

地下室预应力混凝土结构裂缝图像目标快速分割研究

江升¹, 江林², 环志勇³

(1. 如皋皋泰建设有限公司, 江苏 南通 226500;

2. 南通职业大学, 江苏 南通 226007;

3. 中如建设集团有限公司, 江苏 南通 226000)

摘要: 随着城市建设的扩大, 地下成为空间开发的新方向。但高层建筑中地下室经常出现裂缝以及渗漏等问题。为保障地下室建筑的安全, 提出一种基于目标分割网络的混凝土结构裂缝图像目标快速分割模型。首先利用目标分割网络对混凝土裂缝进行识别分割, 然后将分割后的图像二值化处理, 再通过形态学和骨架化等操作对裂缝的特征信息进行量化处理。通过实验分析可知, 所构建模型的平均分割重叠度为 0.889, 裂缝量化特征的误差保持在 7% 以内。模型能够实现裂缝图像精准快速分割, 帮助工作人员及时维护建筑。

关键词: 地下室混凝土结构; 裂缝; 图像分割; 特征量化; 全卷积神经网络

中图分类号: TP391.41 文献标识码: A 文章编号: 1003-7241(2025)04-0020-05

Research on Fast Segmentation of Crack Image Target in Prestressed Concrete Structure in Basement

JIANG Sheng¹, JIANG Lin², HUAN Zhi-yong³

(1. Rugao Gao Tai Construction Co., Ltd., Nantong 226500 China;

2. Nantong Vocational University, Nantong 226007 China;

3. Zhongru Construction Engineering Group Co., Ltd., Nantong 226000 China)

Abstract: With the expansion of urban construction, underground becomes a new direction of space development. But cracks and leakage problems often appear in the basement of high-rise buildings. In order to ensure the safety of basement building, a fast segmentation model for concrete structure crack image based on segmentation network is proposed. First, the target segmentation network is used to identify and segment the concrete cracks, and then the segmented image is binarized, and then the feature information of the cracks is quantified through morphology and skeleton operation. Through the experimental analysis, the average segmentation overlap of the constructed model in the study is 0.889, and the error of the crack quantification features is kept within 7%. The model can achieve more accurate and fast crack segmentation, and help the staff to maintain the building in time.

Keywords: basement concrete structure; crack; image segmentation; feature quantification; full convolutional neural network

0 引言

随着社会经济的迅速发展, 地下空间逐渐成为人们开发的新方向, 地铁、地下车库、地下商场等逐渐进入人们的生活^[1]。地下室混凝土结构由于承受着高层建筑的重量以及地下潮湿等, 极易出现裂缝渗漏的问题。如果地下室裂缝不能及时得到处理, 这将直接影响空间使用者的生活, 同时具有极大安全隐患, 容易出现事故^[2]。随着科学技术的发展, 裂缝检测逐渐从人工检测转变为智

能检测。其中卷积神经网络(convolutional neural networks, CNN)凭借准确度较高、不易受外界因素影响等优势, 在裂缝检测方面有较为广泛的应用^[3]。但常规的 CNN 仍然存在较多缺陷, 比如其并不能提供像素级别的检测结果, 其检测精细程度还有较大的提升空间^[4]。刘宏伟等人针对现有的隧道检测中采集得到的图像存在大量干扰物、质量差的问题, 提出了一种基于轻量化 HR-Net 框架的裂缝检测算法。结果表明, 该算法的均交并比指标达到了 80.21%^[5]。张修杰等人针对目前深度神经网络的裂缝分割模型存在训练参数多, 分割精度不够的问题。对 DeepLabv3+ 模型进行研究, 在训练过程中嵌入注意力机制, 并改进了主干网络。最后基于优化模型的输出对裂缝特征进行量化^[6]。瞿中等人提出了一种基于空洞卷积

*基金项目: 江苏省住房和城乡建设厅 2023 年度江苏省建设系统科技项目 (2023ZD048); 2023 年度 (上半年) 江苏省土木建筑学会科研课题立项项目 (15)

收稿日期: 2023-12-19

和注意力机制的混凝土路面裂缝检测方法。在主干网络中融入了注意力机制,同时利用空洞卷积融合模块实现特征的多尺度融合^[7]。郝巨鸣等人利用 GhostNet 中的 Ghost 模块优化 YOLOv4 特征提取网络,进行裂缝检测。结果表明,该模型相较于传统 YOLOv4 大小降低了 82.31%,参数量减少了 82.56%^[8]。国内外对于裂缝图像检测分割的研究众多,但现有的研究成果的测试精度仍不够理想。为达到更高的精度,实现对裂缝区域的精准分割,本项目选用目标分割网络(target segmentation network, Seg-Net)对地下室混凝土裂缝进行检测分割,然后通过形态学、骨架化等操作对裂缝特征进行量化。由此实现地下室混凝土结构的裂缝图像目标分割,帮助工作人员实现地下室建筑的实时维护。

1 基于 SegNet 的地下室混凝土结构图像目标快速分割模型构建

1.1 地下室裂缝图像数据采集及预处理

在构建图像快速分割模型过程中,需要提前准备对应的测试集和训练集。为此,本项目选用了周围环境下的地下室混凝土结构裂缝数据以及一个开源的道路裂缝数据库 CrackForest。为了统一数据集中的图片尺寸,将数据集中的图片进行裁剪,在裁剪过程中选用相同窗口。最后共得到 5 461 张图像,通过人工排查筛选得到了 1 200 张图像作为后续研究数据。将此 1 200 张图像平均分为测试集与训练集两个集合。选择的数据集中包含有单、多裂缝以及其他复杂背景下的裂缝图像。此外,数据集中还存在一些质量较低的图像,若使用这些图像对模型进行训练将会影响模型的训练效果。为此,采用图形变换技术和图像增加技术,即镜像、翻转等操作,创建多个图像副本。以此丰富训练集与测试集的样本。在进行图像增强时,需要实时生成训练样本,本项目通过变换参数,对原有的少量数据进行改变,进而丰富了数据集中的样本数量。在得到充足的训练数据之后,对所得到的图像中的裂缝进行标注,为后续的模式训练奠定基础。通过标注得到裂缝信息图像,具体如图 1 所示。




图 1 生成裂缝信息图像

将图像中的裂缝与背景进行区分,裂缝区域的 RGB 值分别为 128,0,0,而背景区域进行全部置零处理,以此

突出裂缝位置。采用人工标注和软件标注两种方法对训练集进行标注。使用软件为分割任务标注软件 Label-tool。通过这两种标注方法,互相对比校正,获得标注更加准确的样本集合。在标注结束后,得到的图像并不能够直接输入模型进行训练。为此,在模型训练之前利用 Python 将标注后的文件格式进行转化,实现可视化。除了样本数量不足、质量低等情况,样本数据由于采集过程并未特别注意样本裂缝类型,很容易出现样本不平衡的情况。为避免因为样本不平衡导致模型易陷于局部最优的情况,通过对类别权重进行调整对均衡样本数据。权重的计算方法如式(1)所示。

$$\begin{cases} W = label0 \times 1 + label1 \times \frac{1}{P} \\ P = c_1 / c_2 \end{cases} \quad (1)$$

式(1)中, label0 为裂缝图像背景, label1 为图像中的裂缝, P 为阈值,阈值的取值由 c_1 和 c_2 决定, c_1 和 c_2 分别为裂缝和背景在图像中所占比重, W 为不同类别的权重。

1.2 基于 SegNet 的地下室混凝土裂缝检测分割

对数据集进行增强、标注以及类间不平衡处理之后,利用卷积神经网络进行裂缝目标图像分割。基于深度学习的语义分割具有较高的精度和效率,其中 SegNet 作为一种轻量级的目标分割网络模型优势更加明显^[9-10]。Seg-Net 是一种以深度卷积为基础,融合编码器和解码器结构的对称结构网络。其网络结构如图 2 所示。




图 2 SegNet 进行图像分割的结构示意

SegNet 网络由编码-解码器两部分组成,其中编码器的主要构成为卷积层和池化层。这两层结构主要对图像特征进行提取。每个池化层的最大池化操作将会被记录,并作为最大值索引用于解码器的上采样。而解码器的主要构成为卷积层和反卷积层。这两层结构主要用于对图像进行像素级别的预测。数据输入到反卷积层之后,反卷积层会根据之前得到的索引进行采样,然后将数据输入到卷积层中。在卷积层中将各个特征进行融合,同时进行图像分类,完成每个像素图像具有最大概率类的预测。各特征概率的计算方法如式(2)所示。

$$P(y^i = n | x^i; W) = \left\{ \begin{matrix} y^i = 1 | x^i; W \\ \dots \\ y^i = n | x^i; W \end{matrix} \right\} = \frac{1}{\sum_{j=1}^n e^{W^T_j x^i}} \left\{ \begin{matrix} e^{W^T_1 x^i} \\ \dots \\ e^{W^T_n x^i} \end{matrix} \right\} \quad (2)$$

式(2)中, $P(y^i=n|x^i; W)$ 为概率表达式, $W^T_n x^i$ 为 softmax 层的输入, n 为类别个数, i 为训练次数, y 为真实类别概率, x 为整个网络的第一层输入。

在对模型进行测试时, 很容易出现样本数量不够的问题, 为此, 选择迁移学习对测试集样本进行丰富补充。同时利用 Labeltool 标注的图像对 SegNet 网络模型进行网络结构和超参数的调整优化。训练过程中需要通过计算每次迭代损失判断训练效果, 为此需要选择合适的损失函数, 选用交叉熵函数对训练损失进行计算。计算方法如式(3)所示。

$$L_{ce} = -y \log \hat{y} - (1-y) \log (1-\hat{y}) \quad (3)$$

式(3)中, \hat{y} 为预测类别概率, L_{ce} 为图像整体的损失。

在训练过程中通过交叉熵函数计算得到损失值之后, 为了得到更好的精度, 将训练目标定为损失最小。利用滤波器对模型进行修正。但是滤波器的权值也需要随着模型的训练情况进行改变, 这样才能达到更为理想的训练效果。为此, 使用小批量梯度下降的方法计算梯度和更新滤波器权值。计算方法如式(4)所示。

$$\begin{cases} J_s(w) = \frac{1}{|S|} \sum_{i \in S} l(f(w; x_i), y_i) \\ f(w; x) = w^T x \end{cases} \quad (4)$$

式(4)中, S 为类别种类的集合, $|S|$ 为相对较小的样本量, l 为凸损失函数, w 为预测函数的参考值, f 为预测函数。

得到的最优参数如下: 输入图像尺寸为 $512 \times 512 \times 3$, 权重衰减值为 0.5×10^{-4} , 学习率 1×10^{-4} , 批量大小为 8。

1.3 基于分割结果的裂缝参数量化分析

在利用 SegNet 模型对图像进行识别分割之后, 得到了样本数据的二值黑白图。但这些图像还不能够直接用于特征量化操作中。由于一系列的操作, 图像中还会存在着少量的噪点, 这将影响后续量化精度^[11-12]。为此, 引入形态学理论对图像进行处理, 利用膨胀和腐蚀两个操作对存在的噪点进行去除。通过对所识别分割的裂缝进行分割处理能够帮助工作人员对建筑物结构的健康状况进行更加准确评估。本项目的量化特征包括了长度、宽度以及裂缝角度, 通过这些指标更加精细描述裂缝。首先对分割后的图像进行二值化操作, 具体如式(5)所示。

$$h(i, j) = \begin{cases} 0, f(i, j) < T \\ 255, f(i, j) \geq T \end{cases} \quad (5)$$

式(5)中, $h(i, j)$ 为图像中任一点进行二值化后的灰度值, (i, j) 为图像中像素点坐标, $f(i, j)$ 为原图像中任意点的灰度值, T 为在将裂缝特征与其他背景杂质区分过程中设定的边界阈值。

通过填充小孔、消除噪声像素、标识个别裂缝的方法来标记裂缝。填充小孔使用闭运算的方式, 开闭运算计算方法如式(6)所示。

$$\begin{cases} K' = ((f \oplus \varphi) \ominus \varphi) \\ B' = ((f \ominus \varphi) \oplus \varphi) \end{cases} \quad (6)$$

式(6)中, \ominus 为物体的边界腐蚀, f 为原始图像, φ 为结构元素图像, \oplus 表示膨胀操作, K' 为开运算, B' 为闭运算。运用开运算消除孤立的噪声像素。两个运算流程如图 3 所示。

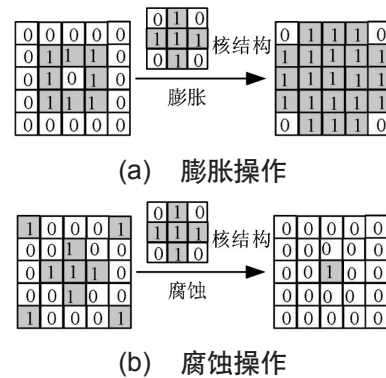


图 3 膨胀与腐蚀的操作流程

为了计算裂缝的长度和厚度, 应该对图像进行细化。采用 Zhang-Suen 细化算法进行裂缝的骨架化, 通过此算法得到中心骨架线, 为不影响后续裂缝参数的计算, 提高量化精准性, 采用链码跟踪的方法消除多余的毛刺。为了分离单个裂缝, 需要确定裂缝的分支点。裂缝与裂缝之间存在相交点, 找到这些相交点即可将两条裂缝分开。为此, 根据相交点将所有图像分为单个裂缝图像。分割后的图像能够实现更为精确的尺寸计算。当裂缝以单像素宽度表示成骨架之后就对裂缝尺寸进行计算。裂缝长度、面积以及宽度、角度等可通过像素点个数进行计算。由此, 实现裂缝特征的分析, 帮助工作人员对地下室预应力混凝土结构的健康状态进行评估。

2 基于改进 CNN 的裂缝图像快速分割模型性能分析

为检验裂缝分割模型的分割效果, 实验将本项目所设计模型(模型 1)与现有研究中较为先进的算法进行对比。对比指标包括准确度、重叠度(intersection over union, IoU)、召回率(Recall)、F1 值。通过增加检测图像的方式对比四项指标的变化情况。对比算法包括融合多尺度特征的马尔科夫随机场裂缝分割(模型 2)、基于改进 U-Net 网络模型的混凝土裂缝分割(模型 3)、基于生成对抗网络的裂缝自动分割模型(模型 4), 具体结果如图 4 所示。

如图 4 所示, 模型 1 在准确度上一直高于另外三个模型, 且随着检测图像数量的增加只出现了较小的变化。

模型1的平均准确度为0.923,另外三个模型的平均准确度皆在0.850。此外,另外三项指标数据中,模型1都有较优秀的表现,具有较高的稳定性。模型1的平均IoU值为0.889,F1值为0.901,Recall值为0.916。在这三个指

标上,模型1依旧处于优势地位。为检验所选择的学习率的正确性,试验对比了不同学习率情况下模型的检测结果。检验结果如表1所示。

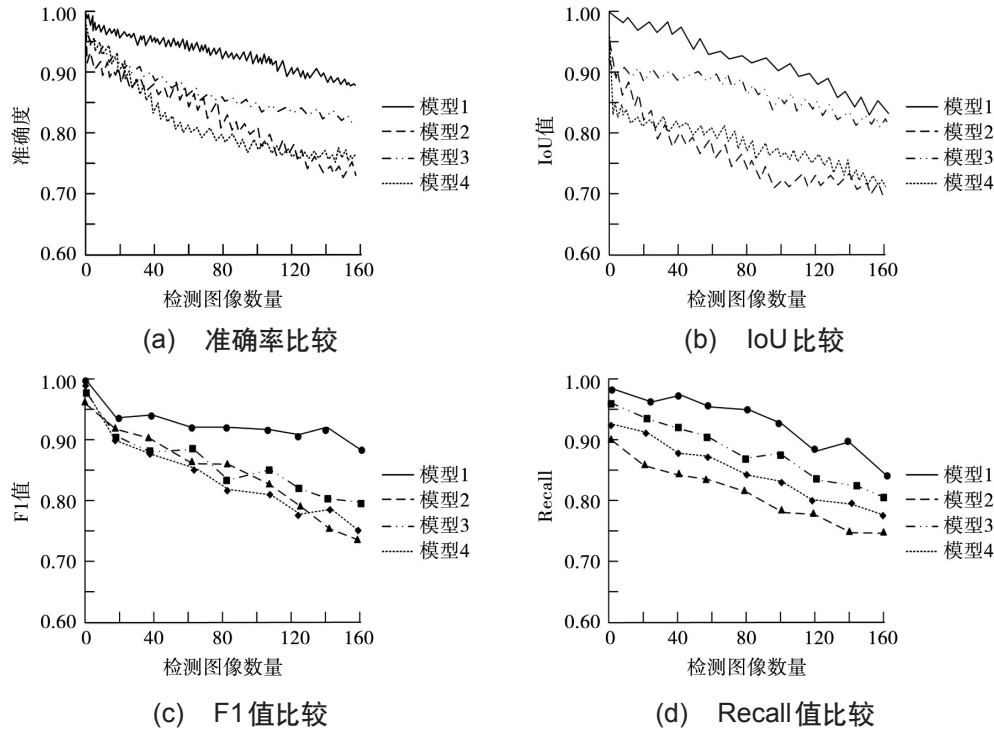


图4 所设计分割模型与其他模型的性能对比结果

表1 学习率不同情况下模型各项指标对比

学习率	试验1%				试验2%			
	准确度	IoU	Recall	F1	准确度	IoU	Recall	F1
0.000 05	91.64	90.85	90.01	91.85	91.45	90.65	91.58	91.55
0.000 10	95.46	96.44	96.52	95.81	95.38	97.09	96.84	95.94
0.000 50	92.32	92.45	92.22	93.10	91.68	92.84	92.02	92.89
0.001 00	85.48	86.42	87.12	88.29	85.39	86.44	87.03	88.45

由表1可知,当学习率为0.000 1时,模型的检测指标最高。当学习率增加到0.000 5时,模型的检测准确度以及IoU值等指标下降明显,其中准确度值下降了3.42%,

IoU值下降了4.12%,Recall值下降了4.56%,F1值下降了2.88%。当学习率减小到0.000 05时,模型的检测准确度下降了3.82%,IoU值下降了5.59%,Recall值下降了6.51%,F1值下降了3.96%。由此可证本项目选用的学习率合理。为检验经过训练的模型输出的裂缝量化数据的准确性,本项目对三个裂缝图像进行量化,量化结果如图5所示。

为进一步检验三个裂缝量化结果与实际结果之间的测量误差,证实模型的检测准确性。将模型对三条裂缝检验的结果进行记录并对比。特征参数量化和使用工具测试得到的结果如表2所示。




图5 三个不同裂缝的特征量化结果

表2 模型分割后裂缝量化值误差情况

测量结果	取向角	裂缝长度	裂缝面积	宽度		
				平均	最大	
裂缝1	模型测量	34.68°	40.81 mm	97.94 mm ²	2.40 mm	2.80 mm
	实际测量	32.88°	41.89 mm	95.93 mm ²	2.29 mm	2.68 mm
	误差	5.47%	2.58%	2.10%	4.58%	4.48%
裂缝2	模型测量	8.54°	40.78 mm	81.97 mm ²	2.01 mm	2.36 mm
	实际测量	8.21°	39.65 mm	77.71 mm ²	1.96 mm	2.28 mm
	误差	4.01%	2.85%	5.48%	2.55%	3.51%
裂缝3	模型测量	127.59°	32.69 mm	35.31 mm ²	1.08 mm	1.27 mm
	实际测量	124.58°	31.88 mm	36.34 mm ²	1.14 mm	1.32 mm
	误差	2.42%	2.54%	2.83%	5.26%	3.79%

结合表2和图5可知,裂缝量化特征的误差保持在7%以内,其中面积的平均测试误差为3.47%,裂缝长度的平均测试误差为2.66%,取向角的测试误差为3.97%,平均宽度的平均测试误差为4.13%,最大宽度的平均测试误差3.93%。由此可以看出,本项目所构建的分割模型及量化方法能够达到较好的裂缝目标图像分割效果,测得的裂缝数据准确度高。能够帮助工作人员对地下室混凝土结构进行科学评估,及时对建筑进行修缮,维护建筑内人员安全。

3 结束语

为实现地下室预应力混凝土结构的实时维护,基于SegNet网络构建了一个裂缝图像目标快速分割模型。利用图像增强、归一化等方式对数据集进行预处理,然后使用SegNet网络对裂缝图像进行识别分割。最后对裂缝图像的特征进行量化处理。建筑维护人员能够通过量化数据对地下室混凝土结构的裂缝情况进行初步判断。通过实验分析可知,模型1的平均准确率为0.923,平均IoU值为0.889,F1值为0.901,Recall值为0.916。裂缝量化特征的误差保持在7%以内,其中面积的平均测试误差为3.93%,裂缝长度的平均测试误差为2.66%,取向角的测试误差为3.97%,平均宽度的平均测试误差为4.66%,最大宽度的平均测试误差3.93%。由此可以看出,本项目所构建的模型能够实现较高精度的裂缝图像目标分割,为工作人员提供参考,实时维护建筑安全。模型能够对较为简单的裂缝进行检测分割,但像网状裂缝等类型的分割精度还有待提高,在之后的研究过程中需要对此进行进一步探索。

参考文献:

- [1] 李海丰,聂晶晶,吴治龙,等.基于多传感器信息融合的机场道面裂缝检测算法[J].现代电子技术,2020,43(24):17-21,25.
- [2] 石颖,马文琪,吴宏杰.改进YOLOv4的混凝土建筑裂缝检

测算法[J].微电子学与计算机,2023,40(3):56-66.

[3] 卢印举,李祖照,戴曙光.融合高阶多尺度特征的路面裂缝图像分割算法[J].小型微型计算机系统,2022,43(6):1197-1203.

[4] 闫浩国.基于GHT的公路隧道衬砌裂缝图像边缘检测系统[J].自动化技术与应用,2023,42(4):49-52.

[5] 刘宏伟,杜晓兵,徐政超,等.利用轻量级高分辨率特征的隧道裂缝检测方法[J].计算技术与自动化,2023,42(2):144-150.

[6] 张修杰,袁嘉豪,岳学军,等.基于优化DeepLabv3+的混凝土梁裂缝分割及特征量化[J].科学技术与工程,2023,23(9):3794-3803.

[7] 瞿中,王彩云.基于注意力机制和轻量级空洞卷积的混凝土路面裂缝检测[J].计算机科学,2023,50(2):231-236.

[8] 郝巨鸣,杨景玉,韩淑梅,等.引入Ghost模块和ECA的YO-LOv4公路路面裂缝检测方法[J].计算机应用,2023,43(4):1284-1290.

[9] 顾书豪,李小霞,王学渊,等.增强语义信息与多通道特征融合的裂缝检测[J].计算机工程与应用,2021,57(10):204-210.

[10] 陈侯秀,高建民,贺青青,等.基于遗传神经网络的机场跑道局部影响的裂缝检测算法[J].计算机测量与控制,2023,31(5):7-13.

[11] Chu H, Wang W, Deng L. Tiny-Crack-Net: A multiscale feature fusion network with attention mechanisms for segmentation of tiny cracks[J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(1): 1914-1931.

[12] 李永红.信息化大数据模型的道路裂痕识别和分析[J].微型电脑应用,2023,39(3):173-176.

作者简介:江升(1994-),男,本科,高级工程师,研究方向:建设工程绿色低碳施工技术。