

doi: 10.16104/j.issn.1673-1891.2025.01.005

蒸压加气混凝土砌块装配式多层建筑裂缝识别方法

左斌峰¹, 吴慧琼¹, 沈 阳²

(1. 铜陵职业技术学院机械工程系, 安徽 铜陵 244061; 2. 湖北省工业建筑集团第三建筑工程有限公司, 湖北 武汉, 430070)

摘要: 蒸压加气混凝土砌块装配式多层建筑图像背景包括不同的建筑材料、颜色、纹理等, 这些背景信息导致不同形态的裂缝特征不显著、裂缝识别性能不佳。基于此, 提出基于 SR-UNet 的蒸压加气混凝土砌块装配式多层建筑裂缝识别方法。引入 Lucas-Kanade 方法对裂缝图像的特征点进行跟踪, 确定裂缝特征点在当前帧图像中的具体位置; 构建 SR-UNet 网络分割模型对包含裂缝特征点的图像进行分割, 并通过密集残差连接模块和注意力模块处理输入的图像, 得到分割后的特征图像; 通过边界损失和区域广义 Dice 损失构成整体损失函数, 计算分割图像与真实图像之间的差异, 并利用反向传播算法优化模型参数, 实现装配式多层建筑裂缝的识别。实验结果表明: 所提方法对装配式多层建筑裂缝的识别准确率最高值为 98, 优于对比的 3 种方法, 且对光线较暗环境下的裂缝图像以及细小裂缝图像进行识别时, 均能完整识别裂缝图像。

关键词: 蒸压加气混凝土砌块; 装配式建筑; 建筑裂缝; 图像识别; SR-UNet; Unet

中图分类号: TU522.32 文献标志码: A 文章编号: 1673-1891(2025)01-0031-08

Crack Identification Method of Autoclaved Aerated Concrete Block Fabricated Multi-storey Building

ZUO Binfeng¹, WU Huiqiong¹, SHEN Yang²

(1. Department of Mechanical and Electrical Engineering, Tongling Polytechnic, Tongling 244061, Anhui, China;
2. Hubei Provincial Industrial Construction Group Third Construction Engineering Co., Ltd.,
Wuhan 430070, Hubei, China)

Abstract: The image background of autoclaved aerated concrete block prefabricated multi story buildings includes different building materials, colors, textures, etc. These background information results in insignificant crack features of different shapes, leading to poor crack recognition performance. Based on this, a crack identification method of autoclaved aerated concrete block fabricated multi-storey building based on SR-UNet is proposed. Lucas Kanade method is introduced to track the feature points of crack images and determine the specific positions of crack feature points in the current frame image. SR-UNet network segmentation model is built to segment images containing crack feature points, and process the input images through dense residual connection modules and attention modules to obtain segmented feature images. By using boundary loss and region generalized Dice loss, an overall loss function is formed, the difference between the segmented image and the real image is calculated, and the model parameters are optimized using backpropagation algorithm to achieve the recognition of cracks in prefabricated multi story buildings. The experimental results show that the proposed method has the highest recognition accuracy of 98% for cracks in prefabricated multi story buildings,

收稿日期: 2024-12-09

基金项目: 2023 年度安徽省高校自然科学研究重点项目(2023AH052893)。

作者简介: 左斌峰(1982—), 男, 安徽枞阳人, 讲师, 硕士, 研究方向: 建筑与房地产, e-mail: zuolang@qq.com。

which is superior to the three compared methods. Moreover, it can fully recognize crack images in low light environments and small crack images.

Keywords: pre-stressed aerated concrete block; panelized building; building crack; image recognition; SR-UNet; Unet

0 引言

蒸压加气混凝土砌块是一种轻质多孔的建筑材料,在装配式多层建筑领域得到了广泛应用^[1]。然而,在实际使用过程中,受材料性能等多种因素影响,采用蒸压加气混凝土砌块的装配式多层建筑常常会出现裂缝,这可能降低蒸压加气混凝土砌块结构强度,带来安全隐患,因此,对建筑裂缝进行识别对保障建筑安全性和耐久性至关重要。传统的裂缝识别方法主要依赖人工巡检,存在效率低、主观性强、难以全面覆盖等缺点^[2],因此,需要设计一种适用于蒸压加气混凝土砌块装配式多层建筑的裂缝识别方法。

蔡晨宁等^[3]通过比较损伤前后导电层边界电压变化,利用TV-SB正则化算法,重建电导率变化分布图像以识别裂缝,从而实现对裂缝的识别,但该方法仅能获取裂缝的大致位置,对于裂缝的识别容易出现漏检。王文斌等^[4]融合U-Net和VGG-16构造适用于混凝土裂缝识别的模型,利用形态学运算进一步优化了裂缝识别的结果,该方法在实际应用中表现出较小的平均偏差,但在面对细小裂缝时,容易出现漏检问题。李秀丽等^[5]融合了注意力机制和U-Net架构,增强了模型在复杂场景下的识别能力,提升裂缝识别的泛化性,但在识别细小的裂缝时,由于其特征不显著,容易造成漏检。王剑等^[6]通过语义分割方法实现裂缝图像的精准分割,这种方法提高了裂缝识别的精度,但对于细小裂缝或复杂背景下的裂缝时,由于这些裂缝的特征往往较为模糊,因此仍然存在一定的漏检风险。

针对上述问题,本文提出了一种基于SR-UNet网络的蒸压加气混凝土砌块装配式多层建筑裂缝识别方法。该方法融合了Lucas-Kanade特征点跟

踪技术与SR-UNet网络分割模型,首先利用Lucas-Kanade方法精确定位裂缝特征点在图像中的当前位置,随后利用SR-UNet模型对含特征点的图像执行分割任务。模型内部集成了密集残差连接和注意力机制以优化图像处理,输出分割后的特征图像。为了提升识别效果,该方法结合了边界损失与区域广义Dice损失的复合损失函数,并借助反向传播算法迭代优化模型参数,确保裂缝识别的准确性和泛化性能。以期突破传统单一特征识别的局限,为蒸压加气混凝土砌块装配式多层建筑的安全监测提供高效的技术手段。

1 基于SR-UNet网络的蒸压加气混凝土砌块装配式多层建筑裂缝识别

1.1 基于光流估计确定裂缝特征点具体位置

通过无人机对装配式多层建筑进行图像视频的采集,如果待识别的图像视频存在抖动,裂缝的位置和形态可能会因此变得模糊^[7],为了解决这个问题,本文引入了Lucas-Kanade方法。设 $I(x, y, t)$ 为待识别图像在 t 时刻的灰度值,其中, x 和 y 分别代表待识别图像中裂缝的像素点横向和纵向位置, t 代表时间,基于光流假设推导出像素点在横向和纵向2个方向上的位移情况,以及裂缝图像灰度值随时间变化的关系,如式(1)所示。

$$I_x \times u + I_y \times v = -\frac{\partial S}{\partial t} \quad (1)$$

式中: I_x 表示图像在 x 方向的梯度; I_y 表示图像在 y 方向的梯度; u 表示像素点在 x 方向的位移; v 表示像素点在 y 方向的位移; $\frac{\partial S}{\partial t}$ 表示灰度值随时间的变化。

均衡化可以对待识别裂缝图像的灰度进行变换^[8],灰度值经分布函数映射后的值如式(2)所示。

$$S_i = \sum_{i=0}^I \frac{n_i}{n}, i = 0, 1, 2, \dots, I - 1 \quad (2)$$

式中: S_i 表示当前灰度值经该分布函数映射后的值; n_i 表示装配式多层建筑裂缝图像像素数量; n 表示装配式多层建筑裂缝图像像素总数。

在裂缝图像局部邻域内最小二乘法拟合中,选取一个小的局部邻域,假设在该邻域内的像素点的灰度值服从匀速运动,通过最小二乘法可以得到一个线性方程组,如式(3)所示。

$$\begin{bmatrix} I_{x1} & I_{y1} \\ I_{x2} & I_{y2} \\ \vdots & \vdots \\ I_{xn} & I_{yn} \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} -\frac{\partial S}{\partial t_1} \\ -\frac{\partial S}{\partial t_2} \\ \vdots \\ -\frac{\partial S}{\partial t_n} \end{bmatrix} \quad (3)$$

根据视频数据中某一帧图像检测到的裂缝图像特征点,在当前帧图像中搜索与之对应的特征点,采用 Lucas-Kanade 光流法来进行光流估计,利用已知的数字视频数据前一帧裂缝图像与当前帧裂缝图像之间的位置关系,计算出像素点的移动情况,从而确定裂缝特征点在当前帧图像中的具体位置。

1.2 构建 SR-UNet 网络分割模型

由于蒸压加气混凝土砌块墙体的材料特性及干缩变形等多种因素^[9],导致得到的裂缝特征点在形态和尺寸上呈现出了多样性^[10],为了融合这些不同尺度的裂缝特征点,采用了 SR-UNet 网络分割模型对包含裂缝特征点的当前帧的图像进行分割。将图像输入到 SR-UNet 网络中,输出的是一个与输入图像大小相同的分割图(图 1),其中每个像素点都被分类为裂缝或非裂缝。

如图 1 所示,该模型具有独特的编码器-解码器 U 型设计,其中,编码器部分集成了卷积操作与池化操作,整个过程共经过 5 次卷积操作,采用 3×3 的卷积层对包含裂缝特征点的当前帧的图像进行处理,如式(4)所示。

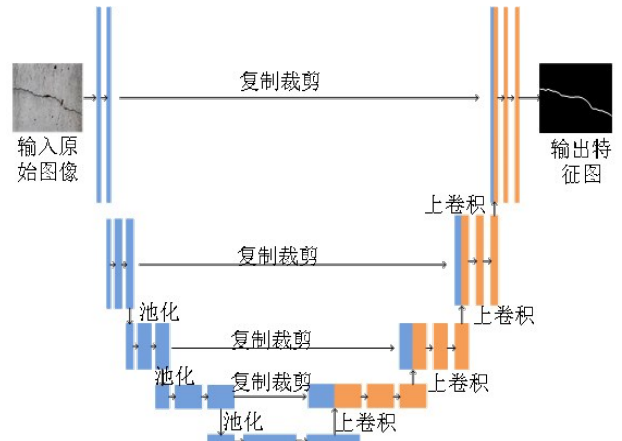


图 1 SR-UNet 网络分割模型

$$o = \frac{2p - k - (k - 1)(d - 1)}{s} - \frac{\partial S}{\partial t_n} \quad (4)$$

式中: o 表示输出裂缝特征图像边长; p 表示补 0 数; k 表示 SR-UNet 网络分割模型卷积核; d 表示裂缝特征图像扩张率; s 表示 SR-UNet 网络分割模型卷积步长。

由于堆叠更多卷积层会导致 SR-UNet 网络分割模型性能的退化^[11],为了解决这一问题,引入了密集残差连接模块,经过多次残差连接的 3 个卷积层,如式(5)所示。

$$K = \left\lfloor \frac{\log_2(C)}{o} + \frac{k}{o} \right\rfloor \quad (5)$$

式中: K 表示输出的裂缝图像特征; C 表示裂缝图像特征通道数。

密集残差连接模块主要负责构建密集的连接路径和残差学习^[12],而注意力模块负责让 SR-UNet 网络分割模型关注裂缝图像关键区域^[13]。注意力模块首先将空间维度压缩为单维向量,形成维度为 $1 \times 1 \times C$ 的通道描述符,随后,注意力模块采用卷积层来处理这些通道级别的特征,以跨通道的方式得到局部相互作用的信息,并根据不同输入特征的具体情况调整相邻通道间的交互范围,这二者的计算如公式(6)所示。

$$\begin{cases} M_k(K) = \sigma \left(M_{LP} \left(A_p(K) + M_{LP} \left(M_p(K) \right) \right) \right) \\ M_i(K) = \sigma \left\{ f \left(\left[A_p(K); M_p(K) \right] \right) \right\} \end{cases} \quad (6)$$

式中: M_k 表示模型的空间注意力机制; σ 表示激活函数; M_{LP} 表示模型的多层感知器; A_p 表示平均池化操作; M_p 表示最大池化操作; M_l 表示模型的通道注意力机制; f 表示卷积层。

对输入的装配式多层建筑裂缝特征图像, 本文通过平均池化和最大池化操作, 得到 2 个池化后的裂缝特征图。进入解码器阶段后, 通过转置卷积操作, 裂缝特征图开始逐步还原至接近原始图像的大小。在这一过程中, 解码器与编码器之间采用了跳跃连接的方式, 使得深层网络能够融合浅层的裂缝特征信息, 每次转置卷积后, 解码器都会与编码器阶段相应尺寸的裂缝特征图进行叠加。随后, 网络继续通过卷积与转置卷积操作, 直至裂缝特征图完全恢复至原始图像的大小, 最终得到分割后的图像。

1.3 多层建筑裂缝的识别

损失函数通过计算分割图像与真实图像之间的差异, 并利用这些信息来调整 SR-UNet 网络分割模型参数。在选择损失函数时, 为了减少特征不平衡对识别结果的影响, 采用边界损失作为损失函数^[14], 将预测裂缝的边界轮廓与裂缝图像输出特征的边界轮廓之间的距离作为损失值, 如式(7)所示。

$$\vartheta(\theta) = \phi_o(K) s_\theta(K) \quad (7)$$

式中: $\vartheta(\theta)$ 表示边界损失函数; ϕ 表示最近距离; s_θ 表示预测图像的轮廓; $s_\theta(K)$ 表示特征图像轮廓指数函数。

由于类的不平衡, 边界损失可能陷入局部最小值^[15], 因此引入区域广义 Dice 损失, 联合构成损失函数。在此过程中, 需要考虑学习率的变化对于裂缝识别的影响, 因此, 引入 L1 损失函数, 如公式(8)所示。

$$\begin{cases} \vartheta_{\text{GBL}}(\theta) = \alpha\vartheta(\theta) + (1 - \vartheta)\vartheta(\theta) \\ \vartheta_{\text{SR}} = \frac{1}{|I|} \sum_{i=1}^N [I_{\text{SR}}(i) - I_{\text{HR}}(i)] \end{cases} \quad (8)$$

式中: $\vartheta_{\text{GBL}}(\theta)$ 表示语义分割损失函数; α 表示模型的学习率; ϑ_{SR} 表示超分辨率损失函数; I 表示高清裂缝图

像像素点集; $I_{\text{SR}}(i)$ 表示重构的装配式多层建筑裂缝图像; $I_{\text{HR}}(i)$ 表示原始的装配式多层建筑裂缝图像。

通过权重参数, 将语义分割损失函数和超分辨率损失函数通过权重系数结合起来, 得到整体损失值, 如公式(9)所示。

$$\vartheta = (1 - \beta)\vartheta_{\text{SR}} + \beta\vartheta_{\text{GBL}} \quad (9)$$

式中: ϑ 表示整体损失值; β 表示权重系数。

将计算得到的整体损失值通过反向传播算法将误差传递给 SR-UNet 网络分割模型的每一层, 并更新模型参数, 将待识别的建筑裂缝图像输入到更新好的模型中, 模型会根据输入图像生成分割结果, 即识别出图像中的裂缝区域, 从而实现建筑裂缝的识别。

2 模拟实验与结果分析

2.1 硬件参数与软件环境

本次裂缝识别实验所使用的硬件配备了 i7-10750H CPU、16 GB 内存、NVIDIA GeForce RTX 2060 GPU 以及 256 GB 显存的 NVIDIA GeForce RTX 4090 显卡。软件环境的配置如表 1 所示。

表 1 软件环境

名称	版本
PyTorch	1.13.0
NumPy	1.23.0
OpenCV-Python	4.6.0.66
Matplotlib	3.6.0
Pillow 图像处理库	9.2.0
Visdom	0.1.8.9
Scikit-image 图像处理库	0.19.2

实验选取了多源裂缝图像数据集为研究对象, 该数据集来源于多个知名的网络共享资源, 并经过筛选与整合, 确保了数据的质量和多样性。该数据集共包含了 3 800 张裂缝图像, 涵盖了不同类型的裂缝、不同的拍摄环境及不同的图像质量。由于数据集来源于多个不同的网络共享平台, 裂缝图像的

大小和格式可能存在差异。为了保证裂缝图像的一致性并避免失真,在裂缝图像四边粘贴灰色条带进行标准化处理,确保了所有图像在尺寸和格式上的一致性,为后续的图像处理和裂缝识别提供了便利。为了进一步增强裂缝图像数据的多样性,对装配式多层建筑裂缝图像进行采集,所采用的装备如图2所示。



图2 建筑裂缝采集系统

在装配式多层建筑裂缝图像采集过程中,本次实验分别采集了3种不同的拍摄距离的裂缝图像,以获得不同距离下的裂缝细节。在得到原始装配式多层建筑裂缝图像后,对裂缝图像进行筛选,仅保留具有代表性的装配式多层建筑裂缝图像,并对选中的裂缝图像进行了适当的裁剪和预处理,经过筛选与整合,最终形成了1个包含2 700张装配式多层建筑裂缝图像的数据集。

将上述2个裂缝图像数据集整合,得到1个包含6 500张裂缝图像的数据集,这些图像包含了多种拍摄角度,还涵盖了强光、阴天、阴影等多种光照条件,裂缝类型则涉及垂直、水平、倾斜、网状等多种形态,数据集中部分裂缝图片如图3所示。

在参数设置方面,将装配式多层建筑裂缝图像分辨率设置为640×480像素,裂缝图像的输入大小



图3 数据集部分图片

设置为4,膨胀系数设置为4,衰减率设置为16,激活函数的学习参数设置为0.25,训练迭代周期设置为100次,每完成1个迭代周期后,使用验证集对模型进行验证。

在本次实验中,选用Labelme作为数据集标注工具。实验数据集的构建流程如图4所示。




图4 图像标注

利用Labelme工具打开待标注的图片,选择创建多边形功能,随后沿着裂缝图像的轮廓进行细致描点,当所有点连接成闭合多边形,并标记裂缝图像对应的类别信息,便完成了标注工作。将标注完成的裂缝图像保存为Json格式,其中,点坐标记录了描绘裂缝轮廓的所有关键点,形状类型指明了标注的具体形式,而裂缝图片路径则确保了标注文件与原始图片之间的关联。为了满足分割网络对标签格式的要求,需要将Json格式的标注文件转换为灰度化的png格式图像,针对本研究中的裂缝识别任务,将装配式多层建筑裂缝图像的背景灰度值设置为0。

2.2 识别结果分析

为了验证SR-UNet网络分割模型的有效性,进行了消融实验,分别移除密集残差连接模块和注意力模块,观察模型性能的变化。并在相同的数据集和训练条件下,与传统U-Net分割模型进行了对比,引入准确率、交并比(IoU)和F1分数为评估指标,具体实验结果如表2所示。

由表2可知,完整SR-UNet模型在准确率、交并比(IoU)和F1分数上均表现出最优性能,分别达到了93.6%、87.3%和92.4。当移除密集残差连接模块后,模型性能显著下降,准确率降低了3.5%,IoU降低了4.3%,F1分数降低了3。移除注意力模块后,模型性能也有一定下降,但幅度相对较小。与传统

表 2 SR-UNet 模型消融实验对比结果

模型	准确率/%	交并比/%	F1 分数
完整 SR-UNet 模型	93.6	87.3	92.4
移除密集残差连接模块	90.1	83.0	89.4
移除注意力模块	91.7	84.8	90.6
传统 U-Net 模型	88.6	79.5	87.8

U-Net 模型相比, SR-UNet 模型在各项评估指标上均有显著提升, 证明了 SR-UNet 网络分割模型在裂缝识别任务中的有效性和优越性。

选取某栋装配式建筑作为研究对象, 在测试模型时, 使用精确率-召回率曲线对模型进行评估, 其大小等于 $P-R$ 曲线所围成的面积, 是评估模型能力的常用指标, 如式(10)所示。

$$P = \frac{P_{TP}}{P_{TP} + P_{FP}} \quad (10)$$

式中: P 表示装配式多层建筑裂缝识别准确率; P_{TP} 表示识别正确的装配式多层建筑裂缝图像数量; P_{FP} 表示识别错误的装配式多层建筑裂缝图像数量。

为了验证本文提出的识别方法在裂缝识别上的优越性, 将其与基于导电油墨层电阻层析成像的识别方法, 基于计算机视觉的识别方法以及基于图像识别这 3 种识别方法进行对比。本次实验使用来源于多个网络共享资源以及实地采集的裂缝图像数据集对 4 种识别方法进行验证, 经过 100 次迭代后, 得到的 4 种方案识别准确率对比结果如图 5 所示。




图 5 识别准确率对比结果

由图 5 可知, 在迭代周期为 100 时, 这 4 种识别方法的识别准确率(P)均达到了最优值, 其中, 本文识别方法在验证集上的识别准确率(P)最高值为 98%, 均高于另外 3 种识别方法, 这表明本文识别方法在蒸压加气混凝土砌块装配式多层建筑裂缝识别测试中表现出色, 具有更高的识别准确性。

为了检查识别方法是否发生过拟合, 需要使用验证集再次对识别方法进行实验, 当迭代次数达到 200 次时, 4 种方法的损失值变化情况如图 6 所示。

4 种识别方法的训练轮次均为 200 轮, 其损失函数均在下降, 并且还都有继续下降的趋势(图 6), 其中, 基于导电油墨层电阻层析成像识别方法的训练集损失曲线显示对训练集的拟合性越来越好, 但在验证集上表现为拟合性从快速变好到逐渐变差。另外 3 种网络的验证集损失均呈现出下降趋势, 其中基于计算机视觉的识别方法验证集损失曲线在 15 轮左右时, 从训练集损失曲线下方向上上升到训练集损失曲线上, 不过未出现过拟合, 仍然在收敛。本文设计的识别方法 2 条损失曲线间隙基本保持不变, 均在逐渐下降, 若继续训练, 不论是训练集还是验证集, 都会有更好的拟合效果, 这意味着本文设计的识别方法能够更准确地捕捉裂缝图像中的特征, 具有更高的识别准确性。

为了验证所设计的识别方法在实际应用中的作用, 在数据集中随机选取 5 种不同类型的裂缝图像进行对比识别实验。4 种方法的裂缝识别结果如表 3 所示。

从表 3 中可以看出, 当裂缝较为清晰时, 例如横向裂缝, 竖向裂缝和斜向裂缝, 这 4 种识别方法均能够准确地对裂缝进行识别; 然而, 在裂缝为网状结构, 且裂缝较为细小时, 基于计算机视觉和基于图像识别的方法出现了无法完整识别裂缝的问题, 存在裂缝本体漏检的现象。相比之下, 本文提出的识别方法在处理这类图像时, 由于引入了损失函数, 减弱了特征不平衡对识别结果的影响, 从而使识别

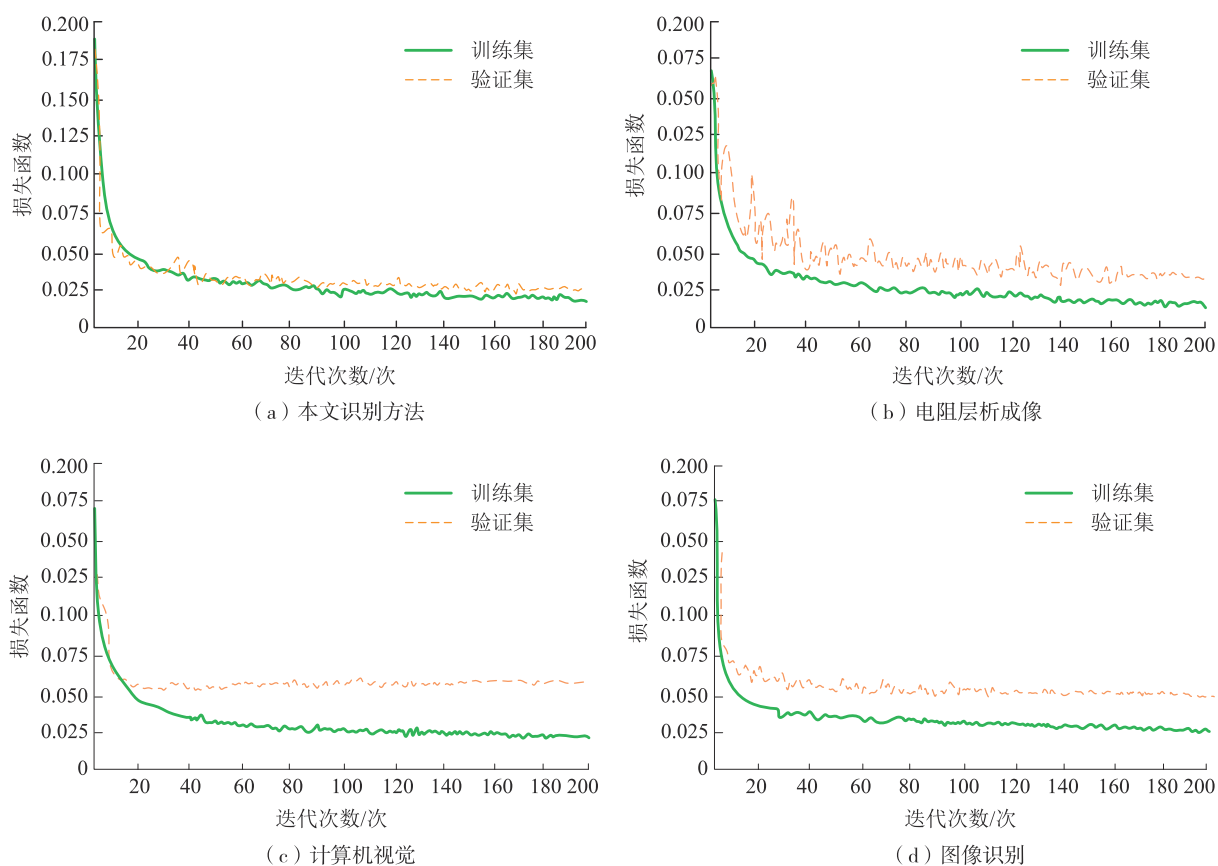


图 6 损失值变化情况

表 3 识别结果

裂缝类型	裂缝图像	本文方法	基于导电油墨层电阻层析成像	基于计算机视觉	基于图像识别
斜向裂缝					
网状裂缝					
横向裂缝					
网状裂缝					
竖向裂缝					

方法表现出了更好的性能,裂缝的连续性较好。此外,当图像中的光线较暗时,并同时包含粗裂缝和细裂缝时,另外 3 种识别方法均出现了漏检的现象,而本文识别方法依旧可以对裂缝进行完整识别。因此可以得出,本文提出的识别方法在对光线较暗环境下的裂缝图像以及细小裂缝图像进行识别时,均能完整识别裂缝图像。

3 结束语

本文设计的基于 SR-UNet 网络的蒸压加气混凝土砌块装配式多层建筑裂缝识别方法,通过

Lucas-Kanade 特征点跟踪以及直方图均衡化处理,使得裂缝的特征变得更加突出,通过构建 SR-UNet 网络模型,以及整体损失函数的计算,从而实现建筑裂缝的识别。实验结果表明,本文所设计的识别方法在裂缝识别中具有较高的精度,平均识别准确率最高值为 98%,同时,在处理复杂裂缝形态和光照条件不佳的裂缝图像时,可以完整识别图像中存在的裂缝。未来将继续优化算法,提高裂缝识别的实时性,为装配式多层建筑的安全性和耐久性提供更加可靠的保障。

参考文献:

- [1] MA N, DONG S, WANG L, et al. Unbalanced graph isomorphism network for fracture identification by well logs[J]. Expert Systems with Applications, 2025, 263: 125794–125794.
- [2] 陈军,王青,周辉阳.装配式工程易变形结构裂缝红外微弱目标识别方法[J].粉煤灰综合利用, 2023, 37(4): 122–127.
- [3] 蔡晨宁,陈少林,刘丽娜.基于导电油墨层电阻层析成像的混凝土裂缝损伤识别[J].传感技术学报, 2024, 37(6): 1084–1089.
- [4] 王文斌,王啸霆,王涛,等.基于计算机视觉的混凝土表面裂缝识别和宽度测量[J].地震工程与工程振动, 2024, 44(3): 41–51.
- [5] 李秀丽,裴瑶瑶.基于图像识别的建筑裂缝自动识别技术研究[J].信息系统工程, 2024(5): 31–34.
- [6] 王剑,袁辉,芮挺,等.基于语义分割的混凝土结构裂缝识别方法[J].建筑结构, 2022, 52(S2): 923–929.
- [7] KUMAR C, SINHA K A. A hybrid framework for concrete crack assessment using grab-cut and improved sobel filtering [J]. Iranian Journal of Science and Technology, Transactions of Civil Engineering, 2025, 49(1): 433–450.
- [8] 邓丽,潘永杰,王琦.基于卷积 LSTM 的混凝土裂缝图像识别技术[J].铁道建筑, 2024, 64(4): 11–18.
- [9] 吴杭姿,韩立芳,杨燕,等.基于卷积神经网络的建筑表面裂纹识别技术[J].施工技术(中英文), 2023, 52(24): 72–75.
- [10] 范立军.基于轻量级卷积神经网络 MobileNetV2 的混凝土结构裂缝识别[J].工业建筑, 2023, 53(7): 231–236.
- [11] 赵青羽.基于极点特征聚类的智能建筑混凝土墙体裂缝识别方法[J].智能建筑与智慧城市, 2022(11): 72–74.
- [12] WU Y J, SHI J F, MA W X, et al. Bridge crack recognition method based on yolov5 neural network fused with attention mechanism[J]. International Journal of Intelligent Information Technologies, 2024, 20(1): 1–25.
- [13] 孙晓贺,施成华,刘凌晖,等.基于改进的种子填充算法的混凝土裂缝图像识别系统[J].华南理工大学学报(自然科学版), 2022, 50(5): 127–136+146.
- [14] 吴子燕,贾大卫,王其昂.基于卷积神经网络与区域生长法的建筑裂缝识别[J].应用基础与工程科学学报, 2022, 30(2): 317–327.
- [15] 张伟,周梦源,夏坚.基于改进 HOG 特征提取与 SVM 分类器的建筑裂缝识别方法[J].南昌工程学院学报, 2022, 41(1): 47–51.