

基于计算机视觉的混凝土表观裂缝识别和宽度测量

王文斌¹,王啸霆^{1,2},王涛^{1,2},陈曦³

(1. 中国地震局工程力学研究所 地震工程与工程振动重点实验室,黑龙江 哈尔滨 150080;
2. 地震灾害防治应急管理部重点实验室,黑龙江 哈尔滨 150080; 3. 北京市建筑设计研究院有限公司,北京 100045)

摘要:对钢筋混凝土(reinforcement concrete, RC)结构表观裂缝的高效识别可以为结构震损快速评估提供佐证。无论在地震现场还是实验室环境,此类工作均表现出量大、重复的特征,适合利用计算机视觉技术完成,以弥补人工方式低效、不确定性强的劣势。以消费级相机输出图像作为数据源,融合 U-Net 和 VGG-16 构造适用于混凝土表观裂缝识别的卷积神经网络(convolutional neural network, CNN)模型,依托多类型 RC 构件裂缝图像数据库完成模型训练和测试。利用形态学运算、Otsu 阈值分割等技术进一步优化裂缝识别结果作为宽度测量的输入数据。为降低相机光轴与裂缝平面不垂直带来的裂缝宽度测量误差,通过特定靶标对原始图像进行透视误差校正,经检验,透视误差校正后的裂缝宽度测量的平均偏差最大可降低约 25%。

关键词:表观裂缝;计算机视觉;裂缝识别;裂缝宽度测量;透视误差校正

中图分类号:TP391.4

文献标识码:A

Detection and width measurement of concrete apparent cracks based on computer vision

WANG Wenbin¹, WANG Xiaoting^{1,2}, WANG Tao^{1,2}, CHEN Xi³

(1. Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China; 2. Key Laboratory of Earthquake Disaster Mitigation, Ministry of Emergency Management, Harbin 150080, China; 3. Beijing Institute of Architectural Design, Beijing 100045, China)

Abstract: Efficient detection of apparent cracks in reinforced concrete (RC) structures can provide evidence for rapid assessment of earthquake-damaged structures. Such work exhibits large and repetitive characteristics in both earthquake sites and laboratory environments, therefore, it is suitable to adopt the computer vision technology to make up the inefficiency and uncertainty of manual methods. Using images from consumer-grade cameras as data sources, a convolutional neural network (CNN) model suitable for concrete apparent crack detection is constructed by integrating U-Net and VGG-16, and the model training and testing are completed based on a multi-type RC component crack image database. Morphological operations and Otsu threshold segmentation are used to further optimize the crack detection results as input data for width measurement. To reduce the measurement error of crack width caused by the non-perpendicularity of the camera axis to the crack plane, perspective error correction is performed on the original image using specific targets. After verification, the average deviation of the crack width measurement after perspective error correction can be reduced up to 25%.

Key words: apparent crack; computer vision; crack detection; crack width measurement; perspective error correction

收稿日期:2023-04-28; 修回日期:2023-05-06

基金项目:国家重点研发计划项目(2019YFE0198900);国家自然科学基金项目(52108482)

作者简介:王文斌(1996—),男,硕士研究生,主要从事损伤识别技术研究。E-mail:wwb_nuhai@163.com

通讯作者:王啸霆(1986—),男,副研究员,博士,主要从事工程结构抗震研究。E-mail:wangxt@iem.ac.cn

0 引言

裂缝识别和宽度测量对于地震现场或者实验室测试的钢筋混凝土结构和构件都是非常重要的组成部分,然而,目前裂缝识别往往是通过人工目视的方式进行的,这不仅是一个非常繁琐而耗时的过程,并且裂缝识别的准确性也容易受到主观错误的影响,因此,越来越多的学者逐渐将计算机视觉技术引入到裂缝识别中来,OLIVEIRA 等^[1]将图像分割成小尺寸的图块,利用 K 近邻算法(K-nearest neighbor, KNN)、Fisher 判别分析等监督学习分类和聚类算法,对图块是否包含裂缝进行分类,实现了图块层次的裂缝检测。KIM 等^[2]首先利用 Mask R-CNN 对图像中的裂缝进行初步分割提取,之后,对提取的裂缝区域应用阈值法实现了像素层次的裂缝分割。SATTAR 等^[3]比较了 6 种常见的边缘检测滤波器与采用 Alexnet 架构的深度卷积神经网络在基于图像的混凝土结构裂缝检测中的性能,研究显示,相比于传统的边缘检测算法,经过充分训练的深度卷积神经网络在计算时间和识别准确度上都更优越。

裂缝宽度是初步确定结构或构件完整性的关键,在裂缝宽度测量方面,杨娜等^[4]设计了一个基于无人机和计算机视觉技术的针对古建筑木结构裂缝的监测系统,通过手动设置无人机飞行路径和位姿保证了采集裂缝照片时相机与裂缝表面基本垂直,基于提前标定的像素分辨率与物距的关系计算裂缝宽度。钟谷新等^[5]为了识别桥梁底部人员无法到达的地方的裂缝,使用无人机平台对裂缝进行识别宽度测量,并通过机载三点激光测距仪测量相机成像平面与裂缝所在平面的角度来修正像素解析度。刘学增等^[6]探讨了拍摄角度对裂缝宽度测量的影响。SHAN 等^[7]采用立体视觉的方法对钢筋混凝土梁进行裂缝宽度检测,检测精度达到了 0.02 亚像素。GANG 等^[8]利用配备长镜头的单反相机对桥梁底部的裂缝进行检测,利用激光测距仪得到像素解析度,同时还分析了不同角度斜向摄影的测量误差,结果显示斜摄识别精度要低于垂直摄影,相对误差在 3.8%~35.7%之间。可以看到大部分基于图像的裂缝宽度测量都要求相机拍摄时与裂缝平面基本垂直,当相机光轴与裂缝平面法向量存在较大角度时,拍摄的照片会存在一定的透视误差,此时裂缝宽度测量的误差会较大,因此,需要通过透视误差校正来提高裂缝测量的准确度。

本文提出采用计算机视觉技术结合消费级相机对 RC 结构表面裂缝进行识别,然后通过粘贴于构件表面的、物理尺寸已知的靶标对原始采集图像进行透视误差校正并计算像素分辨率,进而准确测量 RC 结构表面裂缝宽度本文提出的总体框架包括裂缝识别和裂缝宽度 2 个处理阶段,最后通过实验验证该方法的有效性。

1 基于 CNN 模型的混凝土表面裂缝识别

本文提出的识别方法框架和流程如图 1 所示。第一阶段,表观裂缝识别。采用 CNN 模型自动识别裂缝分布,通过 Otsu 阈值分割技术获得所识别裂缝的二值图像。第二阶段,裂缝宽度测量。对试件表面的靶标进行角点检测,进而计算从斜摄到正摄的透视投影矩阵,利用该矩阵对前述裂缝二值图像进行校正;同时,通过已知的靶标实际尺寸计算像素分辨率,最终获得裂缝宽度数值。

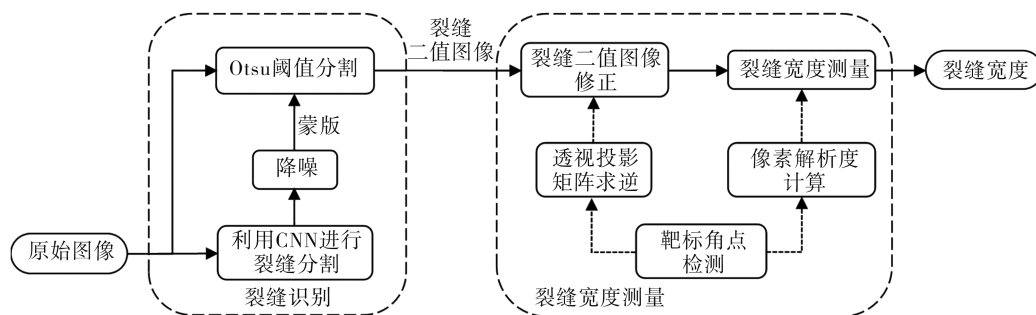


图 1 总体方法框架和流程

Fig. 1 Framework and workflow of overall methodology

1.1 卷积神经网络模型

U-Net 网络架构(图 2)最初用于医学影像中的毛细血管和细胞分割^[9],其在小数据集上取得了良好的

语义分割效果。U-Net 网络架构中的融合分支将特征提取器所获取的不同尺度的视觉特征与对应解码器的输出进行融合,可以显著强化模型对不同尺度的图像特征的识别。由于混凝土结构表面裂缝图像的标注难度大,语义分割数据集的样本数量同样有限,因此,以 U-Net 网络架构为基础构造适用于本研究的模型,将重构之后的卷积神经网络模型命名为 CrackNet。

研究表明迁移学习能够有效降低模型训练时间和提高模型收敛速度^[10],因此可针对 U-Net 原型网络的输入图像尺寸与输出预测尺寸不一致、全新的图像编码器导致的过拟合和收敛速度慢等短板进行针对性改造。VGG-16(visual geometry group network)在大规模通用 ImageNet 数据库进行了充分训练,预训练的 VGG-16 模型可以提取表征自然物体的基本特征(如线条、边缘、角点、纹理、颜色梯度等)及其隐含的深层抽象特征。以 VGG-16 模型替换 U-Net 网络架构中的特征提取器,同时重新构造对应的解码器,以确保模型输入/输出尺寸一致。利用迁移学习的方法将 VGG-16 预训练模型参数导入重构之后的模型中,再利用已收集的清晰图像数据进行参数微调,成型后的 CNN 模型可以在之前已学习到的“知识”基础上进一步获取图像样本集所包含的其他信息。

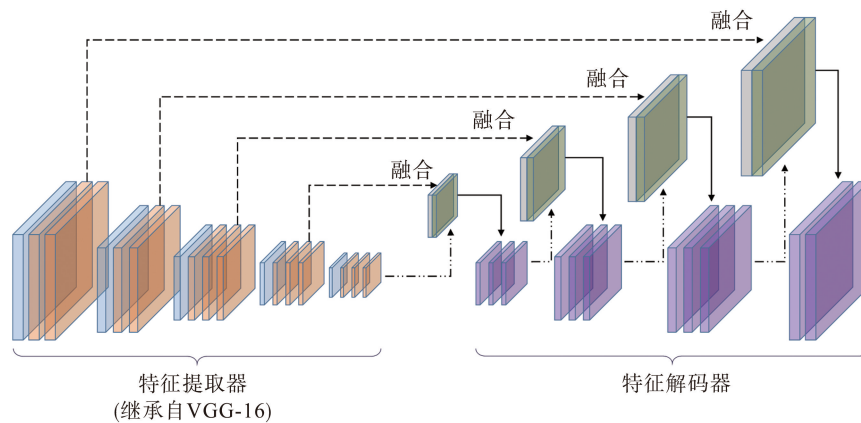


图 2 CrackNet 架构

Fig.2 Architecture of CrackNet

1.2 RC 结构表面裂缝图像数据库

图像数据库的质量会显著影响 CNN 模型的训练效果。因此,本文整理了地震灾害防治应急管理部重点实验室既有的 RC 结构/构件拟静力和振动台试验图像数据,从中筛选出 82 张 RC 墙、连梁、柱、梁和框架节点等构件表面裂缝照片作为数据库的基础图像源。基础数据源中各类型 RC 结构构件中墙占比最高而梁占比最低,构件试验类型以拟静力试验为主,此外混凝土构件表面刷白占绝大部分,而只有少量表面不作任何处理或者刮腻子,如图 3 所示。因此,图像数据库包含足够的 RC 构件震损现象和裂缝形态,可以有效地反映不同类型 RC 构件震损的典型视觉特征,确保数据库样本的代表性。




图 3 基础图像源组成成分

Fig.3 Composition components of basic image sources

为增强数据样本的普适性,本文从 RC 构件表面纹理、物像分辨率、拍摄角度和复杂背景和遮挡等四方面特征进一步梳理了基础图像源的局部信息。得益于多台相机在不同机位,以多个拍摄角度同时记录构件

震损演化过程,基础数据源具有多种表面纹理和物像分辨率,以及复杂的背景和遮挡信息,如图4所示。其中,表面纹理包括素混凝土表面、混凝土表面刷白、混凝土表面刷斑点和混凝土表面刮腻子等4种主要类型;复杂背景和遮挡包括位移计、应变计、线缆、作动器、振动台和螺栓等;拍摄角度主要分为 90° 、 45° 、 60° ,因为试验室过往照片未记录拍摄距离,所以无法统计相关信息。基于此,本文重构的CNN模型显著增强了针对不同RC构件震损图像来源的泛化能力。




图4 图像数据库样本构成

Fig.4 Samples composition of image database

CNN模型理论上可以接受任意尺寸的图像作为其输入数据,但过大的输入尺寸会增加模型在训练时产生不必要的中间参数,降低收敛速度;而过小的输入尺寸则会延长裂缝检测的时间,降低裂缝识别效率。因此,本文将图像输入尺寸设定为 $320\text{ pixel}\times 320\text{ pixel}$,并对基础图像源进行切分。为了进一步拓展样本数据量、丰富样本多样性,通过镜像、旋转、Gamma校正、对比度调整等手段生成样本标签对。图5展示了由基础图像源采样生成样本标签对的主要流程。通过随机选取的采样位置、旋转角度、缩放比例和镜像翻转模拟相机拍摄视角的变化,丰富了数据集样本多样性;通过随机色调及饱和度调整、Gamma校正等技术模拟相机拍摄时外部环境光照的波动,提升了数据集样本代表性。其中值得注意的是,图像旋转会在图像边缘产生一些无效的黑边,因此在第一步进行随机裁剪,并保证其尺寸为最后生成样本对尺寸的 $\sqrt{2}$ 倍,再对此图像进行随机旋转和中心裁切,从而保证最后生成的样本没有黑边,提升训练样本的有效性。每张原始样本图像及其对应标注经过上述数据增强措施生成100张可输入模型的样本标签对,样本标签对包含了训练模型所需的输入图像及其对应标注。拓展后的图像数据库随机划分为训练集、测试集和验证集,其样本数量比例为4:1:1。

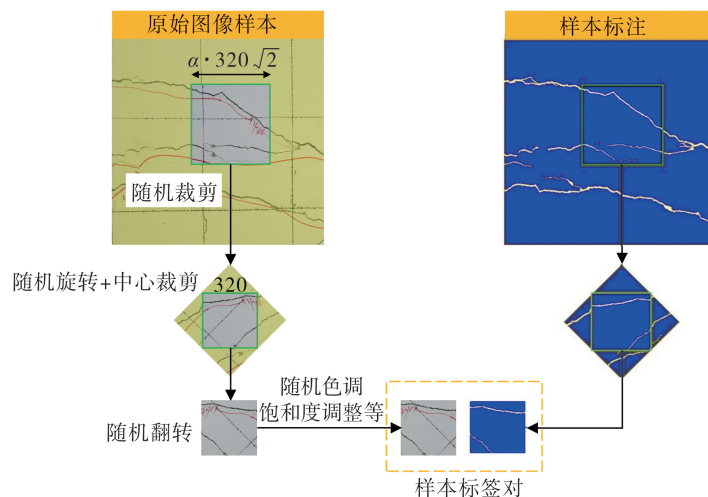


图5 生成样本标签对流程图

Fig.5 Flowchart for the generation of samples and labels

1.3 模型训练、测试和优化

语义分割任务实质上是对输入图片的像素点进行分类,以像素分类的方式达到裂缝分割的目的。首先,

在像素层次上,数据样本中裂缝与背景噪声所占像素的比例分别为 0.7%和 99.3%,两者差异过大。为了防止模型在训练过程中向有利于背景识别的方向优化,反而劣化了裂缝识别效果,本文将像素占比的倒数作为类别权重进行损失函数计算。

其次,在样本层次上,因为裂缝所占的区域相对较小,随机生成样本标签对时,含有裂缝的样本远少于不含裂缝的样本,由此可能导致训练过程中随机出现单批次训练集含裂缝样本数占比偏低的情况,也会影响模型对裂缝的识别效果。为此,本文在由样本标签对生成训练批次的过程中,引入裂缝存在性检查^[12],含有裂缝的样本标签对被纳入此训练批次中,以保证该训练批次中含裂缝的样本标签对占比不低于 50%。

初始学习率设置为 1×10^{-4} ,并且使学习率每 5 个周期减半。采用 RMSProp 优化算法加速训练过程的收敛。其中,算法超参数 $\delta = 0.99$,样本批次设置为 48,为降低模型复杂度、防止过拟合,将权重衰减设置为 0.001。本文中所有基于计算机视觉的裂缝识别和宽度测量算法,均在 Python3 编程环境和 PyCharm 软件中开发实现,其中图像处理相关模块基于 scikit-image 和 OpenCV 算法库实现,CNN 模型相关模块基于 Pytorch 算法库实现。

最终模型训练过程损失函数和平均交并比变化如图 6 所示。最终模型在训练集上的平均交并比超过 60%,损失在 0.05 左右。用测试集上的平均交并比和类交并比来对模型的识别效果进行评价,交并比是衡量语义分割效果的度量标准,其通过真实值与预测值的交集和并集之比计算,平均交并比是每个类别交并比的平均值,计算方法为

$$\text{mean_IoU} = \frac{1}{k + 1} \sum_{i=0}^k \frac{n_{ii}}{\sum_{j=0}^k n_{ij} + \sum_{j=0}^k n_{ji} - n_{ii}} \quad (1)$$

式中: k 为预测类别数; n_{ii} 为真实类别为 i 、预测类别为 i 的像素数; n_{ij} 为真实类别为 i 、预测类别为 j 的像素数。




图 6 模型训练的损失函数和平均交并比变化

Fig. 6 Loss and mean IoU changes of model training

如表 1 所示模型在测试集上的平均交并比为 67.94%,与沈俊凯等^[11]提出的 FCN 网络在有限测试集上获得的 68.85% 的平均交并比相当,更加重要的裂缝类交并比为 38.12%,略低于 MIAO 等^[12]模型的 41.6%,但远高于 LI 等^[13]融合 U-Net 和 ResNet 模型在路面裂缝识别中的 23%交并比。图 7 和图 8 显示裂缝识别宽度偏大和误识别部分点状噪声是导致裂缝交并比偏低的主要原因,但识别结果已包含全部主要裂缝,故认为其满足后续裂缝宽度测量的要求。

表 1 模型在测试集上的评价指标

Table 1 Evaluation indexes of models

on the test set		%
类别	类交并比	
背景		97.76
裂缝		38.12
平均交并比		67.94



(a) 测试集样本

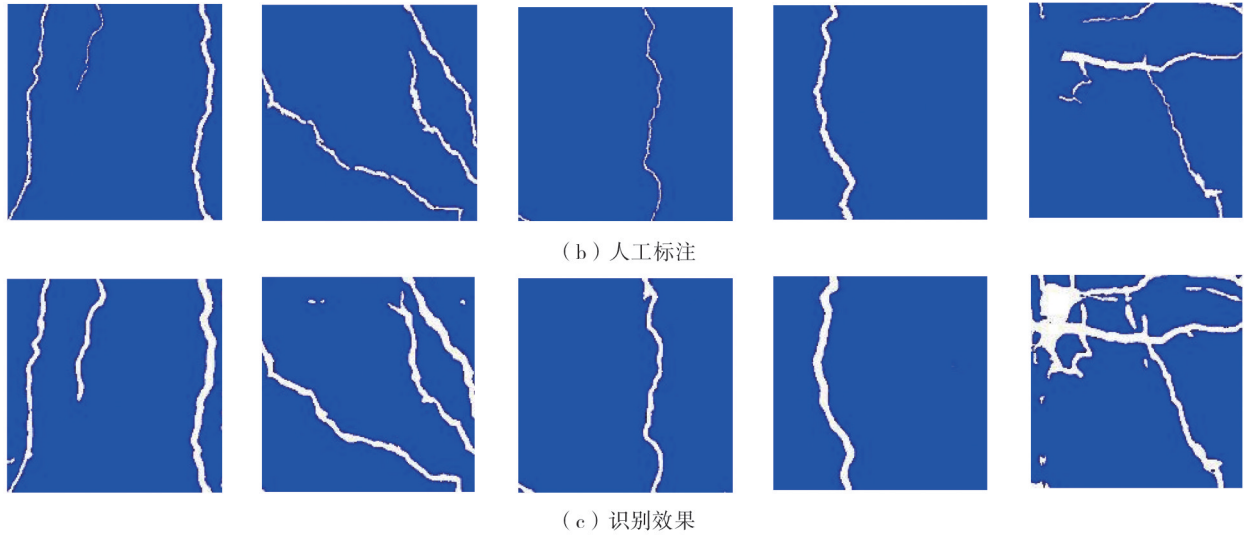


图7 模型在测试集上的裂缝识别效果

Fig.7 Crack detection performance of the model on the test set

为了进一步评估重构 CNN 模型的实际应用效果,随机选取非库存图像样本进行模型识别效果测试。图 8 结果显示模型可以有效区分真实裂缝与其周边形态近似的人工标记线,但仍存在大量离散的干扰噪声。

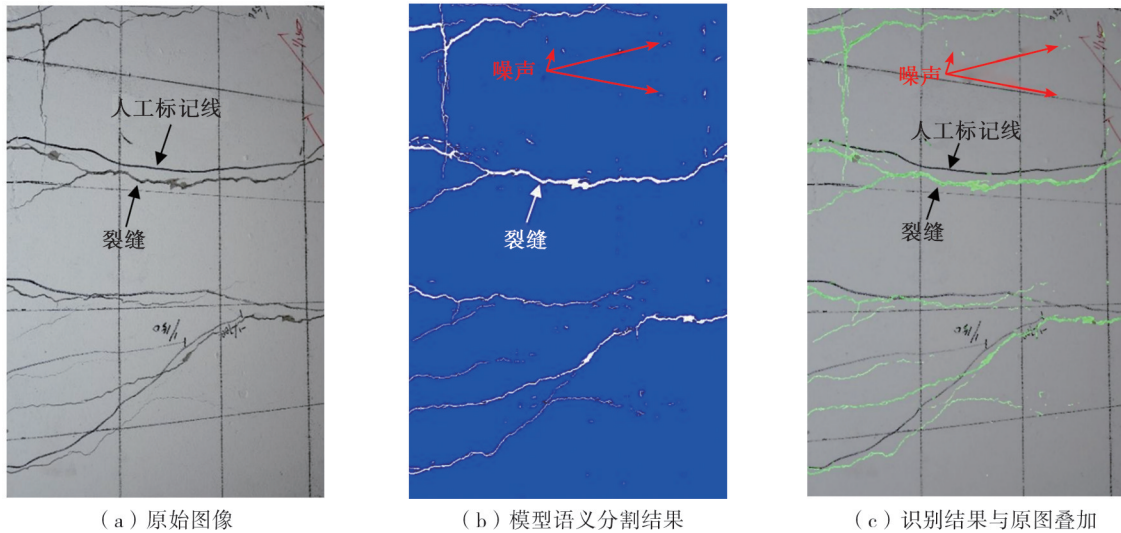


图8 模型裂缝识别效果

Fig.8 Crack detection performance of the model

基于图 8(c) 中裂缝和噪声在形态学上的显著差异,采用细长性指标^[14]作为阈值对不符合裂缝形态特征的连通域进行过滤,细长性指标 F_{pd} 的计算公式为

$$F_{pd} = \frac{A_o}{A_c} \quad (2)$$

式中: A_o 为连通域的面积; A_c 为连通域外接圆面积。细长性指标越小连通域在形态上就越细长,为了能更好地滤除非裂缝目标,将细长性指标阈值设定为 0.12^[15]。

详细分析测试集样本裂缝识别结果后发现识别出的裂缝宽度普遍偏大,为此以裂缝识别结果为蒙版,对原始图像的裂缝应用 Otsu 阈值分割以优化裂缝边界,其流程如图 9 所示。

以 2013 年 4 月 20 日四川雅安 7.0 级地震现场的 RC 结构震损照片为输入,检验本文 CrackNet 模型对实际震损裂缝的识别效果。实际震害裂缝的开展程度一般低于训练集所采用的试验裂缝,且实际 RC 构件的表面附着涂层或其他建筑做法,实际裂缝暴露程度较低,如图 10 所示。因此,虽然主要裂缝仍可以被本文模型有效识别,但也存在漏识别和错识别,后续将采用实际震害照片进一步扩充训练集,以减少此类问题。




图 9 裂缝识别优化流程

Fig. 9 Optimization flowchart of crack detection




图 10 地震现场 RC 结构表观裂缝识别

Fig. 10 Apparent crack detection of RC structure on the earthquake site

2 裂缝宽度测量

2.1 透视误差对裂缝宽度测量的影响

本研究暂不考虑镜头畸变对测量误差的影响,此时相机成像可近似为线性模型,也就是在与相机光轴垂直的拍摄平面上任意物理尺寸与其在相机所成的像的尺寸具有固定的比例关系,用公式表示为

$$J = \frac{O}{O'} = \frac{(L-f)}{f\alpha} \quad (3)$$

式中: J 为像素解析度; O 和 O' 分别为实际物理尺寸及其对应的像素尺寸; L 为物体与相机的距离; f 为相机焦距; α 为相机感光芯片单位物理尺寸包含的像素数。 f 和 α 均为相机的固定参数。

实际拍摄时无法保证相机光轴绝对垂直于构件表面,直接利用像素解析度 J 可以通过像素尺寸(物体在相机感光元件上的投影尺寸)计算其真实物理尺寸会出现较大的透视误差。二维坐标系中物体按照式(3)计算的尺寸约等于其实际尺寸与相机像面与物面夹角余弦值的乘积,如图 11(a)所示。建立如图 11(b)所示的以相机光心为坐标原点、相机光轴为 Z 轴的相机坐标系,观测平面法向量 η 在相机坐标系下的坐标为 (x_η, y_η, z_η) ,则该观测平面与相机坐标系 X, Y 轴的夹角分别为

$$\alpha_x = \frac{\pi}{2} - \arccos \frac{x_\eta}{\sqrt{x_\eta^2 + y_\eta^2 + z_\eta^2}} \quad (4)$$

$$\alpha_y = \frac{\pi}{2} - \arccos \frac{y_\eta}{\sqrt{x_\eta^2 + y_\eta^2 + z_\eta^2}} \quad (5)$$

裂缝在相机成像面上投影的宽度为 $T(u, v)$, $T(u, v)$ 可用有向线段表示,此线段与相机成像面上的图像坐标系的 u 轴夹角为 θ ,其在 U, V 这 2 个方向上的分量分别为 $T_u(u, v) = T(u, v) \cos \theta$ 和 $T_v(u, v) = T(u, v) \sin \theta$,则裂缝宽度在物面坐标系中对应的无透视误差分量 T_x 和 T_y 分别为

$$T_x = \frac{T(u, v) \cos \theta}{\cos \alpha_x} \cdot J \quad (6)$$

$$T_y = \frac{T(u, v) \sin \theta}{\cos \alpha_y} \cdot J \quad (7)$$

由此可得裂缝的真实宽度 T 为




图 11 透视误差

Fig. 11 Perspective error

2.2 逆透视投影变换

透视投影变换是射影变换的一种特殊形式,是关于平面中任意点齐次三维矢量的一种线性变换。齐次坐标是用 $n+1$ 维矢量表示一个 n 维矢量,对于平面上二维矢量表达的任意点 $P(x, y)$,其齐次坐标是 (kx, ky, k) , k 可取任意实数。透视投影变换表示为

$$\begin{bmatrix} x'_1 \\ x'_2 \\ x'_3 \end{bmatrix} = X' = HX = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad (9)$$

式中: H 为可逆的透视变换矩阵,与任意点的齐次表示一样,其意义是矩阵元素的比率,即该矩阵仅有 8 个自由度; X 和 X' 分别为平面中任意点的齐次坐标与其经过透视变换后的对应点的齐次坐标。

在透视变换下,物体的形状会失真,比如,虽然柱子的两条棱线是平行的,但是在图 12 中的柱子棱线不是平行的,会相交于图像的下侧某个位置。实际上平面(或部分平面)的透视投影的图像与其原平面是通过透视变换相关联的,因而该图像是原物体的一种透视失真。通过求解该透视变换的逆变化并把它应用于图像就可以消除这种透视失真。




图 12 具有透视误差的原始图像及其校正图

Fig. 12 Original image with perspective error and its corrected image

本研究基于 OpenCV 的逆透视算法,对原始图像进行透视失真校正。首先对提前粘贴的棋盘格样式的标靶进行关键点检测(图 12),建立检测平面(物面)与图像平面(像面)上对应关键点的匹配关系,进而计算 2 个平面的透视变换矩阵并求其逆,以校正原图像。利用校正后图像上关键点的像素坐标与其实际的物理坐标,计算得到像素解析度 J 为

$$J = \frac{2\sqrt{2}d}{D} \tag{10}$$

式中: d 为棋盘格尺寸; D 为关键点 p_1 和 p_9 的像素距离。

2.3 裂缝宽度测量方法

由于 RC 构件裂缝的角度变化复杂,相比于基于裂缝最小边缘点、基于裂缝边缘切线垂线和基于裂缝面积长度比等裂缝宽度测量方法^[16],基于二维卷积运算的图像滤镜法^[17]是一种更合适的方法。该算法通过一系列不同角度的条带模板与裂缝进行卷积运算,当卷积结果达到最小时认为条带模板与此处裂缝垂直,此时的卷积结果即是卷积核条带宽度与裂缝宽度的乘积,从卷积核条带宽度就可以得到裂缝的宽度。

设置条带模板的尺寸为 $W \times W$,条带是由一系列在水平方向或竖直方向的长度为 w_s 的定长直线构成,条带与水平方向的夹角为 θ_s ,其均匀分布在 $0^\circ \sim 180^\circ$ 范围内,如图 13 所示。本文采用的夹角增幅 $\delta_\theta = 5^\circ$,当条带的角度处于 $[0, 45]^\circ$ 或 $[135, 175]^\circ$ 范围时, w_s 表示条带的竖向宽度,当条带角度处于 $[50, 130]^\circ$ 范围时, w_s 表示条带的水平宽度。为获得裂缝任意位置的宽度,以裂缝骨架线上某个像素作为中心点,取出裂缝二值映射长宽为 W 的局部区域与各个角度的条带模板进行模板卷积,模板卷积实际上得到的是条带模板与裂缝重叠区域的像素数量,也可以认为是两者重叠区域的面积记为 $A(\theta_s)$,当其取最小值时可以近似认为与 θ_s 对应的条带与裂缝垂直,那么裂缝宽度 w_c 可由式(11)得出:

$$w_c = \frac{\min(A(\theta_s))}{w_s \cdot \cos(\arg \min_{\theta_s}(A(\theta_s)))} \tag{11}$$

以裂缝骨架线任意一端为起点,沿着裂缝骨架线重复上述操作即可得到裂缝任意位置的宽度值。

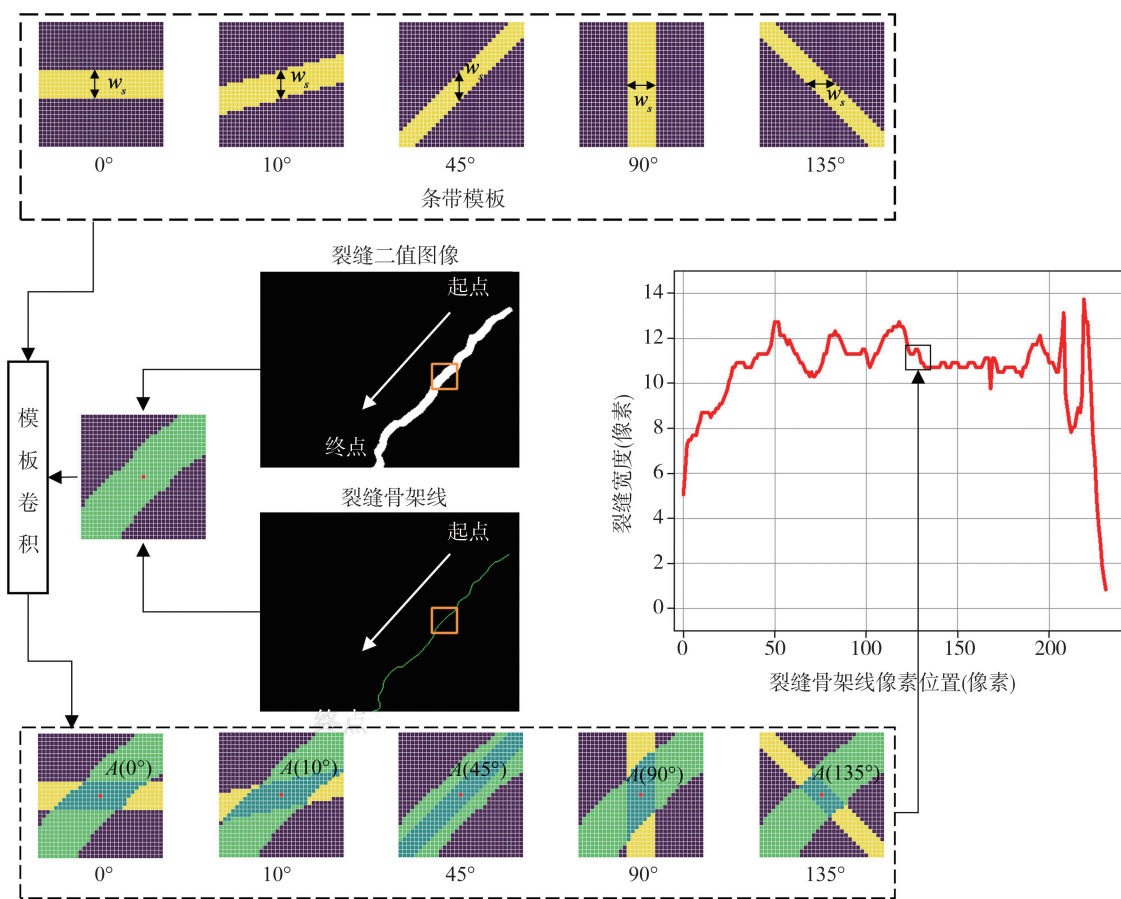


图 13 图像滤镜法测量裂缝宽度的基本流程

Fig. 13 Basic process of measuring crack width using image filtering method

为了计算裂缝的平均宽度和最大宽度,考虑到裂缝骨架线的 2 个端点存在较大测量误差,在计算时根据卷积模板的尺寸剔除骨架线 2 个端点一定位置的裂缝宽度值,计算裂缝最大宽度时为了防止个别位置的突变点的影响,在最大裂缝宽度处往前后延伸若干个像素,把这些位置的裂缝宽度同时考虑进来做平均处理,将结果值作为裂缝最大宽度,计算公式为

$$\overline{W}_c = \frac{1}{n} \sum_{i=0}^n w_i \quad (12)$$

$$W_{\max} = \frac{1}{2m+1} \sum_{i=p-m}^{p+m} w_i \quad (13)$$

式中: n 为裂缝骨架线上的像素总数; p 为沿裂缝骨架线第 p 个像素处裂缝宽度取得最大值; w_i 为沿裂缝骨架线第 i 个像素处的裂缝宽度; m 是为了防止裂缝宽度异常值的影响要求平均的范围。

3 试验验证分析

为了验证上述裂缝宽度测量方法的可行性与准确性,使用消费级单反相机(Canon EOS 5D Mark III, COMS 传感器尺寸 36 mm×24 mm,有效像素 2 230 万,图像最大分辨率 5 760 pixel×3 840 pixel)从不同角度拍摄经振动台试验后的 4 层框架结构模型的某边节点受损区域,选取 3 个不同位置裂缝作为测试点,基于上述方法进行裂缝识别,并按式(12)计算裂缝平均宽度作为该处裂缝的宽度。同时,以裂缝综合测试仪(测量范围 0.01~10 mm)测量相同位置裂缝的宽度,并以其为对比标准。

分别对原始图像进行透视误差校正前和校正后相同位置处的裂缝宽度进行测量,裂缝综合测试仪测量的裂缝宽度记为 C_t ,未经透视校正的原始裂缝图像通过上述算法得到的裂缝宽度记为 C_b ,经过透视校正的裂缝图像通过上述算法得到的裂缝宽度记为 C_a ,对比结果如表 2 所示。

表 2 透视校正前后裂缝宽度测量结果对比

Table 2 Comparison of crack width measurement results before and after perspective correction

拍摄角度/(°)	测试点	C_t /mm	C_b /mm	$(C_t - C_b / C_t) / \%$	平均偏差/%	C_a /mm	$(C_t - C_a / C_t) / \%$	平均偏差/%
30	1	0.19	0.212	12	11	0.196	3	9
	2	0.23	0.216	6		0.174	24	
	3	0.37	0.427	15		0.368	1	
5	1	0.19	0.253	33	19	0.242	27	14
	2	0.23	0.263	14		0.249	8	
	3	0.37	0.405	9		0.399	8	
60	1	0.19	0.433	128	72	0.334	76	47
	2	0.23	0.353	53		0.312	36	
	3	0.37	0.494	34		0.481	30	

在相机光轴与裂缝所在平面成约 30°、45°、60° 夹角时,原始的裂缝照片所测量的裂缝宽度与真实值的平均偏差分别为 11%、19%、72%,当相机光轴与裂缝所在平面的夹角越大裂缝测量的误差也就越大,这符合本文在 2.1 节推导的公式(7)。在 3 个不同拍摄角度下,裂缝图像透视校正前后裂缝宽度测量的平均偏差分别降低了 2%、5%、25%,由相机拍摄角度带来的透视误差得到了一定程度的控制。尽管通过透视校正降低了裂缝测量误差,但是校正后的裂缝宽度平均偏差依然偏大,这是因为裂缝宽度普遍较小(0.19~0.37 mm),对应的像素宽度仅有 4~5 像素,在卷积神经网络识别和后续的处理中都较易引起误差。对比效果如图 14 所示。




图 14 原始图像、裂缝识别结果和裂缝综合测试仪图像的对比

Fig. 14 Comparison of the original image, crack detection and crack synthetic tester images

4 结论

基于图像的非接触式测量技术可以很好地应对重复且繁杂的裂缝识别和宽度测量工作,且可以大幅降

低人工操作引起的误差。本文以消费级相机输出图像为基础,针对钢筋混凝土结构构件表面裂缝,提出基于卷积神经网络的 RC 构件裂缝识别和基于数字图像处理技术的裂缝图像透视误差校正与裂缝宽度测量方法。通过对比试验对透视误差校正算法的可行性和准确性进行检验和评价,得出如下结论:

1)以 U-Net 和 VGG-16 为基础构造的语义分割神经网络可以有效识别 RC 结构构件的表面裂缝,受限于数据样本有限,该模型识别结果的准确度尚待提升。

2)当相机光轴与构件表面法向量夹角不大于 45° 时,采用本文方法测量的裂缝宽度与真实宽度的偏差基本控制在 20% 以内。

3)本文提出的透视误差校正算法可以有效提高裂缝宽度测量的准确度,随着相机光轴与构件表面法向量夹角的增大,其修正效果越明显。

参考文献:

- [1] OLIVEIRA H, CORREIA P L. Supervised strategies for cracks detection in images of road pavement flexible surfaces[C]//2008 16th European Signal Processing Conference. Lausanne, Switzerland. Piscataway, NJ, USA: IEEE, 2008: 1-5.
- [2] KIM B, CHO S. Image-based concrete crack assessment using mask and region-based convolutional neural network[J]. Structural Control and Health Monitoring, 2019, 26(8): e2381.
- [3] DORAFSHAN S, THOMAS R J, MAGUIRE M. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete[J]. Construction and Building Materials, 2018, 186: 1031-1045.
- [4] 杨娜, 张翀, 李天昊. 基于无人机与计算机视觉的中国古建筑木结构裂缝监测系统设计[J]. 工程力学, 2021, 38(3): 27-39.
YANG Na, ZHANG Chong, LI Tianhao. Design of crack monitoring system for Chinese ancient wooden buildings based on UAV and CV[J]. Engineering Mechanics, 2021, 38(3): 27-39. (in Chinese)
- [5] 钟新谷, 彭雄, 沈明燕. 基于无人机成像的桥梁裂缝宽度识别可行性研究[J]. 土木工程学报, 2019, 52(4): 52-61.
ZHONG Xingu, PENG Xiong, SHEN Mingyan. Study on the feasibility of identifying concrete crack width with images acquired by unmanned aerial vehicles[J]. China Civil Engineering Journal, 2019, 52(4): 52-61. (in Chinese)
- [6] 刘学增, 叶康. 隧道衬砌裂缝的远距离图像测量技术[J]. 同济大学学报(自然科学版), 2012, 40(6): 829-836.
LIU Xuezheng, YE Kang. A long-distance image measuring technique for crack on tunnel lining[J]. Journal of Tongji University (Natural Science), 2012, 40(6): 829-836. (in Chinese)
- [7] SHAN B H, ZHENG S J, OU J P. A stereovision-based crack width detection approach for concrete surface assessment[J]. KSCE Journal of Civil Engineering, 2016, 20(2): 803-812.
- [8] LI G, HE S H, JU Y F, et al. Long-distance precision inspection method for bridge cracks with image processing[J]. Automation in Construction, 2014, 41: 83-95.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//International conference on medical image computing and computer-assisted intervention. Cham: Springer, 2015: 234-241.
- [10] GAO Y Q, MOSALAM K M. Deep transfer learning for image-based structural damage recognition[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9): 748-768.
- [11] 沈俊凯. 基于计算机视觉的混凝土裂缝检测算法研究[D]. 哈尔滨: 中国地震局工程力学研究所, 2019.
SHEN Junkai. Research on crack detection algorithm of concrete structure based on computer vision[D]. Harbin: Institute of Engineering Mechanics, China Earthquake Administration, 2019. (in Chinese)
- [12] MIAO Z H, JI X D, OKAZAKI T, et al. Pixel-level multicategory detection of visible seismic damage of reinforced concrete components[J]. Computer-Aided Civil and Infrastructure Engineering, 2021, 36(5): 620-637.
- [13] LI D R, DUAN Z D, HU X Y, et al. Pixel-level recognition of pavement distresses based on U-net[J]. Advances in Materials Science and Engineering, 2021, 2021: 5586615.
- [14] AMMOUCHE A, BREYSSE D, HORNAIN H, et al. A new image analysis technique for the quantitative assessment of microcracks in cement-based materials[J]. Cement and Concrete Research, 2000, 30(1): 25-35.
- [15] LEE B Y, KIM Y Y, YI S T, et al. Automated image processing technique for detecting and analysing concrete surface cracks[J]. Structure and Infrastructure Engineering, 2013, 9(6): 567-577.
- [16] 马国鑫. 基于无人机采集图像的建筑表面裂缝检测方法研究[D]. 镇江: 江苏大学, 2018.
MA Guoxin. Research on detection methods of building surface cracks based on uav image acquisition[D]. Zhenjiang: Jiangsu University, 2018. (in Chinese)
- [17] JAHANSHAHI M R, MASRI S F. A new methodology for non-contact accurate crack width measurement through photogrammetry for automated structural safety evaluation[J]. Smart Material Structures, 2013, 22(3): 035019.