

DOI: 10.19650/j.cnki.cjsi.J2513959

# 基于次声波法的天然气管道小泄漏识别方法研究\*

花靖开, 郎究明

(辽宁石油化工大学信息与控制工程学院 抚顺 113001)

**摘要:**管道泄漏是一个不可避免的问题,然而天然气管道小泄漏存在信号微弱、易被强背景噪声淹没等问题,不及时处理会造成严重危害,所以及时准确识别是一项艰巨的挑战。故开展了一种基于迭代自更新多元变分模态分解结合小波能量变换和双通道神经网络的有效识别研究。首先,引入参数自更新的多元变分模态分解算法,通过双循环策略不断迭代调整内部模态数量与惩罚因子,实现了对多通道次声泄漏信号的自适应、高保真分解,有效避免了传统检测方式的模态混叠和参数依赖问题;然后,提出自适应连续小波变换增强策略,利用 K-means 将本征模态函数区分为高能泄漏分量与低能背景分量,并仅针对高能模态信号进行增强策略,同时保留了低能信号的特征完整,针对关键特征增强了信息提取能力;最后,将其输入到所设计的双通道神经网络中。其中高能通道集成了注意机制和最大池,以提高对重要特征的感知,低能通道使用大的感受野卷积来提取全局背景信息,将不同通道信息进行融合池化操作,利用双路径协同融合提升特征感知能力。最终对实验进行验证,针对小泄漏(孔径 $\leq 2$  mm)的识别准确率达到 97.1%,比传统检测方式主流提高了 10%,并且在跨场景迁移实验中保持了良好的性能与较短的推理时间,证明了其在实际工程应用中的有效性与鲁棒性。

**关键词:**天然气管道;小泄漏识别;次声波;能量选择

**中图分类号:** TH89 **文献标识码:** A **国家标准学科分类代码:** 460.40

## Research on small leakage identification method for natural gas pipeline based on subsonic wave method

Hua Jingkai, Lang Xianming

(School of Information and Control Engineering, Liaoning Petrochemical University, Fushun 113001, China)

**Abstract:** Pipeline leakage is an inevitable problem. However, the small leakage signals of natural gas pipelines are weak, which are inclined to be overwhelmed by strong background noises. The timely and accurate identification of leakage is a crucial and formidable challenge. Therefore, an effective leakage recognition research based on iterative self-updating multivariate variational mode decomposition combined with wavelet energy transform and dual-channel neural network was carried out in this study. Firstly, the MVMD algorithm with self-updating parameters is introduced. Specifically the number of internal modes and the penalty factor are continuously iteratively adjusted through a double-loop strategy, which realizes the adaptive and high-fidelity decomposition of multi-channel infrasonic leakage signals. This effectively avoids the modal aliasing and parameter dependence problems of conventional detection methods. Furthermore, an adaptive continuous wavelet transform enhancement strategy is proposed. Specifically the eigenmode functions are distinguished into high-energy leakage components and low-energy background components by using K-means method, where the enhancement strategy is only implemented for signals of high-energy mode and the feature integrity of low-energy signals is retained. Thereby, the information extraction ability of key features is enhanced. Finally, it is input into the designed dual-channel neural network. Specifically the high-energy channel integrates the attention mechanism and the Max pool to enhance the perception of important features. Meanwhile the low-energy channel utilizes a large receptive field convolution to extract the global background information and perform the fusion and pooling operations for information of different channels, and then utilizes the dual-path collaborative fusion to improve feature perception capabilities. Finally, the experiment was verified. The identification accuracy rate of small leaks (pore size  $\leq 2$  mm) reached 97.1%, which was 10% higher than that of the mainstream detection methods. Moreover, it maintained good

收稿日期:2025-04-22 Received Date: 2025-04-22

\* 基金项目:辽宁省自然科学基金项目(2023-MMS-289)、科技创新团队项目(LJ222410148036)资助

performance and a short reasoning time in the cross-scenario migration experiment, proving its effectiveness and robustness in the practical engineering applications.

**Keywords:** natural gas pipelines; small leak identification; infrasound waves; energy selection

## 0 引言

近年来,随着城市建设的加快,对天然气的需求增加,天然气管道建设规模也随之扩大。随之而来的问题是天然气管道的老化和腐蚀,其中最大的潜在危害是小泄漏(泄漏量 $\leq 1\%$ ,本研究中泄漏孔径 $\leq 2\text{ mm}$ ),其容易被忽视<sup>[1-3]</sup>。为了查明天然气管道小泄漏,人们做了很多努力。Yang等<sup>[4]</sup>使用漏磁检测方法引入膨胀卷积以扩大模型感知范围,并结合残留注意网络使模型聚焦于关键目标,在此基础上,通过将高分辨率特征与高语义特征相融合,最终实现了对小泄漏细节特征的精准捕捉与增强。多数小泄漏管道的声发射信号<sup>[5]</sup>特征表现为幅值变化小、突变点边界模糊,这不可避免地引入了定位误差。为克服此局限,基于数据驱动与模型驱动相结合的混合定位方法受到了研究界的广泛关注。超声导波技术被大量应用于管道腐蚀的检测与评估。王晓娟等<sup>[6]</sup>针对管道腐蚀造成的小缺陷,提出分形函数仿真模型,利用有限元进行仿真揭示小泄漏特征与信号的量化关系。在面对传统负压波处理小泄漏乏力的情况下,Wang等<sup>[7]</sup>利用负压波的衰减特性来精确定位微小泄漏,该方法将小泄漏问题转化为最优一致性问题,利用衰减的负压波在在幅度达成一致来确定,省去了收敛评估和距离问题的运算,降低了一定复杂性。天然气管道泄漏识别方法还有多种,如光纤传感器识别法<sup>[8]</sup>、气相色谱法<sup>[9]</sup>、次声法<sup>[10]</sup>等。每种方法都有自己的优点。其中,次声方法因其传播距离远、定位精度高等优点,作为一种新型有效的方法,得到了广泛的研究。

管道次声信号一般是非平稳和非线性的,即其频率内容随时间而变化。传统的傅立叶变换等方法在分析此类时变信号时存在一定局限性,其性能不如经验模态分解(empirical mode decomposition, EMD)<sup>[11]</sup>和变分模态分解(variational mode decomposition, VMD)<sup>[12]</sup>。基于模态分解的方法将次声分解为多个模态,称为内涵模态分量(intrinsic mode functions, IMF)。与EMD相比,VMD可以避免模态混叠,保持各模态的频率独立性,减少末端效应的影响。多元变分模态分解(multivariate variational mode decomposition, MVMD)<sup>[13]</sup>是针对多信号输入而设计的,它解决了多信号输入的问题。因此提出了改进的MVMD来解决手动参数设定问题。

同时为了解决处理复杂信号的挑战和潜在的迭代收敛问题,设计时引入了一种能量数据增强算法,该算法在

分解和特征提取阶段之间采用聚类结合连续小波变换(continuous wavelet transform, CWT)。这一创新旨在准确区分不同IMF所包含的信息意义。该方法利用适应Morlet基与CWT能量特征相结合进行数据增强。最初,K-means将IMF主要分为两类:高能模式和低能量模式。随后,专门利用CWT对噪声密集的高能模式进行针对性处理<sup>[14]</sup>。值得注意的是,许多学者已将基于能量的方法与深度学习相结合,应用于信号处理<sup>[15]</sup>,证实了其在信号分析中的有效性。本研究设计了一种基于改进的MVMD和双通道神经网络的天然气管道的小泄漏识别方法,能够对天然气管道的小泄漏进行准确诊断。针对传统方法的优点和不足进行了全新的设计,主要的工作的贡献为:

1)提出了一种改进的MVMD(迭代多元变分模态分解)方法,该方法结合迭代原理,建立了一种能够动态自调整的数学驱动模态分解算法。这种方法显著减少了训练时间,同时展示了增强的通用性和优越的分解效率。

2)实现选择性连续小波能量变换,对基函数进行频谱优化,增强了与低频次声信号的兼容性。该策略保留了部分数据集原始信息的完整性,同时针对性变换,从而增强了数据的真实性和频谱多样性。

3)设计了一种新的双通道神经网络体系结构,采用差异化的路径设计。高能通道:精确特征显著性映射的集成注意机制;低能量通道:捕捉整体的特征。现场试验验证了其95%的平均识别准确率,证明了其在作战场景中的强大实际适用性。

## 1 数据获取与小泄漏分析

### 1.1 实验数据介绍

为了验证所提出的方法,通过研究团队设计开发的泄漏模拟测试平台收集数据,如图1所示。这个装置包括通过在天然气管道上安装不同直径的出口封头来模拟管道泄漏。泄漏模拟装置的详细配置包括:1)2800 m长的天然气管道;2)L360MB材料;3)管道内径50 mm、壁厚3.8 mm、首站压力为0.8 MPa、末站压力为0.1 MPa、流量为7.5 m<sup>3</sup>/h;4)为了模拟不同的泄漏情况,沿管道安装了不同孔径(1、2、3和5 mm)的阀门;5)PCB106B次声传感器分别位于管道的起点和终点,在起点100 m处设置一个泄漏阀;6)数据通过NIDAQ9181采集,系统接口通过LABVIEW进行管理。传感器采用时间窗采样方式,以1000 Hz的采样率记录孔径为0~5 mm的泄漏信

号;7)每个样品的持续时间为5 s,每个泄漏尺寸总共有5 000个样品,总共有20 000个样品。

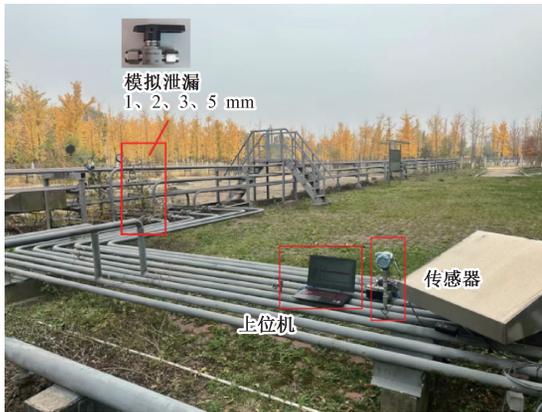


图1 实验现场工况

Fig. 1 Test site diagram

## 1.2 小泄漏分析

小泄漏与较大泄漏具有显著不同的特征。小泄漏通常单位时间内气孔小漏气量少,引起的流量和压力波动较小,允许的漏失时间相对较长;而较大泄漏往往伴随明显的流量和压力波动,对生活与生产影响较大,允许的漏失时间较短。因此,小泄漏检测更注重准确性,而较大泄漏检测则需同时兼顾准确性与实时性。然而,目前基于软件分析的检测方法多集中于较大泄漏的识别,对小泄漏的检测效果仍不理想,使得小泄漏检测成为该领域中的一个突出难点。

小泄漏产生的次声振动幅度通常远低于环境噪声,其信噪比(signal-to-noise ratio, SNR)定义如式(1)所示。

$$SNR_{dB} = 10 \lg \frac{P_{\text{signal}}}{P_{\text{noise}}} \quad (1)$$

其中,  $P_{\text{signal}}$  是信号功率,  $P_{\text{noise}}$  是噪声功率,在上述获取到的数据中(小泄漏),泄漏振幅通常仅为背景噪声幅度的10%~40%,导致其在时域中难以被直接观察。次声泄漏信号本质上属于0.5~10 Hz的窄带弱信号,但管道振动、环境扰动及设备运行所产生的低频噪声恰好在相同频段内具有更高能量,并呈现显著的随机波动。这种“频带重叠+能量对比度低”的环境使得基于固定阈值或能量突变的检测方法失效,因为泄漏信号既没有足够的能量优势,也缺乏明显的瞬时特征,难以在强噪声背景中被分离出来。

因此,在小泄漏条件下,识别的关键不在于直接提取信号幅值,而在于设计一种能够在强噪声背景下分离窄带微弱能量、抑制共频噪声并增强细微成分的方法。这也是进一步提出基于自适应分解、能量分组与深度网络融合的检测策略的理论动机所在;通过将混叠在同一频段的成分分离重构,再以多通道方式提取不同能量层级

的判别特征,克服传统方法在小泄漏场景下的可检测性瓶颈。

## 2 理论方法分析

### 2.1 基于迭代的自更新参数MVMD算法

假设信道维度为  $c$ , 信号采样点为  $N$ , 信号分解的IMF数为  $k$ , 对信号进行希尔伯特变换并转换成单边谱, 得到模态的解析信号如式(2)所示。

$$u_{k,c}^+(t) = \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_{k,c}(t) \right] \quad (2)$$

估计的中心频率  $e^{-j\omega_k t}$  随后被引入, 通过计算给定解调信号的范数平方  $L_2$  来构建约束模型。MVMD最小化所有信道和所有模式带宽的总和, 约束模型确保所有模式的总和等于目标信号, 如式(3)所示, 限制条件如式(4)所示。

$$\underset{|u_{k,c}^+|, |\omega_k|}{\text{minimize}} \left\{ \sum_k \sum_c \|\delta_t [u_{k,c}^+(t) e^{-j\omega_k t}] \|_2^2 \right\} \quad (3)$$

$$\sum_k u_{k,c}^+(t) = x_c(t), \quad c = 1, 2, \dots, c \quad (4)$$

MVMD作为一种完全非递归的分解模型,其性能在很大程度上依赖于两个预设参数——模态数量与惩罚系数。若模态数设定不当,容易引发模态丢失或模态混叠问题;同时,惩罚系数的选择也显著影响MVMD的分解效果,而该算法并未提供关于惩罚系数取值的明确指导原则。这些因素共同制约了MVMD方法的适用性。

此外,在优化求解初期,滤波器需要拥有较宽频带,以精准捕获中心模态;待优化进入末期,已得到的模态已收敛至期望值附近,此时则需收窄带宽,从而有效抑制噪声干扰。故而,在优化过程中动态更新带宽,是更为合理的策略<sup>[16]</sup>。

为克服局限并满足要求,进一步提升MVMD算法的实际应用效能,构建了一个变分优化问题。基于迭代的自更新算法构建了一个变分优化问题,通过优化MVMD来确保每一层/尺度模式的带宽之和最小化。基于式(3)和(4),构建了式(5)的新优化策略。然后,使用拉格朗日法和交替方向乘子法构建并求解优化参数,具体操作如下。

本研究所提出的MVMD优化策略如式(5)所示。

$$\underset{|u_{k,c}^+|, |\omega_k|}{\text{minimize}} \left\{ \alpha \sum_c \|\delta_t [u_{k,c}^+(t) e^{-j\omega_k t}] \|_2^2 + \sum_c \|x_c(t) - u_{k,c}(t) \|_2^2 \right\} \quad (5)$$

其中,在模式和通道计数分别用  $k, c$  表示的情况下,  $x_c(t)$  是每个通道对应的信号,  $\alpha$  是惩罚因子。新算法采用了维纳滤波器的思想。式(2)中的第1项对模态  $u_{k,c}(t)$  施加了平滑约束,该模式表示每层所有通道带宽的总和;第2项则表示每个通道中残余信号的总和。根

据模态  $u_{k,c}(t)$  和频率域中残余信号的正交性,可以推导出惩罚系数  $\alpha$  的更新公式。

上述约束问题是凸优化问题。为了解决这个问题,首先引入拉格朗日乘子法,然后加入两个惩罚项,将问题转化为无约束问题;一个二次项以提高信号重建的保真度,以及一个拉格朗日乘子  $\lambda$ , 确保约束条件严格满足。

基于拉格朗日变换的方程如式(6)所示。

$$L((u_{k,c}), (w_k), \lambda_c) = \alpha \sum_c \|\delta_t [u_{k,c}^+(t) e^{-j\omega_k t}]\|_2^2 + \sum_c \|x_c(t) - u_{k,c}(t)\|_2^2 + \sum_c (\lambda_c(t), x_c(t) - u_{k,c}(t)) \quad (6)$$

交替方向乘子法(alternating direction method of multipliers, ADMM)被引入以解决无约束变分问题,优化问题被转化为几个更简单的次优化问题。新的模态分量  $u_{k,c}(t)$ 、中心频率  $\omega_k$  和次声数据的惩罚系数  $\alpha$  的方程如式(7)~(9)所示。

模态分量:

$$u_{k,c}^{n+1}(\omega) = \frac{x_c(\omega)}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

中心频率:

$$\omega_k^{n+1} \leftarrow \frac{\sum_c \int_0^\infty \omega |u_{k,c}^{n+1}(\omega)|^2 d\omega}{\sum_c \int_0^\infty |u_{k,c}^{n+1}(\omega)|^2 d\omega} \quad (8)$$

惩罚系数:

$$\alpha_c^{n+1} = \alpha_c^n \frac{u_{k,c}^{n+1}(\omega)^* u_{k,c}^{n+1}(\omega)}{u_{k,c}^{n+1}(\omega)^* r_{k,c}(\omega)} \quad (9)$$

式中:“\*”表示该项最优解。

随着模态分量  $u_{k,c}(\omega)$ , 的不断更新,公式中分母的值逐渐减小,使得  $\alpha$  的值增加,随后模态带宽在更新过程中继续减小,满足上述带宽更新的要求。

该算法对原始 MVMD 的目标函数进行了改进,将原有的联合优化框架调整为递归优化框架。具体而言,基于迭代的自适应 MVMD 采用逐次提取的方式分离多变量调制振荡,而非同时提取所有模态。模态数量  $K$  不再需要预先指定,而是依据剩余信号的能量占比自适应确定。此外,基于迭代的自适应 MVMD 引入了基于模态正交性的带宽更新规则,使得各模态的带宽能够在优化过程中动态调整。

基于迭代的自适应 MVMD 算法采用双层循环结构:外循环通过剩余信号的能量占比自动确定模态数  $K$ , 其终止阈值可根据实际噪声水平灵活设定;内循环则与 MVMD 类似,主要负责模态分量、中心频率及其对应取值的迭代更新。

## 2.2 基于模态聚类分析的连续小波变换数据增强

原始数据信号经过改进的 MVMD 分解后,形成一系列的 IMF 和残差。高能模态可能与管道中的异常泄漏有

关,而低能模态可能是管道中的背景噪声,这代表了所描述的声信号与能量模态聚类之间的关系。进一步提出了一种基于 CWT 增强数据增强与模态聚类分析相结合的创新能源模态分类框架。

初始化过程从特征向量的形成开始,这些特征向量封装了来自每个 IMF 的特定尺度的能量分布,这些分布被系统地组织成一个特征矩阵,用于随后的模态能量聚类,如式(10)所示。

$$f_i = [EM_1, EM_2, \dots, EM_n] \quad (10)$$

随机初始化质心,并通过欧氏距离计算迭代更新质心的过程,如式(11)所示。

$$\mu_k = \frac{1}{N_k} \sum_{i \in C_k} f_i \quad (11)$$

其中,  $\mu_k$  为第  $k$  个质心,  $f_i$  为第  $i$  个 IMF 信号的特征向量,  $N_k$  为能量类  $C_k$  中的能量。

为了解决时域能量特征对高噪声环境固有的敏感性,采用连续小波变换对分类高能模态数据进行处理。CWT 框架可以实现瞬态信号变化的精确时间分辨率,同时通过频谱阈值在高频波段内实现选择性噪声衰减。每个高能模态都经过 CWT 处理,随后在多个尺度  $a$  和频带  $b$  上进行能量量化。控制这种转换的数学形式表示如式(12)和(13)所示。

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \tilde{x}(t) \cdot \Psi^*\left(\frac{t-b}{a}\right) dt \quad (12)$$

$$\psi(t) = \pi^{-\frac{1}{4}} \left( e^{\frac{-t^2}{2}} e^{i\omega_0 t} - e^{\frac{-\omega_0^2}{2}} e^{\frac{-t^2}{2}} \right) \times \Gamma(\omega_0, \sigma) \quad (13)$$

其中, \* 表示最优解,  $CWT(a, b)$  为信号在尺度和位置处的连续小波系数,表示信号在尺度  $a$  和位置  $b$  处的局部特征;  $x(t)$  为分解得到的高能信号;  $\psi(t)$  是针对次声信号的一种改进的 Morlet 小波基,它根据次声的低频特性消除了低频偏移。  $\Gamma(\omega_0, \sigma)$  表示针对次声信号保存优化的频谱整形算子,  $\omega_0 = 4$ 。

获取新集合如式(14)所示。

$$EM_{\text{new}} = (EM_h, EM_l) \quad (14)$$

## 2.3 改进的双通道神经网络

当原始信号经改进的 MVMD 分解并按能量模式分类时,高能数据输入通道 1,低能数据输入通道 2。提出的改进的双通道神经网络架构如图 2 所示。

通道 1 由 3 个特征信息提取模块和两个注意力模块(convolutional block attention module, CBAM) 注意机制模块组成。在该模块中,特征信息模块取代了传统的卷积层。其原理是利用小卷积核提取信号中突出而重要的特征表达式,泄漏导致声信号发生突然而剧烈的变化。因此,使用最大池化来强调局部重要特征的保留。增加了卷积注意模块,使模型能够自适应地学习特征的重要性,改进特征表达。

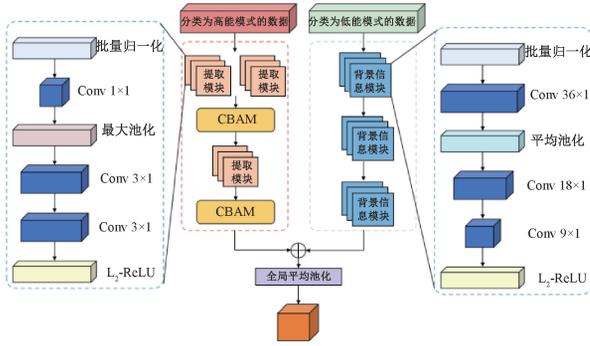


图2 改进的双通道神经网络架构

Fig. 2 Improved dual-channel neural network architecture

在通道2中,构建了一个大的感受野多层神经网络进行处理。为了有效地提取低能量模式的背景信息,采用了平均池化方法。通道2采用的平均池化可以有效地捕捉平滑特征,保留缓慢、细微的变化,与通道1不同,通道1只有3个背景信息提取模块,没有添加注意机制。为了提取背景信息,该模块还首先在头文件中执行批处理规范化,然后执行 $36 \times 1$ 卷积块和平均池化操作。随着卷积块的叠加,灵敏度场逐渐减小到 $18 \times 1$ 和 $9 \times 1$ 。最后,将两个渠道的数据合并为全局平均池。数据经过全局平均池化层处理后,输入Softmax激活函数进行分类。具体来说,将管道泄漏故障分为3种不同的状态:无泄漏、小泄漏和大泄漏。

改进后的双通道神经网络在TensorFlow和Python 3.8上实现,并在基于AMD Ryzen 9 7900X 12核处理器4.70 GHz和64 GB RAM的Windows工作站上进行了网络的训练和测试。

### 3 实验验证

#### 3.1 改进的MVMD有效性验证

首先,将所设计的改进MVMD分解速度与现有的六种新算法(粒子群优化<sup>[17]</sup>、鸚鵡优化<sup>[18]</sup>、鲸鱼优化<sup>[19]</sup>、灰狼优化<sup>[20]</sup>、减法平均优化<sup>[21]</sup>和麻雀搜索<sup>[22]</sup>)进行了比较,并对这些算法进行了统一的迭代训练。得到训练好的模型后,与改进的MVMD的分解速度进行比较。将每种算法分解10次取平均值进行比较,结果如表1所示。

这些模型的分解速度几乎相同,但改进的MVMD在迭代训练时节省了时间,可以大大提高其优势。此外,由于基于深度学习的方法依赖于大量的训练数据,在某些情况下无法获得大量的故障信息,这是一个明显的局限性。

从实验数据中随机选取一个小泄漏(2 mm)次声信号作为分解实例。得到类似如图3所示的结果。

表1 不同算法的信号分解速度

Table 1 Signal decomposition time

模型	分解时间/s
改进的MVMD	34
粒子群优化	41
鸚鵡优化	29
鲸鱼优化	41
灰狼优化	30
减法平均优化	32
麻雀搜索	40

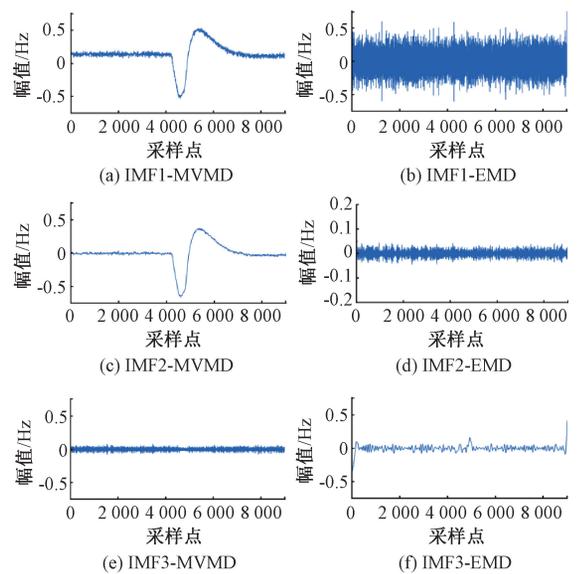


图3 单次分解对比

Fig. 3 Comparisons of single decomposition with different methods

图3(a)、(c)、(e)显示的是新方法(改进的MVMD分解),没有状态混叠和信号失真,成功地实现了对原始信号的高效分解。图3(b)、(d)、(f)为EMD分解的结果,显示了非常清晰的模式混叠。通过对比进一步验证了该方法的有效性。

#### 3.2 IMF聚类分析

验证了基于能量模式的聚类方法的有效性。首先利用实验平台获得的泄漏声信号数据进行模态分解和聚类分析,得到初始聚类分析数据集。原始数据包含多个特征,使用主成分分析来减少其他特征的影响,特别关注能量特征,其中能量模态参数设置为0.5。实验结果如图4所示,验证了能量模态聚类方法可以更好地形成高能模态特征和低能模态特征。

低能模态特征是具有背景信息和非重要特征的声信号的集合。经过实验中的聚类分析,可以发现低能模式

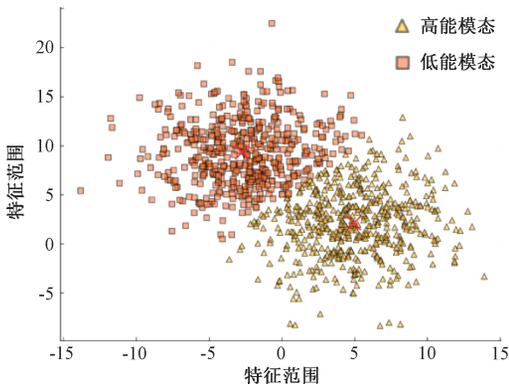


图 4 聚类后 IMF 模态能量分布

Fig. 4 Energy distribution of clustered IMF modal

基本聚在左侧,而高能模式相对松散,但大部分聚在右侧,这可以初步证明基于能量聚类的有效性。

为了进一步证明利用能量指标识别小泄漏的优越性,将通过与其他时域信号的能量对比证明。列举了均值、方差、峰度、偏度和能量的计算结果,并比较了它们的特征值。根据如表 2 所示的计算方法,  $h_i$  为 IMF 信号的第  $i$  个样本值,  $h(t)$  为 IMF 信号的样本总数,  $h(t)$  为 IMF 信号在  $t$  时刻的值,  $E[ \sim ]$  为期望运算。

表 2 不同计算方法

Table 2 Calculation methods for different

序号	特征	计算公式
1	均值	$\mu_h = \frac{1}{N} \sum_{i=1}^N h_i$
2	方差	$Var = \frac{1}{N} \sum_{i=1}^N (h_i - \mu_h)^2$
3	峰度	$kurtosis = \frac{E[(h(t) - \mu_h)^4]}{E[(h(t) - \mu_h)^2]^2}$
4	偏度	$Skewness = \frac{E[(h(t) - \mu_h)^3]}{E[(h(t) - \mu_h)^2]^{\frac{3}{2}}}$
5	能量	$Energy = \frac{1}{N} \sum_{i=1}^N h_i^2$
6	变换后能量	$E_{CWT}(i, a) = \sum_{b=1}^N  CWT(a, b) ^2$

每种泄漏情况从实验数据中选取 10 个数据点进行计算,并加入小泄漏孔径和大泄漏孔径进行对比。

对于每组数据,为了统一维度,对计算数据进行归一化,便于观察情况。图 5 为不同泄漏情况下的特征值对比图。如图 5 所示,随着泄漏孔径的变化,这 6 项指标均呈增大趋势。与其他特征值相比,小波变换后的能量和

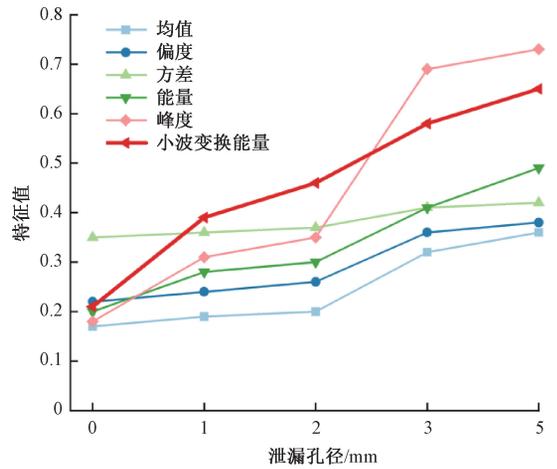


图 5 归一化后不同特征值的比较

Fig. 5 Comparison of different normalized eigenvalues

峰度变化更为明显。如图 6 所示为连续小波变换后的高能部分。

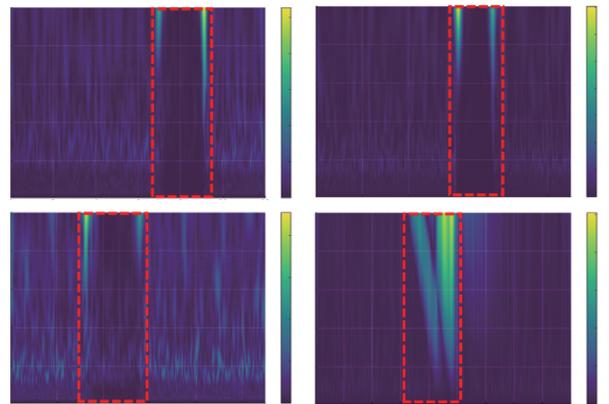


图 6 突出高能特征

Fig. 6 Highlighted high energy features

而在泄漏孔径为 2 mm 时,虽然小波变换后方差值大于能量特征,但方差特征总体上几乎是平坦的,无法通过方差来区分大值和小值的泄漏情况。对于小泄漏,变换能量的变化大于峰度的变化,因此综合考虑后,采用能量作为小泄漏信号特征提取的指标。

### 3.3 泄漏试验对比

实验使用实验室采集的 20 000 组数据,包括 7:2:1 的训练集、验证集和测试集。批大小为 32,学习率设置为 0.001 来训练网络,每 20 次迭代学习率减半,训练的总迭代次数为 100 次。图 7 显示了经过 100 次迭代训练后的准确率和损失曲线。图 7 中从第 20 次迭代开始,训练集的学习效果趋于稳定,平均准确率可以达到 97.22%,损失函数的变化也趋于稳定。经过 100 次迭代,使用测试集测试网络识别能力。

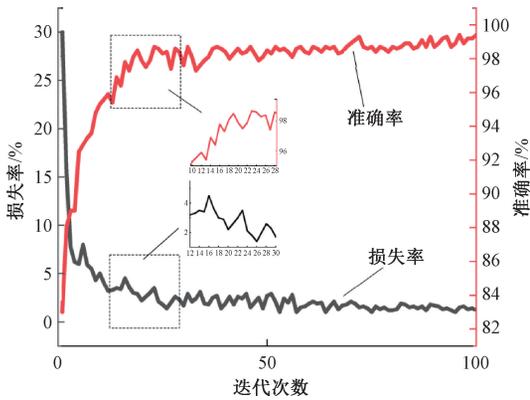


图7 训练集的准确率和损失率。

Fig. 7 The accuracy and loss rate of the training set.

混淆矩阵结果如图8所示。它展示了该方法如何预测不同大小的泄漏。图8中,0、1、2、3、5 mm 分别代表对应的漏径,其中0 mm 代表无漏。

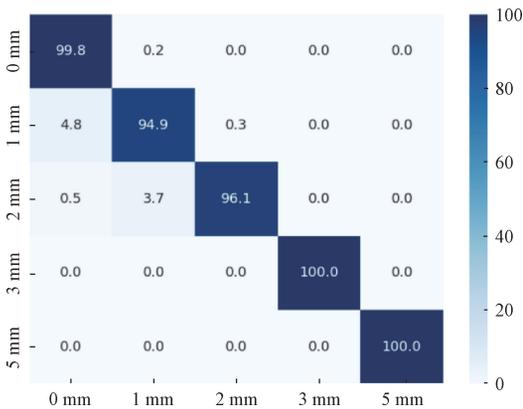


图8 测试集的混淆矩阵。

Fig. 8 Confusion matrix of the test set

根据混淆矩阵,该网络对较大泄漏的识别率可以达到100%,对无泄漏情况的识别率几乎为100%。然而,小泄漏的识别准确率仍然不足,但仍然可以达到94.9%以上。从两个方面总结这些问题的原因,即:

- 1) 迭代次数不足,或者优化器不合理;
- 2) 小泄漏和无泄漏具有相似的数据特征,导致识别错误。

为了进一步证明所研究模型的有效性,进行了消融实验和对比实验。在消融实验中,将新采集的数据作为输入信号,并进行了10次测试,以获得最佳结果进行对比。如表3所示为消融实验及其结果的对比。

以上消融实验表明,使用模态分解和连续小波变换可以有效地优化信号特性,并且改进的MVMD分解策略在复杂信号处理中具有突出的作用。双通道神经网络的双通道设计通过高能量和低能模态特征的融合进一步提

表3 消融实验

Table 3 Ablation experiment

模型	能量变换	识别网络	$F_1$
改进的MVMD	✓	双通道神经网络	0.893
改进的MVMD	✓	1D-CNN	0.814
改进的MVMD	—	1D-CNN	0.636
—	—	1D-CNN	0.624
EMD	—	双通道神经网络	0.666
EMD	✓	双通道神经网络	0.791
原始MVMD	—	双通道神经网络	0.767
原始MVMD	✓	双通道神经网络	0.829

高了模型的分类精度和鲁棒性。相比之下,不使用分解策略或仅使用传统一维卷积(1D convolutional neural network, 1D-CNN)的实验组表现明显较差,凸显了解析与特征分类协同优化的重要性。在此,进一步验证了所提出的双通道神经网络的性能,并通过消融实验进行了探索,评估了高能量和低能通道对模型性能的贡献,如表4所示。

表4 双通道神经网络下消融实验比较

Table 4 Comparison of ablation experiments

实验组	评价指标	
	准确率/%	时间/ms
完整模型	97.6	45
单一高能通道	87.3	35
单一低能通道	84.7	30
无注意力机制	89.0	43
随机分解	81.0	28

如表4所示,消融实验验证了高、低能模式双通道神经网络设计的有效性。结果表明,双通道设计可以显著提高分类性能,高能模式下的注意机制和低能量模式下的多尺度感受野设计分别在特征增强和多样化特征捕获中发挥关键作用。此外,高、低能模式分解策略的使用优于随机分解,进一步证明了合理分解对特征提取的价值。

在对比实验中,将该方法与其他的一维时间序列故障诊断方法改进多尺度网络(improved multiscale network, IMSN)<sup>[23]</sup>、残差卷积自编码(residual convolutional auto encoder, RCAE)<sup>[24]</sup>、第三代生成对抗网络(style generative adversarial networks 3, StyleGAN3)<sup>[25]</sup>和隐写分析网络(symbolic regression network, SRNet)<sup>[26]</sup>进行了比较。以上模型稍作修改,适用于管道泄漏识别。类似地,每个模型测试了100次迭代,并对得到的结果进行了比较。小泄漏的验证精度如图9所示。

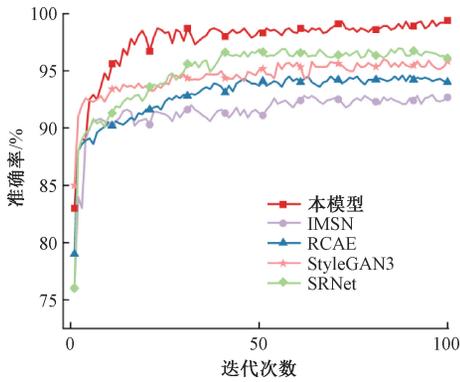


图9 不同模型经过100次迭代训练后的准确率

Fig. 9 Accuracy of different models after 100 iterations of training

图9显示本研究与其他4种方法相比在识别小泄漏方面的优势(这里没有其他显示,仅显示小泄漏的准确性)。大多数传统方法在正常无泄漏状态和对大泄漏的诊断中具有较高的准确性,但对小泄漏不是很敏感。因此,这些实验现象直观地证明了所设计的方法优越性,以及增强有用信息和挖掘低价值信息的能力。与其他网络模型相比,改进的MVMD+改进的双通道神经网络具有更好的特征学习性能,可以达到满意的识别精度,满足工程测试的需要。

### 3.4 迁移实验

为了证明模型在实际场景中的应用效果,使用从某公司收集了小泄漏数据,如图10所示。



图10 管道公司现场

Fig. 10 Field experiment at the pipeline company

这些数据是在4种不同的压力下收集的。该管线管道长度为5322 m,内径为100 mm,管内流体流量为100 m<sup>3</sup>/h。管路内压力设置为1和1.5 MPa。泄漏孔径设置为2和5 mm。在不同压力和泄漏孔径下获得4个数据集:数据1(1 MPa, 2 mm)、数据2(1 MPa, 5 mm)、数据3(1.5 MPa, 2 mm)和数据4(1.5 MPa, 5 mm)。每个数据集共采集2500个样本,得到10000个样本的数

据集。训练集、验证集和测试集的比值分别为7:2:1,学习率设为0.001。经过30次训练,得到如表5所示。

表5 迁移实验准确率

Table 5 Accuracy rate of migration experiment

数据组	IMSN	RCAE	SRNet	本方法 (%)
1	86.2	91.1	93.1	94.2
2	90.4	94.7	95.0	96.4
3	84.6	92.8	93.2	95.4
4	89.3	95.7	95.4	97.5

在迁移实验中4种方法的平均时间分别为49、60、58和43 ms,并且如表5所示,所提方法在迁移学习实验中仍然表现良好,在4种不同的实验条件下,其平均识别准确率超过其他方法。更重要的是,该方法的推理时间短;精度有很大提高,进一步验证了小波能量变化分类机制和所提出的双通道网络在提高化工管网泄漏分析能力方面的有效性。

## 4 结论

针对天然气管道小泄漏识别难题,本研究提出了一种融合迭代自更新多元变分模态分解、小波能量聚类与双通道神经网络的智能诊断方法。该方法通过改进的MVMD算法有效克服了传统模态分解中的模态混叠与参数依赖问题,实现了对次声泄漏信号的自适应高效分解。在此基础上,采用基于能量聚类的连续小波变换增强策略,区分并强化了高能泄漏特征与低能背景信息,显著提升了信号特征质量。进一步设计了双通道神经网络结构,通过差异化路径分别处理高、低能量模态,结合注意力机制与大感受野卷积,实现了对微弱泄漏信号与复杂背景信息的协同感知与特征融合。实验结果表明,该方法在小泄漏识别任务中准确率达到97.1%,显著优于传统方法。

尽管所提方法取得了良好诊断效果,仍存在一定局限性。模型性能在一定程度上依赖于次声传感器的布置与采集环境,面对不同管材、管径或敷设条件的管道时,声波传播特性的差异可能影响模型适用性,需进一步验证。此外,改进的MVMD提升了分解效率,但结合双通道神经网络的整体模型在训练与推理过程中仍具有较高计算开销,可能限制其在资源受限的边缘设备上的部署应用。

未来研究将聚焦于模型轻量化与实际部署,通过模型剪枝、量化等技术优化算法结构,推动其在嵌入式硬件平台上的落地,实现管道监测的实时化与边缘智能化。

此外,针对工业场景中泄漏样本稀少的问题,将探索小样本学习或自监督预训练策略,以降低模型对大量标注数据的依赖,提升其在真实环境中的适应能力。

## 参考文献

- [1] 郑书闽,颜建国,郭鹏程,等. 基于VMD及深度学习的供水管道小尺度泄漏检测研究[J]. 水利学报, 2024,55(8):999-1008.  
ZHENG SH M, YAN J G, GUO P CH, et al. Small-scale pipeline leak detection based on VMD and deep learning[J]. Journal of Hydraulic Engineering, 2024, 55(8):999-1008.
- [2] 黄海东,张志雄,宋丰轩,等. 一种适用于独立计量分区的小泄漏检测方法[J]. 中国给水排水, 2022, 38(15):37-42.  
HUANG H D, ZHANG ZH X, SONG F X, et al. A method for small leakage detection in district metering area[J]. China Water & Wastewater, 2022,38(15):37-42.
- [3] 梁伟,张来斌,王朝晖,等. 输油管道小泄漏诊断和漏点定位研究[J]. 石油机械,2004(12):39-41,3.  
LIANG W, ZHANG L B, WANG ZH H, et al. Research on pipeline small leakage detection and localization[J]. China Petroleum Machinery, 2004(12):39-41,3.
- [4] YANG L J, WANG ZH J, GAO S W. Pipeline magnetic flux leakage image detection algorithm based on multiscale SSD network [J]. IEEE Transactions on Industrial Informatics, 2020, 16(1):501-509.
- [5] CAI Y J, SANTOS R B, GIVIGI S N, et al. A pipeline leak classification and location estimation system with convolutional neural networks [J]. IEEE Systems Journal, 2020, 14(3):3072-3081.
- [6] 王晓娟,杨帆,王错,等. 面向超声导波检测的管道腐蚀建模及仿真实现[J]. 仪器仪表学报,2023,44(5):71-80.  
WANG X J, YANG F, WANG C, et al. Pipeline corrosion modeling and simulation for guided-waves-based inspection[J]. Chinese Journal of Scientific Instrument, 2023, 44(5):71-80.
- [7] WANG T B, ZHANG H G, HU X G, et al. Optimal consensus of attenuated negative pressure waves for pipeline small leakage localization[J]. IEEE Transactions on Instrumentation and Measurement, 2024,73:3470251.
- [8] 王大伟,封皓,杨洋,等. 基于 $\Phi$ -OTDR 光纤传感技术的供水管道泄漏辨识方法[J]. 仪器仪表学报,2017, 38(4):830-837.  
WANG D W, FENG H, YANG Y, et al. Study on leakage identification method of water supply pipeline based on  $\Phi$ -OTDR optical fiber sensing technology [J]. Chinese Journal of Scientific Instrument, 2017,38(4):830-837.
- [9] LI M, LIU B, CHEN T T, et al. On-site leakage locating of underground natural gas pipeline based on Ne tracer by miniature time-of-flight mass spectrometry[J]. Talanta, 2023, 254:124170.
- [10] 尹渊博,李玉星,杨文,等. 成品油管道泄漏次声波监测及信号处理方法[J]. 油气储运,2024,43(8):905-915.  
YIN Y B, LI Y X, YANG W, et al. Study on infrasonic leakage monitoring and signal processing for product oil pipeline[J]. Oil & Gas Storage and Transportation, 2024, 43(8):905-915.
- [11] GE L, YUAN X F, XIAO X T, et al. Acoustic location echo signal extraction of buried non-metallic pipelines based on EMD and wavelet threshold joint denoising[J]. Journal of Measurement Science and Instrumentation, 2024,15(4):417-431.
- [12] 马亮,安腾飞,刘文黎,等. 基于声信号的给水管微小泄漏检测技术研究[J]. 电子测量与仪器学报,2024, 3(12):113-123.  
MA L, AN T F, LIU W L, et al. Research on small leakage detection technology of the pipeline based on acoustic signals [J]. Journal of Electronic Measurement and Instrumentation, 2024,3(12):113-123.
- [13] REHMAN N U, AFTAB H. Multivariate variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2019, 67(23):6039-6052.
- [14] YANG L, DUAN R K, KANG T, et al. Iterative Morlet wavelet with SOSO boosting strategy for impulsive feature extraction[J]. Measurement, 2022,193:110965.
- [15] 席剑辉,修文斌,刘艳梅,等. 基于改进VMD的管道声发射信号去噪算法[J]. 管道技术与设备, 2024(6):31-36.  
XI J H, XIU W B, LIU Y M, et al. Improved VMD-based noise reduction algorithm for pipeline acoustic emission signals [J]. Pipeline Technique and Equipment, 2024(6):31-36.
- [16] CHEN SH Q, YANG Y, PENG ZH K, et al. Adaptive chirp mode pursuit: Algorithm and applications [J]. Mechanical Systems and Signal Processing, 2019, 116:566-584.
- [17] 吴泽民,周临风,冷建成. 基于粒子群优化 LSTM 模型的管道应力预测方法[J]. 压力容器,2021,38(8):76-80.  
WU Z M, ZHOU L F, LENG J CH, et al. Pipeline stress prediction method based on LSTM model optimized

- byparticle swarm [J]. Pressure Vessel Technology, 2021, 38(8):76-80.
- [18] 孙姿姣,周湘贞,李松洋. 鹈鹕算法参数优化 VMD 联合 SVDS 的电机轴承故障诊断[J]. 机械设计, 2025, 42(4):150-155.  
SUN Z J, ZHOU X ZH, LI S Y. Bearing fault diagnosis of electric machinery based on VMD with parameters optimized by pelican optimization algorithm (POA) and singular value difference spectrum (SVDS) [J]. Journal of Machine Design, 2025, 42(4):150-155.
- [19] 杨远鹏,陈志刚,余志红,等. 基于 WOA-VMD 与 PSO-SVM 的滚动轴承故障诊断[J]. 制造技术与机床, 2025(2):23-29, 42.  
YANG Y P, CHEN ZH G, YU ZH H, et al. Fault diagnosis of rolling bearings based on WOA-VMD and PSO-SVM [J]. Manufacturing Technology & Machine Tool, 2025(2):23-29, 42.
- [20] 郑晓亮,谢晓贤,王强. 基于灰狼优化的埋地管道泄漏双波谱定位方法[J]. 仪器仪表学报, 2022, 43(8):204-214.  
ZHENG X L, XIE X X, WANG Q. Grey wolf optimization based buried pipe leak localization using dual-wave spectrum [J]. Chinese Journal of Scientific Instrument, 2022, 43(8):204-214.
- [21] TROJOVSKY P, DEGHANI M. Subtraction-average-based optimizer: A new swarm-inspired metaheuristic algorithm for solving optimization problems[J]. Biomimetics, 2023, 8(2):149.
- [22] 肖述辉,杜传甲,王成军. 改进麻雀搜索算法优化 BP 神经网络管道腐蚀速率预测模型[J]. 油气储运, 2024, 43(7):760-768, 795.  
XIAO SH H, DU CH J, WANG CH J. Pipeline corrosion rate prediction model using BP neural network based on improved sparrow search algorithm [J]. Oil & Gas Storage and Transportation, 2024, 43(7):760-768, 795.
- [23] HU ZH X, WANG Y, GE M F, et al. Data-driven fault diagnosis method based on compressed sensing and improved multiscale network [J]. IEEE Transactions on Industrial Electronics, 2019, 67(4):3216-3225.
- [24] YU J B, ZHOU X R. One-dimensional residual convolutional autoencoder based feature learning for gearbox fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(10):6347-6358.
- [25] 乔通,陈彧星,谢世闯,等. 多色彩通道特征融合的 GAN 合成图像检测方法[J]. 电子学报, 2024, 52(3):924-936.  
QIAO T, CHEN Y X, XIE SH CH, et al. GAN synthetic image detection using fused features in the multi-color channels [J]. Acta Electronica Sinica, 2024, 52(3):924-936.
- [26] MIAO M Q, SUN Y H, YU J B. Deep sparse representation network for feature learning of vibration signals and its application in gearbox fault diagnosis [J]. Knowledge-Based Systems, 2022, 240:108116.

### 作者简介



花靖开, 2019 年于沈阳大学获得学士学位, 现为辽宁石油化工大学信息与控制工程学院硕士研究生, 主要研究方向为管道泄漏检测。

E-mail: liuleyipi@163.com

**Hua Jingkai** received his B.Sc. degree from Shenyang University in 2019. He is currently a master's student in the School of Information and Control Engineering at Liaoning Shihua University. His main research interest is pipeline leakage detection.



郎宪明(通信作者), 分别于 2010 年和 2015 年于辽宁石油化工大学获学士学位和硕士学位, 2018 年于西北工业大学获得控制理论与控制工程博士学位, 现为辽宁石油化工大学副教授, 主要研究方向为管道泄漏检测。

E-mail: langxianming@lnpu.edu.cn

**Lang Xianming** (Corresponding author) received his B.Sc. and M.Sc. degrees both from Liaoning Shihua University in 2010 and 2015, respectively, and his Ph.D. degree from Northwestern Polytechnical University in 2018. Currently, he is an associate professor at Liaoning Shihua University. His main research interest is pipeline leakage detection.