

# 基于卷积神经网络的混凝土路面裂缝检测

王丽苹<sup>1</sup> 高瑞贞<sup>2</sup> 张京军<sup>2</sup> 王二成<sup>1</sup>

(河北工程大学土木工程学院 河北 邯郸 056038)<sup>1</sup>

(河北工程大学机械与装备工程学院 河北 邯郸 056038)<sup>2</sup>

**摘要** 混凝土道路路面中,裂缝的出现常常会导致重大的工程和经济问题。目前,利用计算机视觉技术进行裂缝检测时,需人工预先设计特征提取器对提取的图像特征进行分类,导致泛化能力较差和分类性能较弱。文中提出了一种基于卷积神经网络的裂缝检测方法,实现路面缺陷的自动化检测分类并提高路面裂缝检测效率与精度。首先,设计混凝土路面裂缝卷积神经网络,该模型基于 AlexNet 网络架构,从网络结构层次和超参数两个方面进行优化设计;其次,采用相机收集混凝土路面图像以获得学习数据,根据数据集大小、图像颜色因子的不同,分别创建了 10 000 和 20 000 张的灰色图与彩色 RGB 图 4 个数据集;然后,使用创建的 4 个数据集对设计的混凝土路面裂缝卷积神经网络进行训练,创建裂缝检测模型并与原始 AlexNet 模型相比较;最后,通过数据集大小、图像颜色因子与网络结构和超参数等影响因素对比两个模型。实验结果表明,通过增大数据集、使用彩色 RGB 图、调整网络结构和超参数,所提模型有助于提高分类检测精度。与原始 AlexNet 网络模型相比,所提网络模型的识别准确率更高,对彩色图像样本的识别准确率最高可达 98.5%,同时避免了图像灰度的预处理,提高了裂缝检测的工作效率。

**关键词** 道路路面,裂缝检测,深度学习,卷积神经网络,图像分类

中图分类号 TP391 文献标识码 A

## Crack Detection of Concrete Pavement Based on Convolutional Neural Network

WANG Li-ping<sup>1</sup> GAO Rui-zhen<sup>2</sup> ZHANG Jing-jun<sup>2</sup> WANG Er-cheng<sup>1</sup>

(College of Civil Engineering, Hebei University of Engineering, Handan, Hebei 056038, China)<sup>1</sup>

(School of Mechanical and Equipment Engineering, Hebei University of Engineering, Handan, Hebei 056038, China)<sup>2</sup>

**Abstract** In concrete road pavements, the presence of cracks often leads to major engineering and economic problems. At present, when computer vision technology is used to conduct crack detection, artificial predesigned feature extractor is needed to extract image features for classification, resulting in poor generalization ability and classification performance. In this paper, a crack detection method based on convolutional neural network was proposed to realize the automatic detection and classification of pavement defects and improve the efficiency and accuracy of pavement crack detection. Firstly, the crack convolutional neural network of concrete pavement is designed. The model is based on AlexNet network architecture, and the model is optimized from two aspects: network structure level and hyperparameter. Secondly, the camera collects the concrete pavement image to obtain the learning data. According to the data set size and the image color factor, 10 000 and 20 000 gray maps and four data sets of the color RGB map are respectively created. Then, the created four datasets are used. The data set trains the designed concrete crack convolutional neural network to create a crack detection model and compare it to the original AlexNet model. Finally, the two models are compared by factors such as dataset size, image color factor, network structure and hyperparameters. The experimental results show that by increasing the data set, using the color RGB map, adjusting the network structure and hyperparameters, the proposed model is helpful to improve the classification detection accuracy. Compared with the original AlexNet network model, the network model identification accuracy is high, and the recognition accuracy of color image samples is up to 98.5%. At the same time, the image gray level preprocessing is avoided and the efficiency of crack detection is improved.

**Keywords** Road pavement, Crack detection, Deep learning, Convolutional neural network, Image classification

## 1 引言

混凝土路面缺陷检测对于安全驾驶与运输至关重要,是国家和地方交通维护部门的重要任务。这项任务中尤其是对裂缝的检测在公路养护和修复中起着关键的作用。因此,快

速及时地掌握公路路面信息和实现自动化路面缺陷检测模型是亟待解决的工程实践问题。目前传统的路面检测工作需要人工走查来完成<sup>[1]</sup>,这种检测方法一般由专业人员检测路面缺陷,分析严重程度并对路面进行评估,缺点是主观性强,耗时费力,检测成本高<sup>[2]</sup>。

本文受河北省自然科学基金项目(F2017402182),河北省教育厅高等学校科学研究项目(ZD2018207)资助。

王丽苹(1991—),女,硕士生,主要研究方向为结构健康监测、人工智能与深度学习;高瑞贞(1979—),男,博士,副教授,主要研究方向为人工智能与机器人,E-mail:ruizhenemail@163.com(通信作者)。

为了解决这些问题,基于图像处理的方法得到广泛应用,但易受光照、阴影、背景和纹理等环境因素影响<sup>[3]</sup>,特别是在检测诸如坑洼、松散和裂缝等缺陷时,检测结果可靠性较差。

随着人工智能技术的发展,计算机视觉和机器学习技术已成功应用于路面检测。然而,基于机器学习方法的分类模型需要设计复杂的特征提取器,依赖算法设计者的经验,网络训练过程繁琐,效率和检测精度不高;且特征提取取决于上下文,需要图像处理和路面工程的领域知识。

近年来,深度学习在各种机器视觉识别任务中获得了良好的表现。与传统机器学习不同,深度学习不需要人工设计特征提取器,能够自动根据原始图像特征进行抽象表达,而且深度学习识别的精度超越了传统的图像识别算法。这为路面裂缝的自动化检测提供了新途径。

## 2 相关工作

### 2.1 基于图像处理的裂缝检测

Zhang<sup>[4]</sup>提出了一种基于数字图像处理技术的裂缝检测算法,通过预处理、图像分割和特征提取,获得了有关裂缝图像的信息。彭博等<sup>[5]</sup>采用图像处理技术,将裂缝轮廓进行矢量处理,提取特征并进行裂缝的分类。宋宏勋等<sup>[6]</sup>提出了一种基于双相机立体摄影测量的路面破坏裂缝识别方法。Zou等<sup>[7]</sup>提出了一种基于 CrackTree 的路面裂缝图像分割算法,对非均匀照明路面图像中的裂缝进行自动检测。Talab 等<sup>[8]</sup>对混凝土结构图像进行滤波处理,使用 Otsu 方法检测裂缝。Chen 等<sup>[9]</sup>采用自组织映射图像处理技术(Self Organizing Map Optimization, SOMO)对桥梁进行检测,验证了基于图像处理技术进行裂缝检测的可行性。

### 2.2 基于机器学习的裂缝检测

Liu 等<sup>[10]</sup>开发了一种裂缝分类系统,其中支持向量机(Support Vector Machine, SVM)用于区分图像中的“裂缝”“非裂缝”和“中间”区域。Saar 等<sup>[11]</sup>将图像强度特征输入神经网络,以识别和分类路面裂缝。Mokhtari 等<sup>[12]</sup>将路面图像样本分为“裂缝”和“无裂缝”,并对不同机器学习方法进行比较,结果表明人工神经网络(Artificial neural networks, ANN)具有良好的预测性能。王睿等<sup>[13]</sup>采用 RBF-SVM 算法对裂缝的两值图像进行自动判别,实现了高效裂缝识别。Lins 等<sup>[14]</sup>开发了一种机器视觉系统,使用裂缝模型算法 HSB 和 RSV 自动处理一系列图像并估算裂缝尺寸。Bray 等<sup>[15]</sup>提取了道路图像的密度特征和直方图特征,并基于神经网络技术将图像分为具有裂缝和不具有裂缝。

### 2.3 基于深度学习的裂缝检测

Zhang 等<sup>[16]</sup>将深度学习中卷积神经网络(Convolutional neural network, CNN)应用于道路裂缝检测,证明了 CNN 分类的准确性。Cha 等<sup>[17]</sup>提出了基于深度学习的损伤评估方法,与传统图像检测方法相比,这种方法能够以稳健的方式检测混凝土裂缝。赵雪峰等<sup>[18]</sup>提出了将人工智能与智能手机相结合,利用智能手机进行混凝土裂纹图片收集,再利用人工智能深度学习中的卷积神经网络进行图片中的裂纹识别和定位,达到裂纹检测的目的。Xie 等<sup>[19]</sup>通过在使用低成本智能手机收集的 500 张  $3264 \times 2448$  图像的数据集上应用 ConvNets,证明了基于深度学习(Deep Learning, DL)的路面裂缝检测的潜力。Feng 等<sup>[20]</sup>使用深度残差网络(Deep Residual Network, ResNet),采用深入主动的学习策略,针对民用基础设施缺陷进行检测和分类,但准确率不高。

因此,将深度学习运用到混凝土路面裂缝图像的处理分析中,并实现自动化缺陷检测具有重要的研究意义与较大的发展空间。第 3 节首先概述模型,然后提供有关设计和训练方面的详细描述;第 4 节阐述了路面数据集的形成;第 5 节详细阐述了实验的设置和结果;最后总结全文并展望未来。

## 3 CNN 的混凝土裂缝分类自动化框架

给定路面图像,裂缝检测问题的目的是确定特定像素是否是裂缝的一部分。为了解决这个问题,所提出的解决方案基于卷积神经网络,该 CNN 在裂缝图像进行训练,具有给定的信息,并且可以在没有裂缝的情况下进行分类。如图 1 所示,使用卷积神经网络的整体工作流程包括:首先采集混凝土路面裂缝图像,然后对采集的图像进行预处理,最后训练 CNN 模型并进行缺陷分类。

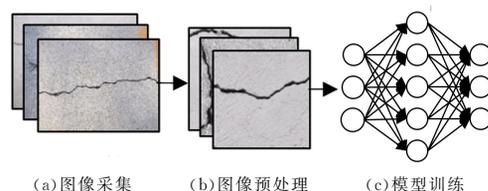


图 1 工作流程概述

### 3.1 CNN 整体架构

CNN 类似于传统的神经网络,因为它们是使用具有权重、偏差和激活函数的人工神经元构建的。人工神经元是接收一个或多个输入的数学函数,并输出它们的加权和。CNN 中有 4 个主要操作:卷积、非线性、池化(或子采样)和完全连接。

模型架构如图 2 所示,共包含 8 层,其中 5 个卷积层,3 个全连接层。模型采用 ReLU(Rectified Linear Unit)函数作为非线性激活函数<sup>[21]</sup>,利用最大池化(MAXPooling)<sup>[22-23]</sup>策略进行池化操作,使用局部响应归一化(Local Response Normalization, LRN)操作和 Dropout<sup>[24]</sup>技术避免模型过拟合。在卷积层中,1-3 层依次进行卷积操作、池化操作和归一化操作;4-5 层只进行卷积操作;6-7 层在全连接后进行 Dropout 操作,第 8 层进行全连接,输出融合了分类标签的 Softmax 值。

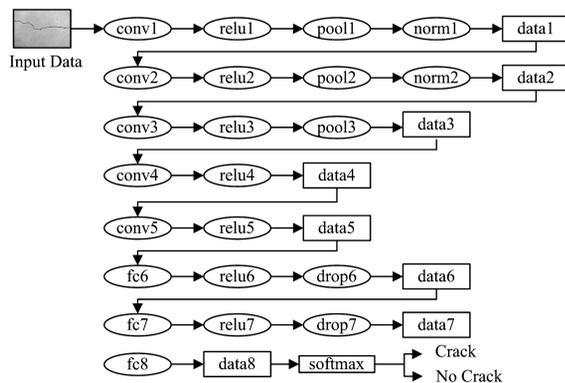


图 2 混凝土裂缝卷积神经网络

CNN 的输入图像是一个矩阵的像素值,然后进行卷积、激活、池化并通过完全连接的层,从而产生输出向量。二进制 CNN 使用两个输出通道(或二维向量)来指示图像是否包含或不包含特定类型的缺陷(参见图 2),输出是 one-hot 的,使得  $[0, 1]^T$  的最终输出值表示存在缺陷,而  $[1, 0]^T$  的输出表示在特定图像中没有缺陷。表 1 列出了输入图像在本文

CNN 训练时的尺寸大小变化情况。

表 1 模型训练数据尺寸

数据	高度	宽度	深度
Data input	227	227	3
Layer1	27	27	96
Layer 2	13	13	256
Layer 3	13	13	384
Layer 4	13	13	384
Layer 5	6	6	256
Layer 6	1	1	4096
Layer 7	1	1	4096
Layer 8	1	1	2

### 3.1.1 卷积

CNN 中卷积层<sup>[25]</sup>的主要功能是通过卷积运算来计算对象特征,其中包括一组具有可学习权重的内核。内核与其图层的输入具有相同的深度,但宽度和高度较小。对于图像卷积,每个内核在图像中从左上角到右下角滑动,如图 3 所示。最后,图像被分成几个重叠的子窗口以从图像中提取特征,一组内核可以从图像中提取不同的特征。

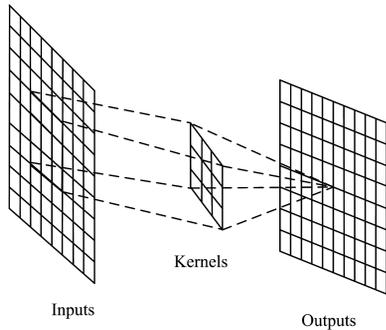


图 3 卷积层操作

卷积层输入表示为  $x \in R^{W \times H \times C}$ , 是一个三维的数据,表示有  $C$  个矩阵,每个矩阵表示为  $x \in R^{W \times H}$ , 也称为特征图。输出  $y \in R^{W_0 \times H_0 \times C_0}$  也是一个三维数据。特征图分辨率从  $W \times H$  变为  $W_0 \times H_0$ , 特征图的个数也从  $C$  变为  $C_0$ 。从输入到输出的一般公式为:

$$y^{C_0} = \sum_C x^C * w_{C,C_0} \quad (1)$$

矩阵  $w_{C,C_0} \in R_{w \times h}$  称为卷积核,属于卷积层的参数,一般通过随机梯度下降更新。 $x^C$  为输入数据的第  $C$  个特征图,但在一些情况下,也会在图像的周围补白。符号  $*$  表示二维数组的卷积运算。每层进行卷积操作和池化操作时各层参数的变化情况如表 2 所列。

表 2 各层卷积和池化操作参数

操作	高度	宽度	深度	步长	填充像素数	输出通道数
conv1	11	11	3	4	0	96
pool1	3	3	—	2	0	—
conv2	5	5	256	1	2	256
pool2	3	3	—	2	0	2
conv3	3	3	384	1	1	384
Pool3	3	3	—	2	0	—
conv4	3	3	384	1	1	384
conv5	3	3	256	1	1	256

该模型中第一个卷积层的输入是  $256 \times 256 \times 3$  的图像,然后用 96 个  $11 \times 11 \times 3$ 、步长为 4 的内核去过滤。第二个卷积层将第一个局部响应归一化 Norm 层的输出作为输入,然后用 256 个  $5 \times 5 \times 48$  的内核进行过滤。第三个卷积层将第二个局部响应归一化 Norm 层的输出作为输入,然后用 384 个  $3 \times 3 \times 256$  的内核进行过滤。第四、五个卷积层前后相连,之间没有池化层和归一化层。第四个卷积层有 384 个  $3 \times 3 \times$

192 的内核,连接着第 3 个卷积层的池化作为输入,第五个卷积层有 256 个  $3 \times 3 \times 192$  的内核,连接着第 4 个卷积层的卷积作为输入。

### 3.1.2 最大池化

池化(Pooling)实际是一种形式上的向下采样。有多种不同形式的非线性池化函数,而其中“最大池化”最为常见。池化层的功能是逐步减少特征图的维数以及网络中的参数量和计算负荷,可用于控制过度拟合。通常在 CNN 的架构中的连续卷积层之间插入向下池化。与卷积层类似,池化层也是平移不变的,因为它们的计算考虑了相邻像素。平均池和最大池是最常用的策略。图 4 给出了最大池化过程的示例。对于  $8 \times 8$  特征映射,输出映射减少到  $4 \times 4$  维度,最大池化操作大小为  $2 \times 2$  且步长为 2。

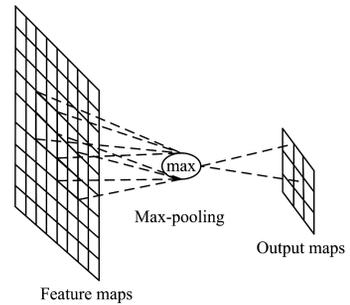


图 4 最大池化操作

对于最大汇集和平均汇集,Boureau 等<sup>[26]</sup>对其表现进行了详细的理论分析。Scherer 等<sup>[27]</sup>进一步对两个汇集操作进行了比较,发现 Max-pooling 可以带来更快的收敛,选择优越的不变特征并改善泛化。因此,该模型中前三层中选用最大池化策略且操作大小为  $3 \times 3$ 、步长为 2 的最大池化。

### 3.1.3 全连接

作为神经网络中的常规层,全连接层连接其先前层中的所有神经元。该层的主要功能是创建点积并在每个神经元的输入中添加偏差。在如图 5 所示的网络中,最后一个池化层之后有几个完全连接的层将 2D 特征映射转换为一维特征向量,用于进一步的特征表示。

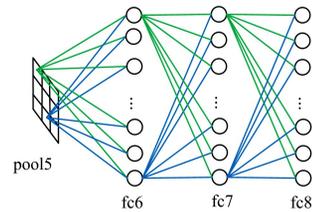


图 5 全连接操作

在几个卷积和池化层之后,全连接层用于将特征向量映射到输出。作为 CNN 的最后一层,完全连接层的神经元与前一层中的所有输出激活具有完全连接。该层的输入是特征向量,其是从先前层的特征图获得,并且输出可以是分类值或适合度值。

### 3.1.4 ReLU 激活函数

在标准 ANN 中给出非线性的最典型的方法是使用 S 型函数,例如  $y = \tan(x)$ ,但 Nair 和 Hinton<sup>[21]</sup>指出饱和非线性会减慢计算速度,并引入 ReLU 作为非线性激活函数(见图 6)。简而言之,其他非线性函数被限制为输出值(例如,正和负的零和零),除了负输入值,ReLU 没有有界输出,即 ReLU 的梯度总是 0 或 1。这些特征比那些使用 S 形函数的计算方便得多,并且达到更高的精度。

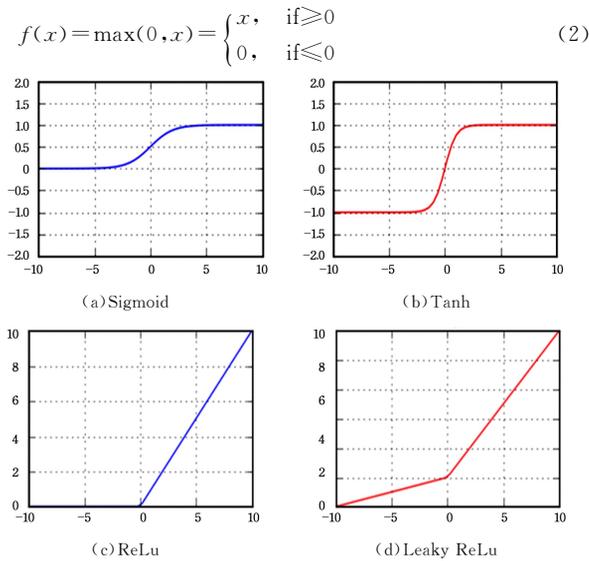


图 6 非线性函数曲线图

## 4 路面裂缝数据集

为了获取足够的混凝土裂缝图像样本数据,本文通过人工采集方式获得混凝土裂缝图像数据,然后对数据进行预处理,构建裂缝图像样本集。

### 4.1 图像数据采集

为了保证数据集的完整性和多样性,并充分考虑光照和阴影等环境因素影响,本文使用 Canon 相机在不同时间和不同时刻对混凝土道路的不同路段和不同位置进行拍摄,获得像素为  $4000 \times 3000$  的彩色裂缝图像,采集的裂缝图像如图 7 所示。



图 7 混凝土裂缝原始图像

### 4.2 图像预处理

#### 4.2.1 原始图像标准化

Cannon 相机采集的图像像素为  $4000 \times 3000$ ,尺寸较大。为了适配网络输入图像像素要求,本文通过自动裁剪技术对原始图像进行标准化。使用 Python 语言编写程序实现图像的批量分割。分割操作采用两种策略,一种是顺序分割策略,即把一张原始图像分割成  $15 \times 11$  张大小为  $256 \times 256$  的标准图像,第二种策略是随机分割策略,即随机确定裁剪位置和角度,获得不同姿态的  $256 \times 256$  的标准图像。顺序分割策略能够充分保留原始图像携带的信息。随机分割策略能够产生随机位置和姿态的图像,有利于网络模型的训练和验证。通过这两种策略,分别由原始图像创建 10 000 张裂缝标准图像数据。

#### 4.2.2 灰度化

图像灰度化是将 24 位 RGB 三色图像从 0 到 255 转换为 8 灰度值的黑白图像<sup>[28]</sup>。灰度化可以显著缩小存储空间,减少计算量。图像灰度计算公式为:

$$g = 0.299R + 0.587G + 0.114B \quad (3)$$

其中, $R, G, B$  分别代表红、绿、蓝 3 种颜色亮度, $g$  代表合成亮度。

将标准化处理后的裂缝图像进行灰度处理,获得 20 000 张灰度标准图像。灰度图像如图 8 所示。

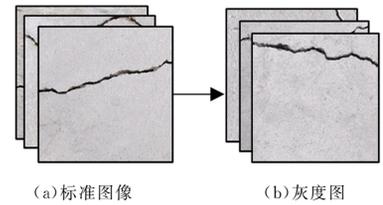


图 8 混凝土裂缝预处理

原始图像经过预处理后得到 20 000 张彩色标准裂缝样本和 20 000 张灰度标准裂缝样本。按照有裂纹和无裂纹两种情形对样本进行分类并设置标签,如图 9 所示。

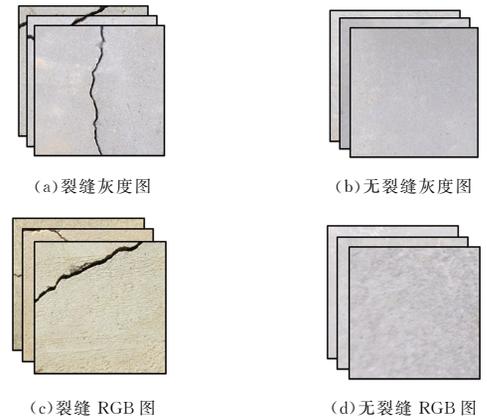


图 9 混凝土裂缝图训练和测试图像

分别将两类标准图像分为训练集和验证集两部分,并且在每一部分中,有裂纹图像数量与无裂纹图像数量相等。在每类标准图像中,训练集图像 16 000 张,验证集图像共 4 000 张,如表 3 所列。

表 3 裂缝图像数据集

样本		有裂缝	无裂缝	总数量
彩色图	训练样本数量/张	8 000	8 000	16 000
	验证样本数量/张	2 000	2 000	4 000
	裂缝图像总数量/张	10 000	10 000	2 000
灰度图	训练样本数量/张	8 000	8 000	16 000
	验证样本数量/张	2 000	2 000	4 000
	裂缝图像总数量/张	10 000	10 000	2 000

## 5 实验及结果

### 5.1 实验装置

本文实验的硬件环境为: Intel Core i7-4720 CPU, NVIDIA GeForce GTX 970 GPU; 软件环境为: Ubuntu16.04 操作系统, Python2.7, 深度学习开源框架 Caffe<sup>[29]</sup>, 以及相关的 OpenCV, Cudnn, CUDA, BLAS, Protobuf, lmdb 等库。

### 5.2 实验结果

基于 Caffe 开发平台,本文进行了两项实验研究:1)数据集大小与颜色信息对模型性能的影响实验;2)网络结构和超

参数对模型性能的影响实验。

### 5.2.1 数据集大小不同

本实验研究数据集大小和图像颜色(彩色图像与灰度图像)对模型性能的影响。在采集数据之后,从灰度图像数据集中随机选出 10000 张和 20000 张图像,并且有裂缝图像与无裂缝图像数量的比例保持一致,分别记为数据集 A 和数据集 B,与 RGB 彩色图一样随机抽出 10000 张和 20000 张图像作为数据集 C 和 D,形成 4 个数据集。利用这 4 个数据集分别对本文提出的混凝土裂缝检测模型(记为模型 M)和原始 AlexNet 网络模型(记为模型 O)进行训练,准确率和损失率计算结果如表 4 所列。

表 4 数据集大小不同时不同模型的准确率与损失率

模型	图像颜色	数据大小 /张	训练结果/%	
			Acc	Loss
Model_A_O	灰度图	A10000	93.7	17.7
Model_A_M		A10000	97.4	8.57
Model_C_O	RGB 图	C10000	95.7	11.9
Model_C_M		C10000	97.6	7.33
Model_B_O	灰度图	B20000	98.02	6.22
Model_B_M		B20000	98.32	5.32
Model_D_O	RGB 图	D20000	96.85	9.75
Model_D_M		D20000	98.5	4.28

表 4 显示,随着数据集图像数量的增加,模型的识别准确率不断提升,损失率逐渐减少。当数据集大小相同时,原始 AlexNet 模型对灰度图的识别准确率高于彩色图像的识别准确率。本文提出的网络模型对彩色图像的识别准确率高于对灰度图的识别准确率,并且该网络可直接对彩色标准图像进行裂缝检测,从而减少了图像预处理计算量。

### 5.2.2 网络结构与超参数不同

本实验研究网络结构和超参数对网络模型性能的影响。相比原始 AlexNet 网络模型,本文设计的网络模型将第一、二层的结构层次进行调整,进行 Pooling 后进行 Norm 操作;第三卷积层增加一个 Pooling 层,最大池化层配置有  $3 \times 3$  窗口,步长为 2。两种网络模型均使用批处理大小为 40 的 SGD 算法进行训练。设置学习率为 0.01,学习策略为“step”,权重衰减系数和动量参数分别为 0.0005 和 0.9,最大迭代次数为 10000 次。分别使用数据集 A, B, C 和 D 对本文优化设计 AlexNet 网络模型和原始 AlexNet 网络进行训练和验证。准确率与损失率计算结果如表 5 所列。

表 5 不同模型的准确率与损失率

模型	图像颜色	数据大小 /张	训练结果/%	
			Acc	Loss
Model_A_O	原始	A10000	93.7	17.7
Model_C_O		C10000	95.7	11.9
Model_B_O	AlexNet	B20000	98.02	6.22
Model_B_O		B20000	96.85	9.75
Model_A_M	优化后	A10000	97.4	8.57
Model_C_M		C10000	97.6	7.33
Model_B_M	AlexNet	B20000	98.32	5.32
Model_D_M		D20000	98.5	4.28

表 5 表明,随着数据量的增加,原始 AlexNet 模型的识别准确率相应提高,损失率逐渐下降,对灰度图像样本的识别准确率最高为 98.02%。本文优化后的 AlexNet 网络模型比原始 AlexNet 网络模型的识别准确率高,对彩色图像样本的识别准确度最高达 98.5%。准确率和损失率与迭代次数的关系曲线如图 10 所示。

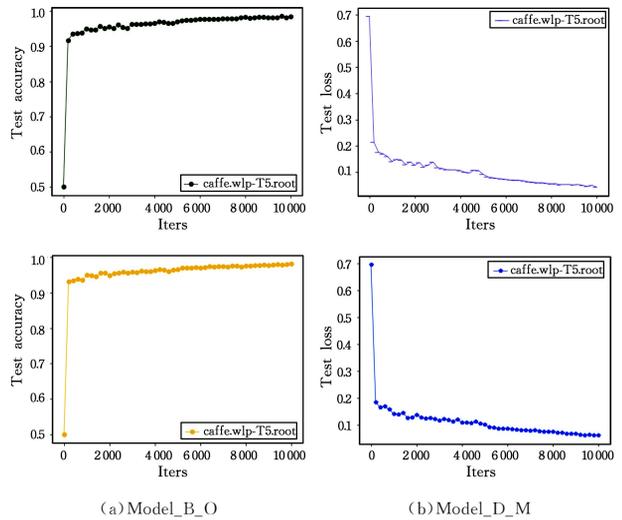


图 10 准确率和损失曲线

**结束语** 本文针对混凝土路面裂缝缺陷,采用深度学习卷积神经网络方法进行自动化检测,主要得到了以下结论:通过人工采集混凝土裂缝图像数据,并对数据进行标准化处理,构建了混凝土路面裂缝的彩色图像样本集和灰度图像样本集;基于深度学习架构,从网络结构和超参数两个方面调整优化网络模型,优化后的模型比原始 AlexNet 网络模型的识别准确率高,对彩色图像样本的最高识别准确度达 98.5%。本文提出的网络模型能够充分利用彩色图像信息,对彩色图像的识别准确率高于对灰度图的识别准确率,并且该网络可直接对彩色标准图像进行裂缝检测,减少了图像预处理计算量,提高了检测效率。

## 参考文献

- [1] OLIVERA H, CORREIA P L. Supervised crack detection and classification in images of road pavement flexible surfaces[M]. Recent Advances in Signal Processing. InTech, 2009.
- [2] JAHANSHAHI M R, JAZIZADEH F, MASRI S F, et al. An unsupervised approach for autonomous pavement defect detection and quantification using an inexpensive depth sensor[J]. Journal of Computing in Civil Engineering, 2013, 27(6): 743-754.
- [3] ZHANG D, QU S, HE H, et al. Automatic ridgelet image enhancement algorithm for road crack image based on fuzzy entropy and fuzzy divergence[J]. Opt. Lasers Eng., 2009, 47(11): 1216-1225.
- [4] ZHANG Y. The design of glass crack detection system based on image pre-processing technology[C]//Proceedings of IEEE 7th Joint International Information Technology and Artificial Intelligence Conference. Chongqing, China, 2014: 39-42.
- [5] 彭博, 蒋阳升, 蒲云. 基于数字图像处理的路面裂缝自动分类算法[J]. 中国公路学报, 2014, 27(9): 10-18, 24.
- [6] 宋宏勋, 马建, 王建峰, 等. 基于双相机立体摄影测量的路面裂缝识别方法[J]. 中国公路学报, 2015, 28(10): 18-25, 40.
- [7] ZOU Q, CAO Y, LI Q, et al. CrackTree: automatic crack detection from pavement images[J]. Pattern Recogn. Lett., 2012, 33(3): 227-238.
- [8] TALAB A M A, HUANG Z, XI F, et al. Detection crack in image using Otsu method and multiple filtering in image processing

- techniques [J]. *Optik*, 2016, 127(3):1030-1033.
- [9] CHEN J H, SU M C, CAO R, et al. A self organizing map optimization based image recognition and processing model for bridge crack inspection [J]. *Automation in Construction*, 2017, 73:58-66.
- [10] LIU Z, SHAHREL A, OHASHI T, et al. Tunnel crack detection and classification system based on image processing [C] // *Proc. SPIE*. San Jose, California, USA, 2002:145-152.
- [11] SAAR T, TALVIK O. Automatic asphalt pavement crack detection and classification using neural networks [C] // *Proceedings of the 12th Biennial Baltic Electronics Conference*. Tallinn, Estonia, 2010:345-348.
- [12] MOKHTATI S, WU L, YUN H B. Comparison of supervised classification techniques for vision based pavement crack detection [J]. *Transportation Research Record: Journal of the Transportation Research Board*, 2016, 2595:119-127.
- [13] 王睿, 漆泰岳. 基于机器视觉检测的裂缝特征研究 [J]. *土木工程学报*, 2016, 49(7):123-128.
- [14] LINS R G, GIVIGI S N. Automatic crack detection and measurement based on image analysis [J]. *IEEE Trans. Instrum. Meas.*, 2016, 65 (3):583-590.
- [15] BRAY J, VERMA B, LI X, et al. A neural network based technique for automatic classification of road cracks [C] // *Proceedings of IEEE International Joint Conference on Neural Network*. Vancouver, BC, Canada, 2006:907-912.
- [16] ZHANG L, YANG F, ZHANG Y, et al. Road crack detection using deep convolutional neural network [C] // *Proceedings of IEEE International Conference on Image Processing*. Phoenix, AZ, USA, 2016:3708-3712.
- [17] CHA Y J, CHOI W, BUYUKOZTURK O. Deep learning-based crack damage detection using convolutional neural networks [J]. *Comput. Aided Civ. Inf. Eng.*, 2017, 32 (5):361-378.
- [18] 赵雪峰, 李生元, 欧进萍. 基于人工智能与智能手机的混凝土裂纹检测 [J]. *物联网技术*, 2017, 7(8):15-18.
- [19] XIE D, ZHANG L, BAI L. Deep learning in visual computing and signal processing [J]. *Applied Computational Intelligence and Soft Computing*, 2017(10):1-13.
- [20] FENG C, LIU M Y, KAO C C, et al. Deep active learning for civil infrastructure defect detection and classification [C] // *International Workshop on Computing in Civil Engineering*. Seattle, Washington, USA, 2017:298-306.
- [21] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines [C] // *Proceedings of the 27th International Conference on Machine Learning*. Haifa, Israel, 2010:807-814.
- [22] BOUREAU Y L, PONCE J, LECUN Y. A theoretical analysis of feature pooling in visual recognition [C] // *Proceedings of the 27th International Conference on Machine Learning*. Haifa, Israel, 2010:111-118.
- [23] SCHERER D, MÜLLER A, BEHNKE S. Evaluation of pooling operations in convolutional architectures for object recognition [C] // *Proceedings of the ICANN*. Thessaloniki, Greece, 2010:92-101.
- [24] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. *The Journal of Machine Learning Research*, 2014, 15(1):1929-1958.
- [25] WANG Y, HUANG M, ZHAO L. Attention-based lstm for aspect-level sentiment classification [C] // *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*. 2016:606-615.
- [26] BOUREAU Y L, PONCE J, LECUN Y. A theoretical analysis of feature pooling in visual recognition [C] // *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*. 2010:111-118.
- [27] SCHERER D, MÜLLER A, BEHNKE S. Evaluation of pooling operations in convolutional architectures for object recognition [M] // *Artificial Neural Networks-ICANN 2010*. Springer, Berlin, Heidelberg, 2010:92-101
- [28] BETTAHAR S, STAMBOULI A B, LAMBERT P, et al. PDE-based enhancement of color images in RGB space [J]. *IEEE Transactions on Image Processing*, 2012, 21(5):2500-2512.
- [29] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding [C] // *Proceedings of the 22nd ACM International Conference on Multimedia*. New York, USA, 2014:675-678.