

DOI:10.19853/j.zgjsps.1000-4602.2021.21.018

# 基于卷积神经网络的排水管道缺陷智能检测与分类

周倩倩, 司徒祖祥, 腾 帅, 陈贡发  
(广东工业大学 土木与交通工程学院, 广东 广州 510006)

**摘 要:** 针对传统排水管道缺陷检测中需要消耗大量人力的问题,基于人工智能算法——卷积神经网络(CNN),建立自动检测和评估排水管道缺陷的智能系统。对 CCTV 视频图像中六种常见的管道状态(裂缝、错口、障碍物、残墙坝根、树根和正常类别)进行模型学习、训练和测试。CNN 模型训练和验证的正确率分别为 100% 和 97%,六类管道状态的平均识别准确率达到 90%,证明所构建的模型在不需要相关检测专业知识的情况下,可以很好地识别本研究中的管道缺陷类型。其中,CNN 模型对树根和错口的检测具有较高置信度,其次是残墙坝根和裂缝,障碍物和正常类别的分类精度最低。深度学习在排水管道缺陷自动检测领域具有可行性,模型具有良好的泛化能力,可为管道缺陷检测提供科学、准确的检测工具。

**关键词:** 排水管道缺陷; 卷积神经网络; 人工智能; 检测与分类

**中图分类号:** TU992 **文献标识码:** A **文章编号:** 1000-4602(2021)21-0114-05

## Intelligent Detection and Classification of Drainage Pipe Defects Based on Convolutional Neural Networks

ZHOU Qian-qian, SITU Zu-xiang, TENG Shuai, CHEN Gong-fa

(School of Civil and Transportation Engineering, Guangdong University of Technology, Guangzhou 510006, China)

**Abstract:** Traditional drainage pipe defect detection needs a lot of manpower. To cope with the problem, a system for automatic detection and evaluation of the drainage pipeline defects was established based on an artificial intelligence algorithm—convolutional neural networks (CNN). Six common pipeline defects (crack, disjoint, obstacle, residual wall, tree root and normal category) observed by CCTV video images were learned, trained and tested by the model. The training and validation accuracies of the CNN model were 100% and 97%, respectively, and the average recognition accuracy of the six kinds of pipeline defects reached 90%, which proved that the established model could well identify the defect types without the need of relevant detection expertise. The CNN model had a high confidence in the detection of the tree roots and disjoints, followed by the residual walls and cracks, and the classification accuracy of the obstacles and the normal type was the lowest. The deep learning is feasible in the field of automatic detection of the drainage pipe defects, and the model has good generalization ability, which provides a scientific and accurate detection tool for the detection of the pipe defects.

基金项目: 国家自然科学基金青年基金资助项目(51809049); 国家级大学生创新训练项目(202111845038); 广州市科技计划项目(201804010406)

**Key words:** drainage pipe defect; convolutional neural networks; artificial intelligence; detection and classification

排水管网是城市最重要的基础设施之一,直接影响城市的公共安全和环境保护。然而随着管道使用时间的增加,管道堵塞、破损、渗漏等问题日益凸显<sup>[1]</sup>。若这些问题得不到妥善解决,将严重影响管道的实际承载能力,造成重大的社会经济损失。为提高管道的排水能力,延长管道使用寿命,需定期组织专业性检查,及时发现管道安全隐患并采取有效的措施进行维护。然而,传统人工评价存在劳动密集和易出错的问题,不仅操作流程复杂,且易受人为主观因素的影响,难以满足现代排水管网检测的发展要求。建立智能化的管道缺陷检测和分类系统,已成为城市排水设施建设和管理的迫切需求<sup>[2]</sup>。

国内外传统的检测方法主要通过图像处理技术,将形态学分割与图像预处理方法相结合<sup>[3]</sup>,对缺陷区域进行特征提取。目前较为先进的机器学习技术也逐渐用于排水管道缺陷的评估<sup>[4]</sup>。但上述两种方法需要预先提取图像的特征和经历繁琐的训练过程,且在复杂情形下的检测和分类能力表现不佳。为克服这些问题,近年来提出了用于计算机视觉和图像分类的卷积神经网络(CNN)算法<sup>[5]</sup>,不仅能够识别和区分多类物品,检测精度高,且模型泛化能力更强。借助CNN算法,排水管道状况的检测和分类有望更加高效和稳定。笔者提出了基于CNN的排水管道缺陷自动检测与分类方法,以期为管道缺陷诊断和维护提供经济、有效的技术支持。

## 1 卷积神经网络算法

卷积神经网络(CNN)是一种具有深度学习算法的前馈神经网络<sup>[6]</sup>,在计算机视觉领域最具代表性。CNN能有效学习重要的特征信息,降低输入维度,同时大幅度提高计算精度和效率。CNN架构由不同类型的层堆叠而成,整个过程将输入量转换成输出量。图1(a)为典型的卷积神经网络模型,主要由卷积层、池化层、激活函数和全连接层组成。卷积层是CNN的构建核心,作用是提取图像的特征。卷积运算可理解为一些小矩阵在输入图像上滑动,做矩阵乘法和加法,输出特征图<sup>[7]</sup>。卷积核大小、步长和填充三个超参数,共同决定卷积层输出特征图的尺寸。当不同作用的卷积核组合到一个神经网络中,可以提取更加复杂的特征。卷积有两大优点:①

局部感知,神经元在图像连接时,只需连接部分像素得到局部特征,汇总后得到全局特征;②权值共享,图像中的部分特征与其他特征是近似相同的,可由此部分学习到的特征应用到其他部分。

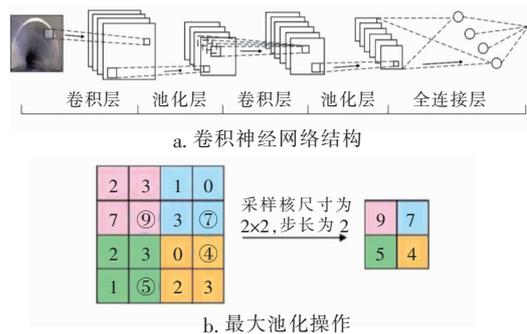


图1 卷积神经网络结构和最大池化操作

Fig. 1 CNN structure and maximum pooling operation

在提取特征后,池化层对特征图进行降维,通过减少参数数量降低运算量。确定池化区域的方法与卷积类似,由池化范围的大小、步长和填充三者控制。常用方法包括最大池化和平均池化,本研究采用最大池化来生成下一层的输入,见图1(b)。经过卷积和池化的组合,可得到线性结果。为使网络具备良好的表征能力,引入非线性元素。目前应用较广泛的是线性整流函数 ReLU<sup>[8]</sup>:

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (1)$$

式中: $x$ 指代上一层神经网络的输出向量。采用ReLU线性整流函数可以提高CNN的收敛速度。此外,全连接层是一类特殊的卷积层,在网络末端使用,对得到的结果通过非线性组合输出,起到分类器的作用。相邻两层的节点成对连接,学习分布式表示,映射到样本标记空间。最后,使用交叉熵(Softmax)损失函数计算输出值,通常选择最大概率值作为分类输出的结果。形式如下:

$$P(y_i | x_i) = \frac{e^{f_{y_i}}}{\sum_j e^{f_{y_j}}} \quad (2)$$

式中: $y_i$ 代表图像 $x_i$ 的正确标签; $f_{y_i}$ 代表预测分数,是一个向量。

## 2 CNN模型构建

### 2.1 数据集构建

本研究调查了我国南方地区常见的排水管道缺

陷<sup>[9-10]</sup>,分为六类,涵盖裂缝、错口、障碍物、残墙坝根、树根和正常(未损坏)等类别,如图 2 所示。本研究并未考虑其他发生概率相对较低的缺陷。上述缺陷既可能导致排水管道横截面面积减小,也可能使管道结构破裂变形,影响排水系统的输水能力,造成系统溢流甚至崩溃。

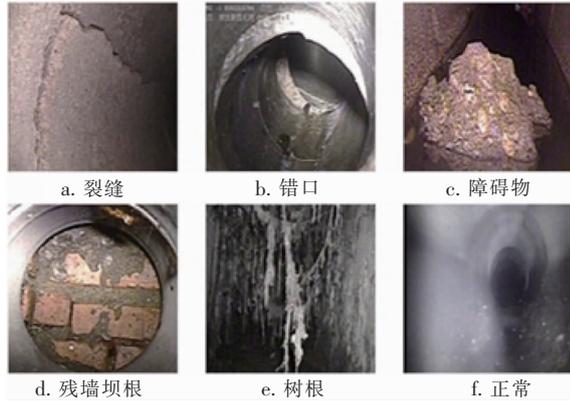


图 2 管道缺陷样本图片

Fig. 2 Sample pictures of pipe defects

管道缺陷图像来源于 CCTV 检测视频。原始排水管道缺陷数据集包括一系列排水管道缺陷的原始图像,通过视频采集设备从实际排水系统收集,再由排水管道专家给出缺陷注释并进一步捕获和分类。由于原始图像的分辨率不同,在处理之前对图像进行统一像素(128 × 128),再进入网络输入层。此外,为降低过拟合造成的影响,提高识别准确率,本研究采用了 11 种数据增强技术对图像数量进行扩增(见图 3),包括几何变换(旋转、镜像和平移)和颜色变换(抖动、颜色调整和添加噪声)。经过数据增强后样本图像达到 7 320 张,包括 610 张原始图像和 6 710 张增强图像,其中训练、验证和测试样本的比例为 80 : 10 : 10。具体数据信息见表 1。

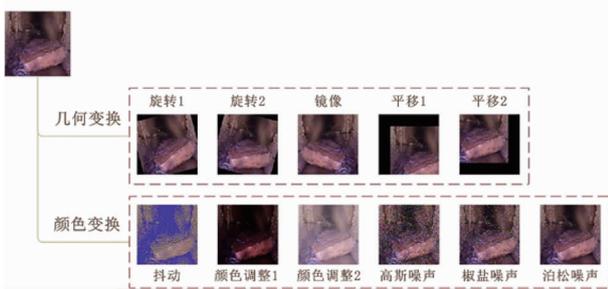


图 3 数据扩增技术的采用(几何和颜色变换)

Fig. 3 Adoption of data augmentation (geometric and color transformation)

表 1 数据集划分

Tab. 1 Specific division of dataset

项目	训练样本	验证样本	测试样本
裂缝	960	120	120
错口	960	120	120
障碍物	960	120	120
残墙坝根	960	120	120
树根	960	120	120
正常	1 056	132	132
总计	5 856	732	732

## 2.2 CNN 模型架构和训练

基于构建的排水管道缺陷数据集,针对模型的架构和主要参数进行了多次模型训练和验证,在反复迭代处理中,得到模型的合理设置。构建的 CNN 模型包含一个图像输入层、三个卷积层、两个池化层、三个激活层、一个全连接层和一个分类输出层(见图 4)。优化后各卷积层的具体参数设定如表 2 所示,两个池化层的池化窗口大小均为 2 × 2,步长为 2。激活层使用 ReLU 函数,防止出现梯度消失的问题。Softmax 函数将应用到分类输出层,并使用批标准化层作为网络的辅助层。

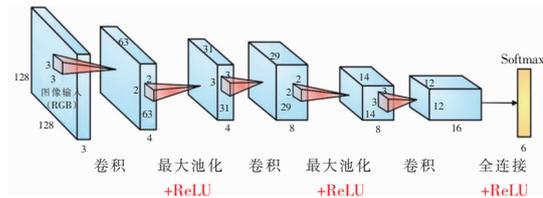


图 4 CNN 模型结构

Fig. 4 Structure of CNN model

表 2 卷积层参数设定

Tab. 2 Parameter setting of convolutional layer

卷积层	卷积核尺寸	步长	填充	特征图
1	3 × 3	2	0	4
2	3 × 3	1	0	8
3	3 × 3	1	0	16

## 3 测试结果及分析

为评估构建的 CNN 模型的性能和鲁棒性,进行了 10 次随机测试,以评估模型的性能,同时避免因随机性和偶然性造成的实验误差。在大多数情况下,模型在 200 次迭代前进行学习,伴随着预测精度的提高,损失曲线呈下降的趋势。经过 1 000 次迭代,网络达到收敛,验证精度达到 96% 以上。图 5 总结了 10 次测试的具体数据,训练和验证的正确率平均值分别为 100% 和 97%。分类检测识别的

平均准确率达到 90%,最高和最低值分别约为 91% 和 89%。

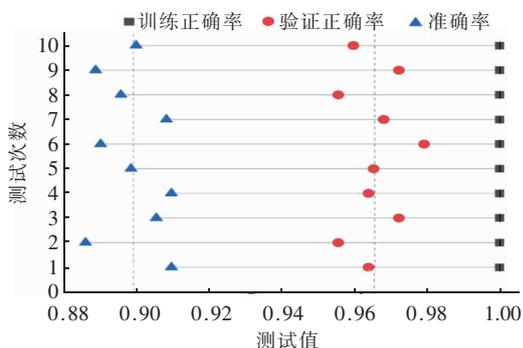


图 5 CNN 模型的训练、验证和预测准确率

Fig. 5 Training, validation and prediction accuracy of CNN model

图 6 为六类排水管道缺陷的识别精度矩阵,识别分类准确率越接近 100%,分类性能就越好。结果表明,CNN 模型能够正确识别不同类型的缺陷,具有较高的精度。模型对树根和错口的分类能力最高,准确率接近 96.2% 和 93.3%。以树根为例,模型在识别过程中,有 96.2% 的几率可以正常识别该缺陷,有 1.0% 错认为正常、0.8% 错认为错口类别,障碍物和裂缝两者的错误识别率接近,均为 0.7%,仅有 0.5% 错认为残墙坝根。识别分类能力中残墙坝根和裂缝其次,但障碍物和正常两种类别的准确率相对较低,只有 85.5% 和 83.9%,距离平均水平差距较大。总的来说,本研究的模型对大多数缺陷类型的预测都具有很高的可靠度。

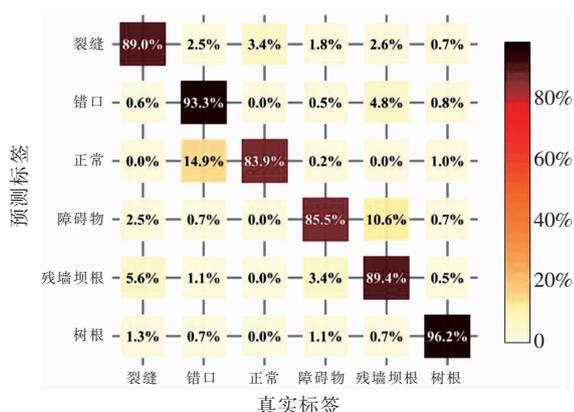


图 6 排水管道缺陷识别精度矩阵

Fig. 6 Classification accuracy matrix of pipe defects

图 7 为随机测试的样本图像,模型的预测标签和真实标签分别在图像的上方和下方显示(12 次测试中能正确分类 11 次,预测错误的图片已用红色方

框和红色字体突出显示)。可以看出,CNN 模型在区分正常和错口两种类别方面的表现相对较差。原因在于,在特定的拍摄条件下,上述两类具有比较相似的特征。此外,图像质量(如:光照、角度、分辨率等)也会影响模型的识别能力,图像因成像不佳无法提取有效、突出的特征。



图 7 CNN 模型分类性能的示例图像

Fig. 7 Sample images of CNN model classification performance

此外,基于已构建的 CNN 分类模型,建立了用于识别和定位多缺陷状态共存的目标检测器,测试结果如图 8 所示,识别的缺陷位置由图中黄色方框突出显示,上面的文字说明了预测的缺陷类别,括号内的数值代表相应的预测置信度。可以看出,即使在多缺陷共存的复杂条件下,构建的目标检测模型也可以在管道图片中同时检测、识别和定位多种缺陷,模型检测的平均准确率达到 75%。



图 8 排水管道缺陷的多分类结果

Fig. 8 Multiple classification results of sewer defects

#### 4 结论

提出了一种基于卷积神经网络的排水管道自动

缺陷检测和识别模型,用于分类六种不同类型的管道缺陷。结果表明,在不需要相关专业知识和技能的前提下,CNN模型能够做到准确识别,平均分类准确率达到90%。其中树根和错口的预测准确率较高,其次是残墙坝根和裂缝,障碍物和正常类别的分类正确率较低。训练图像是在不同情况下从多个来源获得的,由此说明CNN模型具有良好的泛化能力。此外,构建了用于识别多缺陷共存条件的目标检测器,测试结果表明,该检测器具有良好的目标检测效果,平均准确率达到75%。CNN模型可为排水管道缺陷检测和分类提供高效、快捷的支持工具,可在合适场景下协助或替代人工检测工作,提高排水管道检测的质量和效率。

未来CNN模型可在以下方面进一步改进完善:

①样本图像的来源可以更为广泛,通过扩大训练数据集的规模,提高分类和检测的准确率;②进一步优化CNN模型的网络结构和参数。

#### 参考文献:

- [1] 户莹. 基于深度学习的地下排水管道缺陷智能检测技术研究[D]. 西安:西安理工大学,2019.  
HU Ying. Research on Intelligent Detection Technology of Underground Drainage Pipeline Defects Based on Deep Learning [D]. Xi'an: Xi'an University of Technology, 2019 (in Chinese).
- [2] 安关峰. 《城镇排水管道检测与评估技术规程》CJJ 181—2012 实施指南[M]. 北京:中国建筑工业出版社,2013.  
AN Guanfeng. Technical Specification for Inspection and Evaluation of Urban Sewer (CJJ 181 - 2012) Implementation Guide [M]. Beijing: China Architecture & Building Press, 2013 (in Chinese).
- [3] HAWARI A, ALAMIN M, ALKADOUR F, *et al.* Automated defect detection tool for closed circuit television (CCTV) inspected sewer pipelines [J]. *Automation in Construction*, 2018, 89: 99 - 109.
- [4] XIE Q, LI D, XU J, *et al.* Automatic detection and classification of sewer defects via hierarchical deep learning [J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(4): 1836 - 1847.
- [5] GU J, WANG Z, KUEN J, *et al.* Recent advances in convolutional neural networks [J]. *Pattern Recognition*, 2018, 77: 354 - 377.
- [6] GOODFELLOW I, BENGIO Y, COURVILLE A. *Deep Learning* [M]. Cambridge: MIT Press, 2016.
- [7] SENTHILPRABHA R, VIDHYAPRIYA R, RAVITHARAJALAKSHMI N. Performance analysis for a touch dynamic authentication system with reduced feature set using neural networks [J]. *IETE Journal of Research*, 2016, 62(2): 198 - 204.
- [8] 周吉. 非约束环境下人脸识别系统的研究与实现[D]. 北京:中国科学院大学,2013.  
ZHOU Ji. Research and Implementation of Face Recognition System in Unconstrained Environments [D]. Beijing: University of Chinese Academy of Sciences, 2013 (in Chinese).
- [9] 林明波. 福州市某片区污水管道健康状况检测与分析[J]. *中国给水排水*, 2014, 30(9): 96 - 98.  
LIN Mingbo. Health inspection and analysis of sewer system in an area of Fuzhou City [J]. *China Water & Wastewater*, 2014, 30(9): 96 - 98 (in Chinese).
- [10] 齐利华, 祖士卿, 马骥. 珠海市某区域污水管网 CCTV 检测结果与建议[J]. *中国给水排水*, 2017, 33(22): 135 - 138.  
QI Lihua, ZU Shiqing, MA Ji. CCTV inspection and thinking of a regional sewage networks in Zhuhai [J]. *China Water & Wastewater*, 2017, 33(22): 135 - 138 (in Chinese).

作者简介:周倩倩(1984 - ),女,浙江乐清人,博士,副教授,研究方向为市政排水。

E-mail: qiaz@foxmail.com

收稿日期:2020 - 10 - 15

修回日期:2021 - 02 - 03

(编辑:刘贵春)