

基于改进的YOLOv8n模型桥梁裂缝检测识别算法

朱勇强*, 肖柯旭, 吴宗汉

上海理工大学环境与建筑学院, 上海

收稿日期: 2024年12月8日; 录用日期: 2025年1月1日; 发布日期: 2025年1月13日

摘要

本文针对我国桥梁数量众多、维护需求迫切的背景, 提出了一种改进的YOLOv8n模型, 以提升桥梁裂缝检测的准确性和效率。通过引入全局注意力机制(GAM), 研究成功增强了模型从复杂背景中提取显著特征的能力, 结合Wise-IOU损失函数, 优化了对难以检测样本的关注度。实验结果表明, 改进后的YOLOv8n在精确度、平均精度均值(mAP)和F1分数上较原始模型分别提升了2.4、1.1和1.3个百分点, 尽管召回率略有下降, 但整体性能仍优于当前主流检测模型。本文的贡献在于通过技术创新, 提高了桥梁裂缝的自动化检测能力, 填补了传统人工检测方法的效率和主观性缺陷, 为桥梁维护提供了更为高效、可靠的解决方案。未来, 模型的进一步优化及在更广泛的实际应用中的验证, 将是提升桥梁安全性和耐久性的关键。

关键词

桥梁裂缝, 检测, YOLOv8

Bridge Crack Detection and Recognition Algorithm Based on the Improved YOLOv8n Model

Yongqiang Zhu*, Kexu Xiao, Zonghan Wu

School of Environment and Architecture, University of Shanghai for Science and Technology, Shanghai

Received: Dec. 8th, 2024; accepted: Jan. 1st, 2025; published: Jan. 13th, 2025

Abstract

This study addresses the urgent maintenance needs of the numerous bridges in China by proposing

*通讯作者。

文章引用: 朱勇强, 肖柯旭, 吴宗汉. 基于改进的 YOLOv8n 模型桥梁裂缝检测识别算法[J]. 建模与仿真, 2025, 14(1): 158-166. DOI: 10.12677/mos.2025.141016

an improved YOLOv8n model to enhance the accuracy and efficiency of bridge crack detection. By incorporating a Global Attention Mechanism (GAM), the research successfully enhances the model's ability to extract salient features from complex backgrounds. Additionally, the Wise-IOU loss function optimizes the model's focus on hard-to-detect samples. Experimental results indicate that the improved YOLOv8n achieves increases of 2.4, 1.1, and 1.3 percentage points in accuracy, mean average precision (mAP), and F1 score, respectively, compared to the original model. Although the recall rate slightly declined, the overall performance remains superior to current mainstream detection models. The contribution of this research lies in the technological innovation that improves the automation capability of bridge crack detection, addressing the efficiency and subjectivity deficiencies of traditional manual inspection methods, thus providing a more efficient and reliable solution for bridge maintenance. Future work will focus on further optimizing the model and validating it in a broader range of practical applications, which will be key to enhancing bridge safety and durability.

Keywords

Bridge Cracks, Detection, YOLOv8

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

中国的桥梁数量在世界各国中位居首位[1], 中国是世界上桥梁数量最多的国家, 截至 2022 年末, 全国共有桥梁 103.32 万座, 总延米达 8576.49 万, 且近年来持续增加[2]。桥梁的广泛建设和使用大大改善了交通状况, 但随着时间的推移, 桥梁结构容易受到施工材料、施工工艺、极端天气等多种因素的影响, 裂缝成为影响桥梁安全性的重要病害。裂缝的存在可能引发钢筋锈蚀, 从而显著缩短桥梁的使用寿命[3], 因此, 裂缝检测和修复是桥梁养护中的重要环节。我国已初步建立了以检测、鉴定和评价为核心的在役工程结构技术标准体系[4] [5], 以支持基础设施的维护和安全评估。然而, 传统的人工检测方法[6] [7]存在效率低、作业风险大、且易受主观因素影响的问题[8], 难以满足对高时效性和准确性的需求[9]。因此, 发展桥梁表观病害的自动化检测技术对于提升检测效率和准确性具有非常重要的意义[10]。

近年来, 随着计算机技术的持续发展, 众多研究者已经开始采用图像处理和机器学习算法来诊断桥梁结构的损伤。尤其是深度学习技术在计算机视觉领域的快速进展, 已经被广泛引入桥梁裂缝的检测中。这种技术的应用不仅显著提高了检测精度, 而且免除了传统图像处理方法中所需的繁琐预处理步骤。与传统的人工检测方法相比, 基于数字图像技术的检测方法提供了更高的准确性和效率, 并允许对裂缝检测结果进行量化分析[11]。例如, YOLOv2 和 Faster R-CNN 在裂缝检测中表现出较大的性能差异, 其中 YOLOv2 在精度上占有优势[12]。此外, 一些改进的深度学习模型, 如改进的 YOLOv3 [13]-[15]和卷积神经网络(CNN) [16]-[19], 通过引入焦点损失函数和迁移学习策略以及引入注意力模块或者选用更好的损失函数等方法, 有效提升了模型的识别准确性。类似地, 无人机和机器视觉技术[20]的结合也在裂缝检测中取得了显著进展, 提供了更加精准的像素级裂缝分割。Yang 等[21]则提出了一种基于 SSD 深度学习框架的自动路面裂缝检测系统, 并集成了感受野模块以增强网络的特征提取能力。Xiong 等[22]在 YOLOv8 中引入 GAM (Global Attention Module)模块并更新原本的损失函数 CIOU 提出了新的 YOLOv8-GAM-Wise-IOU 深度学习模型用于桥梁裂缝的检测并得到了很好的识别效果。

本文基于现有的 YOLOv8 模型，提出了一种改进的 YOLOv8-GAM-Wise-IoU 深度学习检测模型。通过在颈部网络中加入 GAM 注意力机制，并替换传统的 CIoU 损失函数为 Wise-IoU，进一步提升了检测精度和效率，为桥梁健康监测提供了更为高效的检测工具。

2. 优化模型

2.1. YOLOv8 网络

YOLO (You Only Look Once)是目前一种流行的目标检测算法，它以其速度快和效率高而著称。与传统的目标检测方法不同，YOLO 将目标检测任务作为一个单一的回归问题来处理，直接从图像像素到边界框坐标和类别概率的预测。这种方法使得它能够在处理图像时实现端到端的预测，极大地加快了处理速度。YOLOv8 是 YOLO 系列中的最新作品，相较于目前使用较为流行的 YOLOv5 网络，YOLOv8 网络无论是在检测精度还是速度方面都有长足进步。YOLOv8 根据不同的使用场景目的分为 n、s、l、m、x 共 5 种模型，网络深度依次加深，检测精度依次增高。其中 YOLOv8n 参数量最小且检测速度最快。因此，为保证算法的实时性和模型大小可控，该研究选择使用 YOLOv8n 版本。YOLOv8 网络架构如图 1 所示，包含三个主要部分：主干网络、特征融合网络和检测头。




Figure 1. Overall structure diagram of the YOLOv8 model
图 1. YOLOv8 模型整体结构图

2.2. 全局注意力机制

本文提出了全局注意力机制(Global Attention Mechanism, GAM)作为 YOLOv8 的增强模块。GAM 模

型专为从桥梁检查图像中复杂背景中提取显著特征而设计。通过整合 GAM 模块，YOLOv8 能够有效地从背景中提取关键信息，从而显著提升整体检测性能。此外，本文引入了一种动态非单调聚焦机制，该机制利用“异常值”概念来评估锚框质量。此机制使得检测器能够综合考虑不同质量的锚框，从而优化检测任务的整体性能。采用该方法后，模型能够更好地适应不同质量的锚框，进一步提升检测结果的准确性。总体而言，本研究通过结合 GAM 模型与 YOLOv8，有效应对桥梁裂缝检测中复杂背景的挑战。GAM 模块的引入便于从背景中提取重要特征，而动态非单调聚焦机制通过考虑不同质量的锚框，显著提高了整体检测性能。

鉴于数据集中存在复杂的多重干扰，全局注意力机制(GAM)被认为是抑制图像中非重要信息的最优选择。与其他注意力模块相比，GAM 因其能够减少信息损失并增强全局维度交互特征而尤为突出。在卷积块注意力模块(Convolutional Block Attention Module, CBAM)的基础上，GAM 保留了顺序的通道 - 空间注意机制，并进一步重新设计了子模块。在通道注意子模块中，采用三维排列以保留所有三个维度的信息，并通过两层多层感知器(Multi-Layer Perceptron, MLP)增强跨维度的通道 - 空间依赖性。空间注意子模块则通过使用两层卷积层进行空间信息融合，聚焦于空间信息的提取与处理。GAM 结构图如图 2 所示，其中：

$$F_1 \in \mathbb{R}^{C \times H \times W} \quad (1-1)$$

$$F_2 = M_c(F_1) \otimes F_1 \quad (1-2)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (1-3)$$

F_1 表示上层神经网络输入的特征图， M_c 和 M_s 分别是通道和空间注意力图，采用逐个元素相乘，总体上采用通道 - 空间注意力机制为顺序的结构来保留三个维度的信息，放大跨纬度通道空间特征信息的依赖性。




Figure 2. Schematic diagram of the GAM
图 2. GAM 示意图

2.3. 损失函数

Wise-IOU 损失函数是一种用于目标检测的高级损失函数，其原理是利用预测框与真实框之间的交并比(Intersection over Union, IOU)作为衡量其差异的指标，并以此计算损失值。该损失函数的显著特点是其在训练过程中能够自适应地调整样本的权重，使得模型更加专注于难以检测的样本。具体来说，Wise-IOU 损失函数将 IOU 值离散化为多个区间，并为每个区间分配相应的权重系数。这个权重系数与该区间内样本的数量相关，使得模型在训练过程中能够更加关注那些 IOU 值较小、检测难度较高的样本。通过这种

方式, Wise-IoU 损失函数能够有效地提高目标检测的精度, 确保模型在处理具有挑战性的样本时表现更佳。改进后的结构如图 3 所示。




Figure 3. Structural diagram of the improved YOLOv8 model

图 3. 自改进后 YOLOv8 模型结构图

3. 数据处理

数据来源于网上的公开数据集, 将数据图片按照比例分为训练数据集和验证数据集, 分别为 1774 张和 204 张。

训练模型时需要告诉模型目标的位置信息, 即在训练前首先要人工手动对数据集中的裂缝进行标注, 无论是公开数据集还是自行收集的数据集, 都需要将图中的裂缝用边界框标注出来。本研究运用 Labelimg 标注工具进行桥梁裂缝标注, Labelimg 是 python 下的第三方标注工具包。选用矩形边界框进行标注。本文的裂缝数据集中包括了各种裂缝类型, 如横向裂缝、纵向裂缝等, 为了简单起见, 本研究并未对裂缝进行分类, 均标注为一种类型裂缝(Crack)。对于数据的收集并未包含无裂缝的图片作为背景, 因为图片本身除裂缝之外其余均看作为背景。

4. 实验结果与分析

4.1. 实验环境和参数配置

本次试验在 64 位操作系统下进行, 运行内存 16 GB, 显卡为 NVIDIA GeForce RTX4060, 显存为 8 GB, CPU 为 AMD Ryzen9 7945Hx, 编程语言为 python3.9.19, 采用 PyTorch 深度学习框架搭建模型, CUDA 版本为 11.8。训练参数设置如表 1 所示。

Table 1. Setting of the training parameters
表 1. 标训练参数设置

参数	数值	参数	数值
epochs	1000	optimizer	SGD
patience	100	weight_decay	0.0005
batch	16	momentum	0.937
imgs	640	warmup_momentum	0.8
workers	8	close_mosaic	10
lrf	0.01	patience	100

4.2. 评价指标

本试验使用精确度(Precision)、平均精度均值(mean average precision, MAP)对模型进行评价, 召回率(Recall)以及 F1 分数作为辅助性参考。精确度(Precision)越高表示模型对负样本的识别能力越强; 平均精度均值 MAP 中的 M 代表均值, MAP0.5 指的是当混淆矩阵的 IoU 的阈值为 0.5 时, 针对这一类样本的平均精确度。MAP0.5 是将所有的类别的样本的精确度取平均值, 其反映的是模型的精确度随召回率的变化趋势, 该值越高代表模型越容易在高召回率下保持着高精确度。而 MAP0.5~0.95 则代表在不同 IOU 阈值(从 0.5 到 0.95, 步长 0.05)上的平均 MAP 值。

$$MPA = \frac{\sum PA}{N} \quad (3-1)$$

$$Precision = \frac{TP}{TP + FP} \quad (3-2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3-3)$$

$$F1-score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (3-4)$$

式中: N 为类别综述; PA 为以召回率为横坐标、精确度为纵坐标形成曲线所围成的面积; FP 代表假阳性的数量, TP 代表真阳性的数量, FN 代表假阴性的数量。

4.3. 实验结果与分析

4.3.1. 改进 YOLOv8n 消融试验

为了评估两种改进方法对改进模型的效果和作用, 分别进行了消融试验, 结果如表 2 所示。从表中可以看出更换损失函数 WIOU 之后, 精确度相较于有原始模型提升 0.9 个百分点, 但是召回率、MPA0.5、MPA0.5-0.95 以及 F1-score 均有小幅度的下降, 因此可以得出更换损失函数 WIOU 对精确度的提高是有所帮助的; 添加 GAM 注意力机制之后, 精确度、MPA0.5、MPA0.5-0.95 比原始模型分别提高 1.6、0.8、3.7 个百分点, F1-score 比原始模型提高 0.1, 说明 GAM 注意力机制确实能够提取特征信息从而提升模型的准确率, 但是召回率相对于原始模型降低了 1.2 个百分点; 在引入 GAM 模块的同时更换损失函数的模型在精确度、MPA0.5 以及 MPA0.5-0.95 分别比原始模型提高了 2.4、1.1、1.3 个百分点, F1-score 比原始模型提高 0.1, 但是召回率略微降低。并且与单独更换损失函数和单独引入 GAM 模块相比精确度经有提升, 分别提升 1.5、0.8 个百分点, F1-score 比单独更换损失函数提高 0.2。

从表 2 中也可以看出, 更换损失函数 WIOU 对虽然能提高模型识别裂缝的精确度, 但是会对召回率

和 MPA0.5-0.95 的结果造成一定的不利影响；引入 GAM 模块使得模型的精确度、MPA0.5、MPA0.5-0.95 以及 F1-score 的结果得到一定程度上的提升，但是对召回率有略微的不利影响。

总的来说，改进的模型在桥梁裂缝检测中的各项指标均取得了很好的结果；表明改进后的网络结构可以有效提高桥梁裂缝的检测性能。

Table 2. Ablation test results
表 2. 消融试验结果

模型(%)	精确度(%)	召回率(%)	MPA0.5 (%)	MPA0.5-0.95 (%)	F1-score
YOLOv8n	92.8	90.3	91.5	63.3	0.89
YOLOv8-WIOU	93.7	80.3	91.0	61.1	0.88
YOLOv8-GAM	94.4	89.5	92.3	67.0	0.90
YOLOv8-GAM-WIOU	95.2	89.1	92.6	64.6	0.90

4.3.2. 不同模型的对比结果

为验证该研究算法相比当前热门目标检测模型的优越性，以精确度、召回率、mAP@0.5、mAP@0.5~0.95、F1-score 等作为评价指标，将该研究算法 YOLOv8-GAM-WIOU 与 YOLOv5、YOLOv8n 算法在相同的条件下进行对比试验，试验结果如表 3 所示。

根据表 3 的实验结果可得，虽然 YOLOv5 的精确度略高于 YOLOv8，但是召回率、MPA0.5、MPA0.5-0.95 以及 F1-score 是远低于 YOLOv8；该研究算法除了在召回率上略低于 YOLOv8 原始模型，但是精确度、MPA0.5、MPA0.5-0.95 以及 F1-score 等指标均优于其他模型；通过以上分析可见，该研究提出的 YOLOv8-GAM-WIOU 算法在多个指标方面均展现出其优越性。

Table 3. Experimental results of the different models
表 3. 不同模型实验结果

模型(%)	精确度	召回率(%)	MPA0.5 (%)	MPA0.5-0.95 (%)	F1-score
YOLOv5	93.2	78.8	88.9	49.2	0.87
YOLOv8n	92.8	90.3	91.5	63.3	0.89
YOLOv8-GAM-WIOU	95.2	89.1	92.6	64.6	0.90

4.3.3. 注意力机制的比较

将所建立的 YOLOv8-GAM-WIOU 模型与 YOLOv8-CBAM-WIOU 进行比较，检验 GAM 注意力模块以及 CBAM 注意力模块在精确度、召回率、mAP@0.5、mAP@0.5~0.95、F1-score 等方面进行比较；由表 4 可以看出 YOLOv8-GAM-WIOU 在精确度、召回率、mAP@0.5、F1-score 等分别比 YOLOv8-CBAM-WIOU 高出 0.8%、1.9%、0.5%、0.1，但是 mAP@0.5~0.95 略微降低；但是与原始模型以及其他模型相比该研究算法仍然具有绝对的优越性。

Table 4. Results of performance comparison of attention mechanisms
表 4. 注意力机制的性能比较结果

模型(%)	精确度(%)	召回率(%)	MPA0.5 (%)	MPA0.5-0.95 (%)	F1-score
YOLOv8-WIOU	93.7	80.3	91.0	61.1	0.88
YOLOv8-CBAM-WIOU	94.8	87.2	92.1	65.0	0.89
YOLOv8-GAM-WIOU	95.2	89.1	92.6	64.6	0.90

5. 总结与展望

本研究对 YOLOv8n 的网络结构进行了改造,在特征融合网络中引入了 GAM 注意力模块来提高模型对于桥梁裂缝的关注度。对于收集到的桥梁裂缝数据集用于模型的训练、验证。结果表明:

(1) 本文研究提出了一种改进的 YOLOv8-GAM-Wise-IoU 模型,旨在提升桥梁裂缝检测的准确性和效率。通过引入全局注意力机制(GAM)和 Wise-IoU 损失函数,模型在处理桥梁裂缝检测任务时表现出了显著的性能提升。具体而言,与原始 YOLOv8 模型相比,改进后的模型在精确度、平均精度均值(mAP)和 F1 分数上分别提高了 2.4%、1.1%和 1.3%。尽管召回率略有下降,但整体性能较其他常见目标检测模型(如 YOLOv5、YOLOv8n)具有明显优势,表明该模型能更有效地检测桥梁表面裂缝。

(2) 在模型优化方面, YOLOv8n 的网络结构得到了有效改造,特别是引入 GAM 注意力模块,这使得模型能够更好地聚焦于桥梁裂缝的关键特征,从复杂背景中提取显著信息。此外, Wise-IoU 损失函数的应用提升了对难检测样本的关注,进一步提高了模型的精度。

(3) 实验结果显示,改进后的 YOLOv8-GAM-Wise-IoU 模型在不同指标上均表现优异,尤其在精确度和 F1 分数上超越了其他模型。与 YOLOv8-CBAM-WIoU 进行比较时,本研究模型在大多数评估指标上也略有优势,验证了 GAM 注意力机制的有效性。

综上所述,本文提出的改进方法能够有效提升桥梁裂缝的检测精度和效率,为桥梁健康监测领域提供了一种更为高效的自动化检测模型。未来的研究可以进一步优化模型,提升召回率,并扩展到更多类型的桥梁病害检测任务中。

参考文献

- [1] 《中国公路学报》编辑部. 中国桥梁工程学术研究综述·2021 [J]. 中国公路学报, 2021, 34(2): 1-97.
- [2] 交通运输部. 2022 年交通运输行业发展统计公报[N]. 中国交通报, 2023-06-16(002).
- [3] 梁栋, 李英俊, 张少杰. 融合改进 ResNet-14 和 RS-Unet 模型的混凝土桥梁裂缝识别[J]. 北京交通大学学报, 2023, 47(3): 10-18.
- [4] 岳清瑞, 幸坤涛, 惠云玲. GB 50144《工业建筑可靠性鉴定标准》(报批稿)的修订及主要内容[J]. 工业建筑, 2016, 46(11): 152-156, 167.
- [5] 刘宇飞, 齐玉, 李保罗, 等. 工程结构运维多场景的敏感服役指标智能识别[J]. 建筑结构学报, 2022, 43(10): 1-15.
- [6] 陈榕峰, 徐群丽, 秦凯强. 桥梁裂缝智能检测系统的研究新进展[J]. 公路, 2019, 64(5): 101-105.
- [7] 丁威, 夏哲, 舒江鹏, 等. 基于负压吸附爬壁机器人和 Transformer 的混凝土桥塔裂缝识别检测[J]. 中国公路学报, 2024, 37(2): 53-64.
- [8] 苏卫国, 王景霄. 基于 YOLOv3 深度学习算法的道路裂缝识别模型研究[J]. 中外公路, 2023, 43(2): 58-63.
- [9] 岳清瑞, 徐刚, 刘晓刚. 桥梁裂缝智能识别与监测方法研究[J]. 中国公路学报, 2024, 37(2): 16-28.
- [10] 彭雨诺, 刘敏, 万智, 等. 基于改进 YOLO 的双网络桥梁表面病害快速检测算法[J]. 自动化学报, 2022, 48(4): 1018-1032.
- [11] 杨国俊, 齐亚辉, 石秀名. 基于数字图像技术的桥梁裂缝检测综述[J]. 吉林大学学报(工学版), 2024, 54(2): 313-332.
- [12] Majidifard, H., Jin, P., Adu-Gyamfi, Y. and Buttlar, W.G. (2020) Pavement Image Datasets: A New Benchmark Dataset to Classify and Densify Pavement Distresses. *Transportation Research Record: Journal of the Transportation Research Board*, 2674, 328-339. <https://doi.org/10.1177/0361198120907283>
- [13] Zhang, C., Chang, C. and Jamshidi, M. (2019) Concrete Bridge Surface Damage Detection Using a Single-Stage Detector. *Computer-Aided Civil and Infrastructure Engineering*, 35, 389-409. <https://doi.org/10.1111/mice.12500>
- [14] Zhang, Y., Huang, J. and Cai, F. (2020) On Bridge Surface Crack Detection Based on an Improved YOLO V3 Algorithm. *IFAC-PapersOnLine*, 53, 8205-8210. <https://doi.org/10.1016/j.ifacol.2020.12.1994>
- [15] 邹俊志, 杨建喜, 李昊, 等. 复杂背景下基于改进 YOLOv3 算法的桥梁表面病害识别[J]. 铁道科学与工程学报, 2021, 18(12): 3257-3266.

-
- [16] Zhang, L., Yang, F., Daniel Zhang, Y. and Zhu, Y.J. (2016) Road Crack Detection Using Deep Convolutional Neural Network. 2016 *IEEE International Conference on Image Processing (ICIP)*, Phoenix, 25-28 September 2016, 3708-3712. <https://doi.org/10.1109/icip.2016.7533052>
 - [17] Fan, R., Bocus, M.J., Zhu, Y., Jiao, J., Wang, L., Ma, F., *et al.* (2019) Road Crack Detection Using Deep Convolutional Neural Network and Adaptive Thresholding. 2019 *IEEE Intelligent Vehicles Symposium (IV)*, Paris, 9-12 June 2019, 474-479. <https://doi.org/10.1109/ivs.2019.8814000>
 - [18] 柏嘉洛. 基于深度学习的端到端道路裂缝检测技术研究[D]: [硕士学位论文]. 武汉: 华中科技大学, 2020.
 - [19] 冯卉. 基于深度学习的道路裂缝识别算法研究与实现[D]: [硕士学位论文]. 北京: 北京邮电大学, 2019.
 - [20] Peng, X., Zhong, X., Zhao, C., Chen, A. and Zhang, T. (2021) A UAV-Based Machine Vision Method for Bridge Crack Recognition and Width Quantification through Hybrid Feature Learning. *Construction and Building Materials*, **299**, Article ID: 123896. <https://doi.org/10.1016/j.conbuildmat.2021.123896>
 - [21] Yang, J., Fu, Q. and Nie, M. (2020) Road Crack Detection Using Deep Neural Network with Receptive Field Block. *IOP Conference Series: Materials Science and Engineering*, **782**, Article ID: 042033. <https://doi.org/10.1088/1757-899x/782/4/042033>
 - [22] Xiong, C., Zayed, T. and Abdelkader, E.M. (2024) A Novel YOLOv8-Gam-Wise-IoU Model for Automated Detection of Bridge Surface Cracks. *Construction and Building Materials*, **414**, Article ID: 135025. <https://doi.org/10.1016/j.conbuildmat.2024.135025>