

DOI:10.19853/j.zgjsps.1000-4602.2023.17.008

基于时频卷积神经网络的供水管道漏损检测

赵林硕¹, 叶郭煊^{1,2}, 申永刚^{1,2}, 叶子豪¹, 周永潮^{1,2}

(1. 浙江大学 建筑工程学院, 浙江 杭州 310058; 2. 浙江大学 长三角智慧绿洲创新中心, 浙江 嘉兴 314100)

摘要: 针对供水管道漏损现场检测误判、耗时、低效等问题,基于地面振动信号和时频卷积神经网络设计了漏损信号自动识别模型。将采集的地面振动信号进行连续小波变换,得到了包含漏损特征的时频图像,将其输入到卷积神经网络,并对网络超参数进行优化,最终得到了漏损识别模型。结果表明,最终模型在测试集的平均准确率为97.3%,针对检漏人员难以区分的漏损点与漏损点附近的可疑信号平均识别率分别为91.0%和92.3%,具备良好的诊断漏损能力。相比支持向量机、决策树等方法,所提出的方法具有更高的准确率。

关键词: 供水管道; 漏损检测; 时频分析; 卷积神经网络

中图分类号: TU991 **文献标识码:** A **文章编号:** 1000-4602(2023)17-0053-06

Leakage Detection of Water Supply Pipeline Based on Time-Frequency Convolutional Neural Network

ZHAO Lin-shuo¹, YE Guo-xuan^{1,2}, SHEN Yong-gang^{1,2}, YE Zi-hao¹,
ZHOU Yong-chao^{1,2}

(1. College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China; 2. Innovation Center of Yangtze River Delta, Zhejiang University, Jiaxing 314100, China)

Abstract: This paper designed an automatic identification model of leakage signal based on ground vibration signal and time-frequency convolutional neural network to solve the problems of misjudgment, time consuming and low efficiency of water supply pipeline leakage detection. The time-frequency image containing leakage characteristics was obtained by continuous wavelet transform of the collected ground vibration signals, and was input into the convolutional neural network to optimize the network hyperparameters, and the leakage identification model was eventually obtained. The average accuracy of the final model in the test set was 97.3%, and the average recognition rates of the leak point difficult to distinguish by detectors and the suspicious signal near the leak point were 91.0% and 92.3%, respectively, indicating that the model had a good ability of leak diagnosis. Compared with support vector machine, decision tree and other methods, the proposed method had higher accuracy.

Key words: water supply pipeline; leakage detection; time-frequency analysis; convolutional neural network

基金项目: 国家自然科学基金资助项目(51878597); 国家重点研发计划项目(2022YFF06069003-03)

通信作者: 申永刚 E-mail: sygdesign@zju.edu.cn

管道漏损一直是我国供水行业面临的巨大挑战,会造成水资源浪费、交通隐患、微生物污染等次生灾害,及时发现并修复漏损意义重大。目前,听音检漏法依然是各国水务公司最常用的方法,该方法的漏损点定位效果取决于专业人员的经验,受主观人为判断影响较大,且需要耗费大量时间^[1]。一直以来,各国学者基于听音检漏法的基本原理,优化或延伸出了很多方法和技术。Hunaidi等人^[2]研究了管道泄漏信号的声学特性,可帮助专业人员选择合适的仪器与参数。针对塑料管道传播过程中漏损信号衰减较快问题,Gao等人^[3]提出了塑料管道漏损相关分析模型。Yan等人^[4]采用阵列式振动传感器收集地面漏损信号,研究了不同传感器阵列和不同土壤类型下泄漏信号衰减强度和泄漏源位置的变化规律,认为地面振动信号在漏损定位方面具有优势。

上述研究虽然对漏损检测的可操作性和定位精度有所改善,但检测效率不高。基于数据驱动的方法可实现自动化漏损检测,该方法不必对管网、土壤建立模型,只需对大量数据进行信号处理和统计分析。国内外学者采用支持向量机、K-近邻等机器学习方法识别漏损^[5],并取得了良好效果,但机器学习依赖人为输入漏损特征。基于图像识别的卷积神经网络(CNN)分析方法与听音检漏技术的融合,对于提升检测效率具有理论和实际应用意义。卷积神经网络具备自动提取特征的能力,大大提升了图片识别的准确率,卷积神经网络在混凝土裂缝识别、排水管道缺陷识别等方面具有明显优势^[6]。

漏损的听音信号都是一维信号,反映的是声波时域信息,直接用于卷积神经网络的训练和识别效果并不优秀。Kang等人^[7]研究了基于一维信号进行卷积计算和支持向量机分类的漏损分析算法,由于信号的相关系数较低,造成了较大的定位误差。鉴于很多信息隐藏在频域之中,因此,从频域角度拓展漏损信号的识别值得尝试。从时域和频域两个维度处理信号的方法既可以保留信号的时间连续性,又可以得到完整的频域信息,漏损特征被充分提取^[8]。笔者基于连续小波变换对漏损信号进行了时频分析,得到了包含信号时域信息和频域信息的时频图像,利用卷积神经网络对包含漏损特征的图像进行训练,从而得到了具备自动化诊断供水管道漏损的识别模型。

1 管道漏损的时频卷积神经网络

1.1 基于连续小波变换的时频分析

连续小波变换是一种具有广泛适用性的时频分析方法,其波形振荡是一个振幅从零开始逐渐增大,然后再逐渐减小到零的过程。不同于正弦波在傅里叶变换家族关系中的应用,小波是一种平均值为零的有效时间有限的波形,它们趋向于不规则和非对称,并且持续时间短。连续小波变换可以依靠小波函数的移位和缩放,将信号的局部特征进行放大,可以用不同的分辨率分析不同频率的信号,在分析高频段信号时,其可以提供高时域分辨率和相应较低频域分辨率。在分析低频段信号时,采用高频域分辨率和低时域分辨率^[9]。连续小波变换的计算见式(1)。

$$\text{CWT}_x(\tau, s) = \Psi_x(\tau, s) = \frac{1}{\sqrt{|s|}} [x(t) \cdot \Psi\left(\frac{t - \tau}{s}\right)] dt \quad (1)$$

式中: τ 为平移因子; s 为尺度因子; $x(t)$ 为信号时间序列; Ψ 为小波基函数,本研究采用了常用的Morlet小波,见式(2)。

$$\Psi(t) = \frac{1}{\sqrt{\pi f_b}} e^{\frac{-t^2}{f_b}} e^{2\pi i f_c t} \quad (2)$$

式中: f_b 为信号频率带宽; f_c 为中心频率; i 为虚数,即 $i^2=-1$ 。

1.2 基于时频分析的卷积神经网络

漏损信号经过时频分析之后得到时频图,将时频图作为卷积神经网络的训练对象。卷积神经网络是一种依靠卷积提取特征并且具有监督学习的神经网络,网络主要由卷积层、激活层、池化层、全连接层、分类层组成。卷积神经网络最核心的部分是卷积层,卷积层利用卷积核进行卷积运算进而提取特征,其主要参数为卷积核的大小、数量、步进和填充。卷积神经网络的性能很大程度上取决于卷积核的使用,卷积核的大小和数量的配置直接影响特征提取的效率,其大小通常为奇数;步进表示卷积核每次移动的距离;填充可以用来调节输出尺寸。卷积运算具体见式(3)^[6]。

$$y_i^{l+1}(m) = W_i^l \times x^l(m) + b_i^l \quad (3)$$

式中: W_i^l 为第 l 层第 i 个卷积核的权重; b_i^l 为偏重; $x^l(m)$ 为第 l 层第 m 个通道处的输入; $y_i^{l+1}(m)$ 为第 l 层第 m 个通道处的输出,同时也是第

$l+1$ 层第 m 个通道处的输入。

对于输入为 $W_m \times H_m \times C_m$ 的数据 (W_m, H_m, C_m 分别为输入图像的宽度、高度、通道数),经过卷积运算后,可输出结果 $W_0 \times H_0 \times C_0$,见式(4)~(6)^[10]。

$$W_0 = \frac{W_m - q + 2p}{s} + 1 \tag{4}$$

$$H_0 = \frac{H_m - f + 2p}{s} + 1 \tag{5}$$

$$C_0 = n \tag{6}$$

式中: n 为卷积核的数量; q, f 分别为卷积核的宽度和高度; s 为步进; p 为填充大小。

2 实例分析

2.1 构建数据集

通过电子检漏仪在设置了多种工况的试验场地[见图 1(a)]及多个实际漏损现场[见图 1(b)]采集了大量漏损信号。将漏损点及漏损点 1 m 范围内(符合开挖的最小尺寸)的数据作为漏损信号,定义为“漏损”;将距离漏损点 1 m 之外的可疑信号,定义为“漏损附近”;同时采集了管道正常状态(不发生漏损)的信号,定义为“正常”;在管道检测时,往往会遇到噪声的干扰,因此本研究采集了脚步声、汽车行驶声等十几种噪声作为干扰信号,定义为“干扰”;对采集信号进行预处理,将采集的数据通过低通滤波器将频率限制在 0~2 000 Hz,并将数据切割成以 1 s 为单位的文件并归类。



图1 数据采集场地
Fig.1 Data acquisition site

随机抽取 4 个类别的预处理信号进行时域分析,为了便于分析,对信号的幅值进行归一化处理,得到的归一化幅值为无量纲数,如图 2 所示。

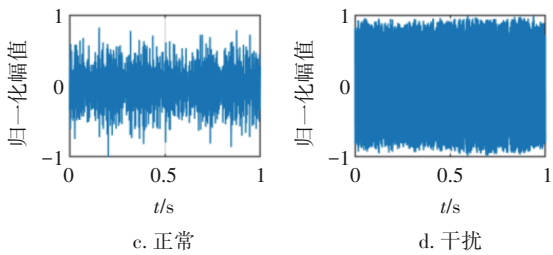
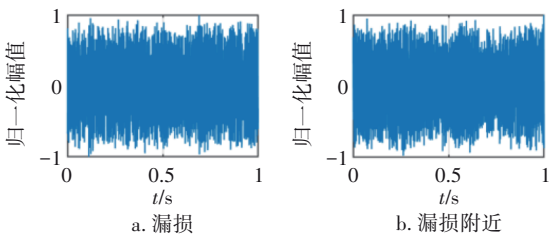


图2 时域分析结果

Fig.2 Results of time domain analysis

继续对信号进行连续小波变换,得到时频图像,如图 3 所示。试验数据经过时频处理后,漏损信号与漏损附近信号难以区分,两者的主频带都在 1 000~2 000 Hz 之间,干扰信号所在的频带也会对漏损信号的判别产生影响,正常信号在各频带的能量较低,无明显特征。

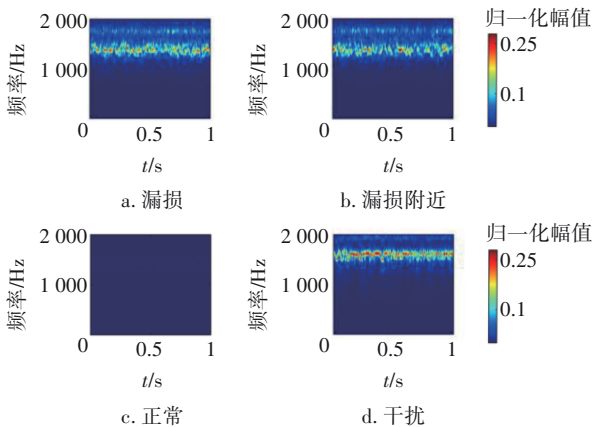


图3 时频分析结果

Fig.3 Results of time-frequency analysis

针对不同类型的数据量不均衡问题,对时频图像进行随机平移、加噪声等处理,使每个时频图像构建增强数据库^[11],通过随机采样算法挑选增强数据与原有数据合并构成数据集,其中原始图像 5 280 张,增强图像 2 720 张,共计 8 000 张,数据集划分结果见表 1,单位为图片张数。

表1 数据集划分结果

Tab.1 Results of specific division of dataset 张

识别类型	训练集	验证集	测试集
漏损信号	1 600	200	200
漏损附近信号	1 600	200	200
正常信号	1 600	200	200
干扰信号	1 600	200	200

2.2 构建卷积神经网络

针对漏损数据,经过反复试验和调整,构建了

一套深度合理、分类结果优良的卷积神经网络模型,其由 6 个卷积层(Conv)、5 个激活层(ReLu)、5 个池化层(Pool)、3 个全连接层(FC)、1 个 Softmax 回归层组成。网络结构具体参数见图 4。激活层选择性将提取特征保留并映射出来,提升模型的非线性能力,本研究采用 ReLu 函数;通过设置池化层,减少了模型参数,缩短了训练时间,同时能防止过拟合,本研究采用最大池化法;设置全连接层可以将分布式特征表示映射到样本标记空间,减少了特征位置对全局的影响;最后设置 Softmax 回归层,该层将分类得分转换为概率,即将输出值映射成为(0,1)的值,将概率最大的结果作为分类结果,实现分类。

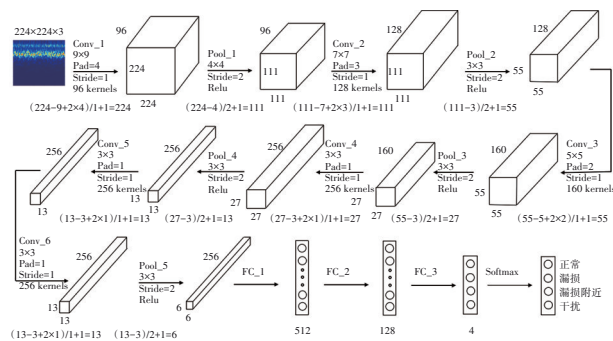


图 4 时频卷积神经网络漏损识别模型

Fig.4 Leakage identification model of time-frequency convolutional neural network

2.3 时频卷积神经网络参数优化

参数设置见表 2。

表 2 参数设计

Tab.2 Network hyperparameter design

参数编号	Learning Rate	Mini-batchsize	模型编号	Learning Rate	Mini-batchsize
1	0.001	8	13	0.001	40
2	0.000 1	8	14	0.000 1	40
3	0.000 01	8	15	0.000 01	40
4	0.001	16	16	0.001	48
5	0.000 1	16	17	0.000 1	48
6	0.000 01	16	18	0.000 01	48
7	0.001	24	19	0.001	56
8	0.000 1	24	20	0.000 1	56
9	0.000 01	24	21	0.000 01	56
10	0.001	32	22	0.001	64
11	0.000 1	32	23	0.000 1	64
12	0.000 01	32	24	0.000 01	64

网络的超参数主要有学习率(Learning Rate)、最小批量尺寸(Mini-batchsize),为了研究超参数对网络准确率的影响^[8],设置了 3 种学习率和 8 种最

小批量尺寸的组合,基于 2.2 节中的模型(见图 4)进行试验,每个模型分别进行了 10 次随机训练,最后将 10 次训练结果的平均值作为该模型的准确率。

网络超参数试验结果如图 5 所示。当学习率为 0.001 时,能取得较好的训练效果,随着学习率继续减小,模型识别准确率变差。最小批量尺寸的变化对模型的影响相对较小,但是更大的最小批量尺寸能让模型收敛更快,缩短训练时间,其中最小批量尺寸为 64 的模型比其他模型准确率下降趋势明显,这可能是因为受限于硬件,无法对梯度进行充分求导。最终采用第 16 组参数作为最终超参数。

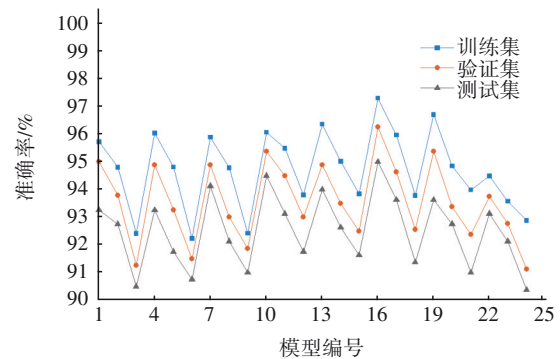
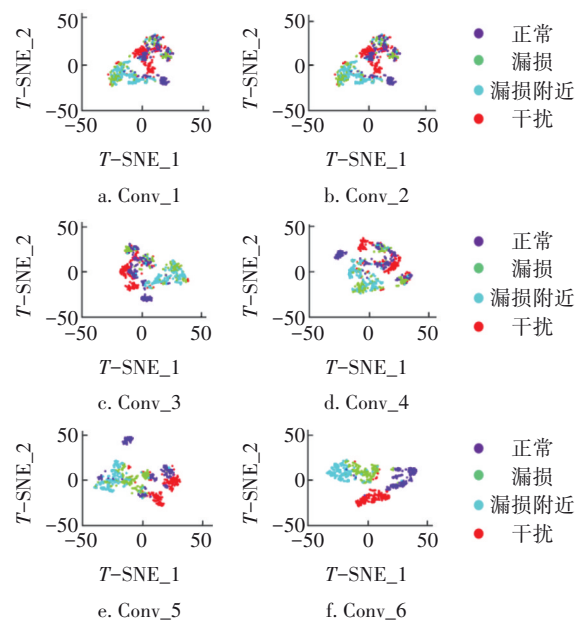


图 5 网络超参数试验结果

Fig.5 Experimental results of network hyperparameter

3 结果分析

利用 T 分布随机近邻嵌入 T -SNE 算法激活了一些网络层^[12],可以直观显示卷积神经网络识别漏损特征的性能发展过程。基于 T -SNE 的特征可视化结果如图 6 所示。



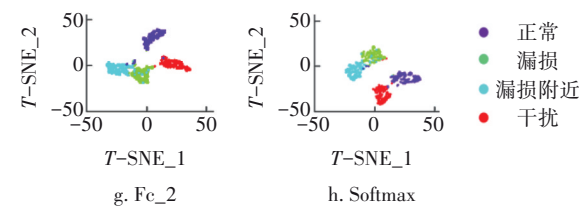


图6 基于 T-SNE 的特征可视化结果

Fig.6 Feature visualization results based on T-SNE

网络前部的层更倾向于学习边缘、颜色等低级特征,不同类别数据的特征相互交错,不具备较高的区分性,聚类效果不明显。网络较深的层具备学习高层次特征的能力,不同类别数据的特征得到了明显区分,特别是 Softmax 层特征界限清晰,说明数据得到了有效分类。

图 7 展示了 16 号模型在测试集单项类别的识别结果,可见对于干扰和正常信号具有较高的准确率,分别为 97.6%、99.0%。漏损和漏损附近的准确率相对较低,分别为 91.0%、92.3%,这是由于一些漏损信号与漏损附近信号采集位置相对较近,漏损特征较为相似,相互识别的事件较多,造成误报概率升高。

真实标签	预测标签			
	漏损	漏损附近	正常	干扰
	91.0%	9.0%	0.0%	0.0%
	7.7%	92.3%	0.0%	0.0%
正常	0.0%	1.0%	99.0%	0.0%
	1.0%	0.5%	1.0%	97.6%

图7 平均准确率混淆矩阵

Fig.7 Average accuracy confusion matrix

为了验证本方法的优势,采用特征提取与机器学习结合的方法,将信号的标准差(X_{std})、信号均方根(X_{rms})、短时过零率(X_{zer})^[1]、经验模态分解 $[x(t)]$ 的前3个模态分量均方根^[8]、梅尔倒谱系数 $[C(u)]$ ^[13]作为特征值,特征计算方法见式(7)~(11)。并利用支持向量机、决策树、贝叶斯分类、K最邻近分类算法进行训练。

$$X_{std} = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}}$$

(7)

$$X_{rms} = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}}$$

(8)

$$X_{zer} = \frac{1}{2} \sum_{i=1}^N |\text{sgn}[x(i)] - \text{sgn}[x(i-1)]|$$

$$\text{sgn}[x] = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases}$$

(9)

$$x(t) = \sum_{i=1}^N \text{imf}_i(t) + r(t)$$

(10)

式中:imf_i(t)为经验模态分量;r(t)为余项。

$$C(u) = \sum_{m=0}^{N-1} s(m) \cos\left[\frac{\pi u(m-0.5)}{M}\right]$$

(11)

式中:u为谱线编号;M为滤波器个数;m为滤波器编号;s(m)为子带能量。

不同模型在测试集的平均准确率见表3。可知,相比其他机器学习方法,时频卷积神经网络具有最高的准确率。其他的方法也存在漏损与漏损附近数据误判率较高的情况,时频卷积神经网络具有最低的误报率。

表3 不同模型在测试集的平均准确率

Tab.3 Average accuracy of different models in test

项目	set				%
	正常信号准确率	漏损信号准确率	漏损附近信号准确率	干扰信号准确率	
本项目	97.6	91.0	92.3	99.0	97.3
支持向量机	94.5	85.5	86.5	89.0	89.0
决策树	92.0	79.0	88.5	93.0	88.5
K-最近邻	94.0	87.5	90.5	80.5	86.0
贝叶斯	82.0	54.5	72.5	85.0	74.0

4 结论

提出了一种基于连续小波变换的时频卷积神经网络供水管道漏损检测模型,该模型可提高检测效率、减少人员误判,为现场漏损检测提供了新的思路。基于本模型的超参数试验结果表明,最佳超参数组合模型的测试平均准确率可以达到97.3%。利用 T-SNE 算法对模型的性能进行分析和验证,结果表明经过充分训练的网络具备较强的特征提取能力。漏损信号与漏损附近的可疑信号具有一定的相似特征,一般较难识别,采用本方法识别漏损信号的准确率可以达到91.0%,比支持向量机、决策树等机器学习模型具有更优秀的识别性能。

参考文献:

- [1] 杨宝明. 基于漏损声波信号分析的供水管道漏点定位试验研究[D]. 哈尔滨:哈尔滨工业大学,2019.
- YANG Baoming. Experimental Study on Locating Leakage Point of Water Supply Pipeline Based on Acoustic Signal Analysis of Leakage [D]. Harbin: Harbin Institute of Technology, 2019(in Chinese).
- [2] HUNAIDI O, CHU W T. Acoustical characteristics of leak signals in plastic water distribution pipes [J]. Applied Acoustics, 1999, 58(3): 235-254.
- [3] GAO Y, BRENNAN M J, JOSEPH P F, *et al.* A model of the correlation function of leak noise in buried plastic pipes [J]. Journal of Sound and Vibration, 2004, 277 (1/2): 133-148.
- [4] YAN S, YUAN H Y, GAO Y, *et al.* Experimental investigation on detection and location of leakage in buried water-filled pipelines under different types of sensor arrays and soils [C]//AIIPCC2019. Proceedings of the International Conference on Artificial Intelligence, Information Processing and Cloud Computing. New York: Association for Computing Machinery, 2019: 1-8.
- [5] KAI C T, CHIN C S, ZHONG X H. Review of current technologies and proposed intelligent methodologies for water distributed network leakage detection [J]. IEEE Access, 2018, 6: 78846-78867.
- [6] SHUKLA H, PIRATLA K. Leakage detection in water pipelines using supervised classification of acceleration signals [J]. Automation in Construction, 2020, 117: 103256.
- [7] KANG J, PARK Y J, LEE J, *et al.* Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems [J]. IEEE Transactions on Industrial Electronics, 2018, 65 (5): 4279-4289.
- [8] GUO G C, YU X P, LIU S M, *et al.* Leakage detection in water distribution systems based on time-frequency convolutional neural network [J]. Journal of Water Resources Planning and Management, 2020, 147 (2): 04020101.
- [9] CHRISTODOULOU S E, KOURTI E, AGATHOKLEOUS A. Waterloss detection in water distribution networks using wavelet change-point detection [J]. Water Resources Management, 2017, 31 (3): 979-994.
- [10] KHARE S K, BAJAJ V. Time-frequency representation and convolutional neural network-based emotion recognition [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(7): 2901-2909.
- [11] 周倩倩, 司徒祖祥, 腾帅, 等. 基于卷积神经网络的排水管道缺陷智能检测与分类 [J]. 中国给水排水, 2021, 37(21): 114-118.
- ZHOU Qianqian, SITU Zuxiang, TENG Shuai, *et al.* Intelligent detection and classification of drainage pipe defects based on convolutional neural networks [J]. China Water & Wastewater, 2021, 37(21): 114-118 (in Chinese).
- [12] XU Y, LI Z X, WANG S Q, *et al.* A hybrid deep-learning model for fault diagnosis of rolling bearings [J]. Measurement, 2021, 169: 108502.
- [13] CHUANG W Y, TSAI Y L, WANG L H. Leak detection in water distribution pipes based on CNN with mel frequency cepstral coefficients [C]//ICIAI2019. Proceedings of the 2019 3rd International Conference on Innovation in Artificial Intelligence. New York: Association for Computing Machinery, 2019: 83-86.

作者简介: 赵林硕(1997-), 男, 河北邢台人, 硕士研究生, 主要研究方向为市政管网漏损控制。

E-mail: zhaolinsuo@zju.edu.cn

收稿日期: 2022-05-06

修回日期: 2022-06-16

(编辑: 任莹莹)