

# 控制与决策

Control and Decision

## 基于声信号多特征时频谱图的供水管网漏损检测

孙庆帅, 张英杰, 刘华亮, 李述杰

引用本文:

孙庆帅, 张英杰, 刘华亮, 等. 基于声信号多特征时频谱图的供水管网漏损检测[J]. *控制与决策*, 2026, 41(5): 1381-1391.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0391>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 含有分数阶有色关联噪声的分数阶系统的卡尔曼滤波器设计

Design of Kalman filter for fractional-order systems with correlated fractional-order colored noises

控制与决策. 2021, 36(7): 1672-1678 <https://doi.org/10.13195/j.kzyjc.2019.1418>

#### 基于转换量测容积卡尔曼滤波器带多普勒量测的目标跟踪算法

Converted measurement cubature Kalman filter for Doppler-assisted target tracking

控制与决策. 2021, 36(6): 1425-1434 <https://doi.org/10.13195/j.kzyjc.2019.1070>

#### Anchor-free的尺度自适应行人检测算法

Anchor-free scale adaptive pedestrian detection algorithm

控制与决策. 2021, 36(2): 295-302 <https://doi.org/10.13195/j.kzyjc.2020.0124>

#### 基于向量集逆区间滤波的故障观测器设计

Vector set inversion interval filtering based fault observer design

控制与决策. 2021, 36(12): 2973-2981 <https://doi.org/10.13195/j.kzyjc.2020.0212>

#### 基于KRLS的非均匀采样非线性系统辨识

Identification of non-uniformly sampled nonlinear systems based on KRLS

控制与决策. 2021, 36(12): 3049-3055 <https://doi.org/10.13195/j.kzyjc.2020.0962>

# 基于声信号多特征时频谱图的供水管网漏损检测

孙庆帅<sup>1</sup>, 张英杰<sup>1†</sup>, 刘华亮<sup>2</sup>, 李述杰<sup>1</sup>

(1. 湖南大学 信息科学与工程学院, 长沙 410082;

2. 湖南省水计量信息工程技术研究中心, 湖南 常德 415000)

**摘要:** 基于声信号的漏损检测方法在人工巡检中具有重要应用价值, 正逐步发展为一种新兴的远程监测手段. 传统基于深度学习的漏损声信号识别方法往往受到信号预处理流程繁琐以及环境噪声干扰的限制, 难以在其他供水管网中实现良好的泛化性能, 漏损检测的准确率亦有待进一步提升. 鉴于此, 首先, 针对供水管网声信号构建高时间分辨率和高频率分辨率下的线性谱图和对数梅尔谱图, 兼顾声信号的高频与低频特征, 突出短时动态变化以及微弱频率特征, 并以并行方式输入至卷积神经网络; 然后, 引入并行机制的时-频注意力卷积块进行特征提取, 增强对时间和频率维度的细粒度特征捕捉能力; 最后, 利用真实供水管网声信号数据和物理仿真数据对所提出方法进行漏损检测性能实验验证, 实验结果表明, 所提出方法显著提高了对漏损事件的识别率, 具有良好的鲁棒性和泛化能力.

**关键词:** 供水管网; 漏损检测; 声信号分析; 时频谱图; 线性谱图; 对数梅尔谱图; 注意力机制

中图分类号: TU991.33 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0391

引用格式: 孙庆帅, 张英杰, 刘华亮, 等. 基于声信号多特征时频谱图的供水管网漏损检测 [J]. 控制与决策, 2026, 41(5): 1381-1391.

## Leak detection in water supply networks based on multi-feature time-frequency spectrograms of acoustic signals

SUN Qing-shuai<sup>1</sup>, ZHANG Ying-jie<sup>1†</sup>, LIU Hua-liang<sup>2</sup>, LI Shu-jie<sup>1</sup>

(1. College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China;

2. Research Center of Hunan Water Metrology Information Engineering Technology, Changde 415000, China)

**Abstract:** Acoustic signal-based leak detection methods play a significant role in manual inspection and are gradually evolving into emerging technologies for remote monitoring. However, conventional deep learning approaches for leak detection from acoustic signals often suffer from complex preprocessing procedures and interference from environmental noise, limiting their generalization performance in other water supply networks. Moreover, the accuracy of leak detection still needs further improvement. To address these challenges, this study first constructs linear spectrograms and log-Mel spectrograms with high time and frequency resolution based on pipeline acoustic signal. These spectrograms are designed to capture both high-and low-frequency features, emphasize short-term dynamic changes and subtle spectral components, and are fed in parallel into a convolutional neural network. A parallel time-frequency attention convolutional block is then introduced for feature extraction, enhancing the network's ability to capture fine-grained temporal and spectral characteristics. Experiments conducted on real-world pipeline acoustic data and physical simulation datasets demonstrate that the proposed method significantly improves the detection rate of leak events and exhibits strong robustness and generalization capabilities.

**Keywords:** water supply networks; leak detection; acoustic signal analysis; time-frequency spectrogram; linear spectrogram; log-Mel spectrogram; attention mechanism

## 0 引言

供水管网的漏损控制是整个供水行业在管网建设和维护过程中面临的重点问题. 管道老化、气候变

化和区域人口增长等因素均为管网埋下了漏损隐患. 根据 2023 年中国城市建设状况公报<sup>[1]</sup>, 我国城市供水管道建设长度呈逐年上升趋势, 截止 2023 年末已

收稿日期: 2025-04-15; 录用日期: 2025-09-26.

基金项目: 湖南省自然科学基金项目 (2023JJ50318); 湖南省战略性新兴产业科技攻关重大专项项目 (2019GK4030).

责任编委: 胡清华.

<sup>†</sup>通信作者. E-mail: zhangyj@hnu.edu.cn.

达到 115.31 万公里,由此可见管网维护工作的重要性.漏损不仅会造成大量的水资源流失致使不可小觑的经济损失,还易引发水污染问题威胁到用水安全<sup>[2]</sup>.因此,及时准确地检测出供水管网中的漏损事件对于运维效率的提升具有重要意义.

基于独立计量区域 (DMA) 的最小夜间流量 (MNF) 法是普及面最广且最成熟的主动漏损检测方法.该方法利用流量计数据分析供水区域的夜间流量波动以实现漏损的检测<sup>[3]</sup>,但是,其检测性能严重依赖于对供水区域的水力校准.此外,居民用水的随机性和人口的流动性均对 MNF 法的实施成效具有显著影响.

流量计和压力计是管网中常见的传感设备,提供了丰富的历史监测数据.因此,基于流量和压力数据,利用数据驱动算法进行漏损检测的技术得到了广泛研究和应用.在相关研究中,Wu 等<sup>[4]</sup>和 Sun 等<sup>[5]</sup>将流量时序数据进行特征重构,利用聚类算法实现了对管网用水量数据的分类并基于此进行漏损识别;McMillan 等<sup>[6]</sup>采用了长短期记忆神经网络和卡尔曼滤波从管网历史用水数据中学习区域的用水行为特征,通过分析预测流量与监测流量的差值来判别漏损事件.现有基于流量的漏损检测方法在大漏损的检测中表现出色,但是对于小漏损的敏感性较低,只有当泄漏水量累积到一定阈值后才能触发报警.

压力计对于漏损引起的压力波动信号十分敏感,有助于提升漏损检测的灵敏度,同时,还能增强对漏损区域定位的精度,如通过分析负压波到达时间来定位漏损<sup>[7]</sup>.Yang 等<sup>[8]</sup>利用深度学习算法分析管道压力数据来识别周期性的非漏损压力波动和漏损压力波动,并设计了压力波速度动态更新机制以实现漏损的定位;Cheng 等<sup>[9]</sup>和李红艳等<sup>[10]</sup>研究了压力计的最优布置,试图通过采集管网压力敏感节点上的数据来重构所有节点的压力,以达到漏损实时监测和定位的目的;除分析单一传感数据,Hu 等<sup>[11]</sup>采集了压力和流量数据,利用基于密度的空间聚类算法将管网划分为多个漏损区域并标记类别,最后设计了基于离散傅里叶变换的多尺度完全卷积网络来检测漏损.流量计和压力计的使用能够满足大多数的漏损检测需求,但是,在早期漏损检测方面存在灵敏度不足的问题.因此,基于声信号的漏损检测技术成为一种有效的补充手段.

当漏损发生时,泄漏水与管壁间相互作用引起的声波会沿着管道传播,而基于声信号检测的原理就是从监听到的声信号中辨别出漏损声音.传统的人工巡检对于巡线工作者有较高的经验要求,且是

一个耗时耗力的过程<sup>[12]</sup>.为提高检测效率,并满足管网对于远程声信号监测的需求,基于声信号数据分析的漏损检测算法得到了广泛关注.在相关研究中,传统模式识别方法通过对信号的先验知识来提取声学特征,其检测性能易受环境噪声和高能干扰影响.为了克服噪声影响,张祎等<sup>[13]</sup>采用自适应的变分模态分解法对声信号进行了降噪处理,然后在降噪后的声信号上提取了峰值、均方根和均值频率等共 16 个时域和频域特征,并融合压力数据利用支持向量机算法实现了漏损识别.随着深度学习技术的发展,声学特征提取逐渐由神经网络自动完成,为声信号漏损检测提供了一种端到端的解决方案<sup>[14]</sup>.

深度学习方法中,通常将采集到的声信号经谱图变换得到对应的图像数据来增强特征表示.何立新等<sup>[15]</sup>基于声信号的梅尔频率倒谱系数特征利用机器学习算法建立了漏损与提取特征间的非线性映射关系;陈炯禧等<sup>[16]</sup>同样是利用梅尔频率倒谱系数构建出声信号的三维图像,随后用一个 5 层卷积神经网络进行特征提取和漏损识别;Guo 等<sup>[12]</sup>为了突出声信号的高时间分辨率和高频率分辨率特征,采用 3 种不同尺寸的短时傅里叶变换窗口得到了 3 幅线性谱图,同时,为降低漏损频带内的噪声影响,Guo 等<sup>[12]</sup>利用带通滤波对谱图进行了处理,最终用一个并行卷积神经网络架构实现了漏损识别;然而,Peng 等<sup>[17]</sup>认为卷积神经网络能够自动识别漏损频带内的干扰而无需引入带通滤波,为了提升谱图的色彩区分度和凸显细节,Peng 等<sup>[17]</sup>采用降噪对数谱图作为输入,由残差网络 (ResNet) 中的 ResNet-18 神经网络实现了漏损识别.现有多数基于卷积神经网络的漏损检测方法在将声信号转化为谱图的过程中,依赖于特定场景下设计的降噪预处理策略,这在一定程度上限制了模型在不同管网环境中的快速迁移和应用,降低了其实用性和通用性.此外,谱图的特征表达能力依赖于变换参数设置,不同的谱图变换在特征提取上具有不同的偏向性.因此,单一谱图往往难以有效覆盖声信号的全部关键特征,可能存在信息缺失或特征偏差的问题.

为进一步提升基于深度学习的声信号漏损检测性能,本文提出一种融合声信号多尺度特征,利用并行时-频注意力卷积神经网络架构的漏损检测方法 (MFAN),主要内容可分为 3 个方面:

- 1) 设计获取声信号的 4 幅不同尺度的时频谱图,使得特征提取过程中更聚焦关键信息,并采用并行输入机制;

2) 构建并行时-频注意力卷积网络, 增强提取谱图时间和频率维度的细粒度特征;

3) 针对部署多水听器的供水管网提出特征谱图通道融合的漏损检测方法.

### 1 方法原理及步骤

声信号是典型的时域信号, 其振幅变化能够反映管网中的水力动态信息. 单纯的时域表征难以揭示信号中频率成分的分布和变化, 而这些频率信息是声信号分析和识别的重要依据. 因此, 各漏损检测方法常用谱图变换将时域信号转换至频域或时频域进行分析. 谱图的生成基于短时傅里叶变换 (STFT), 通过在信号上施加一个滑动窗口, 将长时间的信号切分为若干片段并执行傅里叶变换, 最终以二维图像的形式直观地展现信号的频率特征及其随时间动态变化的特征.

漏损检测中, 漏损声信号通常具有非平稳特性,

常在短时间尺度内因泄漏孔处的湍流噪声产生突发性或微弱的变化. 此外, 声信号受管道结构和流体特性影响, 往往包含特定的频率成分. 漏损信号在频谱上通常表现为高频能量增强. 在金属管道中, 漏损特征峰值往往集中于 2 kHz ~ 6 kHz 频段; 而在塑料管道或传感器距离漏点较远的情况下, 特征频段可能下移至 0.5 kHz ~ 2 kHz. 此外, 在时域波形中, 漏损信号通常表现为连续且无规则的扰动, 与正常状态下平稳、周期性背景流动噪声形成明显对比. 因此, 管网的漏损声信号呈现出明显的多尺度特征, 而时频域特征的有效提取能够帮助模型全面分析信号的复杂性以及漏损的潜在机理<sup>[18]</sup>. 为全面捕捉这些关键时频特征, 本文提出如图 1 所示的基于 MFAN 的漏损检测流程. MFAN 将声信号变换后的 4 幅谱图并行输入至卷积神经网络以提取时频特征, 并通过分类层实现对管网中漏损事件的自动检测.

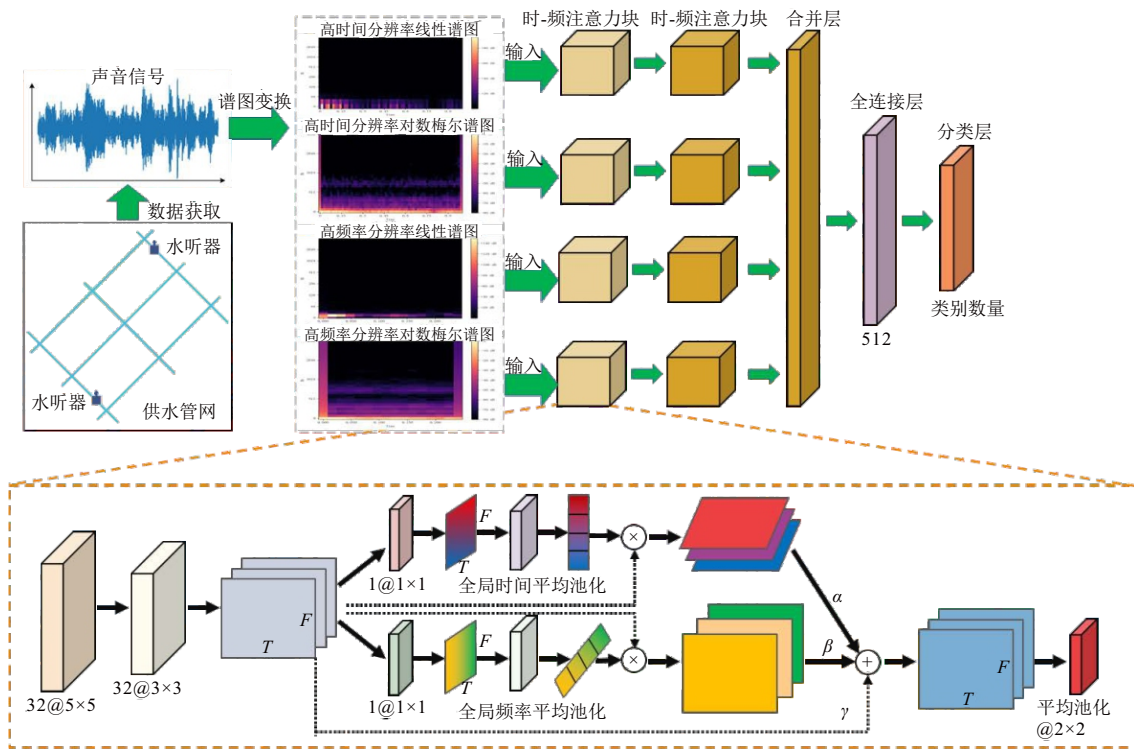


图1 基于 MFAN 的漏损检测流程框架

图 1 中, 从管网获取的声信号经谱图变换后得到了高时间分辨率和高频率分辨率下的线性谱图和对数梅尔谱图. 变换得到的 4 幅谱图从不同频段和时间尺度来表征声信号, 实现了特征互补, 弥补了单一谱图难以覆盖所有关键信息的劣势. 其中: 线性谱图以线性刻度表示频率能量分布, 具有均匀的频率分辨率, 有助于捕捉漏损声信号中高频段的细微特征; 而对数梅尔谱图则通过非线性变换来强调低频

部分, 对环境噪声有更好的抑制效果, 有助于捕捉声信号低频段的动态变化. 两类谱图相结合可以兼顾高频与低频信息的表达, 提高漏损检测的鲁棒性.

除关注高低频信息的敏感性, 本文还设计了不同的快速傅里叶变换 (FFT) 窗口长度, 以获取每类谱图变换下的高时间分辨率和高频率分辨率谱图. FFT 的窗口长度会显著影响生成谱图的时间和频率分辨率. 较短的 FFT 窗口能够提高时间分辨率, 有助

于更清晰地捕捉信号的短时变化;而较长的 FFT 窗口则能够提高频率分辨率,提供更细致的频率结构信息,有助于解析低频或微弱频率特征。

4幅谱图完整覆盖了声信号时频特征的4个核心角度,形成了良好的互补,从不同频段、不同时间尺度下表征声信号,弥补了单一谱图难以覆盖所有关键信息的劣势,为后续的特征提取和漏损识别提供了更加丰富的基础数据。

基于谱图变换,本文引入并行时-频注意力机制分别从时间维度和频率维度对谱图进行特征提取,这种双重注意力机制能够加强模型对细节特征的提取能力<sup>[19]</sup>,有利于学习区分性更强的声信号特征表示<sup>[20]</sup>。如图1所示,并行输入每幅谱图经两个时-频注意力卷积块后在合并层进行特征拼接并送入全连接层以实现特征的融合,最终由分类层实现漏损检测。在时-频注意力卷积块中,每幅大小为 $T \times F \times 1$ 的单通道谱图 $\mathbf{X}$ 首先经两个卷积层进行初步特征提取,得到一个通道数为 $C$ 的特征矩阵 $\mathbf{U} \in \mathbb{R}^{T \times F \times C}$ 送入并行的时-频注意力卷积模块进行时频特征提取。该模块的输出特征矩阵 $\mathbf{U}' \in \mathbb{R}^{T \times F \times C}$ 由如下公式计算得到:

$$\begin{aligned} \mathbf{U}' &= \alpha \mathbf{U}_T + \beta \mathbf{U}_F + \gamma \mathbf{U}, \\ \alpha + \beta + \gamma &= 1. \end{aligned} \quad (1)$$

其中: $\mathbf{U}_T = \mathbf{U}\mathbf{V}_T$ 为时域特征矩阵,通过输入特征矩阵 $\mathbf{U}$ 与时间注意力权重 $\mathbf{V}_T$ 相乘得到; $\mathbf{U}_F = \mathbf{U}\mathbf{V}_F$ 为频域特征矩阵,通过输入特征矩阵 $\mathbf{U}$ 与频率注意力权重 $\mathbf{V}_F$ 相乘得到; $\alpha$ 、 $\beta$ 和 $\gamma$ 为特征融合权重,衡量了时间注意力、频率注意力和原始特征的重要性。权重值可由经验公式给出或作为训练参数动态调整。

基于从4个并行通道得到的输出特征,声信号的漏损检测可由如下公式给出:

$$\begin{aligned} \mathbf{F}_{\text{concat}} &= \\ &\text{Concat}(\phi_1(\mathbf{X}_1), \phi_2(\mathbf{X}_2), \phi_3(\mathbf{X}_3), \phi_4(\mathbf{X}_4)), \\ \mathbf{Z} &= \mathbf{W}_{\text{fc}} \mathbf{F}_{\text{concat}} + b_{\text{fc}}, \\ \mathbf{P} &= \text{Softmax}(\mathbf{Z}), \\ \hat{y} &= \arg \max_{i \in \{0,1\}} (p_i). \end{aligned} \quad (2)$$

其中: $\mathbf{X}_1$ 、 $\mathbf{X}_2$ 、 $\mathbf{X}_3$ 和 $\mathbf{X}_4$ 为声信号对应的4幅输入谱图; $\phi(\cdot)$ 为谱图经时-频注意力卷积块处理后的输出特征矩阵;Concat( $\cdot$ )用于拼接并行输出的4个特征矩阵;合并后的特征 $\mathbf{F}_{\text{concat}}$ 经全连接层权重 $\mathbf{W}_{\text{fc}}$ 和偏置项 $b_{\text{fc}}$ 处理得到变换后的特征向量 $\mathbf{Z}$ ;最后由Softmax层获得输入声信号属于漏损事件或非漏损事件的概率 $p$ ,并基于此实现漏损检测。

## 2 实验分析

### 2.1 数据集准备

本文将所提出 MFAN 算法与其他两个算法 TFCNN<sup>[12]</sup>和 Log PS-ResNet18<sup>[17]</sup>,在一个物理仿真数据集 (Lab-data)<sup>[21]</sup>和一个管网真实监听数据集 (HK-data)<sup>[22]</sup>上进行漏损检测性能对比实验。其中: Lab-data 为一个实验室规模的供水管网模拟数据,漏损事件通过更换人为设计的4种破损类型管道来模拟,由安装在管道上的两个型号为 Aquarian H2c 的水听器采集。模拟实验根据管网的拓扑结构、背景流量大小和漏损类别的不同进行多组场景下的数据采集。HK-data 为从香港真实地下供水管网中由阀门上的水听器监听收集的数据,记录漏损修复前后多次采集得到的声信号。表1为两个数据集的详细信息。

表1 数据集详细信息

| 参数      | Lab-data <sup>[21]</sup> | HK-data <sup>[22]</sup> |
|---------|--------------------------|-------------------------|
| 管网拓扑结构  | 环状结构、分支结构                | 真实地下管网                  |
| 管道直径/总长 | 152.4 mm / 47 m          | —                       |
| 管道材质    | 非金属                      | 金属、非金属                  |
| 背景流量    | 0.18 L/s、0.47 L/s        | —                       |
| 背景噪声    | 交通音频、电锯声                 | 真实噪声                    |
| 漏损类别    | 环向裂缝、纵向裂缝、垫片泄漏、孔口泄漏、无漏损  | 有漏损、无漏损                 |
| 水听器数量   | 2个                       | 1个                      |
| 采样频率    | 8 kHz                    | 4 kHz                   |
| 单个音频时长  | 30 s                     | 10 s                    |
| 音频个数    | 2个/场景                    | 40个/类别                  |

对比表1中两个数据集可以发现,Lab-data 中通过组合不同的管网拓扑、背景流量和漏损类别,可得共20个用水场景,如“环状结构-0.18 L/s-环向裂缝漏损”场景。但是,Lab-data 的每个场景下只有两个水听器记录的一组时长均为30 s的音频。HK-data 中没有提供音频对应的具体漏损类别,但是,针对漏损和无漏损两种场景分别给出了40个时长为10 s的音频。对比两个数据的背景噪声,Lab-data 通过播放真实环境下录制的交通音频以及在实验中加入电锯声来模拟监听环境, HK-data 则是直接记录了监听时刻的真实背景噪声。

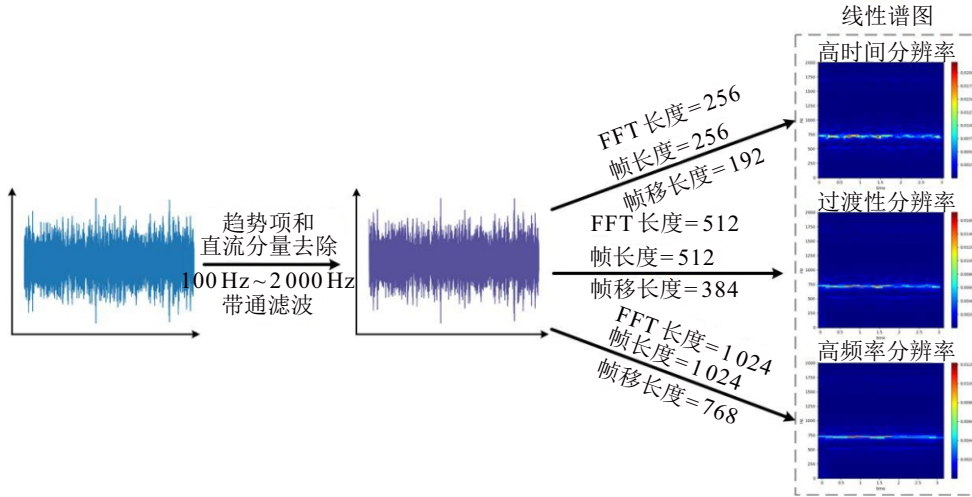
针对两个数据集体量偏小的情况,本文在实验中将所有音频按照1 s的时间长度进行分割来提升样本数量。同时,漏损检测过程以每秒级的速度针对每段音频执行检测。实验中: Lab-data 根据每个音频的监听时长来划分训练集和测试集,取音频监听时长前70%的数据用于训练模型,剩余30%的数据用于进行性能测试;而 HK-data 则是取前70%个音频用于训练,剩余30%个音频用于测试。

### 2.2 参数设置与性能指标

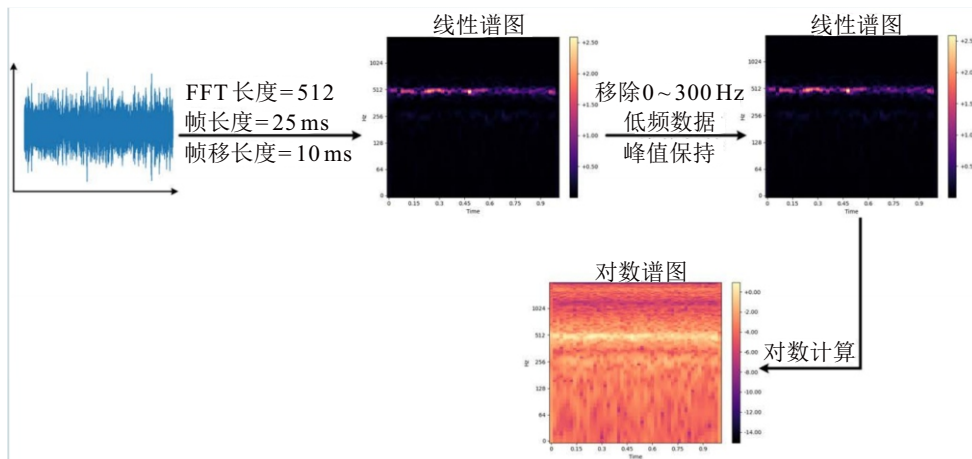
所提出 MFAN 算法与 TFCNN 和 Log PS-ResNet18 算法均在 Python 3.7.3 环境下进行实验, 运行设备配置为 Inter-i7 3.6 GHz CPU、GeForce

GTX1060 6 GB GPU、16 GB RAM 和 64 位的 Windows 操作系统. 实验过程中, 两个对比算法的相关参数设置参见文献 [12, 17].

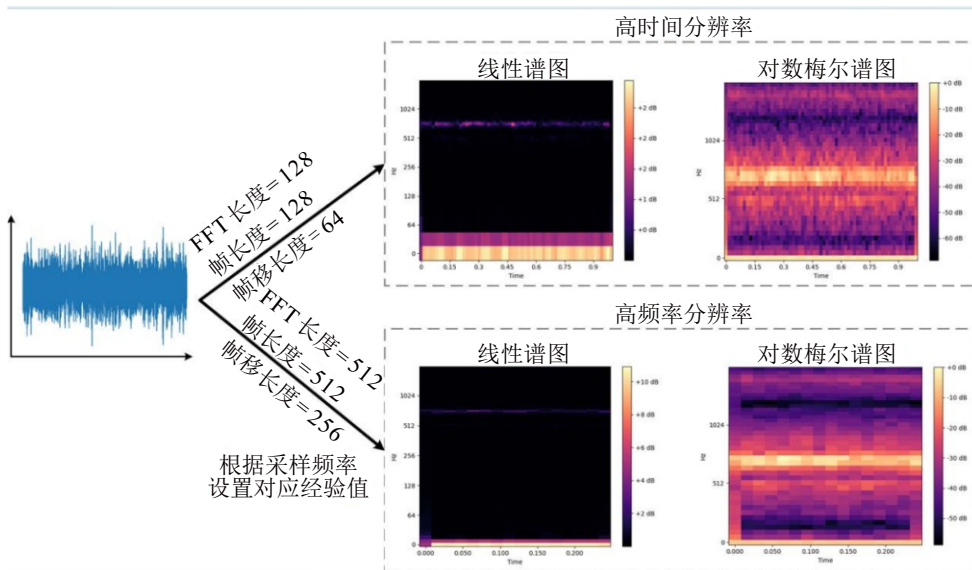
图 2 分别为 3 个算法的声信号谱图变换过程.



(a) TFCNN 谱图生成



(b) Log PS-ResNet18 谱图生成



(c) MFAN 谱图生成

图2 3个算法谱图变换过程对比

如图2(a)所示: TFCNN对获取到的声信号首先执行了趋势项去除操作来消除信号中的低频变化,同时去除信号中的直流分量来突显变化特征,最后采用频率范围为100 Hz~2000 Hz的带通滤波进一步降噪.基于降噪处理后的声信号, TFCNN采用了3组不同的STFT设置得到3幅线性谱图.其中:高时间分辨率谱图的FFT窗口长度和帧长度为256,帧移长度为192;高频率分辨率谱图的FFT窗口长度和帧长度为1024,帧移长度为768;过渡性时间-频率分辨率谱图的FFT窗口长度和帧长度为512,帧移长度为384.

图2(b)中, Log PS-ResNet18没有针对声信号进行去噪,而是首先通过FFT窗口长度为512、帧长度为25、帧移长度为10的谱图变换得到声信号的线性谱图.基于得到的线性谱图, Log PS-ResNet18进行了0~300 Hz低频数据剪除的处理,接着采用从无漏损样本中计算得到的阈值识别谱图中的干扰帧,并通过峰值保持技术(保留干扰帧中的2个最大峰值)来实现降噪.谱图降噪处理后,利用对数运算获取最终的声信号对数谱图.

与Log PS-ResNet18相同,所提出MFAN算法直接在获取的声信号上进行谱图变换,如图2(c)所示.根据采样频率设置不同的STFT经验参数分别获取高时间分辨率和高频率分辨率下的线性谱图和对数梅尔谱图.针对采样频率为8 kHz的声信号(MFAN设置高时间分辨率的FFT窗口长度和帧长度为256,高频率分辨率的FFT窗口长度和帧长度为1024)和采样频率为4 kHz的声信号(MFAN设置高时间分辨率的FFT窗口长度和帧长度为128,高频率分辨率的FFT窗口长度和帧长度为512),4幅谱图变换中采用的帧移长度均取值为对应帧长度的一半.

基于生成的声信号谱图,3个算法均采用卷积神经网络进行特征提取和分类.各算法的卷积层参数设置如表2所示.其中: TFCNN采用5层的神经网络深度,且前3层针对输入的3幅谱图采用并行结构; Log PS-ResNet18采用标准的ResNet18网络架构;所提出MFAN共12层,包括采用并行结构的2个时-频注意力卷积块(第1层~第5层和第6层~第10层).表2中, MFAN算法的第3层、第4层和第8层、第9层内的两个卷积核尺寸分别对应时间和频率注意力卷积分支.时-频注意力卷积层提取到的特征需要在第4层和第9层后经加权求和再传递给下一层.

为评估各算法的漏损检测性能,本文基于分类

表2 3个算法的卷积层参数设置

| 算法  | 卷积层参数设置  |  |
|---|--|--|
| TFCNN <sup>[22]</sup>                                 | 第1层: [卷积核数: 32, 核大小: 4 × 4, 步长: 4] × 3               |  |
|   | 第2层: [卷积核数: 32, 核大小: 2 × 2, 步长: 2] × 3               |  |
|   | 第3层: [池化核大小: 2 × 2, 步长: 2, 批量归一化] × 3                |  |
|   | 第4层: [全连接层单元数: 128, Dropout比例: 0.25]                 |  |
|   | 第5层: [分类层]   |  |
| 激活函数: ReLU, 学习率: 0.001                                |  |  |
| Log PS-ResNet18 <sup>[17]</sup>                       | 第1层: [卷积核数: 64, 核大小: 7 × 7, 步长: 2, 填充: 3]            |  |
|   | 第2层: [池化核大小: 3 × 3, 步长: 2, 填充: 1]                    |  |
|   | 第3层~第6层: [卷积核数: 64, 核大小: 3 × 3, 步长: 1, 填充: 1]        |  |
|   | 第7层~第10层: [卷积核数: 128, 核大小: 3 × 3, 步长: 2   1, 填充: 1]  |  |
|   | 第11层~第14层: [卷积核数: 256, 核大小: 3 × 3, 步长: 2   1, 填充: 1] |  |
|   | 第15层~第18层: [卷积核数: 512, 核大小: 3 × 3, 步长: 2   1, 填充: 1] |  |
|   | 第19层: [分类层]  |  |
|   | 激活函数: ReLU, 学习率: 0.01                                |  |
|   | MFAN   | 第1层: [卷积核数: 32, 核大小: 5 × 5, 步长: 1, 填充: 2, 批量归一化] × 4 |
|   |  | 第2层: [卷积核数: 32, 核大小: 3 × 3, 步长: 1, 填充: 1, 批量归一化] × 4 |
| 第3层: [卷积核数: 1, 核大小: 1 × 1   1 × 1, 步长: 1, 批量归一化] × 4  |  |  |
| 第4层: [池化核大小: H × 1   1 × W, 步长: 1, Sigmoid] × 4       |  |  |
| 第5层: [池化核大小: 2 × 2] × 4                               |  |  |
| 第6层: [卷积核数: 64, 核大小: 5 × 5, 步长: 1, 填充: 2, 批量归一化] × 4  |  |  |
| 第7层: [卷积核数: 64, 核大小: 3 × 3, 步长: 1, 填充: 1, 批量归一化] × 4  |  |  |
| 第8层: [卷积核数: 1, 核大小: 1 × 1   1 × 1, 步长: 1, 批量归一化] × 4  |  |  |
| 第9层: [池化核大小: H//2 × 1   1 × W//2, 步长: 1, Sigmoid] × 4 |  |  |
| 第10层: [池化核大小: 2 × 2] × 4                              |  |  |
| 第11层: [全连接层单元数: 512]                                  |  |  |
| 第12层: [分类层]   |  |  |
| 激活函数: Leaky ReLU, 学习率: 0.01                           |  |  |

混淆矩阵采用准确率、识别率、误警率和F1值4个评估指标.各指标的计算公式如下所示:

$$\begin{aligned}
 \text{准确率} &= \frac{TP + TN}{TP + TN + FP + FN}, \\
 \text{识别率} &= \frac{TP}{TP + FN}, \\
 \text{误警率} &= \frac{FP}{FP + TN}, \\
 F1 &= \frac{2TP}{2TP + FP + FN}. \quad (3)
 \end{aligned}$$

其中: TP为漏损样本中被正确识别的数量, FP表示

被错误识别为漏损的样本数量, TN为无漏损样本中被正确识别的数量, FN为没有被识别出的漏损样本数量. 4个指标中: 准确率衡量了模型对漏损和无漏损事件的整体分类性能, 识别率反映了对漏损事件的检出能力, 误警率则重点关注减少误报事件的发生, F1值综合考虑了提高漏损检测和减少误报的重要性. 一个好的漏损检测算法应做到高识别率的同时保持低误警率.

### 2.3 漏损检测性能对比

3个算法在训练中, 均在 Lab-data 数据上设置批大小为 2, 在 HK-data 数据上设置批大小为 16, Epoch 设置为 100. 同时, 3个算法在同一组数据上均执行 10 次漏损检测实验并计算得到对应评估指标的平均值和标准差. 表 3 和表 4 分别为算法在 Lab-data 数据集两种拓扑结构上的漏损检测结果, 通过组合无漏损样例和不同漏损类别的样例得到了多组实验.

表3 Lab-data 上漏损检测性能对比 (分支网 & 0.47 L/s)

| 算法              | 指标/% | 无漏损 vs 纵向裂缝漏损 | 无漏损 vs 环向裂缝漏损 | 无漏损 vs 所有4个类别漏损 |
|-----------------|------|---------------|---------------|-----------------|
| TFCNN           | 准确率  | 91.94 ± 6.20  | 88.33 ± 17.01 | 88.89 ± 8.15    |
|                 | 识别率  | 96.11 ± 12.30 | 86.67 ± 21.94 | 97.78 ± 4.82    |
|                 | 误警率  | 12.22 ± 3.51  | 10.00 ± 16.73 | 46.67 ± 45.60   |
|                 | F1值  | 91.89 ± 7.51  | 87.38 ± 18.39 | 93.55 ± 4.51    |
| Log PS-ResNet18 | 准确率  | 92.22 ± 9.60  | 87.78 ± 14.36 | 89.11 ± 2.81    |
|                 | 识别率  | 91.11 ± 6.52  | 96.67 ± 3.89  | 97.36 ± 2.01    |
|                 | 误警率  | 6.67 ± 15.67  | 21.11 ± 29.14 | 43.89 ± 11.55   |
|                 | F1值  | 92.50 ± 8.22  | 89.87 ± 9.59  | 93.47 ± 1.67    |
| MFAN            | 准确率  | 80.00 ± 3.41  | 88.89 ± 3.71  | 86.00 ± 0.94    |
|                 | 识别率  | 85.56 ± 5.37  | 91.67 ± 4.72  | 100.00 ± 0.00   |
|                 | 误警率  | 25.55 ± 5.37  | 13.89 ± 5.40  | 70.00 ± 4.68    |
|                 | F1值  | 81.13 ± 3.40  | 89.19 ± 3.51  | 91.96 ± 0.49    |

表4 Lab-data 上漏损检测性能对比 (环网 & 0.18 L/s)

| 算法              | 指标/% | 无漏损 vs 孔口泄漏漏损 | 无漏损 vs 垫片泄漏漏损 | 无漏损 vs 所有4个类别漏损 |
|-----------------|------|---------------|---------------|-----------------|
| TFCNN           | 准确率  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |
|                 | 识别率  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |
|                 | 误警率  | 0.00 ± 0.00   | 0.00 ± 0.00   | 0.00 ± 0.00     |
|                 | F1值  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |
| Log PS-ResNet18 | 准确率  | 95.00 ± 9.43  | 85.72 ± 19.77 | 94.89 ± 6.11    |
|                 | 识别率  | 98.89 ± 2.34  | 88.42 ± 21.49 | 98.61 ± 2.27    |
|                 | 误警率  | 8.89 ± 17.01  | 25.50 ± 21.56 | 20.00 ± 30.90   |
|                 | F1值  | 95.68 ± 7.59  | 87.66 ± 20.51 | 96.97 ± 3.43    |
| MFAN            | 准确率  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |
|                 | 识别率  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |
|                 | 误警率  | 0.00 ± 0.00   | 0.00 ± 0.00   | 0.00 ± 0.00     |
|                 | F1值  | 100.00 ± 0.00 | 100.00 ± 0.00 | 100.00 ± 0.00   |

表 3 中, 3 个算法应用于分支拓扑结构且背景流

量设定为 0.47 L/s 的管网. 实验分别构造了无漏损与环向裂缝漏损、纵向裂缝漏损和所有 4 个类别漏损的 3 组实验. 实验结果显示, 所提出 MFAN 算法对于纵向裂缝漏损的识别均落后于两个对比算法, 且存在较高的误警率. 而针对环向裂缝漏损, MFAN 的漏损识别率达到了 91.67%, 超过 TFCNN 算法识别率的 5%. 但是, 在提高识别率的同时误警率也相对提升了 3.89%. 这体现了 MFAN 更倾向于将不确定样本视为漏损, 以最大限度地减少漏检风险. 而在实际应用中, 关键管段的漏检代价远高于误报, 因此, 适度的假阳性被认为是可接受的. 同样, 可以发现, Log PS-ResNet18 在环向裂缝漏损检测任务中得到了比 MFAN 更高的识别率, 但是, 该算法将误警率提升到了 21.11%. 在无漏损数据混合所有漏损数据的实验组中, 数据呈现出 1 : 4 的类别不平衡现象. 因此, 可以发现, 3 个算法在该组实验中均表现出较大的误警率, 倾向于将所有样例均识别为漏损事件.

分析算法性能的稳定性可以发现, MFAN 相较于 TFCNN 与 Log PS-ResNet18 算法在 10 次实验中表现出更好的性能. MFAN 各指标的标准差明显优于两个对比算法. 而 TFCNN 和 Log PS-ResNet18 算法各指标的标准差存在几乎追平或超过平均值的现象, 反映了算法性能的不稳定特征, 表现出低鲁棒性.

表 4 中, 3 个算法应用于环状拓扑结构且背景流量设定为 0.18 L/s 的管网. 实验分别构造了无漏损与垫片泄漏、孔口泄漏和所有 4 个类别漏损的 3 组实验. 环状拓扑结构对比分支结构具备水流多路径可达的特性, 该特性使得声信号可通过多个路径传播进而增强了声音表达. 因此, 由表 4 可见: MFAN 和 TFCNN 算法在 3 组对比实验中均获得了 100% 的漏损检出以及 0 误警的成绩; 而 Log PS-ResNet18 算法没有学习到漏损和无漏损声信号的所有差异, 导致漏损检测性能略低, 特别是在垫片泄漏识别中表现相对较差, 表现为低识别率和高误警率且算法性能波动较大.

为检验算法在真实管网监听数据上的应用效果并提高算法的实用性, 本文将 MFAN 与 TFCNN 和 Log PS-ResNet18 两个算法在香港真实采集数据上进行对比实验. 此外, 还引入对比两个非基于谱图变换的声信号漏损检测算法 VMD-Transformer<sup>[23]</sup> 与 FFT-Transformer<sup>[24]</sup>. 其中: VMD-Transformer 直接将原始声信号经变分模态分解 (VMD) 去噪后输入多头 Transformer 模型进行特征提取和漏损识别<sup>[23]</sup>, 而 FFT-Transformer 则是通过快速傅里叶变换 (FFT) 将声信号从时域转换至频域后再输入多头 Transformer

模型进行特征提取和漏损识别<sup>[24]</sup>. 实验中, VMD-Transformer 和 FFT-Transformer 的参数设置参见文献 [23-24].

HK-data 上的漏损检测性能对比实验结果如表 5 所示, 所提出 MFAN 算法实现了最佳的漏损检测效果, 超过对比算法 TFCNN 的漏损识别率 11.66%, 且误警率为 0. 对比算法中: Log PS-ResNet18 的漏损检测效果较差, 分析其原因可能是在谱图预处理中执行了低频段剪除操作, 导致算法没有学习到漏损声的代表性特征, 将所有样例均识别为无漏损; 而 VMD-Transformer 和 FFT-Transformer 分别仅关注时域或频域特征, 未能充分利用时域与频域间的互补性, 这可能导致它们在特征提取方面存在局限性, 从而影响了漏损识别的性能; 相比之下, TFCNN 算法表现出了具备竞争力的漏损识别性能. HK-data 数据集上的实验验证了 MFAN 算法在处理复杂真实场景时的优越性和鲁棒性, 为其在实际应用中的漏损检测提供了信心.

表5 HK-data 上的漏损检测性能对比

| 算法              | 准确率/%               | 识别率/%               | 误警率/%              | F1值/%               |
|-----------------|---------------------|---------------------|--------------------|---------------------|
| TFCNN           | 91.21 ± 3.89        | 87.92 ± 8.53        | 5.50 ± 7.87        | 90.82 ± 4.19        |
| Log PS-ResNet18 | 50.00 ± 0.00        | 0.00 ± 0.00         | 0.00 ± 0.00        | 0.00 ± 0.00         |
| VMD-Transformer | 71.55 ± 14.48       | 77.42 ± 25.52       | 34.33 ± 18.34      | 70.67 ± 14.58       |
| FFT-Transformer | 54.12 ± 11.49       | 47.08 ± 24.39       | 38.83 ± 32.28      | 50.88 ± 11.27       |
| MFAN            | <b>99.09 ± 0.33</b> | <b>98.17 ± 0.66</b> | <b>0.00 ± 0.00</b> | <b>99.07 ± 0.33</b> |

## 2.4 消融实验

为评估所提出漏损识别方案中不同输入特征和注意力机制模块对漏损识别性能的影响, 本文设计系列消融实验, 分别从输入时频谱图类型和卷积神经网络结构两个维度进行分析.

在输入特征方面, 所提出模型的原始输入包括高时间分辨率和高频率分辨率的线性谱图以及对数梅尔谱图 4 种. 为验证各类谱图在漏损识别中的有效性, 实验中依次仅保留线性谱图、对数梅尔谱图、高时间分辨率谱图或高频率分辨率谱图, 构建不同

输入组合的模型, 保持卷积神经网络结构一致并与完整输入进行性能对比. 在结构模块方面, 所提出模型引入了并行的时间-频率注意力机制, 以增强模型对声音信号时间动态和频率模式的建模能力. 为评估这些模块的实际贡献, 实验中依次移除时间注意力、频率注意力, 或同时移除两个注意力模块, 保持输入谱图一致并记录模型性能的变化.

实验中, 所有消融实验组均在 HK-data 数据集上进行漏损识别, 并保持相同的训练参数和数据集设置. 同时, 所有实验组均采用 10 次重复实验取平均和标准差的方式显示性能指标. 实验结果如表 6 所示.

由表 6 中消融实验的对比结果可以发现, 所提出模型采用全部 4 种谱图作为输入并引入并行的时间和频率注意力机制, 在 HK-data 数据集上取得了最高的漏损和无漏损事件分类准确率 (99.09% ± 0.33)、漏损识别率 (98.17% ± 0.66) 和 F1 值 (99.07% ± 0.33), 且误警率为 0. 同时, 对比 10 次结果的标准差可以发现, 所提出漏损识别算法具有更高的性能稳定性.

在注意力机制方面, 分别移除频率注意力和时间注意力后, 模型性能均有所下降. 其中: 移除频率注意力的影响更为明显, 识别率降为 96.50% ± 0.86, 该结果表明频率注意力对于捕捉漏损特征的贡献更大; 而仅保留时间注意力时, 其性能在 F1 值指标下表现略优, 但是仍然不及完整结构; 完全去除注意力机制后, 模型性能略有下降, 但是仍然保持较高水平, 表明注意力机制对模型性能具有稳定提升作用, 尤其是在识别率方面提供了增强.

在输入特征方面, 仅使用线性谱图或仅使用对数梅尔谱图时, 模型性能均低于全部谱图组合. 具体而言, 仅使用线性谱图时其漏损识别率为 97.50% ± 1.36, 略优于仅使用对数梅尔谱图的 96.00% ± 0.95, 表明线性谱图所包含的高频信息对于漏损识别更加重要. 同时, 仅使用高时间或高频率分辨率谱图也

表6 HK-data 上消融实验对比

| 输入谱图      | 注意力机制  | 准确率/%               | 识别率/%               | 误警率/%              | F1值/%               |
|-----------|--------|---------------------|---------------------|--------------------|---------------------|
| 全部谱图      | 完整结构   | <b>99.09 ± 0.33</b> | <b>98.17 ± 0.66</b> | <b>0.00 ± 0.00</b> | <b>99.07 ± 0.33</b> |
| 全部谱图      | 仅时间注意力 | 99.00 ± 0.40        | 98.00 ± 0.80        | 0.00 ± 0.00        | 98.99 ± 0.41        |
| 全部谱图      | 仅频率注意力 | 98.25 ± 0.43        | 96.50 ± 0.86        | 0.00 ± 0.00        | 98.22 ± 0.44        |
| 全部谱图      | 无注意力机制 | 99.04 ± 0.44        | 98.08 ± 0.88        | 0.00 ± 0.00        | 99.03 ± 0.45        |
| 仅线性谱图     | 完整结构   | 98.46 ± 0.84        | 97.50 ± 1.36        | 0.58 ± 0.88        | 98.44 ± 0.84        |
| 仅对数梅尔谱图   | 完整结构   | 98.00 ± 0.47        | 96.00 ± 0.95        | 0.00 ± 0.00        | 97.96 ± 0.49        |
| 仅高时间分辨率谱图 | 完整结构   | 97.79 ± 0.48        | 95.75 ± 0.92        | 0.17 ± 0.35        | 97.75 ± 0.50        |
| 仅高频率分辨率谱图 | 完整结构   | 98.54 ± 0.74        | 97.17 ± 1.37        | 0.08 ± 0.26        | 98.52 ± 0.76        |

会导致性能下降, 其中高频谱图的漏损识别效果(识别率为 $97.17\% \pm 1.37$ )略优于高时间谱图( $95.75\% \pm 0.92$ ), 该结果进一步表明了频率维度的细粒度信息对于识别精度更为关键。

综上, 多分辨率谱图的融合输入配合并行的时间-频率注意力机制能够有效提升模型性能, 其中频率维度的建模对于漏损检测起到了更为关键的作用。

### 2.5 谱图抗噪声性能对比

背景噪声的干扰可能会削弱谱图中漏损特征的对比如, 从而减弱其与无漏损信号间的区分度。因此, 可以看到, 对比方法 TFCNN 和 Log PS-ResNet18 在谱图变换中均有自己的去噪声处理。为验证所提出谱图变换方案在抵抗噪声方面的能力, 本文在不同噪声环境下对 3 种谱图变换方案进行对比。实验针对 HK-data 的同一段时长为 1 s 的音频进行谱图变换, 并通过计算结构化信噪比 (SSNR) 和结构相似性指数 (SSIM), 量化不同谱图方案在噪声环境下的抗干扰能力。SSNR 用于衡量信号中有效信息的保真度, 值越大, 噪声对于有效信号的干扰越小; 而 SSIM 则用于量化谱图的结构相似性, 值越大, 谱图在噪声干扰下保持越高的结构一致性。

实验分别在原始音频中添加高斯白噪声和粉红噪声, 并将信噪比 (SNR) 设置为 10 dB、20 dB 和 30 dB, 以模拟不同强度的噪声干扰环境。其中: 高斯白噪声模拟传感器固有的随机噪声, 均匀分布在整个频谱; 粉红噪声则是模拟供水管网中的水流噪声、管道振动等实际工况。表 7 和表 8 分别为 3 个方案在 SSNR 和 SSIM 两个指标下的实验结果, 这里多幅谱图的方案输出为每幅谱图计算结果的平均值。

表7 不同噪声环境下各谱图方案 SSNR 值对比

| 算法              | 高斯白噪声/dB    |              |              | 粉红噪声/dB     |              |              |
|-----------------|-------------|--------------|--------------|-------------|--------------|--------------|
|                 | 10          | 20           | 30           | 10          | 20           | 30           |
| TFCNN           | 4.02        | 14.88        | 25.55        | 3.55        | 14.35        | 25.18        |
| Log PS-ResNet18 | 5.12        | 8.42         | 12.02        | 4.81        | 7.96         | 11.43        |
| MFAN            | <b>9.82</b> | <b>17.69</b> | <b>26.35</b> | <b>9.88</b> | <b>17.69</b> | <b>26.38</b> |

表8 不同噪声环境下各谱图方案 SSIM 值对比

| 算法              | 高斯白噪声/dB    |      |      | 粉红噪声/dB     |      |      |
|-----------------|-------------|------|------|-------------|------|------|
|                 | 10          | 20   | 30   | 10          | 20   | 30   |
| TFCNN           | 0.21        | 0.60 | 0.92 | 0.26        | 0.62 | 0.91 |
| Log PS-ResNet18 | 0.12        | 0.29 | 0.55 | 0.14        | 0.31 | 0.54 |
| MFAN            | <b>0.26</b> | 0.58 | 0.86 | <b>0.32</b> | 0.61 | 0.86 |

表 7 中, MFAN 方法在高斯白噪声和粉红噪声环境下均优于 TFCNN 与 Log PS-ResNet18。在高斯白噪声环境中, MFAN 的 SSNR 值随着信噪比的增

加稳定上升, 从 10 dB 下的 9.82 提升至 30 dB 下的 26.35, 表现出良好的噪声抑制能力。相比之下, TFCNN 与 Log PS-ResNet18 的 SSNR 值在相同条件下显著低于 MFAN, 尤其是在低信噪比 (10 dB) 情况下, MFAN 的 SSNR 值几乎为 TFCNN 的 2 倍, 且高于 Log PS-ResNet18, 表明 MFAN 在强噪声干扰下依然能够较好地保留信号的有效信息。

同样地, 在粉红噪声环境下, MFAN 的表现也占据优势。无论是 10 dB、20 dB 还是 30 dB, MFAN 的 SSNR 值均优于 TFCNN 与 Log PS-ResNet18, 尤其是在高信噪比情况下, MFAN 能够达到 26.38 的 SSNR, 表现出对噪声的强鲁棒性。相比之下, 尽管 TFCNN 与 Log PS-ResNet18 在高信噪比下有所提升, 但是, 其 SSNR 值始终低于 MFAN。

表 8 所示的 SSIM 值比较中, MFAN 也显示出较强的抗噪性。在高斯白噪声和粉红噪声环境下, MFAN 的 SSIM 值整体高于 TFCNN 与 Log PS-ResNet18, 尤其是在低信噪比 (10 dB) 条件下, MFAN 的 SSIM 值明显优于其他两种方法。这表明, MFAN 能够更好地保持谱图的结构一致性, 即使在噪声干扰较强的环境下, 也能较好地还原信号的关键特征。但是, MFAN 在 20 dB 和 30 dB 信噪比条件下, 其性能略逊于 TFCNN, 这可能是由于 MFAN 中的对数梅尔谱图通过对频谱进行对数变换来压缩幅度范围, 放大了部分低频噪声的影响。

两组对比实验表明, MFAN 在不同噪声环境下能够有效地保留信号的有效信息和结构特征, 验证了该方法在噪声环境中的鲁棒性和优势。

### 2.6 多水听器声信号融合的漏损检测

针对部署了多个水听器的供水管网, 漏损信号传播一段时间后, 所有水听器均可能接收到相同漏损信号的不同部分。尽管这些信号的频率特征可能相似, 但是, 每个水听器捕获的信号依然提供了额外的时频信息, 从而有助于提高漏损检测的准确性。因此, 在此情境下, 各水听器的信号可视为是同步的。针对这种情况, 本文提出一种多水听器声信号融合的漏损检测策略, 在构建谱图过程中将同一时刻的多源声信号谱图进行通道拼接, 作为卷积神经网络的输入来执行特征提取和漏损检测。

本文将所提出 MFAN 算法在 Lab-data 数据集上进行多水听器声信号融合的漏损检测实验。Lab-data 数据集提供了管网上的 2 个水听器数据。实验选取表 3 中的纵向裂缝漏损检测组, 管网为分支拓

扑结构,背景流量为 0.47 L/s. 10 次漏损检测实验的结果如图 3 所示. 图 3 结果显示,在融合了 2 个水听器数据构成双通道谱图输入后, MFAN 算法的漏损检测性能得到了有效提升,平均识别率达到了 97.78% 和误警率为 3.33%,且在 10 次实验中有 6 次实现了 100% 的漏损检出和 0 误警. 对比 MFAN 算法在表 3 中的实验结果,凸显了多个声信号融合漏损检测的优势.

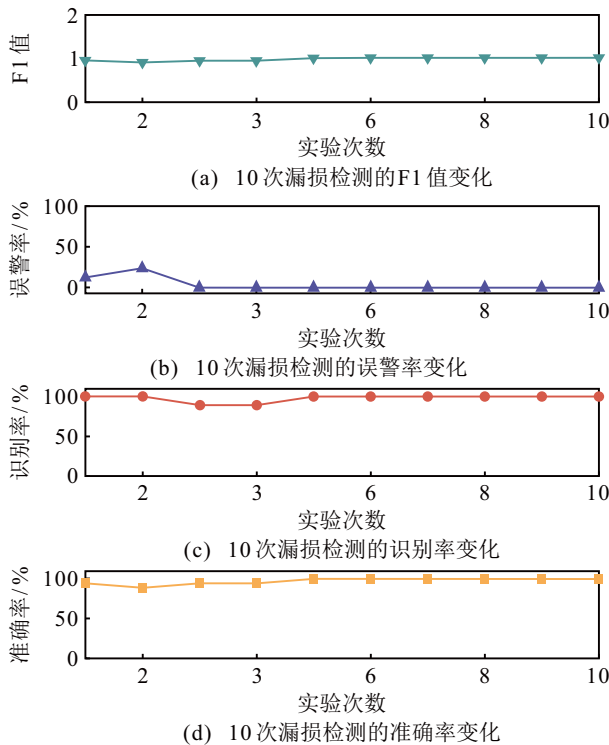


图3 MFAN 在多水听器声信号融合下漏损检测表现

### 3 结论

本文针对现有利用声学谱图的供水管网漏损检测算法存在迁移便捷性不足和谱图变换未能覆盖所有关键特征的问题,提出了基于构建多尺度特征谱图和并行时-频注意力机制的漏损检测方法. 在实验室采集数据和真实管网采集数据上开展了漏损检测实验. 实验结果显示,所提出 MFAN 算法展现了良好的鲁棒性和泛化能力,在真实采集据中的平均漏损识别率达到了 98.17% 以及 0 误警. 对比其他谱图变换, MFAN 基于声信号的多尺度特征谱图表现出了更佳的漏损检测性能,表明了所提出谱图变换策略有利于提升数据的表征能力并降低噪声干扰.

今后研究将针对噪声环境更复杂的情况进一步验证所提出算法的不足,结合多源多类别传感器数据提升漏损检测性能. 同时,开展算法复杂度的优化研究,降低对硬件的要求,使其更利于在巡检设备或远程监测管网中部署.

### 参考文献 (References)

- [1] 中华人民共和国住房和城乡建设部. 2023 年中国城市建设状况公报 [EB/OL]. (2024-10-29)[2025-04-02]. <https://www.mohurd.gov.cn/gongkai/fdzdgnr/sjfb/tjxx/>. (Ministry of Housing and Urban-Rural Development of the People's Republic of China. 2023 China urban construction status bulletin[EB/OL]. (2024-10-29)[2025-04-02]. <https://www.mohurd.gov.cn/gongkai/fdzdgnr/sjfb/tjxx/>.)
- [2] 刘书明. 科学开展漏损控制推进供水基础设施高质量发展[J]. 给水排水, 2022, 58(5): 125-127. (Liu S M. To promote water infrastructure high quality development by implementing leakage control[J]. Water & Wastewater Engineering, 2022, 58(5): 125-127.)
- [3] 陈国栋, 刘阔, 倪炯, 等. 不同地区 DMA 流量特征分析与漏失评估[J]. 给水排水, 2023, 59(4): 113-117. (Chen G D, Liu K, Ni J, et al. Flow characteristics analysis and leakage assessment for DMAs in different regions[J]. Water & Wastewater Engineering, 2023, 59(4): 113-117.)
- [4] Wu Y P, Liu S M, Smith K, et al. Using correlation between data from multiple monitoring sensors to detect bursts in water distribution systems[J]. *Journal of Water Resources Planning and Management*, 2018, 144(2): 04017084.
- [5] Sun Q S, Zhang Y J, Lu B L, et al. Flow measurement-based self-adaptive line segment clustering model for leakage detection in water distribution networks[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3510213.
- [6] McMillan L, Fayaz J, Varga L. Flow forecasting for leakage burst prediction in water distribution systems using long short-term memory neural networks and Kalman filtering[J]. *Sustainable Cities and Society*, 2023, 99: 104934.
- [7] 冯健, 张化光. 管道泄漏计算机在线检测系统及其算法实现[J]. 控制与决策, 2004, 19(4): 377-382. (Feng J, Zhang H G. On-line computer detecting system of pipeline leak and its algorithm[J]. Control and Decision, 2004, 19(4): 377-382.)
- [8] Yang L, Zhao Q. A BiLSTM based pipeline leak detection and disturbance assisted localization method[J]. *IEEE Sensors Journal*, 2022, 22(1): 611-620.
- [9] Cheng M L, Li J. Optimal sensor placement for leak location in water distribution networks: A feature selection method combined with graph signal processing[J]. *Water Research*, 2023, 242: 120313.
- [10] 李红艳, 常子峰, 史文韬, 等. 基于高程邻域信息的 FCM 算法管网漏损控制策略[J]. 控制与决策, 2025, 40(3): 946-954. (Li H Y, Chang Z F, Shi W T, et al. Network leakage control strategy based on high range neighborhood information based on FCM algorithm[J]. Control and Decision, 2025, 40(3): 946-954.)
- [11] Hu X, Han Y M, Yu B, et al. Novel leakage detection

- and water loss management of urban water supply network using multiscale neural networks[J]. *Journal of Cleaner Production*, 2021, 278: 123611.
- [12] 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*, 2021, 147(2): 04020101.
- [13] 张祎, 李素贞. 基于声-压信号融合的城市供水管道泄漏监测[J]. *仪器仪表学报*, 2024, 45(8): 69-76.  
(Zhang Y, Li S Z. Leakage monitoring of urban water supply pipelines based on fusion of acoustic-pressure signals[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(8): 69-76.)
- [14] Wu Y P, Ma X K, Guo G C, et al. Advancing deep learning-based acoustic leak detection methods towards application for water distribution systems from a data-centric perspective[J]. *Water Research*, 2024, 261: 121999.
- [15] 何立新, 张宏洋, 张峥, 等. 基于梅尔频率倒谱系数特征识别供水管网漏损的机器学习模型比较研究[J]. *给水排水*, 2024, 60(8): 137-143.  
(He L X, Zhang H Y, Zhang Z, et al. A comparative study of machine learning models for identifying water supply network leakage based on mel frequency cepstrum coefficient features[J]. *Water & Wastewater Engineering*, 2024, 60(8): 137-143.)
- [16] 陈炯禧, 王琦, 詹凡, 等. 基于 CNN 和 MFCC 的供水管网漏损声信号识别方法[J]. *中国给水排水*, 2024, 40(23): 13-19.  
(Chen J X, Wang Q, Zhan F, et al. A method for identifying leakage acoustic signals in water supply network based on CNN with MFCC[J]. *China Water & Wastewater*, 2024, 40(23): 13-19.)
- [17] Peng H, Xu Z, Huang Q L, et al. Leakage detection in water distribution systems based on logarithmic spectrogram CNN for continuous monitoring[J]. *Journal of Water Resources Planning and Management*, 2024, 150(6): 04024015.
- [18] 陈科, 姬梦晓, 于坤杰, 等. 基于贝叶斯优化与信号重构的旋转机械故障诊断[J]. *控制与决策*, 2026, 41(4): 1135-1142.  
(Chen K, Ji M X, Yu K J, et al. Fault diagnosis of rotating machinery based on Bayesian optimization and signal reconstruction[J]. *Control and Decision*, 2026, 41(4): 1135-1142.)
- [19] 吴鑫, 李靛杰, 魏建好. 融合双重注意力与多尺度级联网络的密集球团粒度测量方法[J]. *控制与决策*, 2025, 40(10): 3155-3166.  
(Wu X, Li L J, Wei J H. Dense pellet size measurement method integrating dual attention and multi-scale cascaded network[J]. *Control and Decision*, 2025, 40(10): 3155-3166.)
- [20] Wang H L, Zou Y X, Chong D D, et al. Environmental sound classification with parallel temporal-spectral attention[C]. *Proceedings of Interspeech*. Shanghai, 2020: 821-825.
- [21] Aghashahi M, Sela L, Banks M K. Benchmarking dataset for leak detection and localization in water distribution systems[J]. *Data in Brief*, 2023, 48: 109148.
- [22] Tijani I A, Tariq S, Zayed T, et al. Acoustic based data acquisition for leak detection of water distribution networks[EB/OL]. (2022-02-10)[2024-12-20]. <https://data.mendeley.com/datasets/hkn8mxcjyz/1>.
- [23] Liu R S, Zayed T, Xiao R, et al. Time-Transformer for acoustic leak detection in water distribution network[J]. *Journal of Civil Structural Health Monitoring*, 2025, 15: 759-775.
- [24] Liu F N, Wang D, Tang J Y, et al. Frequency-informed transformer for real-time water pipeline leak detection[J]. *Autonomous Intelligent Systems*, 2025, 5: 11.

## 作者简介

孙庆帅 (1994-), 男, 博士生, 主要研究方向为时间序列分析与预测、故障诊断, E-mail: [sunqs@hnu.edu.cn](mailto:sunqs@hnu.edu.cn);

张英杰 (1970-), 男, 教授, 博士, 主要研究方向为人工智能、智能控制、故障诊断、节能控制, E-mail: [zhangyj@hnu.edu.cn](mailto:zhangyj@hnu.edu.cn);

刘华亮 (1973-), 男, 高级工程师, 主要研究方向为水流量计量、智能控制、仪器仪表智能生产, E-mail: [15927631558@139.com](mailto:15927631558@139.com);

李述杰 (1999-), 男, 硕士生, 主要研究方向为人工智能算法及应用, E-mail: [lishujie@hnu.edu.cn](mailto:lishujie@hnu.edu.cn).