文章编号:1009-6582(2020)05-0061-05 DOI: 10.13807/j.cnki.mtt.2020.05.007

基于隧道快速检测车数据的公路隧道衬砌开裂识别模型研究

江 桁[1] 刘学增[2] 朱合华[1]
(1 同济大学土木工程学院地下建筑工程系,上海 200092;2 同济大学土木信息技术教育部工程研究中心,上海 200092)

摘 要 随着公路隧道的不断建设,公路隧道的病害识别问题、养护问题日益增多,传统的隧道衬砌裂纹识别工作需要大量人工参与内业工作,效率不高。文章采用隧道快速检测车所采集的图像数据,利用卷积神经网络,研究得出了一套用于定向识别隧道检测车所拍摄的公路隧道衬砌开裂的模型。根据训练过程中发现的问题,针对裂纹数据集对神经网络识别效果的影响进行了对比研究,证明了按照不同裂纹走势分类图像所训练的神经网络识别能力较好,具有较好的适用性。

关键词 公路隧道 隧道检测车 卷积神经网络 裂纹识别 边缘检测
中图分类号:TP183;U457+.2 **文献标识码**:A

1 引 言

随着社会的进步发展,中国目前已建公路隧道具有条数多、里程多、通行车辆多的特点。由于隧道服役时间不断增加,对公路隧道病害的监测和自动识别成为隧道养护工作中的一大难题。传统的公路隧道衬砌开裂检测需要人工巡检,费时费力。随着计算机技术的发展,使用图像处理技术,如边缘检测算法来识别隧道衬砌开裂的方法越来越得到重视。但是,传统使用计算机处理、识别公路隧道衬砌裂纹的方法存在适用性较差、数据获取困难的问题。本文针对上海同岩公司开发的公路隧道快速检测车,以扫描车获取的图像数据为基础,通过定向训练、优化的神经网络,对卷积神经网络识别公路隧道衬砌开裂的效果进行分析。

2 公路隧道快速检测车介绍

2.1 设备概况

上海同岩土木工程科技股份有限公司研发的二代公路隧道快速检测车(图1)具有运行速度快、采集数据精度高、低环境干扰等特点,其采用红外成像技术,通过红外灯光补光、光感相机捕捉的原理进行隧道病害的扫描和检测。通过自主开发的软件记录行驶速度、相机快门时间、拍摄设备等参数可自动计算、拼接整条隧道的病害扫描图像,再经过人工内业处理,即可出具检测报告[1]。



图1 同岩公司公路隧道快速检测车

Fig.1 Rapid testing vehicle for highway tunnel condition developed by Tongyan Corporation

修改稿返回日期:2020-09-01
基金项目:国家重点研发计划(2018YFB2101004).
作者简介:江 桁(1996-),男,硕士研究生,主要从事隧道信息智能化研究工作,E-mail: jiangh@tongji.edu.cn.

2.2 获取图像数据

隧道检测车中后段垂直车身截面方向配有一圈共计24个光感相机，在行驶过程中拍摄整条隧道的衬砌图像，本文所采用数据为检测车拍摄的几条四车道上下行隧道图像。图像具体格式为jpg，每张图片像素为2 560×2 048，位深度为8。

3 边缘检测识别

传统边缘检测算法依赖于图片处理技术，从原始裂纹照片中分离背景和裂纹，得到裂纹的走向。其局限性在于裂缝图片的背景常常过于复杂，受到缺口、斑点等的干扰[2]，在这种情况下从背景中分离出的裂缝特征会包含许多噪点[3]，不同算子对不同类型的图像提取特征的适用性较差。通过这种方法仅仅能够提取出裂纹的特征图像，在之后还需要人工判别确认所提取的图像，并不是一种自动判别裂纹的方法，这样无疑还要增加病害辨识的人工成本。

运用Matlab对隧道快速检测车拍摄的图像进行简单的边缘检测算法处理，结果如图2所示，裂纹分离效果不好，背景干扰大，无法直接有效提取出裂纹特征。

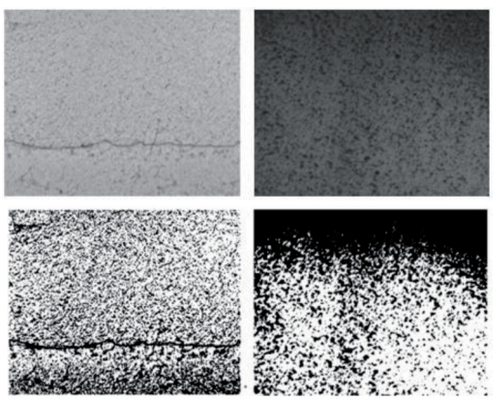


图2 边缘检测算法识别效果

Fig.2 Cracks identified by the edge detection algorithm

4 深度学习识别模型

4.1 卷积神经网络介绍

CNNs (Convolutional Neural Networks)又名卷积神经网络，是众多学习神经网络中的一种。卷积神经网络相较于其它神经网络，其特点在于能够较好地处理和提取图片特征，对于二维图片数据的分类有着较好的效果[4]。

CNNs识别图像的原理在于将二维的图像以数列矩阵的形式不断卷积，在每一次卷积过程中提取图片的轮廓特征，改变权重矩阵并将图像以矩阵的形式与之相乘，通过传递继承每一层学习到的特征，最终得到定向识别图像某一特征的网络模型[5]。

所以，本质上来说，训练一个CNNs，使其能够识别特定的图像，就是让神经网络不断寻找一个合适的权重矩阵模型，通过训练得出我们需要的图片滤波器，最终得出一个由输入到输出的完整映射关系[6]。这其中包含着许多次的卷积操作，需要池化、梯度下降算法、反向传播等方法才能得出一个较好的识别模型。

CNNs的一大好处就是能够减少图像的参数数量，卷积之后的图像相较于原图像，像素缩小了很多，这样能够更好地提升计算机的读取、计算速度，将其应用于隧道病害检测，能够充分发挥识别速度快的优势。

4.2 数据集处理

考虑到训练效率和裂纹识别的特点，为了缩短训练时间并且防止过拟合，使用少量的图像进行训练即可。由于所拍摄的大部分图像中都不含衬砌裂纹，所以由人工从隧道快速检测车拍摄的图像中选取带裂纹及不带裂纹的图像各150张。为了便于训练，调整图像亮度和对比度之后，编程进行图像分割用以制作数据集[7]，如图3所示。

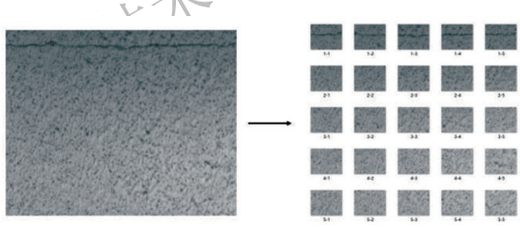


图3 图像切割

Fig.3 Image cutting

为了研究不同数据集对训练和识别效果是否存在影响，本文根据是否区分裂纹走势，设置两组数据集进行训练，其包含的数据标签分别为：

（1）数据集1：裂纹衬砌图像、不含裂纹衬砌图像。

（2）数据集2：纵向裂纹衬砌图像、横向裂纹衬砌图像、不含裂纹衬砌图像，如图4所示。

由于所拍摄的公路隧道衬砌图像中，斜向发展的裂纹较少，所以将斜向裂纹按照发展角度，归入纵向、横向的裂纹数据集中。通过旋转、平移等图像处理技术，对数据集进行初步扩充，最终数据集中包

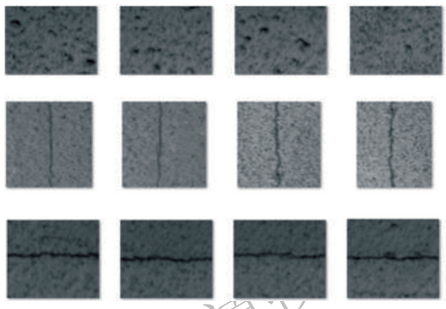


图4 数据集2中的部分图像

Fig.4 Partial images in data set 2

含791张裂纹图片(纵向、横向裂纹比例大致为1∶1)、1 216张不含裂纹图片。在训练之前通过Matlab对所有图片进行去均值化操作。

4.3 网络结构参数设置

本文使用Matlab以及Microsoft Visual Studio搭建训练平台,网络的训练和识别运行在中央处理器CPU上(Intel Core i5-5200U @2.20 Hz)。

建立基于MNIST模型的网络结构,如图5所示。具体为:

第1层,卷积层;卷积核为[5×5×3×20],其中5×5为卷积核尺寸,3为卷积核纵深维度,20为矩阵滤波器数目;步长为1;不设置pad。

第2层,池化层;最大池化;池化矩阵为[2×2];步长为2;不设置pad。

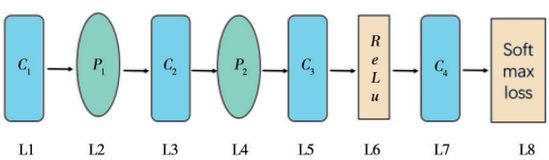


图5 模型网络结构

Fig.5 Structure of CNNs

第3层,卷积层;卷积核为[10×10×20×50];步长为1;不设置pad。

第4层,池化层;最大池化;池化矩阵为[2×2];步长为2;不设置pad。

第5层,卷积层;卷积核为[10×10×50×500];步长为1;不设置pad。

第6层,Relu层。

第7层,卷积层;卷积核为[1×1×500×4];步长为1;不设置pad。

第8层,softmaxloss层。

为了提高训练速度,本文所用网络结构设定输入层图片像素大小为64×64,即在输入层将输入图片压缩成64×64像素再进行学习训练,在第1,4,7层之后添加一层Batch Normalization层。各个层中的相关数据参数如表1所示。

4.4 训练结果

设置数据集1、数据集2训练100代,定义top1err为训练过程中每一代模型的预测准确率指标,其计算公式如下:

$$\text{top1err}=\sum_{i=1}^{n}\left(1-\frac{tc_i}{valnumb_i}\right)/n \tag{1}$$

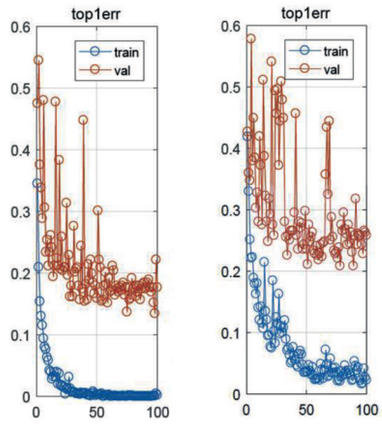
由于分不同batch进行训练,所以计算时式(1)中n代表batch的编号;tc_i代表当前训练模型在第i个batch中预测图片类别与真实标签类别符合的次数;$valnumb_i$代表当前模型在第i个batch中预测集的大小,因为只对预测集中的图片预测1次,所以$valnumb_i$也即第i个batch中的预测次数。

数据集1和数据集2的训练结果如图6所示,横坐标为训练迭代次数,训练100代结束之后数据集1的top1err最终维持在0.17上下浮动,数据集2的top1err维持在0.25上下浮动。

表1 各网络层及操作处理中的数据维度

Table 1 Data dimensions in each layer

层号	宽度	高度	维度	操作	高度	宽度	维度	数量	步长
L1	64	64	3	卷积1	5	5	3	20	1
L2	60	60	20	池化1	2	2	—	—	2
L3	30	30	20	卷积2	10	10	20	50	1
L4	21	21	50	池化2	2	2	—	—	2
L5	10	10	50	卷积3	10	10	50	500	1
L6	1	1	500	ReLU	—	—	—	—	—
L7	1	1	500	卷积4	1	1	500	4	1
L8	1	1	4	Softmax	—	—	—	—	—
OUTPUT	1	1	1	—	—	—	—	—	—



（a）数据集1　　（b）数据集2

图6　数据集1和数据集2训练中top1err参数

Fig.6　Top1err of data set 1 and data set 2 in training

4.5　识别效果

利用人脸识别应用中较为通用的滑动窗口扫描方法[8]，将训练好的2个模型对隧道快速检测车拍摄的两幅相同图像进行识别。为了节省计算资源，提升识别速率，将原始拍摄的图像缩小50%至1 280×1 024像素大小进行识别。设置合适的窗口大小，将窗口历遍整张图像[9]，其中被白框框选的部分即为模型识别的裂纹开展区域，为了更好地观察识别效果，不设置窗口融合，所以会出现部分识别框重叠的现象。

数据集1的识别效果如图7所示，数据集2的识别效果如图8所示。由图可见，数据集1所训练的模型容易把裂纹周围区域错误地识别成裂纹，识别效果与背景的粗糙程度有关；数据集2所训练的模型识别效果则较好，两者所识别区域都能将裂纹开展区域包括在内。就裂纹识别模型而言，并不是训练准确率越低，识别效果就越好。针对1 280×1 024像素大小的图像进行识别，平均每张图像识别时间为5 s。若根据NVIDIA官方提供的数据，使用较好的GPU图形计算设备以及tensorflow工具[10]，能将识别时间缩短至0.5 s以内。

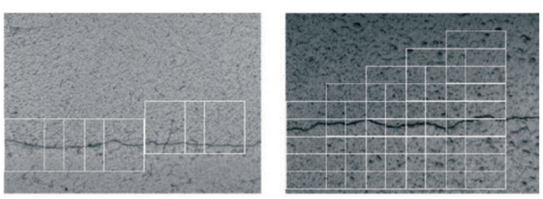


图7　数据集1训练模型识别效果

Fig.7　Crack identification effect using data set 1 model

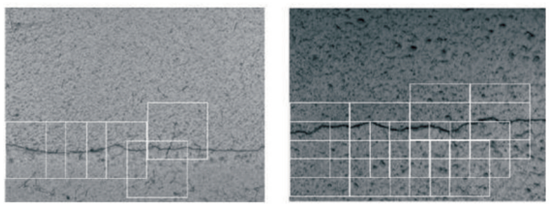


图8　数据集2训练模型识别效果

Fig.8　Crack identification effect using data set 2 model

为了验证识别模型的适用性，随机从网络中下载几幅裂纹图片，调整窗口尺寸，观察识别效果，如图9、图10所示，其能较好地识别其它条件下的裂纹，证明卷积神经网络训练得出的识别模型适用性较好。相比数据集1，数据集2所训练出的模型识别效果更好。

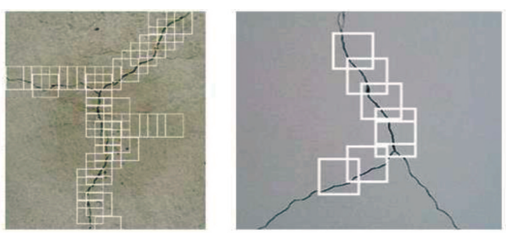


图9　数据集1训练模型识别效果

Fig.9　Crack identification effect using data set 1 model

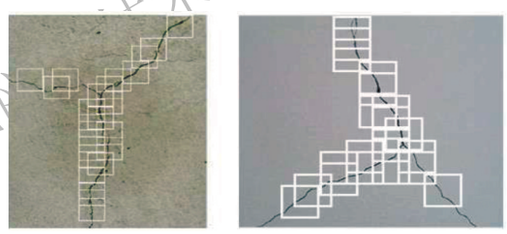


图10　数据集2训练模型识别效果

Fig.10　Crack identification effect using data set 2 model

5　结　论

从模型的识别效果对比中可以看出，针对裂纹特征的识别，并不是训练过程中的识别准确率越高，识别效果就越好。在尝试用不同图像进行的具体识别尝试中发现，相同数据内容的情况下，不同标签分类对模型识别效果的影响是不同的，就裂纹识别而言，将裂纹按照发展走势划分类别的数据集训练出的神经网络模型识别效果要好于只用裂纹和不含裂纹两种标签类别的数据集所训练的模型。本文所得

出的基于卷积神经网络的识别方法能够结合隧道快速检测车获取的扫描图像进行裂纹的初步识别，并且能够应用于内业工作中，从而提高病害检测效率。

参考文献

References

[1] 杨 俊,刘笑娣,刘新根,等.公路隧道结构快速检测车综述[J].华东交通大学学报,2018,35(4):30-38.
YANG Jun, LIU Xiaodi, LIU Xingen, et al. Review of Rapid Test Vehicles for Highway Tunnel Structure [J]. Journal of East China Jiaotong University,2018,35(4):30-38.

[2] ABDEL-QADER I, ABUDAYYEH O, KELLY M E, Analysis of Edge-Detection Techniques for Crack Identification in Bridges[J]. Journal of Computing in Civil Engineering, 2003,17(4): 255-263.

[3] NISHIKAWA T, YOSHIDA J, SUGIYAMA T, FUJINO Y. Concrete Crack Detection by Multiple Sequential Image Filtering[J].Computer-Aided Civil and Infrastructure Engineering, 2012, 27(1):29-47.

[4] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. Nature, 2015, 521(7553):436.

[5] 王 振,高茂庭.基于卷积神经网络的图像识别算法设计与实现[J].现代计算机,2015(20):63-68.
WANG Zhen, GAO Maoting. Design and Implementation of Image Recognition Algorithm Based on Convolutional Neural Networks. [J]. Modern Computer,2015(20):63-68.

[6] 周飞燕,金林鹏,董 军.卷积神经网络研究综述[J].计算机学报,2017,40(6) :1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of Convolutional Neural Network [J]. Chinese Journal of Computers, 2017,40(6): 1229-1251.

[7] CHA Y J, CHOI W, BUYUKOZTURK O. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks[J]. Computer Aided Civil & Infrastructure Engineering, 2017, 32(5):361-378.

[8] 陈才扣,黄建平,刘永俊.基于泛滑动窗与2DLDA的单样本人脸识别[J].计算机应用,2007(11):185-188+199.
CHEN Caikou, HUANG Jianping, LIU Yongjun. Face Recognition with Single Training Sample Per Person Based on Generalized Slide Window and 2DLDA[J]. Joutnal of Computer Applications, 2007(11):185-188+199.

[9] 黄凯奇,任伟强,谭铁牛.图像物体分类与检测算法综述[J].计算机学报,2014,36(12):1-18.
HUANG Kaiqi, REN Weiqiang, TAN Tieniu. A Review on Image Object Classification and Detection [J]. Chinese Journal of Computers,2014,36(12):1-18.

[10] MART IN ABADI, ASHISH AGARWAL, PAUL BARHAM, et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems[R]. Google Brain, 2016.

Research on Crack Identification of Highway Tunnel Linings Based on Data Obtained from the Testing Vehicle

JIANG Heng[1] *LIU Xuezeng*[2] *ZHU Hehua*[1]

(1 Department of Geotechnical Engineering, Tongji University, Shanghai 200092; 2 Civil Engineering Information Technology Research Center of Ministry of Education, Tongji University, Shanghai 200092)

Abstract With the continuous construction of highway tunnels, the problems of disease identification and maintenance of highway tunnels are increasing. The traditional tunnel lining crack identification requires a lot of personnel to participate in the indoor work, resulting in low efficiency. Based on the image data collected by the rapid testing vehicle for highway tunnel condition, this paper uses the convolutional neural networks to train a set of models for recognizing the cracks in the highway tunnel linings. According to the problems found in the training process, a comparative study on the effect of different crack data sets on the recognition effect of the neural network models is carried out, proving that the CNN model trained by images sorted by crack development trends has better recognition ability and better applicability.

Keywords Highway; Testing vehicle for highway tunnel condition; Convolutional neural network; Crack detection; Edge detection