024, 8(1): 1-6.
- [7] CHEN Y L, ZHU Z L, LIN Z J, et al. Building surface crack detection using deep learning technology[J]. Buildings, 2023, 13(7), 1814.
- [8] ZHU W, ZHANG H, EASTWOOD J, et al. Concrete crack detection using lightweight attention feature fusion single shot multibox detector[J]. Knowledge-Based Systems, 2023, 261, 110216.
- [9] LAN M L, YANG D, ZHOU S X, et al. Crack detection based on attention mechanism with YOLOv5[J]. Engineering Reports, 2025, 7(1), e12899.
- [10] YAO J L, XU S, HUANG F J, et al. Improved lightweight infrared road target detection method based on YOLOv8[J]. Infrared Physics & Technology, 2024, 141, 105497.
- [11] LIU Y F, GAO W L, ZHAO T T, et al. A rapid bridge crack detection method based on deep learning[J]. Applied Sciences, 2023, 13(17), 9878.
- [12] LI Q J, ZHANG G Y, YANG P. CL-YOLOv8: crack detection algorithm for fair-faced walls based on deep learning[J]. Applied Sciences, 2024, 14(20), 9421.
- [13] 凌同华, 贝政豪, 张胜, 等. 基于YOLO-Pipe和ByteTrack的排水管道缺陷检测[J]. 中国给水排水, 2025, 41(3): 125-130.
- [14] 张汉钰. 基于深度学习的砌体结构房屋裂缝识别及安全评价研究[D]. 南京: 南京理工大学, 2020.
- [15] ZHANG S, BEI Z H, LING T H, et al. Research on high-precision recognition model for multi-scene asphalt pavement distresses based on deep learning[J]. Scientific Reports, 2024, 14 (1), 25416.
- [16] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443-459.
- [17] LI Y, XIN X Y. Crack detection method based on an improved YOLOv8 model[C]//2024 IEEE 7th International Conference on Automation, Electronics and Electrical Engineering

- (AUTEET). IEEE, 2024: 226–231.
- [18] SUN L, DONG J X, TANG J H, et al. Spatially-adaptive feature modulation for efficient image super-resolution [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023: 13190–13199.
- [19] HAN K, WANG Y H, TIAN Q, et al. Ghostnet: More features from cheap operations [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 1580–1589.