

基于深度学习的盾构隧道衬砌病害识别方法^{*}

薛亚东^{1,2†}, 李宜城^{1,2}

(1. 同济大学 岩土及地下工程教育部重点实验室, 上海 200092; 2. 同济大学 土木工程学院, 上海 200092)

摘要:隧道衬砌病害的检测是隧道维护和保障运营安全的重要环节. 以基于 CCD 线阵相机移动式地铁衬砌病害检测系统的采集图片为研究对象, 利用计算机科学最前沿的深度学习的方法, 提出了一种完全区别于传统手段的隧道病害识别方法, 通过提取并建立隧道病害样本库, 搭建深度学习框架, 利用深度卷积神经网络(Convolutional Neural Network, CNN)训练样本, 建立隧道衬砌特征图像分类系统. 针对既有的 CNN 模型 GoogLeNet, 采用优化的卷积核, 并改进了其 inception 模块与网络结构, 获得了准确率超过 95% 的网络模型. 通过实例对目前流行的深度学习框架(Caffe 与 Torch)以及图像对比度增强处理方法(如直方图均衡化处理(Histogram Equalization, HE))进行了测试. 测试结果表明, 深度学习的方法用于隧道衬砌图像处理, 具有准确率高, 速度快, 可扩展性好等特点, 特别是对背景复杂条件下的图像处理更具鲁棒性.

关键词:盾构隧道; 衬砌病害; 深度学习; 卷积神经网络; 图像分类

中图分类号: TU93

文献标志码: A

A Method of Disease Recognition for Shield Tunnel Lining Based on Deep Learning

XUE Yadong^{1,2†}, LI Yicheng^{1,2}

(1. Key Laboratory of Geotechnical and Underground Engineering of Education Ministry, Tongji University, Shanghai 200092, China; 2. College of Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract: Diseases detection and maintenance of tunnel lining is an important link to ensure the safety of tunnel in operation. Based on the images captured by CCD linear array camera in Movable Tunnel Inspection System, a new method was proposed. It is inspired by cutting-edge computer science-deep learning and different from the traditional ones entirely. The main idea is as follows: a) extracting lining diseases and establishing feature map database; b) building deep learning framework; c) training samples with convolutional neural network; and d) establishing a classification system of gray scale feature maps of tunnel lining. Aiming at CNN model GoogLeNet, inception module and overall architecture were improved by using improved convolutional kernels. The best test-set accuracy is over 95%. At the same time, the influence of different deep learning frameworks (Caffe and Torch) and image contrast enhancement method (such as histogram equalization, HE) were tested with examples. The results show that the deep learning

* 收稿日期: 2017-03-29

基金项目: 国家自然科学基金资助项目(41072206), National Natural Science Foundation of China (41072206); 上海市科学技术委员会资助项目(16DZ1200402), Science and Technology Commission of Shanghai Municipality (16DZ1200402); 浙江省交通厅科技计划项目(2015J05), Science and Technology Plan of Department of Communication of Zhejiang Province(2015J05)

作者简介: 薛亚东(1971-), 男, 山西芮城人, 同济大学副教授, 博士生导师

† 通讯联系人, E-mail: yadongxue@126.com

method is applicable to the tunnel lining diseases detection. The advantages are high accuracy, high speed, good extensibility and very robust in complex cases.

Key words: shield tunnel; tunnel lining diseases; deep learning; convolutional neural network; image classification

城市地铁隧道施工和运营过程中,由于设计或施工水平不足,工程地质条件的不确定,缺少及时维护检测等原因,常会导致隧道衬砌病害的发生。常见的隧道衬砌病害有裂缝、渗漏水等。病害的出现不仅会降低混凝土的强度,对隧道衬砌造成损伤,影响结构安全,还可能降低隧道服役寿命,对城市轨道交通的运营造成巨大的安全隐患。在城市地铁大规模建设的情况下,对隧道衬砌病害的检测、评估、处理至关重要。传统的隧道衬砌结构病害检查,多采用人工巡查、手工记录、拍摄照片等手段采集数据,而后进行室内分析,给出评估结果。以国内每年近千公里隧道建设、运营的爆发式发展速度,人工方式根本无法满足隧道病害检测的需求。近年来,以计算机视觉技术为依托的图像检测技术快速发展,如 Yu 等^[1]在 Komatsu Engineering Corp 开发的图像采集系统基础上进行改进,提出了一种以线阵相机(CCD)为主器件的自动化裂缝检测系统,可以获取 0.3 mm 及以上的裂缝图像。王平让^[2]以线阵 CCD 相机为基础,开发了公路隧道衬砌病害检测车,检测精度达到 0.2 mm;日本太平洋咨询有限公司针对公路隧道开发了 MIMM-R 检测车,可实现公路隧道衬砌表面可见光图像的获取,检测精度达到 0.2 mm。除此之外,王睿^[3]、李鹏^[4]和 Zhang 等^[5]也开展了相关研究。

基于图像扫描方式获取衬砌结构表观信息具有精度高、速度快、数据易保存等优点,但其后处理工作难度大、技术复杂、时间成本高^[6],主要原因包括:线阵相机采集的灰度图像对光照要求较高,不均匀的光照和亮度低的光源均会对图像质量产生影响;隧道衬砌表面纹理的不均匀性以及混凝土材料本身的不均匀性,导致采集到的图像背景颜色存在较大的变化^[7];运营隧道内通常存在较多干扰物,如衬砌接缝、电缆线、螺栓孔等,增加了病害识别的难度。

采用图像处理技术进行病害的自动识别是解决问题的关键。对于隧道病害图像,目前主要的研究尚停留在传统的模式识别研究上,包括图像预处理算

法和病害特征算法的改进等。刘晓瑞等^[7]提出了 SFC 结合增强算法,并使用基于最大类间方差的灰度门限分割算法和基于直方图修正的迭代剪枝法将增强后的图像进行分割,得到了清晰的病害图像。王平让等^[8]提出一种基于图像局部网格特征的隧道衬砌裂缝自动识别方法,通过模板计算将网格中灰度值最小的像素识别为潜在的裂缝种子,而后采用种子连接算法将离散的裂缝种子像素连接成为完整的连续裂缝。王耀东等^[9]提出了一种全局与局部相结合的预处理算法,以及基于连通区域的多级滤波算法,从而消除复杂噪声,对地铁结构表面裂缝进行智能检测。朱力强等^[10]利用 Mask 均匀光等处理算法改善隧道图像的质量,通过支持向量机对隧道表面裂缝图像各成分进行提取,综合效果达到了 81% 的准确率。Zhao 等^[11]针对难以识别的微小裂缝,提出了从任意分配的像素点筛选出裂纹簇的聚类方法,建立了全局凸分割模型。Moon 等^[12]使用了改进的减法算法和形态运算算法提取了混凝土裂缝图像的特征信息,并结合 BP 神经网络进行了裂缝图像的分类工作。

上述识别手段均采用了手工设计特征的方法,这也是传统图像处理的核心工作之一,在此基础上,有学者开展了浅层学习方法的研究^[10-12]。现有方法的实际应用依赖于手工调参,因而效率低,周期长,且检测方法的鲁棒性差,特别是在结构病害相关检测中的准确率不能令人满意^[2-3]。除此之外,针对大尺度隧道衬砌图像中的病害识别,传统方法也不能胜任。鉴于此,本文提出了一种基于深度学习的智能识别方法,尝试利用卷积神经网络建立隧道病害自动检测系统,探索一条解决大规模图像病害自动识别处理的思路。

1 深度学习与卷积神经网络

深度学习(Deep Learning)是机器学习的一种方式,是近十年来人工智能领域取得的重要突破。它在语音识别、自然语言处理、计算机视觉、图像与视频分析、多媒体等诸多领域的应用取得了巨大成功。

从本质上来说,深度学习是一种特征学习方法,把原始数据通过一些简单但非线性的模型转变为更高层次、更加抽象的表达.通过足够多的转换组合,任意复杂的函数理论上都可以被学习^[13].卷积神经网络是深度学习的一种重要手段,在图像分类领域表现出强大的能力. Hubel 等^[14]以猫的视觉神经细胞为研究基础而提出“感受野”概念,卷积神经网络的提出源于此,即以复杂神经网络模仿生物对物体的学习和识别方式,在神经网络中体现为稀疏连接和权值共享. Fukushima^[15]提出的神经认知机具有一定的自我学习能力,可以认为是卷积神经网络的首次尝试. Lecun 等^[16]提出了一种实用性的卷积神经网络模型,用于手写数字的识别,效果显著. 由于 CNN 庞大的参数量(权值和偏置参数),模型进行学习(训练)花费的时间代价极大,受限于当时人们对 CNN 的认识、网络训练的反向传播算法以及计算机硬件的落后, CNN 的发展一度止步不前. Hinton 等^[17]在 Science 上发表论文提出逐层训练的方法,即以上一层训练的结果作为下一层的输入,解决了模型难以达到最优的问题. 2012 年在世界图像识别大赛上(ILSVRC), Krizhevsky 等^[18]提出的 CNN 模型有三点创新: Dropout 训练策略、非线性的激活函数(ReLU)以及随机平移扰动,刷新了以往的比赛成绩(错误率由 26% 降低至 15%),至此以后 CNN 在世界范围内被大量应用于图像识别领域. 例如,在人脸识别领域,2013 年提出的 DeepFace^[19], DeepID^[20]等具有超过 97% 的识别率,而增加了扩展网络结构的 DeepID2+ 达到了 99.47% 识别率^[21],超过了人类的识别能力. 其他领域上, Cruz-roa 等^[22]利用深度学习对癌细胞和正常组织细胞进行分类,采用了 1 417 张图像作为数据库,在训练集和测试集上均达到了超过 90% 的准确率. 徐珊珊等^[23]采用渐进式学习确定了训练样本,克服了传统算法的缺点,应用卷积神经网络实现了木材缺陷自动识别.

以上研究为深度学习应用于隧道衬砌病害的智能识别提供了启发,且可能具有如下优势:1)机器学习特征而非手工设计特征,高效而且稳定;2)深度学习可利用图形处理器(GPU)进行并行运算,速度远超传统的图像处理算法;3)特征表示与分类器联合优化,可以最大程度地发挥二者联合协作的性能;4)深度学习充分利用了大数据的优势,可扩展性好.

2 隧道特征图像样本库的建立

深度学习的兴起依赖于大数据相关技术发展的日新月异,对于卷积神经网络的研究,其数据样本至关重要,充足的数据一方面可以提升网络模型特征抽象表征能力,另一方面能够增加网络对数据的鲁棒性,避免模型出现过拟合. 国内外针对隧道病害图像采集工作开展的时间比较短,大部分图像为普通相机甚至是手机拍摄,通常质量不高,且数量上也比较少,无法满足深度学习训练集的要求. 本文利用自主研发的采集设备,开展盾构隧道衬砌表观图像采集,初步建立了训练样本库.

2.1 数据来源与标签

盾构隧道衬砌病害图像采集所用的设备是自主研发的快速移动式隧道扫描检测系统: MTI-100 系统(图 1)^[24],可实现高精度衬砌表观图像连续、快速地扫描. 针对上海市地铁 1、2、4、7、8 和 10 号线区间隧道开展了多次检测,采集了大量的隧道衬砌灰度图像,为深度学习提供了基础样本. 图 2 为 MTI-100 系统在上海市地铁 2 号线进行检测.



图 1 移动式地铁隧道结构病害检测系统
Fig. 1 Movable tunnel inspection system (MTI-100)



图 2 MTI-100 隧道病害检测
Fig. 2 Tunnel disease detection with MTI-100

2.2 样本设定和标签

根据混凝土结构规范要求,结构健康度检测需要统计宽度 0.2 mm 及以上的裂缝,因此需要采用高分辨率线阵相机.盾构地铁隧道直径通常为 5.5 m,MTI-100 系统环向扫描长度 13 m,以 3 000 像素宽度提取图像,可获得大小为 3 000 像素×22 344 像素(半环)的图像,如图 3 所示.




图 3 MTI-100 采集的完整图像

Fig. 3 Whole image gathered by MTI-100

通过对隧道衬砌病害的统计分析^[25],裂缝、渗漏水是最主要的病害(占比超过 86%),因此本文中目前重点针对裂缝与渗漏水进行处理.考虑到城市地铁隧道衬砌中其他典型特征,例如衬砌拼缝、管线等可能会对病害的检测造成干扰,故将其纳入到卷

积神经网络的特征样本库中.针对 MTI-100 采集的大量数据,提取渗漏水、裂缝、管片拼缝和管线 4 类建立样本,分别标定标签号为 1、2、3、4(图 4).




图 4 4 种隧道衬砌特征图像

Fig. 4 Four classes of tunnel lining feature images

经过图像提取,共得到 7 560 张隧道衬砌特征图像,标记为样本 O.取其中 5 670 张作为训练样本,1 890 张作为测试样本,每类标签具体图像的数量见表 1.

表 1 样本标签和数量
Tab. 1 Label and number of the samples

类别	标签	训练样本	测试样本	总计
渗漏水	1	1 155	385	1 540
裂缝	2	1 680	560	2 240
拼缝	3	1 495	500	1 995
管线	4	1 340	445	1 785
合计		5 670	1 890	7 560

2.3 直方图均衡化

鉴于 CCD 相机采集的图像对比度过低,相似度过高,可能不利于卷积神经网络的训练,为了探究对比度增强算法对 CNN 的影响,提出采用直方图均衡化方法进行对比度的增强.直方图均衡化(Histogram Equalization, HE)是图像空间域增强点运算的一种方法,其核心思想是把原始图像的灰度直方图进行非线性拉伸,重新分配图像像素灰度值,即从比较集中的某个灰度区间更新为全部灰度范围内的均匀分布,且一定灰度范围内的像素数量大致相同^[26].对某一渗漏水的图像进行 HE 操作,如图 5 所示,可以发现处理后的图像增强了人眼观察的视觉效果.对 7 560 张原始图像进行 HE 处理,标记为样本 HE.

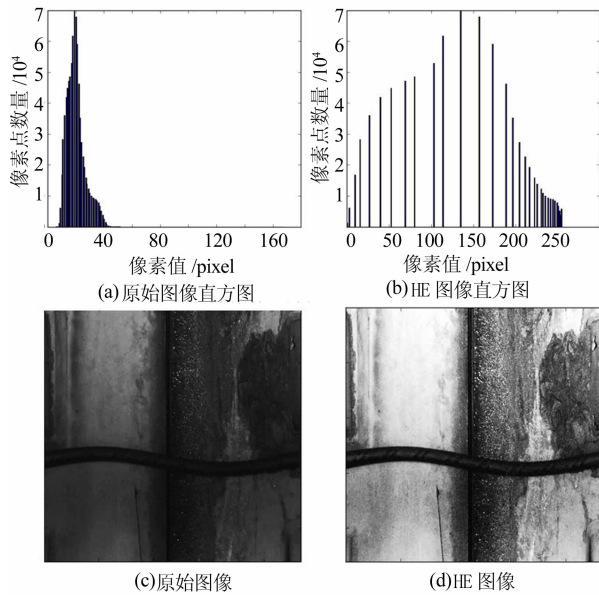


图5 特征图像的直方图均衡化

Fig. 5 Histogram equalization of feature map

3 隧道衬砌特征图像分类识别方法

3.1 卷积神经网络

通常认为,卷积神经网络是含有多个隐含层的复杂神经网络.模型由数据层、视觉层(卷积层、池化层、激励层)以及其他层(全连接层,随机失活层,分类层等)组成.

1)数据层是模型的入口,处于网络的最底层,以固定大小的图像为输入数据“喂”给网络模型,在图像的每个通道,每个像素点以具体灰度数值(0~255)表示.

2)视觉层是卷积神经网络的主要组成部分,体现了卷积神经网络的核心思想.由于图像具有局部性和不变性的性质,因此采用不完全连接方式可以大大减少模型的参数数量,同时可避免关键特征信息的丢失^[17].

卷积层由若干个大小为 $l \times l$ 的卷积核和 $w \times h$ 的输入图像的一个邻域进行卷积,即以一组权重和不同窗口内数据做内积,并以一定步长 s 进行滑动,同一个卷积核在一次运算中共享权重,输出 $(h-l)/(s+1) \times (w-l)/(s+1)$ 维度的特征图像.每一次卷积宏观上可理解为对图像某种特征的抽取,卷积层数越多,可得到更抽象的图像特征.

池化层也称降采样层,通常设置在卷积层和激励层之后,以一定大小 $l \times l$ 的池化窗口和一定步长 s 对 $w \times h$ 的特征图像的一个邻域进行降采样,得到

$(h-l)/(s+1) \times (w-l)/(s+1)$ 的特征图像.池化可以减小模型参数,学习特征图像的空域特征,实现对位移、缩放和其他形式扭曲的不变性,减小过拟合的发生^[24].常用的池化操作为最大值池化和平均值池化,最大值池化侧重于保留图像的纹理信息,而平均值池化侧重于保存图像的背景信息.

激励层通常与卷积层合并,对卷积层输出结果进行非线性函数变换,用于模拟神经元的激活阈值控制.早期人工神经网络神经元的激活函数多采用Sigmoid函数.激励层不会改变神经元的个数和分布,常用的激活函数见表2.

表2 卷积神经网络中常用的激活函数
Tab. 2 Common activation function in CNN

函数名称	函数表达式
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
Hyperbolic Tangent	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Power	$f(x) = (a + bx)^c$
ReLU	$f(x) = \max(x, 0)$
ELU	$f(x) = \begin{cases} x, & x > 0 \\ a(\exp(x) - 1), & x < 0 \end{cases}$

非线性激活函数ReLU(Rectified-Linear Units)既可以避免梯度过大导致的梯度弥散(梯度爆炸)以及梯度过小导致的梯度消失现象,又可以保持较快的计算速度,因此在CNN中广泛采用.

3)其他层中包含了全连接层,随机失活层(Dropout),分类层,批次规范化层(Batch Normalization)等,实现对CNN结构模型增加期望的功能.本文中使用了随机失活层和分类层(softmax).

在神经网络的训练过程中,过拟合是经常出现的问题,在CNN中这个问题更加突出,因此,本文采用了随机失活层^[27],其作用是在前向传播的过程中使得某些节点随机失活.随机失活层很大程度上避免了过拟合的发生,增加了网络结构的鲁棒性.

softmax层是卷积神经网络的分类层,完全嵌入到CNN中,是端对端(end to end)的结构,通常设置在CNN的最后一层.这种方法分类准确率高,计算量小,并行分布处理能力强,能充分逼近复杂的非线性关系.softmax层的损失函数为交叉熵损失(cross-entropy loss),数学表达式见式(1).

$$L_i = -f_{y_i} + \log \sum_j e^{f_{y_j}} \quad (1)$$

式中: L_i 为第 i 个标签的损失; j 为总标签数; f_{y_j} 为前向传播得到的得分向量.

3.2 Goog LeNet 卷积神经网络

2014 年图像识别大赛上提出了 22 层的 Goog LeNet 模型^[28]. 该模型放弃了 Alex Net 传统的整体构架, 根据不同尺度的 Gabor 过滤器处理多尺度问题, 提出了 inception 模块, 极大减少了整个网络模型的参数数量, 同时增加了网络的深度和结构的非线性, 一方面加快了计算速度, 另一方面可以提取更深层次的特征. inception 模块结构如图 6 所示. 每个 inception 模块包含 4 条线路: 1) 1×1 小卷积并 ReLU 激活; 2) 1×1 小卷积和 3×3 卷积并 ReLU 激活; 3) 1×1 小卷积和 5×5 卷积并 ReLU 激活; 4) 3×3 最大值池化和 1×1 卷积.

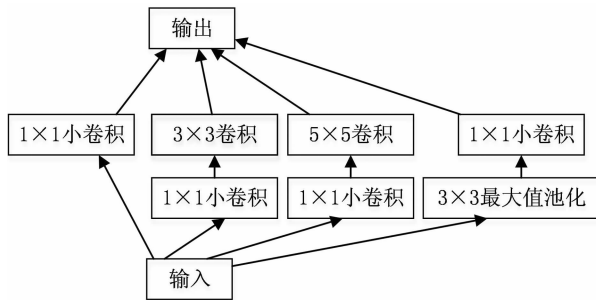


图 6 inception 模块结构图
Fig. 6 Structure diagram of inception module

3.3 改进的卷积神经网络结构

Simonyan 等^[29]提出了 VGG 模型, 并且对比了不同大小的卷积核, 结果表明使用小卷积核可以有效地降低测试结果的错误率. 而在 GoogLeNet 中仍然使用了较大的卷积核(inception 模块中含有 5×5 卷积和主体结构中含有 7×7 卷积). 基于大量的试验, 针对隧道衬砌图像处理, 提出了 2 种改进方式.

1) 优化改进 inception 模块. 在新的 inception 模块中, 全部采用大小为 1×1 和大小为 3×3 的卷积核, 将最大值池化和 3 种不同的卷积方式并行起来, 增加了网络的宽度; 同时 4 条线路的网络层数不尽相同, 堆叠在一起, 增加了网络的深度, 提高了对不同尺度图像的适应性. 改进后的 inception 模块如图 7 所示.

2) GoogLeNet 第 1 个卷积层使用了 7×7 的卷积核, 这里提出了 3 种不同的优化方式, 具体形式见表 3. 经过改进后的整体网络结构如图 8 所示. 将原始的 inception 模块和改进的 inception 模块与表 3 的优化方式相结合, 构成了本文的 6 种不同网络结构(见表 4).

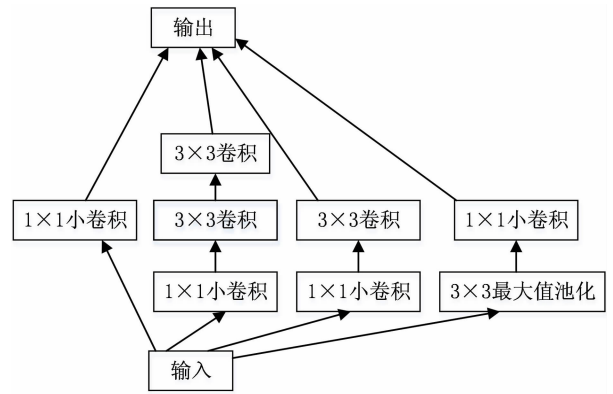


图 7 改进的 inception 模块结构图
Fig. 7 The schema of improved inception module

表 3 3 种优化方式

Tab. 3 Three optimization methods

方式	具体形式
1	卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 $2 \times 2 \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 2×2
2	卷积 $3 \times 3 \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 $2 \times 2 \rightarrow$ 卷积 $3 \times 3 \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 2×2
3	卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 $2 \times 2 \rightarrow$ 卷积 $3 \times 3 \rightarrow \text{ReLU} \rightarrow$ 最大值池化 2×2

表 4 6 种网络结构

Tab. 4 Six network architecture

网络结构	inception	优化方式	结构层数
V-1	原始	方式 1	25
V-2	原始	方式 2	25
V-3	原始	方式 3	23
V-4	改进	方式 1	34
V-5	改进	方式 2	34
V-6	改进	方式 3	32

4 实例分析

4.1 超参数(Hyper Parameters)设定

以图形处理器(GPU)为计算核心, 应用 Caffe 深度学习框架^[30]进行计算. 经过大量的调参最终使用的超参数设定如下:

使用涅斯捷罗夫加速梯度法(Nesterov's Optimal Gradient Method), 训练轮次(epoch)为 30 轮, 每一轮训练 1 134 批次, 每批次数量为 5, 初始学习率设定为 0.01, 在第 10 个训练批次下降为 0.001, 在第 20 个训练批次下降为 0.000 1, 学习率变化如图 9 所示.

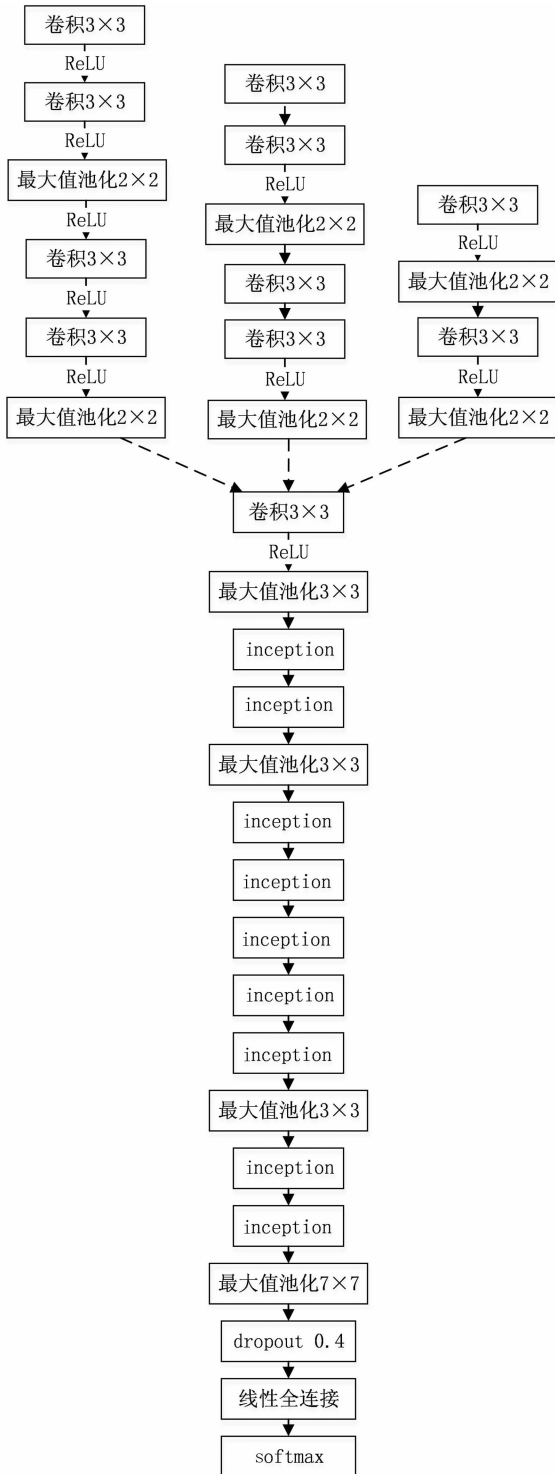


图8 整体卷积神经网络结构图

Fig. 8 The overall architecture schema of CNN

4.2 训练测试过程和结果

本文构建的模型中最后一层使用的是 softmax 分类器,在测试阶段,对提取的深层卷积特征进行分类,输出为每一类概率值.取概率最大值为预测结果,和真实标签比较,统计结果获得整个测试集上的

准确率(accuracy).本文分别测试了不同模型的适应性,不同深度学习框架和不同数据的影响性,结果如下:

1)以本文 3.3 节提出的改进方式构建了 6 种不同的模型,使用原始数据进行网络训练和预测,以传统的 GoogLeNet 为基准进行对比,取所有 epoch 中最大的准确率为最终结果,汇总结果见表 5.




图9 学习率-epoch 曲线图

Fig. 9 Curves of learning rate vs epoch

表5 不同模型的训练结果
Tab. 5 Results of different models

数据	网络结构	准确率/%
原始数据	GoogLeNet	93.42
原始数据	V-1	93.42
原始数据	V-2	93.68
原始数据	V-3	94.74
原始数据	V-4	93.95
原始数据	V-5	94.74
原始数据	V-6	95.24

结果表明,GoogLeNet 在本数据集上的准确率为 93.42%,而本文提出的 V-6 网络结构模型的精度为 95.24%,提升了 1.82 个百分点,表明在隧道病害的识别上,V-6 模型更具适用性.

2)使用 1)中 V-6 模型应用不同的深度学习框架 Caffe 和 Torch 分别对提取的原始数据和经过 HE 的数据进行训练,得到结果见表 6 和图 10,图 10 中横坐标轴(x 轴)为 epoch,指所有训练数据都经过一次迭代,纵坐标轴(y 轴)为测试准确率.

通过 Caffe 的 python 接口对测试集进行批量处理,统计分类信息并得到混淆矩阵(confusion matrix).混淆矩阵中的 x 轴和 y 轴分别表示图像的类别,第 i 行 j 列的值表示第 i 类图像被分类为第 j 类图像的个数,混淆矩阵对角线上元素的值代表每类图像正确分类的个数.通过混淆矩阵可以清晰地观

察和分析每类图像正确分类的个数以及与之易混淆造成错分的类别. 分别见表 7~表 10.

表 6 训练和测试结果汇总
Tab. 6 Results of training and test

数据	框架	训练时间/s	训练集样本数	训练集准确率/%	测试集样本数	测试集准确率/%	混淆矩阵	测试时间(不含 HE 处理时间)/s	每张图片测试时间/s
原数据	Caffe	3 715	5 670	95.41	1 890	95.24	见表 7	106	0.056
原数据	Torch	8 075	5 670	93.83	1 890	92.11	见表 8	114	0.060
HE 数据	Caffe	3 715	5 670	94.44	1 890	91.80	见表 9	99	0.052
HE 数据	Torch	8 100	5 670	96.39	1 890	93.39	见表 10	110	0.058




图 10 准确度-epoch 曲线图
Fig. 10 Curves of accuracy vs epoch

表 7 O-Caffe 测试混淆矩阵
Tab. 7 O-Caffe test confusion matrix

标签	渗漏水	裂缝	拼缝	管线	准确率/%
1	350	0	16	19	90.91
2	9	530	11	10	94.64
3	0	9	490	1	98.00
4	11	0	4	430	96.63

表 8 O-Torch 测试混淆矩阵
Tab. 8 O-Torch test confusion matrix

标签	渗漏水	裂缝	拼缝	管线	准确率/%
1	325	4	31	25	84.42
2	0	530	11	19	94.64
3	0	18	466	16	93.40
4	10	0	20	415	93.26

表 9 HE-Caffe 测试混淆矩阵
Tab. 9 HE-Caffe test confusion matrix

标签	渗漏水	裂缝	拼缝	管线	准确率/%
1	301	19	5	10	78.18
2	4	535	21	0	95.54
3	25	30	440	5	88.00
4	0	1	9	435	97.75

表 10 HE-Torch 测试混淆矩阵
Tab. 10 HE-Torch test confusion matrix

标签	渗漏水	裂缝	拼缝	管线	准确率/%
1	365	4	9	7	94.81
2	9	545	6	0	97.32
3	48	30	415	7	83.00
4	1	4	0	440	98.88

从 4 个案例的结果分析,输出层测试集上的准确率均超过了 90%,其中使用 Caffe 训练原始数据的测试准确率为 95.24%,在 378 张图像中的误检率仅为 4.76%,表明本方法准确率高. 从测试的速度上分析,每张图像消耗的时间均低于 0.07 s,远快于传统图像病害识别算法^[9](测试时间大于 50 s/张).

对比 Caffe 和 Torch 两种深度学习框架,准确率指标上差异不明显,在原始图像上和经过 HE 处理的图像上的准确率均超过了 90%,而在计算效率上,Caffe 远快于 Torch.

对比原始数据和经过 HE 处理的数据,无论在准确率还是消耗时间上,二者的差异不明显,表明 HE 操作虽然能够大幅度增加图像对比度,人眼观察更清楚,但是同时也增加了背景的复杂程度,造成了某些细节的消失,故对于卷积神经网络,并不能提高效率,因此在实用中建议不进行 HE 操作.

4.3 鲁棒性分析

为了探究模型在不良条件下的适应性和鲁棒性,以及避免搜集数据集可能造成的人工影响,开展了复杂背景条件下病害图像的测试. 主要包含两类:调焦失误引起的模糊图像,破损环境下的衬砌裂缝. 采用本文 4.2 节中表现最优的原数据+Caffe+V-6 模型对图像(共 96 张)进行测试,其中 89 张图像检测正确,准确率 92.71%,图 11 展示了部分结果. 表明本文的模型在复杂条件下具有良好的适应性和鲁棒性.




图 11 复杂条件下图像分类结果

Fig. 11 Classification results in hard conditions

5 结论

针对 CCD 线阵相机采集的城市地铁盾构隧道衬砌灰度图像病害识别问题,提出基于卷积神经网络的深度学习对目标进行特征学习,实现隧道衬砌图像病害的自动分类识别,得到如下结论:

1)隧道衬砌病害图像对比度低,相似度高,既有的识别方法难以有效处理渗漏水 and 裂缝病害,而以深度学习为基础的识别方法具备同时识别裂缝和渗漏水的能力,且准确率高,识别速度快,鲁棒性好,可适用于隧道病害自动识别系统.

2)通过使用更小的卷积核加深卷积神经网络结构,改进 inception 模块,最终优化得到 32 层卷积神经网络结构 V-6 在本数据样本下得到了 95.24% 的准确率,效果优于 GoogLeNet,表明在隧道结构病害的识别上,V-6 模型适用性更佳.

3)不同深度学习框架对卷积神经网络的训练速度和训练准确率会产生不同程度的影响,应用深度学习时,应测试不同框架,寻找最优方案.对比度增强图像预处理算法(如 HE)提升了人眼的视觉效果,但也增加了背景的复杂程度,造成了细节丢失,难以提升卷积神经网络的训练效果.

4)深度学习对样本数据要求较高,目前成熟的数据库样本往往数以十万百万计,大量的样本不仅可以提高模型训练的识别率,而且还可以避免机器学习中常出现的过拟合问题.本文首次尝试建

立隧道结构病害特征图像样本库,但目前样本库的数量还远远不够,且样本的来源比较单一(目前主要为上海地铁盾构隧道样本),开展样本收集整理是进一步研究工作的任务之一.

6 展望

本文提出的方法虽然可以识别盾构隧道衬砌病害,但对于大尺度图像(如 MTI-100 采集的 3 000 像素×22 344 像素图像),尚没有考虑病害的位置特征等信息,因此检测效率还有较大的提升空间.在下一步的工作中将开展结合区域建议网络(Region Proposal Network)和卷积神经网络开展增强特征大尺度图像病害快速检测研究,其核心思想为通过区域建议网络在完整图像上进行候选框的选择,使用卷积神经网络模型判断候选框中的内容是否为病害,思路流程如图 12 所示.而本文训练的 V-6 模型将会用于病害检测模型的初始化.同时将评定结果反馈回隧道中,进行病害的整治和隧道的养护也将在后续的研究中展开.

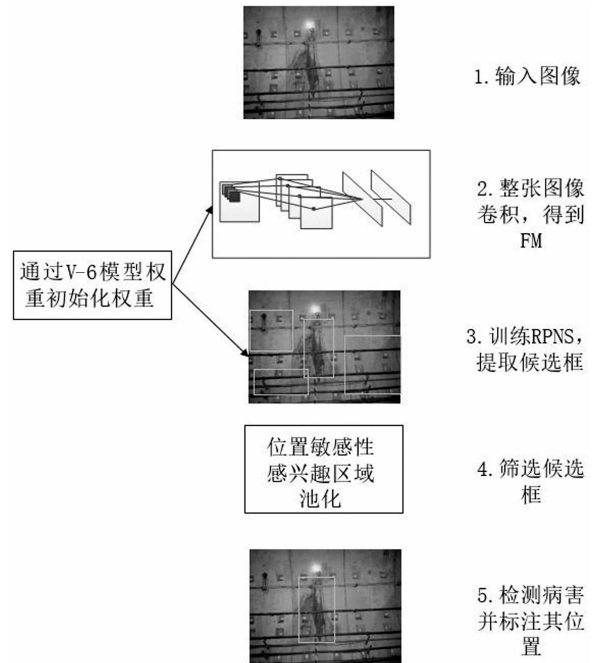


图 12 大尺度图像病害检测流程图

Fig. 12 Disease detection flow chart on large scale image

参考文献

[1] YU S N, JANG J H, HAN C S. Auto inspection system using a mobile robot for detecting concrete cracks in a tunnel[J]. Automation in Construction, 2007, 16(3): 255-261.

[2] 王平让. 隧道衬砌裂缝机器视觉检测方法及其结构安全评估研究[D]. 上海: 同济大学土木工程学院, 2013: 61-88.

WANG P R. Study on machine vision inspection method for cracks and structural safety assessment in tunnel lining[D].

- Shanghai: Collage of Civil Engineering, Tongji University, 2013;61-88. (In Chinese)
- [3] 王睿. 隧道衬砌裂缝车载检测图像分析研究[D]. 成都:西南交通大学土木工程学院,2012;16-29.
WANG R. Research on image processing of in-vehicle tunnel lining crack detection[D]. Chengdu: Collage of Civil Engineering, Southwest Jiaotong University, 2012;16-29. (In Chinese)
- [4] 李鹏. 基于图像处理的隧道检测[D]. 北京:北京交通大学信息与科学学院,2006;29-41.
LI P. Tunnel detection based on image processing[D]. Beijing: Collage of Information Science and Technology, Beijing Jiaotong University, 2006;29-41. (In Chinese)
- [5] ZHANG W, ZHANG Z, QI D, *et al.* Automatic crack detection and classification method for subway tunnel safety monitoring [J]. *Sensors*, 2014, 14(10):19307-19328.
- [6] 黄宏伟, 孙奕, 薛亚东. 基于机器视觉的隧道衬砌表面病害检测技术研究进展[J]. *现代隧道技术*, 2014, 51(S1):19-30.
HUANG H W, SUN Y, XUE Y D. Research progress of machine vision based disease detecting techniques for the tunnel surface[J]. *Modern Tunnelling Technology*, 2014, 51(S1):19-30. (In Chinese)
- [7] 刘晓瑞, 谢雄耀. 基于图像处理的隧道表面裂缝快速检测技术研究[J]. *地下空间与工程学报*, 2009, 5(S2):1624-1628.
LIU X R, XIE X Y. Rapid crack inspection of tunnel surface based on image processing[J]. *Chinese Journal of Underground and Engineering*, 2009, 5(S2):1624-1628. (In Chinese)
- [8] 王平让, 黄宏伟, 薛亚东. 基于图像局部网格特征的隧道衬砌裂缝自动识别[J]. *岩石力学与工程学报*, 2012, 31(5):991-999.
WANG P R, HUANG H W, XUE Y D. Automatic recognition of cracks in tunnel lining based on characteristics of local grids in images[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2012, 31(5):991-999. (In Chinese)
- [9] 王耀东, 余祖俊, 白彪, 等. 基于图像处理的地铁隧道裂缝识别算法研究[J]. *仪器仪表学报*, 2014, 35(7):1489-1496.
WANG Y D, YU Z J, BAI B, *et al.* Research on image processing based subway tunnel crack identification algorithm[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(7):1489-1496. (In Chinese)
- [10] 朱力强, 白彪, 王耀东, 等. 基于特征分析的地铁隧道裂缝识别算法[J]. *铁道学报*, 2015, 37(5):64-70.
ZHU L Q, BAI B, WANG Y D, *et al.* Subway tunnel crack identification algorithm based on feature analysis[J]. *Journal of the China Railway Society*, 2015, 37(5):64-70. (In Chinese)
- [11] ZHAO G, WANG T, YE J. Anisotropic clustering on surfaces for crack extraction[J]. *Machine Vision & Applications*, 2015, 26(5):675-688.
- [12] MOON H G, KIM J. Intelligent crack detecting algorithm on the concrete crack image using neural network[C]// *Proceedings of the 28th ISARC*. Seoul: ISARC, 2011:1461-1467.
- [13] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553):436-444.
- [14] HUBEL D H, WIESEL T N. Receptive fields and functional architecture of monkey striate cortex[J]. *Journal of Physiology*, 1968, 195(1):215-243.
- [15] FUKUSHIMA K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position[J]. *Biological Cybernetics*, 1980, 36(4):193-202.
- [16] LECUN Y, BENGIO Y. Convolutional networks for images, speech, and time series[J]. *The Handbook of Brain Theory and Neural Networks*, 1995, 3361(10):1-14.
- [17] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786):504-507.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// *International Conference on Neural Information Processing Systems*. Nevada: NIPS, 2012:1097-1105.
- [19] TAIGMAN Y, YANG M, RANZATO M, *et al.* DeepFace: Closing the gap to human-level performance in face verification [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014:1701-1708.
- [20] SUN Y, WANG X, TANG X. Deep learning face representation from predicting 10 000 classes[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014:1891-1898.
- [21] SUN Y, WANG X, TANG X. Deeply learned face representations are sparse, selective and robust[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014:2892-2900.
- [22] CRUZ-ROA A A, OVALLE J E A, MADABHUSHI A, *et al.* A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Heidelberg: Springer, 2013:403-410.
- [23] 徐姗姗, 刘应安, 徐昇. 基于卷积神经网络的木材缺陷识别[J]. *山东大学学报(工学版)*, 2013, 43(2):23-28.
XU S S, LIU Y A, XU S. Wood defects recognition based on the convolutional neural network[J]. *Journal of Shandong University (Engineering Science)*, 2013, 43(2):23-28. (In Chinese)
- [24] HUANG H W, SUN Y, XUE Y D, *et al.* Inspection equipment study for subway tunnel defects by greyscale image processing [J]. *Advanced Engineering Informatics*, 2017(32):188-201.
- [25] 刘德军. 山岭隧道二次衬砌开裂机理及基于纤维编织网增强混凝土(TRC)的修复研究[D]. 上海:同济大学土木工程学院, 2014:22-39.
LIU D J. Study on cracking mechanism of tunnel lining and strengthened by Textile-Reinforced Concrete [D]. Shanghai: Collage of Civil Engineering, Tongji University, 2014:22-39. (In Chinese)
- [26] 陈永亮. 灰度图像的直方图均衡化处理研究[D]. 合肥:安徽大学信息与科学学院, 2014:11-16.
CHEN Y L. Gray image histogram equalization processing research[D]. Hefei: Collage of Information Science Technology, Anhui University, 2014:11-16. (In Chinese)
- [27] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, *et al.* Dropout: a simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15(1):1929-1958.
- [28] SZEGEDY C, LIU W, JIA Y, *et al.* Going deeper with convolutions[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015:1-9.
- [29] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:1409.1556*, 2014.
- [30] JIA Y, SHELHAMER E, DONAHUE J, *et al.* Caffe: Convolutional architecture for fast feature embedding[C]// *ACM International Conference on Multimedia*. Orlando: ACM, 2014:675-678.