

# 基于稀疏轻量卷积神经网络的管道泄漏检测

刘杰 朱正伟

(常州大学微电子与控制工程学院 常州 213164)

**摘要:**针对传统供水管网泄漏检测问题,本文提出了一种基于稀疏轻量卷积神经网络的管道泄漏检测算法。首先通过声音传感器采集管道泄漏的声音信号,经过立体声转换、重采样、长度对齐等预处理操作后,将其转换成梅尔频谱图。然后,构建一种稀疏轻量化的卷积神经网络模型来对梅尔频谱图进行特征抽取和泄漏检测。针对声音特征图的稀疏和时延性质,本文采用 Inception 网络结构来进行提高模型的特征抽取能力。此外,因为该模型需要被部署到边缘侧,因此设计了一种基于 SqueezeNet 的轻量化卷积神经网络模型来减少模型的参数,降低模型复杂度。实验结果表明,提出的管道泄漏检测算法在保证复杂度较低的同时具有较高的识别准确率。

**关键词:**管道泄漏检测;卷积神经网络;梅尔频谱图;稀疏特征

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.40

## Pipeline leakage detection algorithm based on sparse and lightweight convolutional neural network

Liu Jie Zhu Zhengwei

(School of Microelectronics and Control Engineering, Changzhou University, Changzhou 213164, China)

**Abstract:** In order to address the leakage detection problem of traditional water supply pipeline, in this paper, we propose a pipeline leakage detection algorithm based on the sparse and lightweight convolutional neural network technology. First, the sound signal leaked from the pipeline is collected by the sound sensors. After preprocessing operations such as stereo conversion, resampling, and length alignment, it is converted to a mel spectrogram. Then, a sparse and lightweight convolutional neural network model is proposed to perform feature extraction and leak detection on the mel spectrogram. Due to the sparse and time-delayed characteristics of sound feature images, we introduce the Inception structure to improve the feature extraction ability. In addition, to deploy the proposed model to the edge side, a lightweight convolutional neural network based on SqueezeNet is designed to reduce model parameters and thus reduce the model complexity. Massive experimental results show that the proposed pipeline leakage detection algorithm has less computation complexity and better recognition accuracy.

**Keywords:** pipeline leakage detection; convolutional neural network; mel spectrogram; sparse feature

## 0 引言

随着人类社会的迅速发展和城市化规模的不断扩大,各种地下管道网络系统日趋复杂。由于管道腐蚀、地质变化和人为破坏等各种因素,各种管道系统发生泄漏的情况无法避免,且会带来很多非常恶劣的影响<sup>[1]</sup>。例如,供水管道的泄漏会带来大量水资源的浪费,原油管道的泄漏会引发严重的环境破坏等<sup>[2]</sup>。为了保障管道系统的安全运行,在其发生泄漏时能及时将损失减小到最低,实时管道泄漏检测系统<sup>[3]</sup>具有非常重要的现实意义和应用价值<sup>[4]</sup>。

目前常见的管道泄漏检测技术主要包括以下3种方

法:1)区域装表法<sup>[5]</sup>:在某一区域的输入位置和输出位置分别按照流量表进行流量检测,通过泄漏引起的计量差来判断该区域是否发生泄漏。该种方法的主要缺点是只能判断泄漏的区域,但是无法确定泄漏的具体位置。2)红外法<sup>[6]</sup>:运用红外热成像技术检测管道区域,通过对泄漏引发的环境温度差进行监测。该种方法的缺点是无法判断泄漏和正常地下排水,同时红外辐射也有可能是其他因素发生干扰。3)声振法<sup>[7]</sup>:运用某种传声工具检测泄漏的声音,根据泄漏声音的大小和音质特点来判断泄漏的具体位置。这是目前国外应用最为普遍也非常有效地方法。

随着物联网技术和机器视觉技术的发展,声振法可以

通过部署声音传感器来采集管道泄漏的声音信号，并利用机器视觉模型来智能判断管道泄漏情况，从而可以实现对管道泄漏的实时智能监测。

将声音传感器采集到的管道泄漏声音信号转换成声音特征图像之后，可以采用卷积神经网络模型来推断该声音图像的类别，即是否发生管道泄漏<sup>[8]</sup>。常见的卷积神经网络模型主要有：1) AlexNet 网络<sup>[9]</sup>引入了 ReLU 激活函数和 Dropout 等技术，首次在图像识别竞赛中打败了特征抽取加浅层分类器的传统模式识别算法。2) VGG 网络<sup>[10]</sup>采用堆积的小卷积核，通过提高网络深度来提高图像特征抽取能力。3) ResNet 网络<sup>[11]</sup>通过残差学习来解决模型退化问题，从而可以通过大幅度增加网络深度来提高模型的性能。以上几种卷积神经网络针对一般的机器视觉问题具有较好的表现，但在管道泄漏检测问题中具有一定的局限性。因为声音信号具有时延性和稀疏性，导致对应的声音特征图像不具有位移不变性，即不同位置表示不同的听觉对象<sup>[12]</sup>。此外，为了部署在边缘侧传感器的模型能够实时地处理采集的声音信息，模型需要进行轻量化压缩，以满足监测系统的实时性要求。

针对以上这些问题，本文提出了一种基于稀疏轻量卷积神经网络的管道泄漏检测模型。首先，将采集到的管道泄漏信号进行相应的预处理操作后，将其转换成梅尔频谱图<sup>[13]</sup>。然后，设计了一种基于 Inception 模块<sup>[14]</sup>和 SqueezeNet 网络<sup>[15]</sup>的稀疏且轻量化的卷积神经网络模型。通过 Inception 模块来抽取声音频谱图中的稀疏特征，并基于 SqueezeNet 网络中的 Fire 模块来压缩模型，减小模型的时间复杂度。实验结果表明，提出的管道泄漏检测算法能够在保证复杂度较低的同时具备较高的检测准确率，从而满足现实场景下管道泄漏的实时监测需求。

## 1 管道泄漏检测模型

为了解决供水管道的泄漏检测问题，本文提出了一种稀疏且轻量化的卷积神经网络模型。首先，将采集到的声音信号经过预处理操作后，转换成相应的梅尔频谱图。然后，通过稀疏轻量卷积神经网络模型处理，得到声音信号对应的检测结果。

### 1.1 梅尔频谱图构建

通过声音传感器采集到管道声音后，首先对其进行预处理操作，以便后续生成质量较高的图像数据。音频预处理操作包括重新采样，立体声转换和长度对齐处理。

由于人类对声音频率的感知并不是线性的，对低频声音信号的感知能力远远强于高频声音信号，因此在语音分析时将语音分解为多个子带。在利用子带滤波器组实现时，将其截断频率按照主观音高梅尔尺度相等的间隔进行设置。一般性的频率变换<sup>[16]</sup>采用如下方法：

$$f_{scaled} = A \lg(f/f_{break} + 1) \quad (1)$$

式中：A 是任意标定常数，本文设置其为 2 595。 $f_{break}$  是频

率截断尺度参数，本文设置为梅尔尺度，即 700 Hz。图 1 展示了实验数据集中某一音频数据转换成梅尔频谱图的示意图。

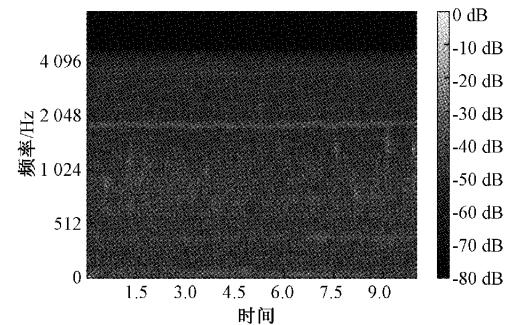


图 1 梅尔频谱图示意图

### 1.2 稀疏轻量卷积神经网络

声音信号转换成梅尔频谱图之后，设计了一种稀疏且轻量化的卷积神经网络模型来预测声音信号的类别标签，即是否发生管道泄漏。该模型的结构示意图如图 2 所示，声音信号转换成梅尔频谱图之后，经过 2 个 Inception 网络、3 个 SqueezeNet 网络的 Fire 模块和 1 个 Softmax 层，最后输出其对应的类别标签。

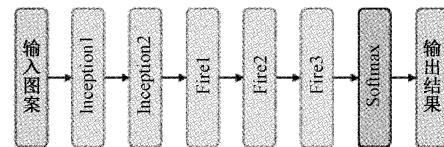


图 2 稀疏轻量化卷积神经网络结构示意图

#### 1) 稀疏模块设计

不同于一般的机器视觉图像具有一定程度的位移不变性的特征，听觉频谱图像是由频率和时延进行索引的，因此导致声音频谱图中不同位置对应于不同的听觉对象。此外，由于每个声音通常只包含相对少量的特征，所以声音特征图像一般具有稀疏性。针对声音频谱图的时延和稀疏性质，该模型首先采用 Inception 网络结构来对声音图像进行互相交叠的重复特征抽取，从而提高模型的高表达能力。

Inception 网络结构的示意图如图 3 所示，首先包含 4 个  $1 \times 1$  卷积的卷积层，该处理可以将同一位置的不同通道进行线性组合，从而可以进行跨通道数据通讯同时降低数据维度。然后，数据分别经过  $3 \times 3$  和  $5 \times 5$  卷积的卷积层，这样可以增加感受野，从而可以捕捉更大范围的特征，从而提高模型对声音特征的抽取能力。

#### 2) 轻量化模块设计

因为供水管网分布较为复杂，需要布置较多的声音传感器实时地采集分析数据，所以该模型需要被部署到各传感器等边缘侧。针对该问题，本文设计了一种基于 SqueezeNet 网络的轻量化卷积神经网络，来降低模型的计算复杂度。相较于传统的卷积神经网络，SqueezeNet 网络主要采用 Fire 模块来减少模型的参数，压缩模型。

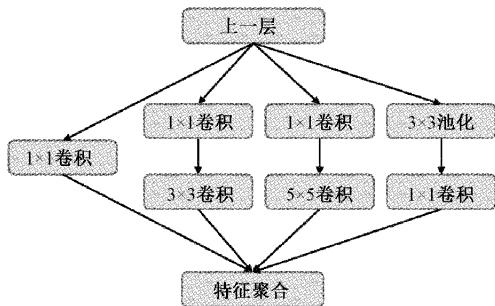


图3 Inception 网络结构示意图

Fire 模块的示意图如图 4 所示,其中包含 3 个卷积层。其中,首先经过一个  $1 \times 1$  卷积的卷积层来压缩数据的通道数,然后分别经过  $1 \times 1$  和  $3 \times 3$  卷积的卷积层来扩展通道数,最后两个不同卷积核尺寸的结果经过聚合合并输出到下一层。

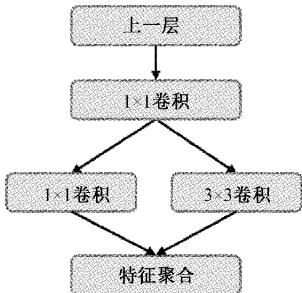


图4 Fire 网络模块示意图

### 3)模型损失函数

输入声音图像经过 2 个 Inception 网络层和 3 个 Fire 网络层之后,再经过 Softmax 层<sup>[17]</sup>来计算该声音图像属于泄漏或正常类别的后验概率。Softmax 的计算采用如下方法:

$$y_i = \frac{e^{z_i}}{\sum_k e^{z_k}} \quad (2)$$

式中:  $k$  表示类别数量,  $y_i$  表示属于第  $i$  类的后验概率,  $z_i$  表示上一层网络的输出结果。

模型训练采用的损失函数为交叉熵损失函数,其计算采用如下方法:

$$l = - \sum_i \hat{y}_i \log y_i \quad (3)$$

式中:  $y$  是由式(2)计算得到的样本数据的后验概率,  $\hat{y}$  是样本数据的真实类别标签。

## 2 实验结果与分析

### 2.1 实验数据集与实验设置

本节实验采用的实验数据来自于声音传感器采集到的真实环境下的声音数据。原始声音数据格式为 mp3 格式,按照 10 s 的时间间隔进行切割处理后,再转换成 wav 声音

格式。采集到的声音数据共有 3 136 条,其中包括漏水环境下的声音数据 2 088 条和正常不漏水环境下的声音数据 1 048 条。实验时将漏水和正常的声音数据按照 9 : 1 的比例随机划分成训练数据集和测试数据集,其中训练数据集共有 2 822 条声音数据,测试数据集共有 314 条声音数据。

实验在百度 AI Studio 平台上运行,硬件环境包括双 CPU,16 GB 内存,实验显卡为英伟达 Tesla V100 显卡,显存 16 GB;软件环境为 Python 3.7 版本,深度学习开发框架为百度 PaddlePaddle 1.8.4 版本,显卡加速框架为 cuDNN 7.6 版本。

### 2.2 对比实验结果与分析

本文提出的稀疏轻量卷积神经网络模型采用了 Inception 网络模块和 SqueezeNet 网络的 Fire 模块构成,实验时对比了其他两种传统的卷积神经网络模型,即 AlexNet 网络和 VGG 网络。

本文提出的算法模型及对比的两种卷积神经网络模型在解决管道泄漏检测问题上的准确率及参数复杂度结果如表 1 所示。其中,准确率计算的是模型在测试集上成功预测管道是否泄漏的比例,参数数量是指各个模型中神经网络的参数量级。从表 1 可以看出,本文提出的基于 Inception 模块和 SqueezeNet 网络的稀疏轻量卷积神经网络模型复杂度最低,同时精度最高。这是因为相对于 AlexNet 网络和 VGG16 网络,本文算法采用了 SqueezeNet 网络中的 Fire 模块来减少模型参数,缩减网络规模,因此其所需的训练时间更短,收敛更快。此外,本文算法采用了 Inception 模块来构建卷积层,这样能够增加网络中卷积核的感受野,同时能够有效提取样本中的稀疏特征,而这正好适用于处理具有时延和稀疏性质的声音频谱图像,因此本文算法具有更优的识别精度。以上实验结果表明,提出的稀疏轻量化卷积神经网络模型能够有效地解决管道泄漏检测问题,在获得较高精度的同时具有较低的时间复杂度。

表 1 实验精度及参数复杂度对比表

算法	准确率/%	参数数量/百万
AlexNet	95.8	60
VGG	97.9	138
本文算法	98.3	1.2

图 5 展示了本文所提模型在训练阶段的准确率及损失函数随训练轮次的变化情况图。从图 5 可以观察到,模型训练时损失函数在开始阶段快速下降,然后逐渐放缓,在第 20 个轮次后逐渐收敛;模型的准确率从第 15 个轮次之后可以稳定达到 95% 以上。这些实验结果表明模型收敛速度较快,即模型能够有效地解决声音图像分类问题。图 6 展示了本文所提模型和 AlexNet 模型、VGG 模型在每个训练轮次后分别应用到测试数据上时准确率的变化情况。从图 6 可以看出,本文算法需要较少的训练轮次就能够测

试集上取得较高的识别准确率,且后续变化平缓。而 AlexNet 模型稳定性不足,随着训练轮次的增加准确率波动较大;VGG 模型需要较多的训练轮次才能够达到较高的准确率。因此,相较于 AlexNet 和 VGG 模型,本文提出的模型准确率更高,稳定性更强,能够有效地泛化到测试数据集上,因此具有较强的实际应用价值。

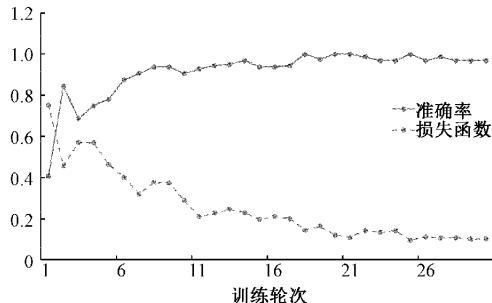


图 5 训练阶段准确率和损失函数变化情况图

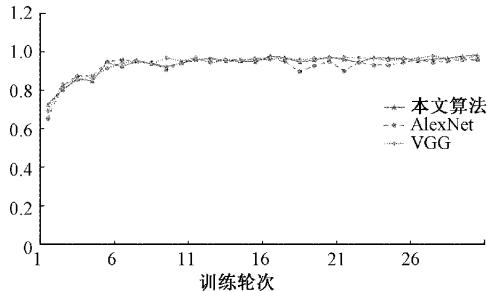


图 6 测试集上不同模型的准确率变化情况图

### 2.3 消融实验结果与分析

为了详细分析模型中 Inception 模块和 Fire 模块的作用,我们进行了模型的消融实验来进一步分析模型的结构及其对性能的影响。模型消融实验结果见表 2,其中剪除 Inception 模块和剪除 Fire 模块分别指模型除去 Inception 设计和 Fire 设计,即图 2 模型网络中的 Inception 模块或 Fire 模块分别用常规的卷积层来代替。AlexNet 网络作为对比模型,既不包含 Inception 模块,也不包含 Fire 模块。本文算法同时采用了 Inception 模块和 Fire 模块设计。从表 2 中可以看出,相对于原始的 AlexNet 网络模型,本文提出的模型具有更好的性能表现。此外,本文模型在剪除 Inception 模块之后,其准确率下降了 1.8%。以上实验结果表明,设计的 Inception 模块能够有效提取声音频谱图像中的有效特征,从而提高模型的精度。综上所述,本文提出

表 2 消融实验结果对比表

算法	准确率/%
AlexNet	95.8
剪除 Inception 模块	96.5
剪除 Fire 模块	98.1
本文算法	98.3

的稀疏轻量化卷积神经网络模型能够有效地解决声音信号的泄漏检测,同时鉴于其轻量化优势,因此可以被部署到边缘侧传感器,用来解决实际应用场景下的管道泄漏检测问题。

## 3 结论

目前主流的卷积神经网络模型主要用来解决机器视觉中的图像处理问题,但在声音图像处理等机器听觉问题中性能一般。为了解决供水管网的泄漏检测问题,本文提出了一种稀疏且轻量化的卷积神经网络模型。针对声音特征图像的时延和稀疏性质,模型采用了 Inception 模块取代常规的卷积层操作,同时引入了 Fire 模块来减小模型的复杂度,以便将模型部署到边缘侧进行实时的管道泄漏检测。实验结果证明,提出的模型在精度和时间复杂度上都有一定的优势。本文模型首先将声音信号转换成梅尔频谱图之后,再经过设计的卷积神经网络模型进行管道泄漏检测。声音信号转换成图像特征时会带来一定的信息损失,未来研究可以考虑设计直接适用于声音信号处理的神经网络模型,进一步提高模型的实际应用能力。

## 参考文献

- [1] 高琳,曹建国.管道泄漏检测中两个难点问题的研究进展[J].科学技术与工程,2021,21(31):13203-13210.
- [2] 杨菊,张玉强.埋地输油管道泄露的正演模拟研究[J].电子测量技术,2021,44(15):136-141.
- [3] 艾信,田鹏,吉效科,等.多算法融合管道泄漏检测预警系统试验研究[J].石油矿场机械,2021,50(6):26-33.
- [4] 贾盼龙,王蕊,谷国剑,等.管道泄漏报警定位技术应用综述[J].仪器仪表学报,2021,28(5):97-100.
- [5] 康佳乐,丁志强,张萌,等.自动化仪表在油气管道泄漏检测中的应用分析[J].中国石油和化工标准与质量,2017,37(9):26-27.
- [6] 张艳博,任瑞峰,梁鹏,等.基于热成像的埋地热力管道缺陷检测试验研究[J].仪器仪表学报,2020,41(6):161-170.
- [7] 刘翠伟,李雪洁,李玉星,等.基于音波法的输气管道泄漏检测与定位[J].化工学报,2014,65(11):4633-4642.
- [8] 李传坤,郭锦铭,李剑,等.基于频谱位移模块的环境声音识别方法[J].电子测量技术,2022,45(5):62-67.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [10] SENGUPTA A, YE Y, WANG R, et al. Going

- deeper in spiking neural networks: VGG and residual architectures[J]. *Frontiers in Neuroscience*, 2019, 13: 95.
- [11] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [12] 张芝旖, 姚恩涛, 石玉. 小波分析和MFCC融合的声音信号端点检测算法[J]. 电子测量技术, 2016, 39(7): 62-66.
- [13] 孟镇, 王昊, 虞为, 等. 基于特征融合的声乐分类研究[J]. 数据分析与知识发现, 2021, 5(5): 59-70.
- [14] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [15] LEE H J, ULLAH I, WAN W, et al. Real-time vehicle make and model recognition with the residual SqueezeNet architecture[J]. *Sensors*, 2019, 19(5): 982.
- [16] 麻曼, 李祥. 一种基于 MATLAB 实现的男女声识别算法[J]. 仪表技术, 2018(7): 21-23.
- [17] LIU W, WEN Y, YU Z, et al. Large-margin softmax loss for convolutional neural networks [C]. Proceedings of The 33rd International Conference on Machine Learning, 2016: 507-516.

### 作者简介

刘杰,硕士研究生,主要研究方向为嵌入式系统。

E-mail:814967801@qq.com

朱正伟,教授,硕士研究生导师,主要研究方向为智能检测技术及应用、嵌入式系统。