

融合深度学习聚类分割和形态学的混凝土 表面裂缝量化识别

杨杰文¹, 章光¹, 陈西江^{1*}, 班亚²

¹武汉理工大学安全与应急管理学院, 湖北 武汉 430079;

²重庆市计量质量检测研究院, 重庆 404100

摘要 混凝土结构在施工与使用的过程中易产生各种形式的裂缝,由此会产生诸多安全问题。传统的人工安全检测方法,不仅耗费财力和时间,而且无法保障其检测精度。为了提高混凝土表面裂缝的识别效率,提出了一种基于卷积神经网络结合聚类分割的识别方法,实现了对较复杂背景下混凝土表面裂缝图像的准确识别。研究结果显示,该方法不仅能够高效地分类,还能够高精度地对较复杂背景下的裂缝进行识别,这为降低混凝土表面裂缝识别的工作量、维护混凝土结构,对其进行安全检测提供了理论依据,同时也为以后更高精度和更复杂条件下的裂缝识别研究提供了一些参考。

关键词 图像处理; 裂缝识别; 安全检测; 卷积神经网络; 聚类分割; 形态学处理; 量化识别

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP57.221023

Quantitative Identification of Concrete Surface Cracks Based on Deep Learning Clustering Segmentation and Morphology

Yang Jiewen¹, Zhang Guang¹, Chen Xijiang^{1*}, Ban Ya²

¹School of Safety & Emergency Management, Wuhan University of Technology, Wuhan, Hubei 430079, China;

²Chongqing Academic of Measurement and Quality Inspection, Chongqing 404100, China

Abstract Various forms of cracks can easily occur during the construction and use of concrete structures, leading to many security problems. The traditional manual safety detection method not only consumes financial resources and time but also provides no guarantee of accuracy. To improve the efficiency of crack recognition on a concrete surface, a recognition method based on convolutional neural network combined with clustering segmentation is proposed herein, which achieves accurate recognition of concrete surface crack images under more complex backgrounds. Results show that the proposed method can not only efficiently classify but also identify cracks in more complex backgrounds with high accuracy. In addition, the proposed method provides a certain theoretical basis for the workload reduce of crack recognition on concrete surfaces, as well as the maintenance and safety inspection of concrete structures. Furthermore, the proposed method provides references for future fracture-identification studies under higher accuracy and more complex conditions.

Key words image processing; crack identification; safety detection; convolutional neural network; clustering segmentation; morphological processing; quantitative identification

OCIS codes 100.2960; 100.3008; 100.4996

收稿日期: 2020-02-10; 修回日期: 2020-02-29; 录用日期: 2020-03-06

基金项目: 国家自然科学基金青年科学基金(41501502)、重庆市质量技术监督局科研计划项目(CQZJKY2018004)、重庆市技术创新与应用发展专项面上项目(cstc2019jscx—msxmX0051)、长江科学院开放研究基金资助项目(CKWV2019758/KY)

* E-mail: cxj_Q421@163.com

1 引言

目前,我国混凝土结构的应用十分广泛,涉及许多工程行业,其在施工与使用的过程中会产生各种裂缝,这给结构的施工以及维护保养带来了安全隐患。目前最普遍的检测方法仍是人工检测,不仅效率低下,还存在安全问题。而较为先进的无损检测方法成本高昂且无法完全实现非接触测量。近年来,随着计算机视觉技术的不断发展,基于计算机技术对裂缝实现高精度检测成为了热点。然而,其检测方法主要分为传统的图像处理方法(包括滤波处理^[1]、边缘检测^[2]、阈值分割^[3]、区域分割^[4]等)和机器学习方法(基于深度学习^[5]和聚类分割^[6]等)。

针对传统图像处理方法,孙卫红等^[7]利用相位角及灰度分布改进 Canny 算子,对较细的表面裂缝进行识别,但是产生了较多的噪声。肖利芳等^[8]尝试基于 Sobel 算子的改进边缘检测算法对混凝土表面裂缝进行检测,较好地去除了噪声,但对于裂缝整体骨架的提取效果不佳。韩豫等^[9]采用 Otsu 法改进 Canny 边缘算法,实现了对裂缝的提取,但是提取的裂缝骨架不够完整并且整体识别准确率不够高。而邵闯等^[10]在中值滤波方法的基础上,提出了一种改进的中值滤波方法,结合阈值分割方法,能较好地对比度差异不明显的混凝土表面裂缝进行识别,但是该方法不能识别复杂背景下的裂缝。瞿中等^[11]利用改进选择算子的遗传规划算法实现了对混凝土裂缝图像的光照归一化,能对一定复杂背景下的裂缝进行识别,但是效果不够显著。

相比于传统图像处理方法,刘新根等^[12]基于深度卷积神经网络,结合滑动窗口技术,不仅能一定程度上减少背景对裂缝识别的影响,还能够对大批量的裂缝图片进行较高精度的识别,但还是仅限于施工缝、线缆等背景的干扰。而 Cha 等^[13]利用深度学习,从大量图像样本中学习共有特征,提出一种鲁棒性很强的分类器,但仅能实现对不同光照条件下的混凝土构件上的裂缝检测。王森等^[14]引入全卷积神经网络实现了较复杂背景下的裂缝目标的有效检测,降低了错误标记的概率,但是处理效率仍不够高。薛亚东等^[15]基于改进优化的卷积神经网络 GoogleNet,较好地实现了复杂背景下多样裂缝的高精度识别,但是对裂缝数据集识别的准确率不够理想。

基于以上研究,针对混凝土表面裂缝,本文提出基于神经网络和聚类分割组合的混凝土表面裂缝识别的方法,实现了对混凝土表面裂缝图像的精确识别和量化计算。

2 裂缝初步识别

2.1 裂缝识别网络(CIN)

针对裂缝形状的多样性及裂隙量级的不确定性,在卷积神经网络基础上提出了一种名为裂缝识别网络(CIN),其结构如图 1 所示。令 i 为序号,则 L_i 为第 i 层; C_i 为第 i 次卷积操作; P_i 为第 i 次池化操作。其中: $L_1, L_3, L_4, L_6, L_8, L_9$ 为卷积层; L_2, L_5, L_7, L_{10} 为池化层; L_{11} 为全连接层; L_{12} 为 ReLU 层; L_{13} 为 Dropout 层; L_{14} 为 Softmax 层。




图 1 裂缝识别网络(CIN)结构示意图

Fig. 1 Schematic of Crack Identification Net (CIN)

该模型的基本结构由 6 个卷积层、4 个池化层、1 个全连接层和 1 对输入、输出层组成。其中,对所有的卷积层和全连接层均进行批规范化处理,以提升模型的泛化能力;为了保证图像不因过大或过小而影响识别效果,设定输入层为尺寸大小 $256 \times 256 \times 3$ 的图像,其中 3 个维度分别为长度、宽度和

RGB 分量(红色、绿色和蓝色分量);为了更好地进行特征压缩,简化网络复杂程度,设置 L_2, L_5, L_7, L_{10} 的池化窗口大小分别为 $2 \times 2, 4 \times 4, 4 \times 4, 6 \times 6$, 步长均为 2,并采用最大池化法则;而为了得到更深层的图像特征,同时保证不增加网络的复杂性,设置卷积层 L_1, L_3, L_6, L_8 的卷积核尺寸为 $3 \times 3, L_4$ 和

L_9 卷积核的尺寸为 5×5 , 所有卷积层步长均为 1; 经由卷积和池化处理, 通过 Flatten 操作输出包含 512 个元素的矢量至 ReLu 层; 再经过 Dropout 层随机切断部分神经元连接, 使得网络模型参数之间的依赖性降低, 以提高模型的鲁棒性, 有效防止过拟合; 最后通过 Softmax 层来判断经过以上处理后

的数据是否为裂缝图像。

根据所构建的裂缝识别网络进行裂缝的识别。首先, 建立大量的裂缝数据集, 并将该数据集划分为训练集和验证集。利用划分好的训练集和验证集对裂缝识别网络模型进行训练, 然后通过测试集检验模型预测的效果, 其整体识别流程如图 2 所示。

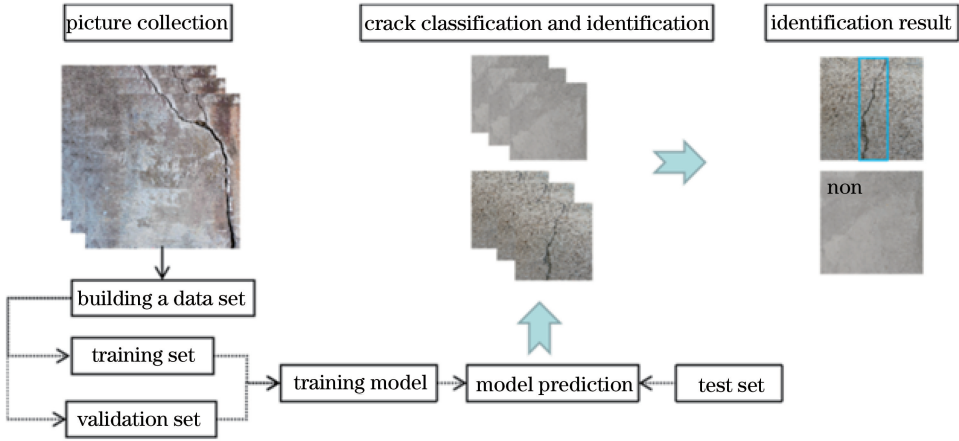


图 2 识别流程图

Fig. 2 Flowchart of identification

2.2 数据集验证

利用数码单反相机(Nikon D5600)采集 500 张原始图像, 拍摄距离为 15 m, 角度控制在 $60^\circ \sim 90^\circ$ 。每张图像由于拍摄距离及角度不同, 光照强度均有所差异。在 500 幅原始图像中, 300 幅图像用于训练、验证和测试, 200 幅图像用于第二次测试。将 300 幅图像的尺寸裁剪为 $256 \text{ pixel} \times 256 \text{ pixel}$, 然

后将每幅图像标注上无裂缝, 将其作为预处理步骤构建用于训练、验证和测试的数据库。生成的数据库包含广泛的裂缝图像类型, 如裂缝图像中包含了交叉裂缝、粗细裂缝以及带杂物裂缝等, 非裂缝图像包含了带有阴影、凸起和纹理等的混凝土表面, 便于训练出具有高鲁棒性和高精度的裂缝检测模型, 如图 3 所示。




图 3 裂缝与非裂缝图像。(a)裂缝图像;(b)非裂缝图像

Fig. 3 Example of crack and non-crack images. (a) Crack images; (b) non-crack images

为了对识别模型的识别精度进行有效地验证, 并且保证检测方法的简便性, 采用交叉验证法^[16]进行验证, 训练 5 组模型, 得到 5 组模型的训练结果, 图 4 所示为随机挑选的第 4 组训练结果, 分别为训练集与验证集的正确率和损失率曲线。

由图 4(a)可知, 模型收敛速度十分迅速。在较少样本数据的情况下, 损失曲线下降较快, 在 20 epochs 时曲线便趋于稳定, 代表样本训练几乎完成。由图 4(b)可清楚地看到验证集精度不断上升, 损失值不断降低, 且在 20 epochs 时精度趋于 100%, 损失值趋于 0, 且两者趋于稳定, 说明在 20 epochs 时训练完成。

由图 4(a)可知, 模型收敛速度十分迅速。在较




图4 第4组模型的训练以及验证结果。(a)训练结果;(b)验证结果

Fig. 4 Training and validation results for group 4th model. (a) Training results; (b) validation results

图5所示为5种交叉验证的结果,5组模型训练集的正确率均在99%以上,验证集正确率的平均值为99.1%。5组模型的验证集的正确率有稍许变动,但变动范围较小,由此体现出裂缝网络训练模型

具有较好的鲁棒性和稳定性。

从数据集中随机抽取部分图像测验裂缝识别网络的识别裂缝的效果,其识别结果如图6所示。

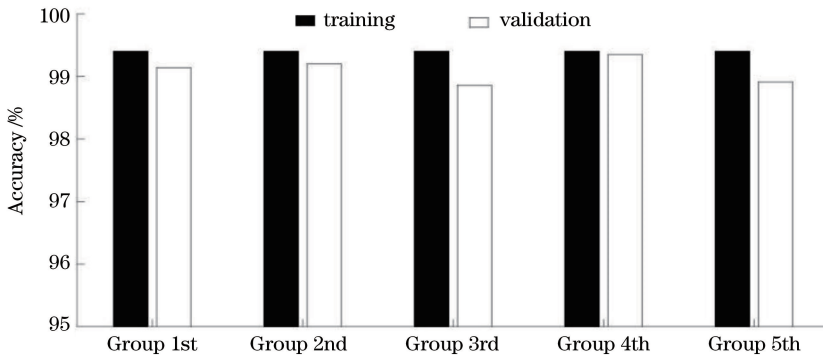


图5 5种不同组合的训练与验证正确率

Fig. 5 Accuracy rate of training and validation for 5 different groups




图6 裂缝识别效果。(a)原始图像;(b)裂缝分类与识别结果

Fig. 6 Example of identification results. (a) Original image; (b) crack classification and identification result

由图6可知,裂缝识别网络虽然对确定的裂缝图像进行了准确定位,但是定位结果没有对裂缝进行完整的标识,缺乏连续性,并且不能消除图中背景杂物对裂缝的影响。如果仅依此结果进行裁剪来进行定量计算,将产生较大的误差,所以需要进一步对裂缝进行精确分割。

3 裂缝精确分割

经过裂缝初步识别,得到了初始裂缝图像,但没

有实现对裂缝图像中裂缝的准确分割。对此,本节在改进K-means聚类算法的基础上实现对裂缝的精确分割。

3.1 改进K-means聚类分割算法

K-means聚类算法虽然具有快速、高效的分割特性,但是其对聚类中心选取的要求很高且极易收敛到局部最优解,从而错过全局最优解。针对此,本研究利用动态粒子群优化(DPSO)实现对K-means聚类算法的改进。

具体改进步骤如下:

1) 首先将彩色图像转换为灰度图像,得到裂缝的初始灰度图像,给定初始聚类数 k 。

2) 根据 K-means 算法确定聚类中心 m 。

3) 聚类中心确定之后,计算粒子 i 的适应度值,表达式为

$$f_i = \sum_{i=1}^n \sum_{j=1}^k \|x_i - m_j\|^2, \quad (1)$$

式中: x_i 为数据点集 X 中的第 i 个数据点; m_j 为第 j 个聚类中心; n 为粒子个数。

4) 确定粒子的惯性系数 ω ^[17] 和学习因子 s ^[17]。惯性系数可表示为

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min}) \times (f_i - f_{\min})}{f_{\text{ave}} - f_{\min}}, & f_i \leq f_{\text{ave}} \\ \omega_{\max}, & f_i > f_{\text{ave}} \end{cases} \quad (2)$$

式中: ω_{\max} 为最大惯性系数; ω_{\min} 为最小惯性系数; f_i 是粒子 i 的当前适应值; f_{ave} 是所有粒子的当前平均适应值; f_{\min} 是所有粒子的最小适应值。学习因子可表示为

$$\begin{cases} s_1 = s_{1,\text{int}} + \frac{s_{1,\text{fin}} - s_{1,\text{int}}}{t_{\max}} \times t \\ s_2 = s_{2,\text{int}} + \frac{s_{2,\text{fin}} - s_{2,\text{int}}}{t_{\max}} \times t \end{cases}, \quad (3)$$

式中: s_1, s_2 分别代表粒子的自我学习能力和向优秀集体的学习能力; $s_{1,\text{int}}$ 和 $s_{2,\text{int}}$ 代表粒子初始的学习能力; $s_{1,\text{fin}}$ 和 $s_{2,\text{fin}}$ 代表粒子最终的学习能力, $s_{1,\text{int}} > s_{2,\text{int}}, s_{1,\text{fin}} > s_{2,\text{fin}}$; t_{\max} 表示算法的最大运行时间。

5) 利用步骤 4) 得到的惯性系数 ω 和学习因子 s 更新粒子的速度 v_i 和位置 x_i , 表达式为

$$\begin{cases} x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1), & j = 1, 2, 3, \dots, d \\ v_{ij}(t+1) = \omega v_{ij}(t) + s_1 r_1 [p_{ij} - x_{ij}(t)] + \\ \quad s_2 r_2 [p_{gj} - x_{ij}(t)] \end{cases}, \quad (4)$$

式中: r_1, r_2 为区间 $[0, 1]$ 上均匀分布的两个随机数; t 为时间; p_{ij} 为粒子 i 在更新过程中经历的位置; p_{gj} 为粒子 i 在更新过程中经历的最佳位置。

6) 当达到最大迭代次数或者粒子群适应度方差 δ^2 收敛于固定值时,输出全局最优解,得到粒子群适应度方差 δ^2 , 即

$$\delta^2 = \frac{1}{n} \sum_{i=1}^n (f_i - f_{\text{ave}})^2, \quad (5)$$

否则重复步骤 2) 至步骤 4)。

7) 以步骤 5) 的最优解为最优聚类中心,进而得到 k 个聚类。

8) 进行准则函数判断。采用戴维森堡丁指数 (DBI, η_{DBI}) 指标函数^[18] 作为最终聚类结果的准则函数,其计算公式为

$$\eta_{\text{DBI}} = \frac{1}{k} \sum_{i=1}^{k-1} \sum_{j=i+1}^k \max \left\{ \frac{S_i + S_j}{d(i, j)} \right\}, \quad (6)$$

式中: $d(i, j)$ 表示为第 i 个类与第 j 个类间的类间距离; S_i 表示为第 i 个聚类中每一个数据点与该类的中心 m_i 之间的欧氏距离标准误差和; k 表示为数据集的总聚类数。

9) 若 η_{DBI} 收敛则将此时的聚类结果作为最终结果输出;若不收敛则重复步骤 2) 至步骤 8) 直至收敛,然后再输出结果。

3.2 算法性能分析

采用精确率 (precision)、召回率 (recall) 和 F-measure 评价指标对算法的有效性进行评价,具体评价指标^[19] 的定义为

$$P = \frac{a}{a + b}, \quad (7)$$

$$R = \frac{a}{a + c}, \quad (8)$$

$$F = \frac{2PR}{P + R}, \quad (9)$$

其中: P 代表精确率; R 代表召回率; F 代表 F-measure 值; a 代表裂缝图像中被正确识别为裂缝的图像数; b 代表背景图像中被识别为裂缝的图像数; c 代表裂缝图像中被识别为背景的图像数。

3.3 与传统算法对比

基于本文裂缝数据集,以几张较为简单的裂缝图像为例,将本文提出的改进算法与传统改进的 Otsu 算法^[20]、改进的 Canny 算子^[21] 以及改进的中值滤波算法^[22] 的分割效果进行对比,其对比效果如图 7 所示。

由图 7 可知,针对图示裂缝,传统算法带有大量的极细微的噪声,并且连续性和完整性较差;而本文算法比较真实准确地还原了原始裂缝骨架的轮廓,并且能够完全去除表面杂质带来的噪声。再将各算法与本文提出的 CIN 进行融合,并对整体的识别效果进行对比分析,其各项评价指标对比如图 8 所示。

由图 8 可知,基于本文数据集,改进 K-means 算法的召回率和 F-measure 值均在 90% 以上,精确率达到了 97%,均远高于其他三类算法。由此可




图 7 利用本文算法和传统方法获得的分割效果。(a)原图像;(b)改进 Otsu 算法;(C)改进 Canny 算法;(d)改进中值滤波算法;(e)本文算法

Fig. 7 Segmentation results obtained by the proposed algorithm and traditional methods. (a) Original image; (b) improved Otsu algorithm; (c) improved Canny algorithm; (d) improved median filter algorithm; (e) our algorithm

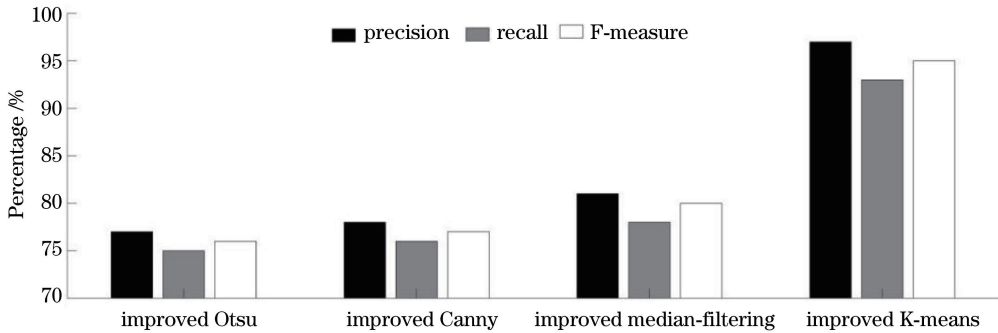


图 8 各算法的评价指标对比

Fig. 8 Comparison of evaluation indicators of each algorithm

知,改进 K-means 算法的性能要优于上述三类传统算法。

3.4 与聚类算法对比

基于本文裂缝数据集,利用本文提出的改进的 K-means 分割算法对带有大量青苔、带落叶或水渍的混凝土表面裂缝图像进行识别,并将识别结果与 K-means 算法^[23]、mean shift 算法^[24]以及 Fuzzy C-means 算法^[25]进行对比分析,如图 9 所示。

由图 9 可知,针对图示的带青苔的裂缝图片,各算法均能提取出裂缝骨架,但是只有改进 K-means 算法能够去除所有噪声。而针对带落叶和水渍的裂缝图片,只有改进 K-means 算法去除了干扰物带来的噪声,且完整而又精确地提取出了裂缝骨架。而各算法结合 CIN 后的指标评价对比如图 10 所示。

由图 10 可知,基于本文数据集,改进 K-means 算法的召回率和 F-measure 值均在 90%以上,精确率达到了 97%,仍远高于其他三类聚类算法。由上可知,改进 K-means 算法的性能要优于以上聚类

算法。

4 裂缝量化识别

基于 CIN 和改进 K-means 算法准确分割出的裂缝骨架,本章将对裂缝的相关物理尺寸进行量化识别。

4.1 裂缝物理尺寸

需对裂缝的物理尺寸,即面积、长度、平均宽度以及占据比例进行计算,计算方法如下。

1) 裂缝面积:计算出每个连通域包含的像素数目,依据每个像素所对应的实际物理尺寸,得到每个连通域的面积,并对所有连通域的面积进行求和。裂缝的实际物理尺寸为

$$P_a = \eta^2 \cdot P_i, \quad (10)$$

式中: P_a 单位为 mm^2 ; P_i 为裂缝的像素尺寸,单位为 pixel^2 ; η 为裂缝在图像中的缩放比例,单位为 $\text{mm} \cdot \text{pixel}^{-1}$ 。

2) 裂缝长度:对裂缝骨架进行图像细化,细化后

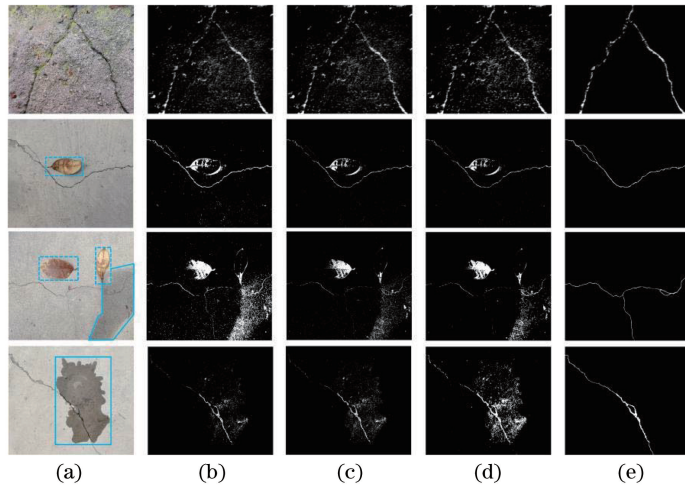


图9 利用本文算法和聚类方法获得的分割效果。(a)原图像;(b) K-means 算法;(c) Meansshift 算法;(d) Fuzzy C-means 算法;(e)本文算法

Fig. 9 Segmentation results obtained by the proposed algorithm and clustering methods. (a) Original image; (b) K-means algorithm; (c) mean shift algorithm; (d) fuzzy C-means algorithm; (e) our algorithm

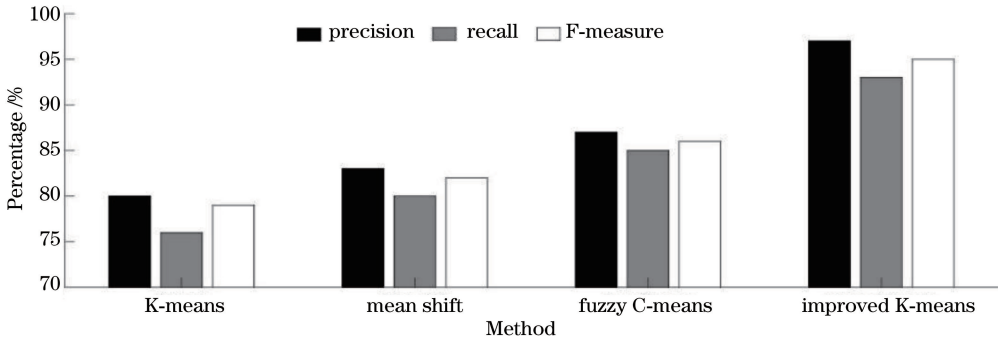


图10 各算法的评价指标对比

Fig. 10 Comparison of evaluation indicators of each algorithm

的裂缝宽度为单个像素,计算此时周长的一半可得此时裂缝的像素数目,并依据(12)式每个像素实际物理尺寸,得到裂缝长度。

3) 裂缝平均宽度:裂缝平均宽度为裂缝面积与长度之比,结合裂缝长度的计算方法可得裂缝平均宽度,计算公式为

$$d_i = 2S_i / C_i, 1 \leq i \leq n, \quad (11)$$

式中: S_i 为第 i 个裂缝的面积, C_i 为第 i 个裂缝的周长, d_i 为第 i 个裂缝的平均宽度, n 为裂缝总数。

4) 裂缝占据比例:裂缝的面积与图像总面积之比。

4.2 裂缝标识

为了便于计算裂缝的尺寸,需对采集到的裂缝图像进行标识。基于本文数据集,结合 CIN 网络模型的输出结果,对裂缝图片进行标识测试。使用软件为 matlab 2016b,处理器为 Intel(R) Core(TM) i5-8300H CPU @2.30 GHz,内存为 8.00 GB,显卡

为 NVIDIA GeForce GTX1050Ti,操作系统为 Windows 10。

为更好地验证本文方法对裂缝的标识性能,以图 11 所示的裂缝为例,进行标识测验,并且为了便于对裂缝进行量化计算,对裂缝进行了分段标识。其中图 11(a)为裂缝原图像;利用本文方法对裂缝图像进行基于深度学习的识别,其识别结果如图 11(b)所示;对识别裂缝的分割如图 11(c)所示;对分割的裂缝的标识如图 11(d)所示。

由图 11 可知,本文方法对图 11(a)中的裂缝图像标识效果十分良好。对第一张裂缝图像的宽窄部分均做到了有效识别和标识;对第二张极细裂缝图像的标识均恰当地在转折处分段;对第三张带有一定角度且有微小断裂的裂缝仍做到了精确标识和分段。

4.3 裂缝尺寸计算

利用本文方法对裂缝进行识别、分割和标识,最




图 11 裂缝标识示例。(a)原图像;(b)神经网络识别;(c)分割;(d)标识

Fig. 11 Identification of cracks with different thicknesses. (a) Original image; (b) identification of neural network; (c) segmentation; (d) mark

终实现了量化标识,如图 12 所示。本研究所用拍摄设备为数码单反相机(Nikon D5600),该相机在图像拍摄中的缩放比例 η 为 $0.21 \text{ mm} \cdot \text{pixel}^{-1}$ 。

由图 12 可知,由于每段裂缝的宽度不一,对裂缝采取了分段标识,图12(a)中裂缝1包含8个分

段标识,图 12(b)中裂缝 2 包含 4 个分段标识,裂缝 1 和裂缝 2 各分段以及整体的像素尺寸和占据比例如表 1 所示。结合表 1 和缩放比例 η ,得到裂缝 1 和 2 的实际尺寸,并与裂缝测量仪测量结果进行了对比,得到的结果如表 2 所示。




图 12 裂缝标识示例图。(a)裂缝 1;(b)裂缝 2

Fig. 12 Example of crack marking. (a) Crack 1; (b) crack 2

表 1 裂缝 1 和 2 的像素尺寸

Table 1 Pixel sizes of crack 1 and crack 2

Crack number	Segmentation number	Width / pixel	Length / pixel	Average width /pixel	Overall length /pixel	Area / pixel ²	Occupation ration /%
Crack 1	1	4	107	4.63	1193	5994	0.76
	2	4	63				
	3	4	97				
	4	5	152				
	5	6	163				
	6	6	286				
	7	5	258				
	8	3	67				
Crack 2	1	5	913	4.75	1384	6213	1.47
	2	6	106				
	3	4	240				
	4	4	125				

表 2 裂缝 1 和 2 的实际尺寸

Table 2 Actual size of cracks 1 and crack 2

Crack number	Quantitative calculation			Crack gauge measurement		
	Average width /mm	Overall length /mm	Area /mm ²	Average width /mm	Overall length /mm	Area /mm ²
Crack 1	0.97	250.53	264.33	1.00	251.20	261.52
Crack 2	1.00	290.64	273.99	0.98	288.42	270.26

从表 1 和表 2 可知,本文提出的识别方法所得尺寸与裂缝测量仪所得尺寸误差并不是很大。为了更加精确地对本文方法精度进行验证,从数据集中随机抽取部分图像,将这部分图像分成 10 类,每一

类选取一幅具有代表性的图像,如图 13 所示。对这 10 幅裂缝图像的量化识别的结果进行统计,并与裂缝测量仪所测的平均宽度、整体长度和面积进行对比,其统计结果如表 3 所示,精度如表 4 所示。



图 13 用于量化计算的裂缝原始图像

Fig. 13 Original crack images for quantitative calculation

表 3 统计结果对比

Table 3 Comparison of statistical results

Group number	Average width /mm			Overall length /mm			Area /mm ²		
	Quantitative calculation	Crack gauge measurement	Error	Quantitative calculation	Crack gauge measurement	Error	Quantitative calculation	Crack gauge measurement	Error
1	0.98	1.00	0.02	253.11	257.33	4.22	250.52	254.33	3.81
2	0.9	0.92	0.02	232.45	236.62	4.17	211.20	215.69	4.49
3	1.12	1.08	0.04	289.27	280.94	8.33	320.98	318.41	2.57
4	1.05	1.02	0.03	271.19	265.44	5.75	281.74	277.74	4
5	0.97	1.00	0.03	250.53	256.28	6.75	248.82	253.28	4.46
6	1.02	1.00	0.02	263.44	259.60	3.84	266.70	260.24	6.46
7	0.95	0.98	0.03	245.36	250.42	5.06	240.12	247.41	7.29
8	0.95	0.97	0.02	246.72	251.53	4.81	244.54	248.78	4.24
9	0.99	1.02	0.03	265.7	263.44	2.26	265.88	267.23	1.35
10	1.2	1.16	0.04	309.93	304.60	5.33	364.81	355.60	9.21

表 4 统计结果精度

Table 4 Accuracy of statistical results

Group number	Accuracy of average width /mm	Accuracy of overall length /mm	Accuracy of area /mm ²
1	98.00	98.36	98.50
2	97.83	98.24	97.92
3	96.30	97.03	99.19
4	97.06	97.83	98.56
5	97.00	97.37	98.24
6	98.00	98.52	97.52
7	96.94	97.98	97.05
8	97.94	98.09	98.30
9	97.06	99.14	99.49
10	96.55	98.25	97.41

由表4可知,本文提出的量化识别方法具有较好的稳定性,与裂缝测量仪测量结果相比,精度最低为96.55%,最高可达99.49%,具有极高的识别精度。

5 结 论

提出了一种融合深度学习卷积神经网络、聚类分割以及形态学方法的混凝土表面裂缝识别和尺寸计算方法。该方法能够实现混凝土裂缝与非裂缝图像的有效分类,并能对裂缝进行精确分割和量化识别。主要结论如下:

1) 运用深度学习卷积神经网络进行训练,得到了裂缝初步识别模型。经过验证与测试,识别正确率可达98.8%以上。同时将深度卷积神经网络的裂缝识别模型与聚类分割、形态学方法结合,提出了一种名为CIN的混合多算法裂缝识别提取方法。

2) 对比传统分割算法以及同类的聚类分割算法,可知本文提出的改进K-means算法在保证极高的分割精度和准确率的情况下,能够对复杂背景下的多种混凝土表面裂缝进行识别。

3) 在本文算法的基础上结合形态学方法,实现了对裂缝的标识、量化识别,以及裂缝物理尺寸的计算,且实验证明量化识别的精度最低为96.55%,最高可达99.49%。

4) 为保障混凝土表面裂缝检测人员的安全、减少工作量、维护混凝土结构、对结构进行安全检测,提供了一定的理论依据,也为以后更高精度和更复杂条件下的同类裂缝的识别研究提供了一些参考。

参 考 文 献

- [1] Zhu H C, Tong Y J, Ji T, et al. Elimination technology of noise introduced by top-up injection in synchrotron radiation infrared beamline [J]. Journal of Infrared and Millimeter Waves, 2018, 37(2): 251-257.
朱化春, 佟亚军, 吉特, 等. 使用区域中值滤波算法降低同步辐射红外线站由Top-Up模式引入的噪声[J]. 红外与毫米波学报, 2018, 37(2): 251-257.
- [2] Chen Z G, Li Y G, Chen X F, et al. Edge and texture detection of metal image under high temperature and dynamic solidification condition[J]. Journal of Central South University, 2018, 25(6): 1501-1512.
- [3] Wen N, Yang S Z, Zhu C J, et al. Adaptive contourlet-wavelet iterative shrinkage/thresholding

for remote sensing image restoration[J]. Journal of Zhejiang University SCIENCE C, 2014, 15(8): 664-674.

- [4] Wang G L, Zhang X H, Han Y C, et al. Automatic multi-region segmentation of intracoronary optical coherence tomography images based on neutrosophic theory[J]. Journal of Biomedical Engineering, 2019, 36(1): 59-67.
王光磊, 张学红, 韩业晨, 等. 基于中智学理论的冠脉光学相干断层图像的全自动多区域分割[J]. 生物医学工程学杂志, 2019, 36(1): 59-67.
- [5] Lin L K, Wang S Y, Tang Z X. Point target detection in infrared over-sampling scanning images using deep convolutional neural networks[J]. Journal of Infrared and Millimeter Waves, 2018, 37(2): 219-226.
- [6] Wu Q P, Wu C M. A fast and robust clustering segmentation algorithm for kernel space graphics[J]. CAAI Transactions on Intelligent Systems, 2019, 14(4): 804-811.
- [7] Sun W H, Li Q K, Shao T F, et al. Crack detection algorithm of protective wall for piles based on machine vision [J]. Computer Engineering and Applications, 2019, 55(14): 260-265.
孙卫红, 李乾坤, 邵铁锋, 等. 基于机器视觉的桩护壁裂缝检测方法[J]. 计算机工程与应用, 2019, 55(14): 260-265.
- [8] Xiao L F, Zhou D Y. Application of Sobel operator improved edge detection algorithm in concrete crack identification[J]. Software Guide, 2017, 16(1): 112-114.
肖利芳, 周道洋. Sobel算子改进边缘检测算法在混凝土裂缝识别中的应用[J]. 软件导刊, 2017, 16(1): 112-114.
- [9] Han Y, Sun H, Li L, et al. Design and implementation of rapid inspection system for building surface crack based on UAV[J]. Journal of Civil Engineering and Management, 2019, 36(3): 60-65.
韩豫, 孙昊, 李雷, 等. 基于无人机的建筑外墙裂缝快速检查系统设计与实现[J]. 土木工程与管理学报, 2019, 36(3): 60-65.
- [10] Shao C, Wang S H, Xu F H, et al. Research on concrete surface crack detection based on image processing [J]. Journal of Hubei University of Automotive Technology, 2019, 33(2): 47-50, 59.
邵闯, 王生怀, 徐风华, 等. 基于图像处理的混凝土表面裂缝检测研究[J]. 湖北汽车工业学院学报,

- 2019, 33(2): 47-50, 59.
- [11] Qu Z, Chen Y X. Concrete surface cracks detecting algorithm based on improved genetic programming [J]. *Computer Engineering and Design*, 2019, 40(6): 1660-1664.
瞿中, 陈宇翔. 改进遗传规划的混凝土路面裂缝检测算法[J]. *计算机工程与设计*, 2019, 40(6): 1660-1664.
- [12] Liu X G, Chen Y Y, Zhu A X, et al. Tunnel crack identification based on deep learning [J]. *Journal of Guangxi University (Natural Science Edition)*, 2018, 43(6): 2243-2251.
刘新根, 陈莹莹, 朱爱玺, 等. 基于深度学习的隧道裂缝识别方法[J]. *广西大学学报(自然科学版)*, 2018, 43(6): 2243-2251.
- [13] Cha Y J, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2017, 32(5): 361-378.
- [14] Wang S, Wu X, Zhang Y H, et al. Image crack detection with fully convolutional network based on deep learning [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2018, 30(5): 859-867.
王森, 伍星, 张印辉, 等. 基于深度学习的全卷积网络图像裂纹检测[J]. *计算机辅助设计与图形学学报*, 2018, 30(5): 859-867.
- [15] Xue Y D, Li Y C. A method of disease recognition for shield tunnel lining based on deep learning [J]. *Journal of Hunan University (Natural Sciences)*, 2018, 45(3): 100-109.
薛亚东, 李宜城. 基于深度学习的盾构隧道衬砌病害识别方法[J]. *湖南大学学报(自然科学版)*, 2018, 45(3): 100-109.
- [16] Qiu C G, Kong L F, Yang S H. Automatic recognition of flavor types of flue-cured tobacco based on GA-SVM algorithm [J]. *Tobacco Science and Technology*, 2019, 52(2): 101-108.
- [17] Li H G, Lian Y, Fang M Q. Entropy-based dynamic particle swarm optimization algorithm [J]. *Journal of Beijing University of Technology*, 2015, 41(5): 657-661.
李宏光, 廉莹, 方梦琪. 基于熵模型的动态粒子群优化算法[J]. *北京工业大学学报*, 2015, 41(5): 657-661.
- [18] Tang L L, Yu Z W, Ren C, et al. Information acquisition method of three-dimensional intersection spatial structure based on vehicle GPS trajectory [J]. *Journal of Traffic and Transportation Engineering*, 2019, 19(5): 170-179.
唐炉亮, 于智伟, 任畅, 等. 基于车载 GPS 轨迹的立体交叉口空间结构信息获取方法[J]. *交通运输工程学报*, 2019, 19(5): 170-179.
- [19] Li Z J, Jiang X J, Zhu Z T, et al. Bullet defect detection method based on deep learning [J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2019(9): 102-106, 110.
利照坚, 江秀娟, 朱铮涛, 等. 基于深度学习的子弹缺陷检测方法[J]. *组合机床与自动化加工技术*, 2019(9): 102-106, 110.
- [20] Lu Q J. An improved two-dimensional otsu image segmentation algorithm [J]. *Natural Science Journal of Xiangtan University*, 2018, 40(6): 82-87.
鲁秋菊. 一种改进的二维 Otsu 图像分割算法研究[J]. *湘潭大学自然科学学报*, 2018, 40(6): 82-87.
- [21] Zhao F, Zhou W H, Chen Y T, et al. Application of improved canny operator in crack detection [J]. *Electronic Measurement Technology*, 2018, 41(20): 107-111.
赵芳, 周旺辉, 陈岳涛, 等. 改进的 Canny 算子在裂缝检测中的应用[J]. *电子测量技术*, 2018, 41(20): 107-111.
- [22] Yang X F, Zhao L, Du J J. The pipeline's crack detection algorithm based on improved Median filtering and morphology [J]. *Computer Simulation*, 2018, 35(12): 81-85, 180.
杨先凤, 赵玲, 杜晶晶. 改进中值滤波和形态学的油管裂纹检测算法[J]. *计算机仿真*, 2018, 35(12): 81-85, 180.
- [23] Wang Y Y, Yu G. Image edge detection of joint K-means and morphological operator [J]. *Ship Electronic Engineering*, 2019, 39(7): 105-107, 156.
王益艳, 于贵. 联合 K-means 和形态学算子的图像边缘检测[J]. *舰船电子工程*, 2019, 39(7): 105-107, 156.
- [24] Jin Y W. Objective graph theory image segmentation algorithm based on mean shift [J]. *Resource Information and Engineering*, 2019, 34(3): 172, 175.
金延薇. 基于均值漂移的面向对象图论图像分割算法研究[J]. *资源信息与工程*, 2019, 34(3): 172, 175.
- [25] Feng G Z, Ni M Y, Ou S F, et al. A preferential interval-valued fuzzy C-means algorithm for remotely sensed imagery classification [J]. *International Journal of Fuzzy Systems*, 2019, 21(7): 2212-2222.