

DOI: 10.20098/j.cnki.1001-5132.2025.0130

基于深度学习的外墙饰面砖系统空鼓定量识别与评估

潘金晶¹, 童璐璐², 娄添添², 章子华^{1*}, 叶春阳^{1,3}

(1.宁波大学 土木工程与地理环境学院, 浙江 宁波 315211; 2.宁海县房管中心, 浙江 宁波 315615;
3.宁波宁大工程建设监理有限公司, 浙江 宁波 315211)

摘要:为实现外墙饰面砖系统空鼓的自动识别与定量评估,采用红外相机拍摄并建立包含1686个实例的图像数据库,然后根据真实几何关系对饰面砖和缺陷进行标定,用以评估深度学习实例分割方法中Mask R-CNN与YOLACT模型在空鼓及饰面砖识别上的性能与效率,并基于Python自主开发饰面砖空鼓率计算与可视化程序。结果表明,Mask R-CNN与YOLACT模型在数据集上均表现良好,平均分割精度分别达到0.855和0.771,其中YOLACT模型在计算效率与模型复杂度方面表现更优。自主开发程序能直观、量化反映空鼓区域及所占比例,可有效辅助准确判断缺陷程度。

关键词: 饰面砖系统; 空鼓; 红外热像; 深度学习; 实例分割; 定量评估

中图分类号: TU767

文献标志码: A

文章编号: 1001-5132(2026)01-0026-10

Quantitative identification and evaluation of hollowing in exterior wall tiling system based on deep learning

PAN Jinjing¹, TONG Lulu², LOU Tiantian², ZHANG Zihua^{1*}, YE Chunyang^{1,3}

(1.School of Civil & Environmental Engineering and Geography Science, Ningbo University, Ningbo 315211, China;
2.Ninghai County Housing Administration Center, Ningbo 315615, China;
3.Ningbo Ningda Engineering Construction Supervision Co., Ltd., Ningbo 315211, China)

Abstract: To achieve automatic identification and quantitative evaluation of hollowing in exterior wall tiling system, an infrared camera was used to capture hollowing images, with which an image dataset containing 1686 instances was established and labeled based on real geometric relationships. The performance and efficiency of the Mask R-CNN and YOLACT models in deep learning-based instance segmentation were evaluated for hollowing and tiles detection, and a Python-based program was developed to calculate and visualize the hollowing rate of tiles. The results show that Mask R-CNN and YOLACT models perform well on the dataset, with mAP being 0.855 and 0.771, respectively. The YOLACT model demonstrates superior computational efficiency and model complexity. The developed program can effectively and intuitively visualize the hollowing areas and proportions, providing valuable assistance in accurately evaluating the defect severity in exterior wall tiling system.

Keywords: tiling systems; tile hollowing; infrared thermography; deep learning; instance segmentation; quantitative evaluation

收稿日期: 2025-01-24

宁波大学学报(理工版)网址: <http://journal.nbu.edu.cn/>

基金项目: 国家自然科学基金(52378162); 宁波市“科创甬江2035”重大应用示范项目(2024Z014)

第一作者: 潘金晶, 硕士研究生, 主要研究方向为外墙饰面层病害检测与加固。E-mail: panjinjing1208@163.com

*通信作者: 章子华, 博导/教授, 主要研究方向为基础设施病害诊治理论与技术。E-mail: zhangzihua@nbu.edu.cn

饰面砖因其经济、美观和耐用等优势被广泛应用于建筑外墙装饰^[1]。外墙饰面砖系统是一个多层复杂系统,各种材料在温(湿)度、极端气候以及施工因素等影响下的物理响应各有不同,导致饰面砖系统的分层与破坏^[2],从而影响建筑外观风貌,若发生饰面砖掉落还会造成经济损失和人员伤亡。因此,及时准确地检测与评估饰面层的脱黏缺陷已成为维护建筑结构完整性和确保居民安全的关键问题。传统饰面层脱黏检测方法主要有目测法、锤击法与拉拔法,存在效率低、覆盖范围有限等的不足^[3]。随着无损检测(Nondestructive Testing, NDT)的快速发展,红外热像技术开始应用于建筑立面空鼓等缺陷检测^[4-5]。红外热成像将来源于物体的热辐射转换为电信号,以热像图形式显示,不同颜色对应不同温度^[6]。脱黏区域一般会形成一个充满空气的空间(空鼓),而空气层具有良好隔热性,从而影响了热传递过程^[7],使缺陷区域温度异于正常区域。在实际检测过程中,往往需要技术人员根据热像图人工判断缺陷区域,具有较强的经验性与主观性,不适用于大规模检测。部分学者^[8-9]通过传统图像处理技术实现了缺陷的初步自动化定性判断,但相对可见光图像,红外图像具有分辨率和信噪比低的特点,而传统图像处理技术受噪声影响较大,在复杂度高和分辨率低的情况下表现不佳。

近年来,深度学习因强大的自动特征提取和泛化能力已被逐渐应用于缺陷检测领域。Li等^[10]提出两阶段网络,对包含建筑立面脱黏缺陷的红外图像先进行目标检测,然后再实现目标区域内的缺陷语义分割。Cao^[11]提出一种基于YOLOv7和BlendMask的图像分割模型,对建筑饰面砖剥落的可见光图像进行缺陷识别,平均精度较原基准模型提高了1.32%。米庆仁^[12]则对可见光与红外图像进行融合及缺陷的语义分割。另外,有学者^[13-14]对多个目标检测模型在建筑外墙裂缝的可见光识别效果做了测试,并发展了裂缝的定量评估方法。鉴于实际修复工程通常是对空鼓区域局部进行修复,而非整个立面翻新,因此还存在对局部区域进行脱黏程度评价的需求。现有研究多集中在缺陷分类、目标检测与语义分割,不能区分同类缺陷的不同个体,进而无法对缺陷所在局部区域进行脱黏程度评价。Melo等^[15]指出,面砖黏结强度会随面砖-砂浆界面

脱黏面积的增加而急剧下降,即每块面砖空鼓率与残余黏结性能密切相关。另一方面,目前外墙饰面砖红外图像数据库缺陷标定通过人为判断边界,由于红外热像比可见光更易受噪声和环境影响^[16],所以真实缺陷边界和人为判断边界仍然存在误差。

本文针对模拟真实饰面砖系统考虑了空鼓面积、形状及位置等因素,同时制备了一批试件,在不同环境条件和距离下对试件进行拍摄,建立相应的红外图像数据库,其中缺陷区域与正常区域的标定依据为预设理论值,而非人为主观判断,避免了人为因素与红外图像噪声导致的误差。同时选用深度学习中实例分割模型以区分同类中的不同个体,并对实例分割中Mask R-CNN和YOLACT模型在识别空鼓区域和正常区域的表现做出比较,主要包括边界框结果和分割结果精度,以及模型复杂度和计算效率。在此基础上还自主开发程序以实现每块饰面砖空鼓率的自动可视化,为局部区域的脱黏程度评估提供定量依据。

1 试件设计与红外拍摄

1.1 试件设计

针对空鼓区域面积、形状与位置设计3组模拟真实饰面砖系统的试件和1组对照试件,空鼓区域示意图和几何信息如图1和表1所示。其中每组试件由3×3的单个饰面砖排列而成,系统基层底板为C30混凝土,黏结砂浆层与灰缝采用1:2的水泥砂




图1 空鼓布置示意图

表 1 空鼓的几何尺寸

形状	几何尺寸	空鼓率/%
	25 mm×25 mm	6.25
	75 mm×75 mm	56.25
	50 mm×50 mm	25.00
	75 mm×50 mm	37.50
	50 mm×25 mm	12.50
	对角线 50 mm	12.50
	直径 50 mm	19.60
	边长 25 mm	15.90
	边长 25 mm	30.20

浆，饰面砖为 100 mm×100 mm 白色哑光釉面饰面砖，相关几何尺寸如图 2 所示。基层底板在标准养护室（温度(20±2)℃，湿度 95%）内养护 28 d 后取出，在表面充分润湿后铺设厚度为 6 mm 的黏结砂浆层以及背面固定 2 mm 厚发泡苯乙烯板的饰面砖，如图 2（c）所示。面砖铺设 24 h 后，使用水泥砂浆完成灰缝制作。需要说明的是，考虑到空鼓通常位于饰面砖与黏结砂浆层界面^[17-18]，而空鼓区域内常充斥空气，因此试验采用与空气热传导性能相近的发泡苯乙烯板来模拟空鼓区域。试件制作完成后，在室内放置 28 d 后再进行红外拍摄。




图 2 试件

1.2 红外拍摄

使用 FLIR E95 红外热像仪进行拍摄，分辨率为 464×348。根据《JGJ/T 277-2012 红外热像法检测建筑外墙饰面粘结质量技术规程》规定^[19]，白色哑光饰面砖发射率设定为 0.92。拍摄时间为夏季午后，试件向阳放置（图 3）。拍摄前，测量气温和相对湿度，并输入红外热像仪以进行热辐射校正。拍摄在不同天气（晴、多云、阴）以及距离条件下进行，以增加数据多样性，进一步提高模型的泛化能力^[11]。



图 3 采集热像图

2 正常区域与空鼓区域的实例分割

2.1 数据集

使用 Labelme 对获得的红外热像图进行像素级注释^[20]，注释对象包括空鼓区域与饰面砖正常黏结区，如图 4 所示。在注释时，空鼓区与正常黏结区的边界并非通过人为判定，而是在获得饰面砖边界像素坐标后，根据图 1 与表 1 的几何关系进行计算后予以确定。图像数量与实例数量见表 2。为了训练模型在训练过程中调整模型参数以及评估模型在实际场景中的性能和准确性，上述图像与其注释文件可按 7:2:1 比例被随机划分为训练集、验证集与测试集，相关数据集的注释文件被整合转换为




图 4 注释后的图像示例

有利于实例分割和模型评估的 COCO 格式。此外, 因本研究重点为空鼓区的面积占比, 为避免过度的数据增强造成标签偏离原始位置, 进而影响区域预测, 在每个训练周期中仅采用随机翻转作为数据在线增强手段, 以增加训练数据的多样性, 来进一步提高模型性能和泛化能力。

表 2 数据集的图像数与实例数 单位: 个

项目	图像数	实例数
训练集	420	1 266
验证集	120	230
测试集	60	190

2.2 模型架构

实例分割的两阶段模型首先在输入图像的特征图上提出候选对象边界框, 然后对这些候选区域进行分类、边界框回归以及掩码分割, 通常能提供更高的精度和掩码质量, 但一定程度上也会牺牲一定的处理速度。一阶段模型则直接预测类别、边界框和掩码, 无须生成候选区域, 在推理时更加高效, 适合需要实时处理的场景。由于在实例分割领域难以兼顾处理速度和性能^[21], 须同时考虑模型在不同任务时的表现, 所以本文选取两阶段模型和一阶段模型中典型且先进的模型进行测试。

2.2.1 Mask R-CNN 模型

Mask R-CNN 是由 He 等^[22]提出的用于目标检测与实例分割的两阶段模型, 是对 Faster R-CNN^[23]的扩展。Mask R-CNN 网络结构如图 5 所示, 主要包括 3 个模块: 特征提取网络 (Backbone)、候选区域生成模块 (RPN) 和任务预测头 (Head)。本文选用残差网络 (Residual Network, ResNet) 结

合特征金字塔网络 (Feature Pyramid Network, FPN) 作为骨干网络, 以提取多尺度的特征表示。其中, ResNet 通过深度残差学习引入跳跃连接, 以缓解梯度消失问题, 确保深层网络训练稳定性^[24]。FPN 则通过自上而下的特征融合路径与横向连接实现不同尺度特征的整合, 以提升对小目标的检测性能^[25]。区域提议网络 (Region Proposal Network, RPN) 通过滑动窗口在特征图上生成多个锚框, 并对其进行前景/背景分类和边界框回归, 进一步生成高质量的目标候选区域, 然后传递给后续网络。为消除传统兴趣区域池化 (ROI Pooling) 过程中因量化误差导致的特征对齐问题, Mask R-CNN 引入区域兴趣对齐 (ROI Align) 操作, 通过双线性插值实现精确的候选区域特征映射, 有效提升了分割任务的准确性。最终, 经过 ROI Align 处理的候选区域特征被送入两个并行分支, 一条分支用于目标的分类与边界框回归, 另一条则生成目标的二值掩码, 实现像素级分割。

2.2.2 YOLACT 模型

YOLACT 是由 Bolya 等^[21]提出的一种一阶段实时实例分割模型, 它将实例分割任务分为两个并行子任务: 生成全局原型掩码与预测每个实例的掩码系数, 然后通过原型掩码与掩码系数线性组合生成实例掩码。由于此过程不依赖于重新池化, 且两个子任务可并行运算, 因此能生成高质量的掩码和实现快速计算。YOLACT 网络架构如图 6 所示, 主要包括特征提取网络、原型生成分支 (Protonet)、目标检测头以及后处理部分。本文选用 ResNet 结合 FPN 作为骨干网络, 以提取多尺度的特征表示。这些特征图既用于目标检测分支生成目标框、类别




图 5 Mask R-CNN 模型架构




图6 YOLACT 模型架构

及掩码系数的预测,也作为输入传递到 Protonet 中生成的原型掩码。需注意在 YOLACT 中, Protonet 实现为全卷积网络(Fully Convolutional Network, FCN),用于生成一组固定数量的全局原型掩码,这些掩码独立于具体实例类别或位置,表示图像中的通用分割特征,且这些掩码都基于每张输入图像单独生成,而不是从整个数据集中学习到的固定模板,因此能灵活适应不同场景中的特征分布。另外在目标检测分支中,非极大值抑制(Non-Maximum Suppression, NMS)应用于抑制重复检测。最后原型掩码与掩码系数线性组合生成实例掩码,并通过裁减和阈值化得到明确清晰的分割结果。

2.3 实施过程

所有模型均使用 ImageNet^[26]预训练权重,在 GPU (NVIDIA GeForce GTX 1060 6 GB) 上进行以批量大小为 1 的训练,训练与测试中采用 PyTorch 结合 MMDetection^[27]框架。以 0.001 初始学习率采用随机梯度下降方法(Stochastic Gradient Descent, SGD)进行 25 000 次迭代训练,并分别在第 17 000 次和第 23 000 次迭代时,将学习率除以 10,权重衰减为 0.000 1,动量为 0.9。所有模型的图像输入尺寸均设置为 (550, 550)。

2.4 评价指标

为了全面评估实例分割模型的性能,通常需要考虑在不同交并比(Intersection over Union, IoU)阈值、不同物体大小条件下的平均精度(Average Precision, AP)等多项性能指标。其中, IoU 是衡量预测边界框与真实物体重叠程度的关键指标。在标准 COCO 的评价指标中,通常需考虑 AP_{50} (IoU>50%)、 AP_{75} (IoU>75%) 以及均值平均精度 (Mean

Average Precision, mAP), 其中 mAP 是主要评价指标。物体大小是目标检测中的一个关键因素,由于通常模型都能够高效检测较大物体,但对较小物体则表现不佳^[11]。此外,标准 COCO 指标还考虑了按物体大小分类的均值平均精度:小物体 (AP_S , $S \leq 32^2$)、中等物体 (AP_M , $32^2 < S < 96^2$)、大物体 (AP_L , $S \geq 96^2$), 其中, S 表示面积。更多关于各个指标的详细计算方法可参考文献[28]。

另一方面,快速且高效的模型能够更好地满足实际应用需求,尤其是在需要实时处理的场景中。同时,降低模型的复杂性也能够进一步提高计算效率,使模型更易于部署和应用。因此,采用 Params、Frames Per Second (FPS) 以及 Floating-point Operations (FLOPs) 来衡量模型复杂度与计算效率,其中 FPS 是主要评价指标。

2.5 结果与讨论

2.5.1 模型的训练结果

所有模型在训练集上的损失 (Loss) 及验证集上的均值平均精度 (mAP) 如图 7 所示,可观察到所有模型损失曲线 (Loss) 均已下降到一个平稳水平,而均值平均精度曲线 (mAP) 在很长一段时期内均已平稳或不再显著提升,说明模型已达到收敛,可用于后续测试。

2.5.2 实例分割任务的测试结果

从表 3 分割结果中可观察到,当使用相同的主干网络时,Mask R-CNN 系列模型的精度普遍高于 YOLACT 系列模型。当主干网络为 ResNet50 时,Mask R-CNN 模型比 YOLACT 模型的 mAP 值高 0.108;当主干网络为 ResNet101 时,差值为 0.084。当 IoU=50%时,两个系列模型的 AP_{50} 值差异不大;




图 7 模型训练结果

表 3 各模型的分割结果和目标框结果

结果	模型	AP ₅₀	AP ₇₅	mAP	AP _S	AP _M	AP _L
分割结果	Mask R-CNN-ResNet50-FPN	0.982	0.944	0.849	0.500	0.737	0.869
	Mask R-CNN-ResNet101-FPN	0.973	0.960	0.855	0.650	0.744	0.872
	YOLACT-ResNet50-FPN	0.965	0.839	0.741	0.701	0.651	0.717
	YOLACT-ResNet101-FPN	0.970	0.869	0.771	0.404	0.645	0.788
边界框结果	Mask R-CNN-ResNet50-FPN	0.982	0.953	0.852	0.625	0.759	0.871
	Mask R-CNN-ResNet101-FPN	0.973	0.960	0.857	0.725	0.757	0.870
	YOLACT-ResNet50-FPN	0.965	0.831	0.683	0.725	0.647	0.645
	YOLACT-ResNet101-FPN	0.970	0.810	0.680	0.353	0.577	0.696

注: 表中加粗数据为各指标中表现最好的模型精度。

但当 IoU=75%时, Mask R-CNN 系列模型的 AP₇₅ 值全部优于 YOLACT 系列模型, 并且主干网络为 ResNet50 与 ResNet101 的 Mask R-CNN 模型的 AP₇₅ 值分别较 YOLACT 模型高了 0.105 与 0.091。在对不同尺寸目标检测上, Mask R-CNN 系列模型在中等目标和大目标的检测上略好于 YOLACT 系列模型。对于 ResNet50 与 ResNet101 主干网络,

中等目标 AP_M 差值分别为 0.086 与 0.099, 大目标 AP_L 差值分别为 0.152 与 0.084; 但小目标检测上的两个模型相差较大, YOLACT-ResNet50-FPN 表现最好, 其 AP_S 值为 0.701, 并且相较 Mask R-CNN-ResNet50-FPN 高了 0.201。在同系列的模型中, 主干网络层数的加深对模型精度影响程度不大。对于 Mask R-CNN 模型来说, 主干网络为 ResNet101 模

型比主干网络为 ResNet50 模型的 mAP 高 0.006, 而 YOLACT 模型差值则为 0.030。

从表 3 各模型边界框预测结果来看, 整体趋势与分割结果相似, 总体上 Mask R-CNN-ResNet101-FPN 模型的精度要略好于其他模型。另外, 相对于各模型在 COCO 数据集上的表现, 由于检测对象种类相对较少, 任务较简单, 各个模型在本数据集上的精度都较好。图 8 为 YOLACT-ResNet50-FPN 和 Mask R-CNN-ResNet101-FPN 模型的部分预测结果, 图中多数空鼓与饰面砖正常区域都被准确分割, 但对于图 1(c) 所示的不规则空鼓, 模型预测图像与理论空鼓区域略有差别, 原因可能与红外热像对部分复杂边界不敏感有关。

2.5.3 模型复杂度与计算效率分析

为比较各模型的复杂度与计算效率, 将各模型对应的 Params、FPS 与 FLOPs 值列于表 4 中。

Params 指模型中所有可学习的参数总数, 参数越多意味着模型越复杂, 同时也意味着更多的存

储需求。Mask R-CNN 模型的参数数量显著多于 YOLACT 模型, 其中, Mask R-CNN-ResNet50-FPN 比 YOLACT-ResNet50-FPN 多了 26.6%, 主干网络为 ResNet101 时, 两者相差 17.2%。主干网络层数加深大大增加了参数数量, 相较于 ResNet50, 主干网络为 ResNet101 的 Mask R-CNN 模型增加了 43.2%, YOLACT 模型则增加了 54.7%。

FPS 衡量模型每秒能够处理并输出结果的图像帧数。在实时处理的场景中, FPS 是非常重要的性能指标, 高 FPS 意味着模型具有更高的计算效率, 此特点对资源受限环境尤其重要。从表 4 可见, YOLACT 模型效率显著高于 Mask R-CNN 模型, 在同一主干网络情况下, 其 FPS 值接近于 Mask R-CNN 模型的 3 倍; 但主干网络层数的加深在一定程度上也造成了其 FPS 值的下降。尽管 YOLACT-ResNet50-FPN 的 FPS 值还没有达到实时示例分割的标准 (FPS>30), 但由于 FPS 值与硬件关联性较强, 且考虑到本文计算只采用了 1 个 GPU 的情况,




图 8 模型测试结果

表 4 模型的计算效率与复杂度

模型	Params	FPS	FLOPs
Mask R-CNN-ResNet50-FPN	43.977×10^6	6.7	234.496×10^9
Mask R-CNN-ResNet101-FPN	62.969×10^6	5.1	301.056×10^9
YOLACT-ResNet50-FPN	34.734×10^6	20.7	61.524×10^9
YOLACT-ResNet101-FPN	53.726×10^6	15.2	84.789×10^9

因此仍有较大的性能提升空间。

FLOPs 反映模型计算所需计算量, FLOPs 值越大意味着模型计算成本越高。从表 4 可见, Mask R-CNN 模型的 FLOPs 数量比较庞大, 其 FLOPs 值约为 YOLACT 模型的 4 倍。综上所述, YOLACT-ResNet50-FPN 模型在模型复杂度与计算效率上更为优越。

为了综合考察模型性能与计算效率, 各模型的 mAP 与 FPS 的关系如图 9 所示。由图可见, 尽管 YOLACT-ResNet50-FPN 模型 mAP 不是最高, 但它却仍可以较小代价换取数倍的计算效率提升, 并且模型性能依然保持在较高水平, 因此本文最终选用 YOLACT-ResNet50-FPN 模型进行后续研究。




图9 模型的 mAP—FPS 比较结果

3 单块面砖的空鼓比例可视化

3.1 空鼓区域与所属饰面砖的匹配

在实例分割模型输出中, 各个被识别的空鼓区域与正常区域的类别、掩码、存储图像路径等信息均被分别记录存储在 pickle 文件。由于一张图像内存在多个空鼓区域与正常区域, 因此实现空鼓率的自动化计算与可视化须首先匹配空鼓区域与其所

属的饰面砖。本文通过自主研发的 Python 脚本实现空鼓区域匹配与空鼓率可视化, 核心逻辑如下:

(1) 统计各实例非零像素数, 计算给定掩码区域的面积; (2) 遍历所有空鼓区域与正常区域掩码, 计算其质心; (3) 通过欧几里得距离公式找到离当前空鼓掩码最近的正常掩码; (4) 记录配对关系; (5) 针对每组空鼓掩码与正常区域掩码, 进行空鼓率计算; (6) 对每块面砖空鼓率实现可视化。具体来说, 假设掩码中非零像素点共有 N 个, 其坐标为 $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, 则质心 (x_c, y_c) 算式如下:

$$x_c = \frac{1}{N} \sum_{i=1}^N x_i, y_c = \frac{1}{N} \sum_{i=1}^N y_i \quad (1)$$

式中: N 为掩码中非零像素的总数; x_i 、 y_i 分别为第 i 个非零像素的列坐标和行坐标。

在得到各实例掩码的质心后, 通过式 (2) 计算质心间距离, 寻找每个空鼓区域相对距离 (D) 最近的正常区域, 完成匹配, 如图 10 所示。

$$D = \sqrt{(x_c^D - x_c^N)^2 + (y_c^D - y_c^N)^2} \quad (2)$$

式中: x_c^D 、 y_c^D 为空鼓区域的质心坐标; x_c^N 、 y_c^N 为正常区域的质心坐标。

完成配对后, 通过式 (3) 计算得到每块饰面砖的空鼓率 (R)。

$$R = \frac{A_D}{A_D + A_N} \quad (3)$$

式中: A_D 为空鼓区域掩码面积; A_N 为正常区域掩码面积。

3.2 空鼓率可视化

如图 11 所示, 通过上述空鼓与其所属饰面砖的匹配以及空鼓率计算后, 每块面砖空鼓率被标记在饰面砖中心, 同时空鼓区域与饰面砖的边界分别




图10 匹配过程示意图




图 11 空鼓率可视化示例

用不同颜色予以标记。对比图 11 中各空鼓所占饰面砖的理论面积比,可发现计算得到的空鼓率还是能够比较准确地反映真实情况。

4 结论

建立近远景的饰面砖空鼓红外图像数据库,评估了不同深度学习模型在饰面砖空鼓识别上的适用性,并对识别结果进行后处理,实现每块饰面砖空鼓率的可视化。

(1) 两阶段模型 Mask R-CNN 与一阶段模型 YOLACT 均能在空鼓与饰面砖的实例分割任务中达到较好精度。其中,Mask R-CNN 模型最高达到 0.855 的平均分割精度,YOLACT 模型则为 0.771。

(2) 在模型复杂度及计算效率方面,YOLACT 模型的 FPS 值几乎是 Mask R-CNN 模型的 3 倍,且 YOLACT 模型参数量和计算量也远远小于 Mask R-CNN 模型,在需要实时检测或将模型部署于移动端情况下,YOLACT 模型更具优越性。

(3) 鉴于空鼓率会显著影响饰面砖黏结性能,本文通过实例分割模型与研发的 Python 脚本实现了每块饰面砖空鼓率的计算及可视化,以及可区分同类个体的缺陷区域和正常区域的检测识别,能为饰面砖空鼓的定量检测与每块饰面砖的脱黏程度

评估提供依据。

综上所述,本文方法可减少人工工作量和辅助判断脱黏区域掉落的风险。下一步可以进行以下研究来扩大该方法的适用性:数据集数量和质量会影响深度学习模型的性能,因此增加数据集图像数量及增加其他常见外墙饰面砖病害类别,可提高模型泛化能力。另外,因建筑阴影、冷热源及材质等因素会影响红外热成像,所以拍摄时应避免上述因素的干扰,或进行相关研究来评价其影响程度。同时,可尝试使用搭载红外热成像镜头的无人机进行巡检,并将上述实例分割模型与 Python 脚本封装成应用程序,进一步推动上述方法的工程应用。

参考文献:

- [1] 冯力强,王欢祥,晏大玮,等. 红外热像法检测建筑外墙饰面层内部缺陷试验研究[J]. 土木工程学报, 2014, 47(6):51-56.
- [2] PEREIRA C, DE BRITO J, SILVESTRE J D. Contribution of humidity to the degradation of facade claddings in current buildings[J]. Engineering failure analysis, 2018, 90:103-115.
- [3] 刘强,胡玉琨,朱红光,等. 基于红外检测的外墙饰面砖粘结[J]. 建筑技术, 2015, 46(10):924-926.
- [4] 庞森,王长军,王健,等. 工程渗漏检测技术研究进展

- 及展望[J]. 工业建筑, 2023, 53(增刊 2):883-888.
- [5] BARBOSA M T G, ROSSE V J, LAURINDO N G. Thermography evaluation strategy proposal due moisture damage on building facades[J]. Journal of building engineering, 2021, 43:102555.
- [6] 张俊悦, 史夏杰, 李光明, 等. 红外热成像技术在古建安全评价中的应用[J]. 工业建筑, 2014(增刊 1):219-222, 192.
- [7] HATIR M E, INCE I, BOZKURT F. Investigation of the effect of microclimatic environment in historical buildings *via* infrared thermography[J]. Journal of building engineering, 2022, 57:104916.
- [8] GARRIDO I, BARREIRA E, ALMEIDA R M S F, et al. Introduction of active thermography and automatic defect segmentation in the thermographic inspection of specimens of ceramic tiling for building facades[J]. Infrared physics & technology, 2022, 121:104012.
- [9] LAI W W L, LEE K K, POON C S. Validation of size estimation of debonds in external wall's composite finishes *via* passive infrared thermography and a gradient algorithm[J]. Construction and building materials, 2015, 87(15):113-124.
- [10] LI Q X, PENG X, ZHONG X G, et al. Quantitative identification of debonding defects in building facades based on UAV-thermography using a two-stage network integrating dual attention mechanism[J]. Infrared physics & technology, 2024, 138:105241.
- [11] CAO M T. Drone-assisted segmentation of tile peeling on building facades using a deep learning model[J]. Journal of building engineering, 2023, 80:108063.
- [12] 米庆仁. 基于深度学习多模态 RGB-T 图像融合的建筑外墙缺陷检测研究[D]. 哈尔滨: 哈尔滨工业大学, 2024.
- [13] 刘颖. 基于深度学习的红外墙体裂缝高精度检测技术研究[D]. 北京: 北京邮电大学, 2021.
- [14] 蔡茹莹. 基于计算机视觉的建筑物外墙裂缝智能检测及其几何量化评级研究[D]. 深圳: 深圳大学, 2022.
- [15] MELO A C, COSTA E SILVA A J, TORRES S M, et al. Influence of the contact area in the adherence of mortar: ceramic tiles interface[J]. Construction and building materials, 2020, 243:118274.
- [16] GARRIDO I, LAGÜELA S, OTERO R, et al. Thermographic methodologies used in infrastructure inspection: a review-post-processing procedures[J]. Applied energy, 2020, 266:114857.
- [17] CURCI H C F, DE ANDRADE R P, MARANHÃO F L, et al. Analysis of adhered tiling systems based on experimental evaluation and numerical modeling[J]. Construction and building materials, 2022, 325:126746.
- [18] WINNEFELD F, KAUFMANN J, HACK E, et al. Moisture induced length changes of tile adhesive mortars and their impact on adhesion strength[J]. Construction and building materials, 2012, 30:426-438.
- [19] 中华人民共和国住房和城乡建设部. 红外热像法检测建筑外墙饰面粘结质量技术规程: JGJ/T 277-2012[S]. 北京: 中国建筑工业出版社, 2012.
- [20] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International journal of computer vision, 2008, 77(1):157-173.
- [21] BOLYA D, ZHOU C, XIAO F Y, et al. Yolact: real-time instance segmentation[C]//IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, South Korea. 2019:9156-9165.
- [22] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask r-CNN[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Hawaii, USA. 2017: 2961-2969.
- [23] REN S, HE K, 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.
- [24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Las Vegas, USA. 2016:770-778.
- [25] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Hawaii, USA. 2017:2117-2125.
- [26] DENG J, DONG W, SOCHER R, et al. Imagenet: a large-scale hierarchical image database[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Miami, USA. 2009:248-255.
- [27] CHEN K, WANG J Q, PANG J M, et al. MMDetection: open MMLab detection toolbox and benchmark[EB/OL]. [2024-03-21]. <https://arxiv.org/abs/1906.07155v1>.
- [28] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context[C]//13th European Conference on Computer Vision (ECCV). Zurich, Switzerland. 2014:740-755.