

基于深度学习的建筑结构裂缝智能检测与安全评估系统研究

祖明新

(河北康城建设集团有限公司, 河北 保定 072651)

摘要 传统人工检测方式效率低、主观性强, 难以满足大规模工程巡检需求。针对这一困境, 本文提出一种融合改进 YOLOv8 目标检测网络与裂缝形态参数化分析的建筑物裂缝智能检测系统。在自建的 8 420 幅混凝土裂缝图像数据集上, 引入注意力机制与多尺度特征融合策略对基础网络加以改造, 检测精度 mAP@0.5 达到 94.3%, 较基线模型提升 6.8%。裂缝宽度估算误差控制在 0.05 mm 以内, 安全评级与专家人工评级的一致率达到 91.2%。该量化评估模型旨在为结构健康监测提供技术参考。

关键词 裂缝检测; YOLOv8; 注意力机制; 安全评估; 结构健康监测

中图分类号: TU317; TP183

文献标志码: A

DOI: 10.3969/j.issn.2097-3365.2026.23.012

0 引言

混凝土裂缝是建筑结构耐久性退化最直观的表面信号。当裂缝宽度超过《混凝土结构设计规范》规定的一类环境普通构件最大限值 0.3 mm 时, 易形成贯通性渗水通道, 大幅提升外界水、氯离子等侵蚀介质侵入内部的效率, 会显著加速钢筋锈蚀进程, 进而逐步削弱结构的长期承载性能。^[1]《民用建筑可靠性鉴定标准》(GB 50292-2015) 明确要求定期人工巡检, 但现实情况是, 光照条件、检测人员经验和作业面可达性这三个变量叠加在一起, 复杂工程现场的漏检率能轻松突破 15%^[2]。深度学习目标检测算法自 2015 年以来在视觉检测领域取得了实质性进展, YOLO 系列模型凭借单阶段推理的速度优势已在工业缺陷检测场景中站稳脚跟, 2023 年发布的 YOLOv8 更是在多项公开基准上重新定义了精度与速度的平衡点^[3]。从问题驱动的视角看, 真正的难点不在于某个算法跑出多漂亮的数字, 而在于如何把深度检测模型与裂缝形态量化计算衔接起来, 构建从图像采集、缺陷定位到安全分级的完整闭环^[4]。本文针对混凝土表面裂缝在光照不均、背景纹理复杂环境下检测精度不足的痛点, 提出基于改进 YOLOv8 的检测框架, 建立与《混凝土结构现场检测技术标准》(GB/T 50784) 相衔接的定量安全评级体系, 并通过实际工程图像验证系统的有效性。

1 裂缝图像采集与数据集构建

在建筑结构裂缝检测的计算机视觉任务中, 标注数据的质量是决定检测模型性能上限的核心约束条件, 这一规律在该类任务上体现得尤为突出。研究团队选取 6 栋在役混凝土建筑作为采集现场, 涵盖商业建筑、既有住宅及工业厂房等多种结构类型, 使用工业相机(分辨率 4 032×3 024 像素, 像素尺寸 2.4 μm)在自然光与补光灯两种照明条件下拍摄原始图像共 11 380 幅。图像筛选阶段剔除了模糊、过曝及重叠率超过 80% 的冗余样本, 保留 8 420 幅有效图像, 裂缝宽度覆盖 0.05 mm~2.80 mm, 发丝裂缝、结构性裂缝与贯穿裂缝三类形态均有充分样本。标注环节由两名具有 10 年以上检测经验的工程师独立完成边界框标注, 意见不一时引入第三位专家仲裁, 最终积累标注实例 29 643 个, 格式采用 COCO JSON 标准。

数据集按 7:1.5:1.5 划分训练集、验证集与测试集。值得关注的是, 三个子集的裂缝宽度分布经 Kolmogorov-Smirnov 检验 ($p=0.43 > 0.05$) 符合同分布假设, 从根本上消除了分层不均导致评估失真的隐患。现场图像中裂缝实例稀疏分布的问题同样不容忽视, 研究采用马赛克拼接 (Mosaic) 与随机仿射变换组合的数据增强策略, 将训练样本扩充至原始规模的 4 倍^[5]。增强时对亮度 (因子范围 0.6~1.4)、对比度及旋转角度 ($\pm 15^\circ$) 施加有限幅度的随机扰动, 刻意保留裂缝形态的物理合理性, 而非追求数量上的无限膨胀。

作者简介: 祖明新 (1987-), 男, 本科, 工程师, 研究方向: 工程施工技术管理。

2 改进的 YOLOv8 裂缝检测模型

2.1 基础架构与改进动机

YOLOv8 以 C2f 模块取代 C3 模块，在 Neck 部分引入 PAN-FPN 结构完成多尺度特征融合，检测头则解耦为分类与回归两个独立分支^[6]。这套架构在通用目标检测场景表现出色，但混凝土裂缝目标有其特殊性：裂缝宽度通常仅占图像宽度的 0.1% ~ 0.5%，属于极细长的微小目标，标准 32 倍下采样带来的分辨率损失相当可观；与此同时，混凝土表面纹理与裂缝在低对比度条件下局部梯度特征高度相似，特征提取阶段背景噪声的干扰几乎难以避免。这两个具体挑战指向了三个清晰的改进方向：注意力引导、特征尺度扩展与回归损失优化。

2.2 CBAM 注意力机制嵌入

本研究在 C2f 模块输出端嵌入卷积块注意力模块 (CBAM)，其核心由通道注意力与空间注意力串联而成。通道注意力权重的计算如下：

$$M_c(F) = \sigma(W_1 ReLU(W_0 F_{avg}^c) + W_2 ReLU(W_0 F_{max}^c)) \quad (1)$$

空间注意力在通道压缩之后对空间位置重新加权，强制网络聚焦裂缝边缘高曲率区域，而非取决于混凝土骨料纹理^[7]。消融实验的数字很明显：单独引入 CBAM 模块，验证集 mAP@0.5 提升 2.1%，足以证明注意力机制在细粒度纹理辨别上切实有效。

2.3 浅层特征融合路径与损失函数优化

微小裂缝的细节在深层特征图里往往已经消失，为此，研究在 Neck 结构中增加一条短路径，将 Backbone 第二阶段输出（步长 8 倍下采样）直接接入检测头，使检测头同时接收步长 8、16、32 三种尺度的特征图。在代价方面，网络参数量从 6.3M 增至 7.1M，推理时延在 RTX 3080 上从 8.2 ms 增至 9.6 ms，这些计算开销换来的精度增益远超预期。在回归损失层面，原始 YOLOv8 采用 CIOU，对细长形状目标的长宽比惩罚力度不够，替换为 Wise-IoU (WIoU) 后，动态聚焦系数 β 对高质量预测框赋予更大梯度权重：

$$L_{WIoU} = r^\beta \cdot L_{IoU}, \quad r = \exp \cdot \left(\frac{(x-x_g)^2}{w_g^2} + \frac{(y-y_g)^2}{h_g^2} - 1 \right) \quad (2)$$

验证集结果显示，WIoU 相较 CIOU 使 AR@0.5 提升 1.4%，宽度小于 0.2 mm 的发丝裂缝漏检率从 11.3% 降至 8.6%，改进效果集中体现在最难检测的那批样本上。

3 裂缝特征量化与安全评估方法

3.1 裂缝宽度像素标定

裂缝宽度的估算精度高度依赖物理标定的准确性，稍有偏差便会在后续安全评级中放大误差。研究在每个检

测场景放置标准标定板（格点间距 10.00 ± 0.01 mm），通过单应性矩阵推算每像素对应的实际物理尺寸。经 15 组重复测量评估，95% 置信区间内物理尺寸误差不超过 ±0.02 mm/pixel。宽度估算本身采用骨架化细化算法提取裂缝中心线，沿中心线方向每隔 5 个像素采样一次法向宽度，取最大法向宽度作为特征宽度 w_{max} 。对照 120 个裂缝实例的游标卡尺人工量测值，自动估算的 RMSE 为 0.047 mm，达到《混凝土结构现场检测技术标准》(GB/T 50784-2013) 规定的 0.05 mm 精度门槛。从宽度区间来看，0.05 mm ~ 0.30 mm 段偏差最大 (RMSE=0.041 mm)，超过 0.50 mm 后误差进一步收窄至 0.028 mm，宽裂缝反而更好处理。

3.2 安全评级模型

依据《民用建筑可靠性鉴定标准》(GB 50292-2015) 的裂缝分级原则，安全评级模型综合了裂缝宽度、裂缝长度与裂缝密度（单位面积裂缝像素占比）三个特征量。三个特征量归一化后线性加权，权重系数由 10 名结构工程师参与专家打分法确定，组间变异系数分别为 9.3%、12.1%、14.7%，专家意见的分歧程度在可接受范围内，权重稳定性较好。评级公式如下：

$$S = 0.55 \cdot f(w_{max}) + 0.30 \cdot f(L) + 0.15 \cdot f(\rho) \quad (3)$$

其中， $f(\cdot)$ 为分段线性映射函数，将各特征量归一化至 [0, 1]。自定义结构安全评价指标 SS S 值按区间 [0, 0.3)、[0.3, 0.6)、[0.6, 0.8)、[0.8, 1.0]，依次对应 A 级（安全）、B 级（观察）、C 级（限制使用）、D 级（危险）四个安全等级；所有等级划分的阈值均与现行《混凝土结构设计规范》中的裂缝宽度限值逐一校核，确保最终评级结果完全贴合工程实践要求。

4 实验结果与分析

4.1 检测性能对比

表 1 列出改进模型与基线 YOLOv8 及近年主流方法在测试集上的检测性能。

改进模型 mAP@0.5 达到 94.3%，比基线 YOLOv8n 高出 6.8%，比双阶段 Faster R-CNN 高 5.4%，9.6 ms 推理时延对应实时检测（30 fps 上限约 33 ms）留有充裕余量。在细长裂缝子集（宽度 < 0.2 mm, n=1 263 个实例）上，改进模型 AP 为 89.2%，基线模型仅 78.5%，提升幅度 10.7%，这正是浅层特征融合路径的针对性贡献所在。消融实验的分解结果见表 2，逐项引入三种改进模块后，mAP@0.5 分别增加 2.1%、3.2%、1.4%，三者累计贡献了总提升量的 99%，且各模块增益相互独立，未见负向叠加，说明三种策略分别针对不同特征瓶颈，改进路径在内在逻辑上站得住脚。

表1 各模型在裂缝测试集上的检测性能

模型	mAP@0.5	mAP@0.5:0.95	AR@0.5	推理时延 (ms)
YOLOv5s	84.6%	52.3%	82.1%	6.8
YOLOv8n (基线)	87.5%	55.7%	84.3%	8.2
Faster R-CNN	88.9%	57.4%	86.7%	42.5
本文改进模型	94.3%	62.1%	91.4%	9.6

表2 消融实验结果 (mAP@0.5)

配置	mAP@0.5
基线 YOLOv8n	87.5%
+CBAM	89.6%
+CBAM+ 浅层融合路径	92.8%
+CBAM+ 浅层融合路径 +WIoU	94.3%

4.2 安全评级验证

在独立验证场景(2栋与训练场景不同的建筑外墙,共387幅图像)中,系统自动评级与结构工程师人工评级的一致率为91.2%(353/387),加权Kappa系数 $\kappa=0.87$,属于高度一致区间。不一致的34个样本中,28个属于系统评级偏严,6个评级偏松,偏严型误判占不一致样本的82.4%,单向性相当明显。深挖这28个样本可以发现,问题集中在裂缝密度特征 ρ 的计算上:施工缝纹理在阈值分割阶段被错误纳入裂缝骨架, ρ 值因此虚高,综合评分S随之被拉升。针对这一根源,在骨架化前增加形态学闭运算预处理步骤可有效分离施工缝纹理,该修正方案已在后续100幅图像上完成预实验, ρ 虚高样本的比例从8.8%降至2.1%,预计整体一致率修正后可升至93%以上。至于6个偏松误判,均发生在多条发丝裂缝密集交叉的场景,单条裂缝宽度未超过阈值,但整体结构退化程度不轻,这类场景需要引入裂缝网络连通性特征加以补充,是下一步要解决的问题。

4.3 复杂光照条件下的鲁棒性验证

按拍摄光照条件将测试集划分为强光直射、阴影遮挡、逆光及低照度四类场景,每类单独统计检测指标,mAP@0.5分别为93.1%、91.7%、88.4%、89.9%,最大波动幅度4.7%,整体检测性能保持稳定。逆光场景表现相对偏弱,主要原因在于裂缝边缘与背景之间的灰度对比度被大幅压缩,导致特征提取阶段有效信息不足,CBAM注意力机制难以凭空补足缺失的边缘细节。为此,研究团队在图像预处理阶段引入自适应直方图均衡化(CLAHE)作为补充手段,逆光场景mAP@0.5由

88.4%提升至90.6%,低照度场景同步提升1.3%,验证了预处理增强与模型结构改进相结合的可行性。

5 结论

本文提出的改进YOLOv8裂缝检测系统,通过嵌入CBAM注意力模块、引入浅层特征融合路径及替换WIoU回归损失三项改造,在8420幅混凝土裂缝图像测试集上取得94.3%的mAP@0.5,裂缝宽度自动估算RMSE为0.047mm,安全评级与专家评级一致率达91.2%($\kappa=0.87$),精度与速度均满足工程现场实时检测的要求。核心价值在于将检测模型的精度提升与裂缝形态参数化计算及国标分级体系有机融合,构建了从原始图像到安全等级输出的完整技术链路,消融实验进一步厘清了三项技术手段各自的贡献边界。裂缝密度特征在施工缝干扰下鲁棒性不足,是当前系统最明显的短板。未来研究应探索基于语义分割的裂缝与施工缝区分策略,同时在预应力构件、砌体墙等更多结构类型上扩展数据集,以提升模型的跨场景泛化能力。

参考文献:

[1] 孟阳.基于深度学习的混凝土裂缝智能检测与修复策略研究[J].城市建设理论研究(电子版),2026(07):100-102.
[2] 张勇飞,张新,林芙蓉,等.基于深度学习的道路裂缝检测系统[J].电脑知识与技术,2026,22(04):18-23,43.
[3] 白先浪,张群利.深度学习技术在道路裂缝检测中的应用[J].黑龙江交通科技,2026,49(01):74-80.
[4] 张虎耀,吕丽,高田田,等.基于无人机与深度学习的钢筋混凝土桥裂缝检测方法[J].铁道技术监督,2025,53(11):45-50.
[5] 丁伟立.基于深度学习的沥青道路裂缝自动检测与分类技术研究[J].汽车周刊,2025(11):113-115.
[6] 代忠,程航,景嘉煜,等.基于多源图像融合的深度学习方法在道路裂缝检测中的应用与优化[J].公路,2025,70(10):359-367.
[7] 屈强.基于深度学习的沥青路面裂缝检测方法研究[J].工程机械与维修,2025(08):134-136.