

DOI:10.19853/j.zgjsps.1000-4602.2024.23.003

基于CNN和MFCC的供水管网漏损声信号识别方法

陈炯禧¹, 王琦^{1,2}, 詹凡¹, 陈彦冰¹, 黄颀¹, 张宏洋³,
王志红¹, 陈贡发^{1,2}, 赵志伟^{1,2}, 辛萍⁴

(1. 广东工业大学 土木与交通工程学院, 广东 广州 510006; 2. 广东工业大学 海洋工程
安全与可持续发展创新交叉研究院, 广东 广州 510006; 3. 河北工程大学 水利水电
学院, 河北 邯郸 056038; 4. 深圳拓安信物联股份有限公司, 广东 深圳 518052)

摘要: 针对供水管网漏损识别效率低和对人工经验依赖性强等问题,基于卷积神经网络(CNN)和梅尔频率倒谱系数(MFCC)提出了一种供水管网漏损声信号识别方法。对噪声记录仪和水音传感器采集的漏损声信号提取MFCC及其一、二阶差分作为漏损声信号特征,得到了包含漏损特征的特征图像,将其输入到CNN模型,通过超参数优化后最终得到了漏损识别模型。结果表明,使用MFCC与MFCC的一阶差分特征参数组合作为输入特征训练模型时的识别效果最好,其测试集准确率达到95.26%,F1分数达到89.22%,具备优良的漏损识别能力。

关键词: 供水管网; 漏损识别; 声学信号; 卷积神经网络; 梅尔频率倒谱系数

中图分类号: TU991 **文献标识码:** A **文章编号:** 1000-4602(2024)23-0013-07

A Method for Identifying Leakage Acoustic Signals in Water Supply Network Based on CNN with MFCC

CHEN Jiong-xi¹, WANG Qi^{1,2}, ZHAN Fan¹, CHEN Yan-bing¹, HUANG Xin¹,
ZHANG Hong-yang³, WANG Zhi-hong¹, CHEN Gong-fa^{1,2}, ZHAO Zhi-wei^{1,2},
XIN Ping⁴

(1. School of Civil and Transportation Engineering, Guangdong University of Technology,
Guangzhou 510006, China; 2. Cross Disciplinary Research Institute of Marine Engineering Safety
and Sustainable Development Innovation, Guangdong University of Technology, Guangzhou
510006, China; 3. School of Water Conservancy and Hydroelectric Power, Hebei University of
Engineering, Handan 056038, China; 4. Shenzhen ANSO IOT Co. Ltd., Shenzhen 518052,
China)

Abstract: Aiming at the problems of low efficiency and strong dependence on artificial experience in leakage identification of water supply network, a leakage acoustic signal identification method of water supply network was proposed based on convolutional neural network (CNN) and Mel frequency cepstral coefficient (MFCC). MFCC and its first- and second-order differences were extracted from the leakage sound signals collected by noise recorders and water sound sensors as leakage sound signal features. Feature images containing leakage features were obtained and input into a CNN model. After

基金项目: 广州市重点研发计划农业和社会发展科技专题项目(2023B03J1333)

通信作者: 王琦 E-mail: q.wang@gdut.edu.cn

hyperparameter optimization, the leakage identification model was finally obtained. The results showed that using the combination of MFCC and its first-order differential feature parameters as input features to train the model yielded the best identification performance, with a test set accuracy of 95.26% and an *F1* score of 89.22%, demonstrating excellent leakage identification ability.

Key words: water supply network; leakage identification; acoustic signal; convolutional neural network; MFCC

供水管网是城市基础设施中至关重要的一部分,其运行状态直接关系到城市居民的生活质量和经济发展,其中供水管网漏损一直是城市供水管理中的重要问题。管网漏损不仅会导致水资源浪费,增加供水成本,还会造成环境污染和社会资源浪费^[1]。管道漏损造成的水损失约占不同国家供水总量的20%~30%^[2]。随着城镇化进程的不断推进,供水管网建设取得了显著成效,公共供水覆盖率也得到了显著提高,但是在许多城市和县城,供水管网漏损率仍然居高不下。为此,在2022年2月相关部门发布了《关于加强公共供水管网漏损控制的通知》,该通知明确提出,到2025年全国城市公共供水管网漏损率力争控制在9%以内。

为了能够保障供水管道长期稳定运行,对供水管道进行在线实时监测,探测出供水管道是否存在漏损显得十分必要。然而供水管道具有隐蔽性,很难察觉其工作状态。考虑经济性和可靠性,如何有效地进行管道监测及预警一直是工程界的关注点之一。目前针对供水管网领域的探漏技术主要有听音杆检测法、噪声记录仪检测法、相关仪检测法、探地雷达检测法、红外成像法等^[3]。但这些方法都有一定的缺陷^[4-5],比如听音杆法十分依靠人工经验,GPR探地雷达法设备价格昂贵并且易受电磁干扰,红外成像法使用性能取决于环境温度等。现在许多城市仍依靠人工听漏进行漏损识别定位,这种方法对检漏工人的经验有着很强的依赖性,管道漏损声信号识别智能化是解决当前困境的趋势。

随着技术的快速发展,已逐渐开始结合人工智能(AI)算法进行漏损检测研究。其中深度学习技术在智能诊断和行为预测方面具有广阔的应用前景,在供水管网漏损检测领域已经取得了一些不错的发展。王珞桦等^[6]通过深度学习神经网络算法,基于管网在线压力监测数据结合供水管网水力模型,可以预测爆管位置,但这种非声学技术对实际

情况中的小漏损并不敏感。另外,也可以通过管道信号特征来识别是否有漏损,Tijani等^[7]记录真实供水管网发出的声学信号并进行去噪,提取其声学特征并基于决策树(DT)、支持向量机(SVM)和人工神经网络(ANN)算法开发了供水管网漏损识别模型,并且发现ANN的表现优于SVM和DT。Kang^[8]将收集的管道振动时域信号作为原始数据,创新地提出了一种将卷积神经网络(CNN)与支持向量机相结合的漏损识别方法。可以看出,通过提取出能够反映供水管网漏损声信号的特征,可以通过深度学习的方法对供水管网进行漏损识别。

声信号识别中常用的声信号特征参数有谱质心、能量、频谱平坦度、时频谱、平均幅度、频率质心、峰值频率、梅尔频率倒谱系数(MFCC)等^[9],其中MFCC提取的特征更接近人类听觉系统的响应^[10]。事实上,人类听觉系统可以很容易地区分各种听觉特征,因此可以提取梅尔频率倒谱系数模拟人类听觉系统对漏损信号进行识别。

为此,使用卷积神经网络作为分类器,提取真实供水管道声信号的梅尔频率倒谱系数作为听觉特征,提取MFCC及其一阶差分与二阶差分,并比选出最优的特征参数组合,利用卷积神经网络对包含漏损特征的图像进行训练,最终得到供水管网漏损声信号识别模型。

1 研究方法

所提出的基于CNN和MFCC的供水管网漏损声信号识别方法由三部分组成,技术路线见图1。首先,选择适当的实验场地安装设备收集供水管网的声信号数据(见图2)并进行预处理,其中声信号预处理包括数据去噪、数据标记和数据增强;第二,提取合适的声信号特征,并将提取梅尔频率倒谱系数及其一阶差分与二阶差分作为声信号特征;第三,将声信号特征输入CNN进行训练,并确定CNN的最佳超参数,搭建性能最佳的漏损识别模型。




图1 技术路线

Fig.1 Technology roadmap




图2 供水管网漏损声信号收集及预处理示意

Fig.2 Water supply network leakage acoustic signal collection and preprocessing diagram

1.1 MFCC特征提取

在实际的漏损检测过程中,声学探漏设备可以接收到由环境源非漏损声信号和漏损声信号组成的声信号,仅靠人工经验并不能高效地区分漏损声信号和非漏损声信号。因此,选择合适的声信号特征是供水管网漏损识别的一项重要任务。

MFCC是声信号分析领域常用的特征参数之一,其基于人耳听觉特性提出,具备较好的抗噪能力^[11]。人耳对声音的感知并不是线性的,而是非常复杂的非线性过程。在低频段,人耳对声音的变化更为灵敏,可以区分较小的差异;而在高频段,人耳对声音的变化相对较迟钝,需要更大的差异才能感知到,梅尔频率尺度就是根据该特性提出的,更能代表人类听觉系统的反应。因此,对于声信号的处理和分析,采用基于人耳听觉特性的方法更能有效地提取有用的特征,可以利用基于梅尔频率尺度的MFCC特征模拟人耳进行漏损声信号识别。声信号的梅尔频率和实际频率的关系可以表示为:

$$F_{\text{Mel}} = 2595 \times \lg\left(1 + \frac{f}{700}\right) \quad (1)$$

式中: f 为实际频率,Hz; F_{Mel} 表示对应的梅尔频率。

根据梅尔频率和实际频率的关系,当实际频率 ≤ 1000 Hz时,实际频率和梅尔频率近似呈线性关

系;当实际频率 > 1000 Hz时,实际频率和梅尔频率近似呈对数关系。MFCC的提取流程如下:首先,将接收到的声学信号进行预加重,对音频信号进行高通滤波处理;通过增强高频部分,使信号的频谱变得平坦,保持在低频到高频的整个频带中,能用同样的信噪比求频谱。预加重后,需要将信号分成短时帧,分帧时长一般取10~30 ms。其次,对每一帧数据应用窗函数进行加窗处理,增加帧与帧之间的平滑过渡,以避免信号的不连续性。对加窗后的每一帧数据进行快速傅里叶变换得到每一帧的频域信息。然后,将得到的频域信息通过梅尔滤波器组进行滤波,对每个滤波器通道上的能量进行对数运算,得到对数能量,并将其转换为对数梅尔频谱。最后,通过离散余弦变换(DCT)将对数梅尔频谱转化为MFCC。

研究提取了MFCC及其一阶和二阶差分作为声信号的特征,MFCC反映声信号的静态特性,MFCC的一阶和二阶差分反映声信号的动态特性,能够描述漏损声信号前后两帧之间的关系。MFCC一阶差分(ΔMFCC)与二阶差分($\Delta\Delta\text{MFCC}$)的计算公式如下:

$$\Delta C(j) = C(j+1) - C(j) \quad (2)$$

$$\Delta\Delta C(j) = \Delta C(j+1) - \Delta C(j) \quad (3)$$

式中: j 为帧数; $C(j)$ 为MFCC的第 j 帧; $\Delta C(j)$ 为MFCC一阶差分特征参数 ΔMFCC 的第 j 帧; $\Delta\Delta C(j)$ 为MFCC二阶差分特征参数 $\Delta\Delta\text{MFCC}$ 的第 j 帧。

1.2 CNN

CNN是一种深度学习算法模型,已被广泛应用于图像处理和语音识别领域^[12]。它的设计灵感来源于人类视觉系统的工作原理。CNN主要由输入层、卷积层、池化层、全连接层和输出层组成。CNN的输入可以是图像、语音信号或其他形式的数据。

输入层通常是由原始数据组成的矩阵或张量,比如对于一个图像分类任务,输入数据通常是一组二维矩阵,每个矩阵表示一张图像,该参数就需要指定输入图像的大小和通道数。在卷积层中,卷积核通过一定步长滑动窗口的方式在输入数据上进行卷积运算,其中步长决定了卷积核在水平和垂直方向上每次滑动的距离。卷积层中,将局部视图与卷积核进行点乘并求和,然后再通过激活函数处理

得到输出特征图。池化操作通常是通过将特征图划分为不重叠的区域,并对每个区域进行聚合操作从而减小特征图的空间维度。在池化层中,常见的池化操作包括最大池化(Max Pooling)和平均池化(Average Pooling),它们分别选择最大值和平均值作为池化区域的输出。步长同样也适用于池化层,用于控制池化区域的移动步长,从而影响输出特征图的尺寸。在经过多个卷积层和池化层之后,最后一层通常是全连接层。全连接层将前一层的所有神经元与当前层的每个神经元相连接,将前面卷积层和池化层提取到的特征进行组合和整合,生成最终的输出结果。CNN通过卷积操作和多层堆叠的方式,能够自动学习输入数据的特征,并具备良好的特征提取能力,使其在语音情感识别、语音文字识别和声纹识别等语音识别任务中得到广泛应用。

在CNN的数据计算过程中,每一层产生的特征被称为特征图。因此,对于每一层来说,都有输入特征图和输出特征图。随着网络层次的增加,CNN逐渐增强了在特征图中提取特征的能力,最后一层的输出特征图即为整个模型的最终输出结果。

2 管网漏损声信号识别模型的建立

2.1 数据收集与预处理

供水管网漏损声信号数据采集于华南某探漏实操基地,该基地可以模拟多种工况的供水管网漏损声信号并通过现场布置的噪声记录仪和水音传感器进行声信号采集,声信号数据采集场地及设备安装如图3所示。该场地可以模拟金属管道和非金属管道在不同流量和水压等条件下发生的漏损,可以提供足够的供水管网漏损声信号数据。



a. 部分管道

b. 设备安装

图3 声信号数据采集场地及设备安装

Fig.3 Sound signal data acquisition site and equipment installation

在实验区域的供水管道上布置合适数量的噪声记录仪和水音传感器,在相对安静的时间段(每天22:00后)收集球墨铸铁管和PE管供水管道的漏

损声信号,采集声信号数据过程中在主管上使用调压阀进行调压,调压范围为0.15~0.32 MPa。每次进行小幅度调压(例如0.05 MPa),以模拟不同大小的漏损。每个声信号的持续时长为5.46 s,声信号频率为8 000 Hz,最后以波形音频文件格式(WAV)保存声信号数据,这些声信号数据将被标记为有漏损或无漏损。共采集788条声信号数据,其中612条声信号被标记为有漏损,176条声信号被标记为无漏损。

首先,对所有声信号数据进行剪裁,保留1 s,并使用小波去噪的方法进行降噪。为了进一步提升模型输入数据的质量与模型训练效果,减少理想环境与实际环境的差异,一种解决方法是将实际环境的噪声叠加到训练数据中,用含噪的数据来训练模型。因此,通过添加白噪声和实际环境噪声两种方式对原始声信号进行数据增强。通过上述预处理后,可以提高输入数据的数量和质量,最终有1 836条声信号样本标记为有漏损,528条声信号样本标记为无漏损。

2.2 声信号特征提取

根据MFCC特征提取原理,对收集到的声信号进行MFCC特征提取。MFCC输出的特征参数维度为13,包括该帧的对数能量和12个梅尔倒谱系数。提取出MFCC特征后,利用式(2)和式(3)进行一、二阶差分计算,最终得到每个声信号数据的MFCC、 Δ MFCC、 $\Delta\Delta$ MFCC三种特征,每种特征参数的维度都是13维。

图4和图5分别展示了典型有无漏损声信号的MFCC及其一阶和二阶差分的特征图,两类信号于同时段(例如夜里02:00—04:00)由同一设备采集。在图4(a~c)和图5(a~c)中,横轴上分成13个维度,纵轴表示1 s内声音信号的音频帧(Audio Frame)数(包含56个音频帧,每帧时长约为18 ms),图中较小的数值映射为蓝色,较大的数值映射为红色,中间数值则映射为介于绿色和黄色之间的颜色。这些不同类型的特征图像将单独或组合作为卷积神经网络的输入数据。两上特征图可以较为直观地判別有无漏损时MFCC特征的差异。在反映静态特性的MFCC中,第1维度的对数能量特征值在两种情况下存在明显的差异,在有漏损情况下,对数能量特征值平均为2.55;在无漏损情况下,对数能量特征值平均为-3.55。而反映动态特性的MFCC一阶

和二阶差分中,第2、3维度以及第8、9维度的特征值在两种情况下存在明显的差异,有漏损情况下,第2与第8维度的平均值大于0,第3与第9维度的平均值小于0;无漏损情况下则相反,第2与第8维度的平均值小于0,第3与第9维度的平均值大于0。特别地,图4(d)和图5(d)显示了由MFCC及其一、二阶差分组成的39维特征矩阵沿时帧的变化。与有泄漏信号相比,无泄漏信号在后26维的动态特征中,特征值随时帧的变化更不稳定,在后26维中,每维度特征值的平均方差为1.38,而有泄漏信号在后26维中每维度特征值的平均方差仅为0.42。

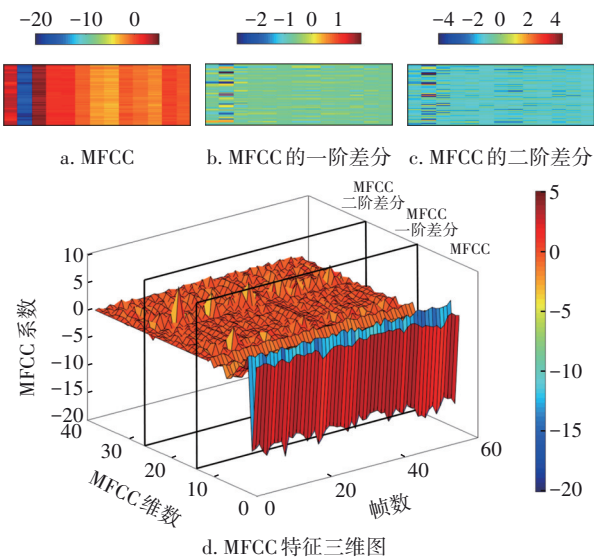


图4 有漏损声信号的MFCC特征图

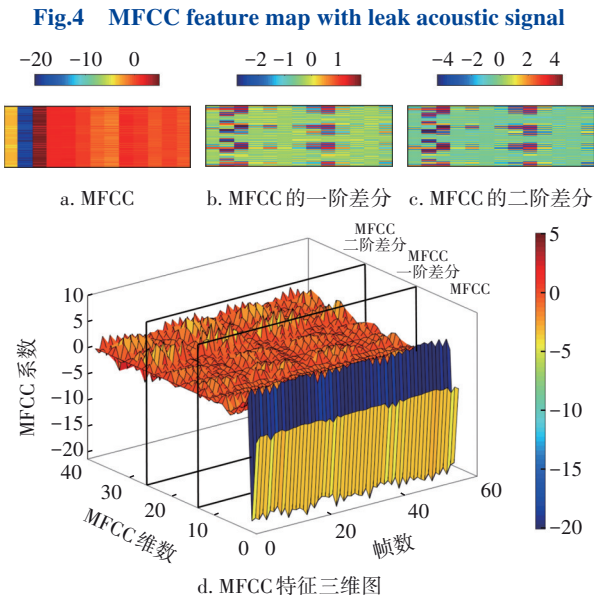


图5 无漏损声信号的MFCC特征图

Fig.5 MFCC feature map with non-leak acoustic signal

此外,虽然特征融合的方式是直接组合,但是在图像中也能反映MFCC及其一、二阶差分的信息,包括静态特性和动态特性。虽然三者有数量级的差异,但在对信息进行拆解之后发现,在一阶差分 and 二阶差分中有一定的差异,其中一阶差分的每维度特征值的平均方差为1.40,而二阶差分的每维度特征值的平均方差为0.40。这些数值差异都反映在输入的图像中,而CNN有良好的图像识别能力,可以有效识别出这种差异。

2.3 CNN模型构建与训练

针对采集到的漏损声信号数据提取其MFCC特征后,MFCC、 Δ MFCC、 $\Delta\Delta$ MFCC三种特征可以单独或组合输入到CNN模型进行训练。通过多次调整和实验,构建了一个分类结果优良的CNN模型,其由2个卷积层、2个池化层、1个全连接层、1个Softmax输出层组成。CNN模型网络结构具体参数如表1所示。

表1 CNN模型的结构参数

Tab.1 Structural parameters of CNN

层类型	设置
输入层	输入尺寸=[62,188,3],每张特征图的尺寸为62 px×188 px,颜色通道数为3
卷积层1	卷积核大小为5,填充方式(Padding)为“same”,保持输出和输入的形状相同,激活函数=ReLU
池化层1	最大池化,卷积核大小与步长为2
卷积层2	卷积核大小为5,Padding为“same”,激活函数=ReLU
池化层2	最大池化,卷积核大小与步长为2
全连接层	输出单元的个数为2,符合二分类问题
输出层	激活函数=Softmax

采用线性整流函数(ReLU)作为卷积层的激活函数,用于增加神经网络的非线性能力,增强神经网络的表达能力,并且有助于解决梯度消失问题;池化层采用最大池化法,该方法将输入特征图分割成若干个不重叠的矩形区域,并从每个区域选取最大值作为输出,具有降低特征图的空间尺寸、保留主要特征以及减少数据量等方面的优点,对卷积神经网络的性能提升起到了积极的作用;全连接层对提取到的特征进行整合和转换,以便进行最终的分

类或回归预测,设置输出个数为2,适用于二分类问题;在最后一层使用Softmax激活函数,将神经网络的输出转化为适合分类任务的概率分布,以便进行分类预测。

为进一步提高模型识别性能,需要尝试不同的超参数组合。为此,使用贝叶斯优化对CNN进行超参数寻优。首先,需要确定待优化的超参数有学习率(Learning Rate)、最小批量尺寸(Mini-batchsize)和最大训练轮数(MaxEpochs),针对每一项超参数设置可能的取值范围;其次,综合考虑后确定选取 $F1$ 值($F1$ -score)作为优化目标;在优化过程结束后,选择具有最佳性能的超参数组合作为最终的选择,然后使用这些超参数进行训练和测试。经过优化,最佳性能的超参数组合为:学习率=0.000 27,最小批量尺寸=64,最大训练轮数=8。最后,以8:2的比例将数据集划分为训练集和测试集。在训练卷积神经网络前,对图像进行归一化处理,将数据的范围调整到 $[-1, 1]$,从而保留原始数据之间的相对关系,并去掉了量纲的影响。

2.4 评价指标

供水管网漏损声信号识别问题实际上是一个二分类问题,因此根据识别模型的预测分类结果和实际分类标签得到四种分类组合结果,分别为真阳性(TP)、真阴性(TN)、假阳性(FP)和假阴性(FN)。假设有漏损为正样本,无漏损为负样本,那么TP表示模型将有漏损的样本正确地预测为有漏损,TN表示模型将无漏损的样本正确地预测为无漏损,FP表示模型将无漏损的样本错误地预测为有漏损,FN表示模型将有漏损的样本错误地预测为无漏损。

由于所使用的声信号数据的正负样本分布不平衡,模型可能更倾向于预测出现频率较高的类别,单独使用准确率(Accuracy)指标可能会失去意义,因此还选取了 $F1$ 分数来评估模型的整体分类性能。 $F1$ 分数综合考虑精确率(Precision)和召回率(Recall)两者的表现,相关计算公式见文献[13]。

3 结果与讨论

3.1 训练结果

将第2.2节提取到的特征参数进行以下组合:MFCC、 Δ MFCC、 $\Delta\Delta$ MFCC、MFCC+ Δ MFCC、MFCC+ $\Delta\Delta$ MFCC和MFCC+ Δ MFCC+ $\Delta\Delta$ MFCC,每个组合下都有1 836样本标记为有漏损,528条样本标记为无漏损。将上述特征参数组合分别作为输入特征训练构建的CNN模型,每次训练完成后记录不同输入条件下的测试集准确率与 $F1$ 分数(见表2),通过训练结果对各特征参数组合进行分析。

表2 不同输入条件下的模型性能

Tab.2 Model performance with difference inputs

输入特征	数据维度	准确率/%	$F1$ 分数/%
MFCC	13	93.33	83.97
Δ MFCC	13	89.81	74.21
$\Delta\Delta$ MFCC	13	92.64	83.64
MFCC+ Δ MFCC	26	95.26	89.22
MFCC+ $\Delta\Delta$ MFCC	26	94.38	85.89
MFCC+ Δ MFCC+ $\Delta\Delta$ MFCC	39	94.93	88.08

3.2 对比讨论

从表2可以看出,使用MFCC及其相关特征组合输入到CNN模型时,经过训练后都有着优良的漏损识别性能,每种输入组合的测试集准确率和 $F1$ 分数都较高。使用MFCC+ Δ MFCC的特征组合作为输入时,测试集准确率和 $F1$ 值都是最高的,分别达到了95.26%和89.22%。

使用MFCC的特征组合作为输入时,测试集准确率达到93.33%, $F1$ 分数达到83.97%,都比反映动态特性的 Δ MFCC或 $\Delta\Delta$ MFCC的特征组合要高。说明相比于动态特性,供水管网漏损声信号静态特性之间的差异更大,识别模型能更容易通过静态特性的差异,在供水管网声信号间做出是否漏损的区分,最终得到正确的分类结果。

使用MFCC的特征组合作为输入时,测试集准确率和 $F1$ 值都比反映静态与动态特性相结合的MFCC+ Δ MFCC或MFCC+ $\Delta\Delta$ MFCC的特征组合要低。说明漏损声信号的动态特性与静态特性相结合后,可以提高模型的分类效果。

另外,与MFCC+ $\Delta\Delta$ MFCC相比,MFCC+ Δ MFCC特征组合的准确率与 $F1$ 分数分别高出0.88%与3.33%(绝对差异)。说明在与MFCC参数进行组合时, Δ MFCC可以对漏损声信号进行更精准的分类。

使用MFCC+ Δ MFCC+ $\Delta\Delta$ MFCC的特征组合作为输入时,测试集准确率达到94.93%, $F1$ 分数达到88.08%,分别比MFCC+ Δ MFCC的特征组合低0.33%和1.14%,但比MFCC+ $\Delta\Delta$ MFCC组合分别高0.55%和2.19%。说明融合形成新的39维特征参数组合MFCC+ Δ MFCC+ $\Delta\Delta$ MFCC时, $\Delta\Delta$ MFCC可能带来了一部分无效特征,导致识别性能下降。

综合考虑准确率和 $F1$ 分数两项指标,MFCC+ Δ MFCC参数组合性能最优,更适用于供水管网漏损

识别分类,但鉴于数据样本仍有不足之处,需要在不同环境下进一步测试。

4 结论与展望

① 基于CNN和MFCC,构建了一个性能优良的供水管网漏损识别模型。在提取MFCC及其相关特征后,利用CNN对6组MFCC特征参数组合进行了性能对比,当以体现供水管网漏损声信号静态特性和动态特性的26维MFCC+ Δ MFCC特征参数组合作为输入时,训练CNN后的漏损识别效果优于其他5组,测试集准确率为95.26%, $F1$ 分数达到89.22%。

② 研究还存在诸多不足,为进一步提高供水管网漏损识别的准确性和实用性,下一步将开展如下工作:探究不同漏点形状和不同路面埋设条件对识别效果的影响规律;尝试利用生成对抗网络等解决数据样本不足或不均衡的问题;与谱质心、频谱平坦度、谱质心带宽以及谱下降率等其他声学特征进行对比或融合,优化漏损识别模型效果;与其他机器学习模型(如循环神经网络)进行漏损识别效果的对比。

参考文献:

- [1] MEKONNEN M M, HOEKSTRA A Y. Four billion people facing severe water scarcity [J]. *Science Advances*, 2016, 2(2): e1500323.
- [2] CHAN T K, 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.
- [3] HAMILTON S, CHARALAMBOUS B. *Leak Detection: Technology and Implementation* [M]. London: IWA Publishing, 2020.
- [4] ZHANG X, LIN T, JIANG F, *et al.* Application of acoustic intelligent leak detection in an urban water supply pipe network [J]. *Journal of Water Supply Research and Technology*, 2020, 69(5): 512-520.
- [5] ISMAIL M I M, DZIYAUDDIN R A, SALLEH N A A, *et al.* A review of vibration detection methods using accelerometer sensors for water pipeline leakage [J]. *IEEE Access*, 2019, 7: 51965-51981.
- [6] 王路桦,李红卫,吕谋,等.基于BP神经网络深度学习的供水管网漏损智能定位方法[J].*水电能源科学*, 2019, 37(5): 61-64.
WANG Luohua, LI Hongwei, LÜ Mou, *et al.* Intelligent locating method of water pipeline leakage based on deep learning of BP neural network [J]. *Water Resources and Power*, 2019, 37 (5): 61-64 (in Chinese).
- [7] TIJANI I A, ABDELMAGEE S, FARES A, *et al.* Improving the leak detection efficiency in water distribution networks using noise loggers[J]. *Science of the Total Environment*, 2022, 821: 153530.
- [8] KANG J. Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65: 4279-4289.
- [9] 沈永鑫.供水管道漏损声信号的统计特征分析与智能识别技术研究[D].杭州:浙江大学,2022: 31-102.
SHEN Yongxin. Research on Statistical Characteristics of Water Distribution System Leakage Signals and Intelligent Identification Technology [D]. Hangzhou: Zhejiang University, 2022: 31-102 (in Chinese).
- [10] DAVIS S, MERMELSTEIN P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences[J]. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1980, 28(4): 357-366.
- [11] SAHIDULLAH M, SAHA G. Design, analysis and experimental evaluation of block based transformation in MFCC computation for speaker recognition[J]. *Speech Communication*, 2012, 54(4): 543-565.
- [12] CHOI J, IM S. Application of CNN models to detect and classify leakages in water pipelines using magnitude spectra of vibration sound[J]. *Applied Sciences*, 2023, 13(5): 2845.
- [13] 何黎,陈磊,纪莎莎,等.基于K-shape聚类的连续液位监测数据异常检测方法[J].*中国给水排水*, 2023,39(11):56-61.
HE Li, CHEN Lei, JI Shasha, *et al.* Abnormal detection of continuous water level monitoring data based on K-shape clustering[J]. *China Water & Wastewater*, 2023, 39(11): 56-61 (in Chinese).

作者简介:陈炯禧(2000-),男,广东佛山人,硕士研究生,主要研究方向为供水管网漏损控制。

E-mail:986786810@qq.com

收稿日期:2024-03-11

修回日期:2024-07-26

(编辑:李德强)