

DOI: 10.13382/j.jemi.B2407651

# 基于声信号的给水管微小泄漏检测技术研究\*

马亮 安腾飞 刘文黎 李德恩

(华中科技大学土木与水利工程学院 武汉 430074)

**摘要:** 为了有效解决管道泄漏信号难以从复杂背景噪声中分离以及微小泄漏特征提取困难的问题,提出一种基于VMD和ELM的管道微小泄漏工况识别的方法。首先,利用霜冰优化算法RIME改进VMD的关键参数选取,实现VMD的自适应分解。采用VMD分解产生的各阶本征模态函数之间的互信息熵值作为RIME算法参数优化中的适应度函数值,选择最佳的VMD分解参数,建立基于RIME-VMD的管道泄漏信号去噪方法。在此基础上,计算得到的滤波信号的Bubble熵值,实现对管道微小泄漏特征提取的目的。最终,将特征输入到RIME-ELM模型中进行,实现了4种不同管道工况的识别。实验结果表明,RIME-VMD方法在滤波效果方面表现优异,其信噪比最高,达23.922 dB,说明其滤波后的重构信号中有效信号的占比最大。同时,该方法的平均绝对误差和均方误差分别为0.187和0.056,均为最小值,表明该方法重构信号中的噪声最少。将得到的故障特征向量输入到RIME-ELM模型后,分类准确率达到95.71%,相比将故障特征向量直接输入ELM模型提高了37.4%,验证了所提出方法的有效性。

**关键词:** 管道泄漏检测;变分模态分解;霜冰优化算法;Bubble熵;极限学习机

**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 560.5510

## Research on small leakage detection technology of the pipeline based on acoustic signals

Ma Liang An Tengfei Liu Wenli Li Deen

(School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract:** To address the challenge of separating pipeline leakage signals from complex background noise and the difficulty of extracting small leakage features, a denoising method that uses the RIME to improve VMD is proposed. This method calculates the Bubble entropy value of the denoised signal for feature extraction, and then identifies the small leakage condition of the pipeline using an improved ELM optimized by RIME. First, RIME is used to improve the selection of key parameters for VMD, achieving adaptive decomposition. The mutual information entropy value between the IMFs generated by VMD is used as the fitness function value in the parameter optimization of the Rime algorithm, establishing a denoising method for water pipeline leakage signals based on RIME-VMD. Experiments have shown that compared to other heuristic optimization algorithms, the RIME-VMD method has the highest SNR of 23.922 dB, indicating that the reconstructed signal filtered by this method has the highest proportion of effective signal. The RIME-VMD method also has the lowest MAE and MSE, at 0.187 and 0.056 respectively, indicating that the reconstructed signal contains the least noise. Second, a method for extracting features from pipeline micro leakage signals using Bubble entropy is proposed, and these features are input into a model with ELM parameters optimized by RIME for pipeline leakage detection. Ultimately, the classification accuracy of the RIME-ELM model reached 95.71%, which is a 37.4% improvement compared to directly inputting fault feature vectors into the ELM, verifying the effectiveness of the proposed method.

**Keywords:** pipeline leakage detection; variational mode decomposition; rime optimization algorithm; bubble entropy; extreme learning machine

收稿日期:2024-07-05 Received Date: 2024-07-05

\* 基金项目:“十四五”国家重点研发计划(2023YFC3805802)项目、国家自然科学基金面上项目(72171094)、国家自然科学基金重大项目(52192664)、湖北省社会科学基金法治湖北专项预立项课题预立项项目资助

## 0 引言

近年来,随着城市化进程的加快和人口的持续增长,城市给水管道的铺设长度不断增加。然而现有的城市给水管网在一些地区存在老化和损坏的问题,导致管道泄漏现象频繁发生。城市给水管道的泄漏是水资源浪费的重要原因,由其引发的城市道路塌陷也会对人民生命和财产安全构成威胁<sup>[1-2]</sup>。对于城市给水管道的运维而言,如何及时且有效地检测出给水管道的微小泄漏成为亟需解决的研究问题。

目前,国内外学者对管道泄漏声波检测方法的进行了大量研究。2023 年 Hou 等<sup>[3]</sup>提出了改进的 MPA-VMD 算法,利用海洋捕食者算法寻找 VMD 中的两个重要参数——分解层数  $K$  和惩罚因子  $\alpha$ ,再利用动态熵选择有效模态。2023 年 Jiang 等<sup>[4]</sup>提出了基于变分模态分解 (variational mode decomposition, VMD) 和 Hilbert 变换的降噪算法,首先利用 VMD 将泄漏信号分解为若干个本征模态函数 (intrinsic mode functions, IMFs),确定分解层数,再用 Hilbert 变换对噪声进行初步过滤,最后利用滤波技术和互相关算法对噪声进一步滤除。2023 年张勇等<sup>[5]</sup>首先提出了一种基于 GAHE-VMD 与 SVD-SCEC 的管道信号联合去噪法,首先通过 GAHE 算法改进 VMD 算法,用以初步去除信号中的中高频噪声,同时解决 VMD 参数难以确定和传统遗传算法收敛慢的问题,再采用 SVD 结合 SCEC 算法进一步去除信号中的中低频噪声,克服了非线性和非平稳信号中直流分量对奇异值选择影响的问题。2023 年刘建锋等<sup>[6]</sup>使用遗传算法来优化 VMD 参数选取,然后将 VMD 分解后的相关模态使用小波阈值法去除残余噪声,选择并提取降噪漏磁场信号的特征向量,将特征向量输入到改进 ELM 中进行训练和分类,实现了故障诊断。2023 年 Lu 等<sup>[7]</sup>提出了利用参数优化变分模态分解对煤矿送风管道振动信号进行分解去噪,再提取多尺度熵值并将其输入 ELM 进行训练和测试,最终 ELM 模型表现出的测试准确率达到 94.17%。

综上所述,国内外学者处理管道泄漏声信号的研究上已有一定的成果,但在如何进一步提升管道泄漏检测的准确性、可靠性和鲁棒性方面仍有较大的研究空间。现有研究主要集中在传统的信号分解与特征提取方法上,然而这些方法在应对复杂背景噪声时的效果有限,无法有效区分大孔径和小孔径下的供水管道泄漏。为此,本文通过比选多种优化算法,选取出滤波效果表现最好的霜冰优化算法 (rime optimization algorithm, RIME) 改进的 VMD 算法进行信号去噪,有效提高信号去噪的精度和效率。此外,采用 Bubble 熵作为信号特征提取的指标,

构建故障特征向量,捕捉微小泄漏的特征信息,然后结合 RIME 优化极限学习机 (extreme learning machine, ELM) 的隐藏层节点数选取,使得模型在微小泄漏工况识别方面的性能得到显著提升。

## 1 基于 RIME 优化的 VMD 滤波方法

### 1.1 模拟实验平台

为进行管道泄漏检测研究,搭建如图 1 所示的管道实验平台。该平台由实验管道、抽水泵机、水听器 and 示波器组成。其中,实验管道为硬聚氯乙烯 (PVC) 管,内径 250 mm,可承受 0~2 MPa 的大气压强。分别在管道两端开设了由球形阀控制的进水出水口,并在管道实验区段开设最大孔径为 10 mm 的可调节式泄漏孔。实验采用的两个抽水泵机均为凌霄 CMI3 系列不锈钢卧式多级离心泵,最大运行环境温度 50℃,最大运行压力 8 MPa,满足给水管道的模拟实验要求。实验数据通过与水听器相连的 TBS 1102X 数字示波器显示,并采用触发采集传输至 LSWL-10SC2.0-2 软件保存在电脑硬盘中。



图 1 管道实验平台

Fig. 1 Pipeline experimental platform

通过水听器采集了给水管道的正常、敲击、小孔径泄漏和大孔径泄漏 4 种工作状态各 200 组的音频信号,其中正常信号在管道内部无泄漏且不含泵机噪声干扰的情况下采集到的,作为基准参考信号。

### 1.2 VMD 算法初步验证

VMD 是一种先进的信号分析方法,旨在改进经验模态分解 (empirical mode decomposition, EMD) 中出现的模态混叠问题<sup>[8]</sup>。VMD 通过对信号进行变分模式分析,将其分解为若干个本征模态函数  $u_k(t)$ ,每个 IMF 代表信号的一个不同频率成分  $\omega_k$ <sup>[9]</sup>。这些模态分量的集合能够更好地表示原始信号的内在结构,并且每个分量都是平滑的基带信号<sup>[10]</sup>。其具体计算流程如下:

1) 定义一个变分问题,目标是最小化所有模态分量的带宽之和,同时保证各模态分量之和等于原始信号。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中:  $\partial_t$  表示对  $\partial$  的偏导数;  $u_k(t)$  表示第  $k$  个模态函数。

2) 利用拉格朗日乘子求解给定的约束优化问, 并将其转换为无约束问题。

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = \\ \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - u_k(t) \rangle \end{aligned} \quad (2)$$

3) 利用交替方向乘子法对无约束问题进行求解。这涉及到迭代更新每个模态分量  $u_k(t)$  和拉格朗日乘子  $\lambda(t)$ , 以及中心频率  $\omega_k$ 。

4) 在每次迭代中, 根据当前的  $\omega_k$  和  $\lambda(t)$ , 更新模态分量  $u_k(t)$ 。

$$u_k^{(n+1)}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

5) 更新每个模态分量的中心频率  $\omega_k$ 。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

6) 迭代直至收敛: 重复上述更新步骤, 直到满足收敛条件, 即当  $u_k(t)$  和  $\lambda(t)$  的变化小于预设的收敛阈值  $\varepsilon$  时, 停止迭代。

为了初步验证所选取算法的可行性利用 3 个幅值和频率互不相同的正弦波组成的信号进行仿真实验, 其中, 3 个正弦波的具体频率分别为 5 Hz、50 Hz 和 250 Hz。为了模拟真实环境中的数据噪声, 在信号中加入高斯白噪声, 其强度设定为 0.05。通过此设置, 旨在验证 VMD 算法在处理含噪仿真数据时的有效性和可靠性。仿真中生成的原始信号遵循式(5)的定义, 含噪信号遵循式(6)的定义。

$$f(t) = \sin(10\pi t) + 1/4\sin(100\pi t) + 1/8\sin(500\pi t) \quad (5)$$

$$f(t) = \sin(10\pi t) + 1/4\sin(100\pi t) + 1/8\sin(500\pi t) + \delta \quad (6)$$

原始信号与含噪信号  $f(t)$  时域图对比如图 2 所示。由于含噪信号  $f(t)$  由频率为 5 Hz、50 Hz 和 250 Hz 3 个正弦波以及一个白噪声共同构成, 将分解层数  $K$  设定为 4, 惩罚因子  $\alpha$  为默认值 600。将仿真信号输入到 VMD 算法后, 得到了如图 3(a) 所示的各模态分量时域图和图 3(b) 所示的各模态分量频域图。


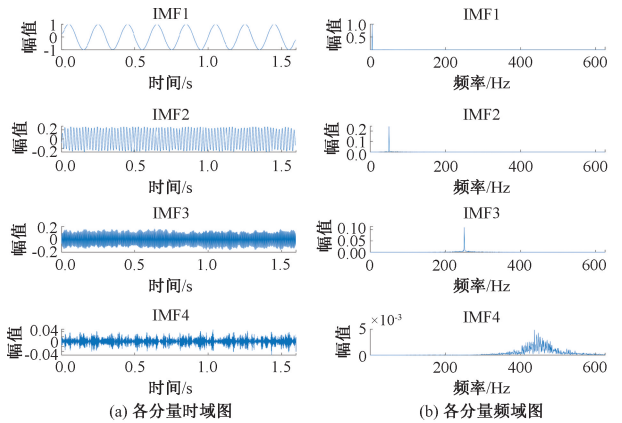


图 2 原始信号与含噪信号时域图

Fig. 2 Time domain plot of original and noisy signals



(a) Time-domain plots of each IMF (b) Frequency-domain plots of each IMF

图 3  $f(t)$  经 VMD 分解后各模态分量时域图和频域图

Fig. 3 Time-domain and frequency-domain plots of each mode component after VMD decomposition of  $f(t)$

根据图 3 可知, 原始信号中 3 种正弦信号均被完整地分离出来。经过对信号的处理, 移除了失真程度较高的第 4 个分量, 并仅选取前 3 个分量进行了信号的重构。如图 4 所示为重构信号  $f_1(t)$  与原始纯净信号对比, 两种信号时域图重合度较高, 证明了 VMD 在处理平稳信号方面表现良好。




图 4 原始信号与重构信号对比

Fig. 4 Comparison of original signal and reconstructed signal

然而,在 VMD 算法的计算过程中,需要提前设定两个关键参数:惩罚因子  $\alpha$  和分解层数  $K$ 。 $K$  值决定了分解后产生的模态分量的个数, $K$  的值过小可能导致有效信息无法全部分离, $K$  的值过大可能导致出现虚假模态<sup>[11]</sup>。惩罚因子  $\alpha$  对分量的带宽产生影响,合理的  $\alpha$  值可以提升 VMD 的分解效果,否则可能导致信号中部分有用信息的丢失<sup>[12]</sup>。因此,只有选择适当的参数,才能确保 VMD 算法在信号分解方面的效果达到最佳<sup>[13]</sup>。

### 1.3 霜冰优化算法改进 VMD

霜冰优化算法是一种基于自然界霜冰生长过程的启发式优化算法<sup>[14]</sup>。该算法通过模拟霜冰的软霜和硬霜两种不同的生长过程,以此设计出软霜搜索策略和硬霜穿刺机制,来进行全局优化搜索。它包括初始化、搜索策略、穿透机制和选择机制等多个步骤。以下是 RIME 算法的主要步骤和相关公式:

1) 初始化种群:算法首先初始化一个称为霜冰种群的集合。每个个体(霜冰晶体)在解空间中随机生成,并被赋予一个初始位置和适应度。

2) 软霜搜索策略:这一策略模拟了软霜冰晶在低风速环境中随机且广泛地生长,用于算法的全局搜索。软霜策略有助于算法在早期迭代中快速覆盖整个搜索空间,以减少陷入局部最优的可能性。其公式表示为:

$$R_{new} = r_l \cdot \cos(h) \cdot (b \cdot h \cdot (U_b - L_b) + L_b) + R_{best} \quad (7)$$

式中: $R_{new}$  是新的位置, $R_{best}$  是当前种群中最好的解, $r_l$  是  $[-1, 1]$  范围内的随机数, $h$  是与迭代次数相关的调整系数, $b$  是环境因子, $U_b$  和  $L_b$  分别是解空间的上、下界。

3) 硬霜穿刺策略:硬霜策略模拟高风速条件下硬霜的快速定向生长,主要用于算法的局部搜索。通过在已知最优解周围进行细致的搜索,提高解的精确度。

$$R_{new} = R_{best} \text{ if } r_3 < F_{norm}(S_i) \quad (8)$$

式中: $r_3$  是  $[0, 1]$  范围内的随机数, $F_{norm}(S_i)$  是个体适应度的归一化值。

4) 更新和选择:算法更新种群中的个体,根据生成的新解和当前解的比较结果决定是否接受新解。

RIME 优化 VMD 算法的性能取决于适应度函数的选取,互信息熵(mutual information entropy, MIE)是衡量两个随机变量之间共享信息量的一个度量<sup>[15]</sup>。在 VMD 分解的过程中互信息熵表示两个 IMF<sub>s</sub> 包含彼此信息的多少,互信息值越小,表示两模态分量的相关性越低,各模态分量之间越独立<sup>[16]</sup>。各分量的互信息熵表达式如式(9)所示。

$$I(X;Y) = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log\left(\frac{p(x,y)}{p(x)p(y)}\right) \quad (9)$$

式中: $X$  和  $Y$  为随机变量, $p(x,y)$  是联合分布概率, $p(x)$  和  $p(y)$  分别是它们的边际分布概率。

互信息熵的优点在于它对于样本大小的变化和数据中的噪声具有相对较高的鲁棒性,既适用于离散型变量,也适用于连续型变量,是一种非常通用的相关性度量方法。因此使用互信息熵作为霜冰优化算法的适应度值,使得该算法不依赖于特定的信号模型或假设,具有较强的适应性。得到的基于 RIME 优化的 VMD 滤波方法如图 5 所示,RIME-VMD 方法的伪代码如图 6 所示。

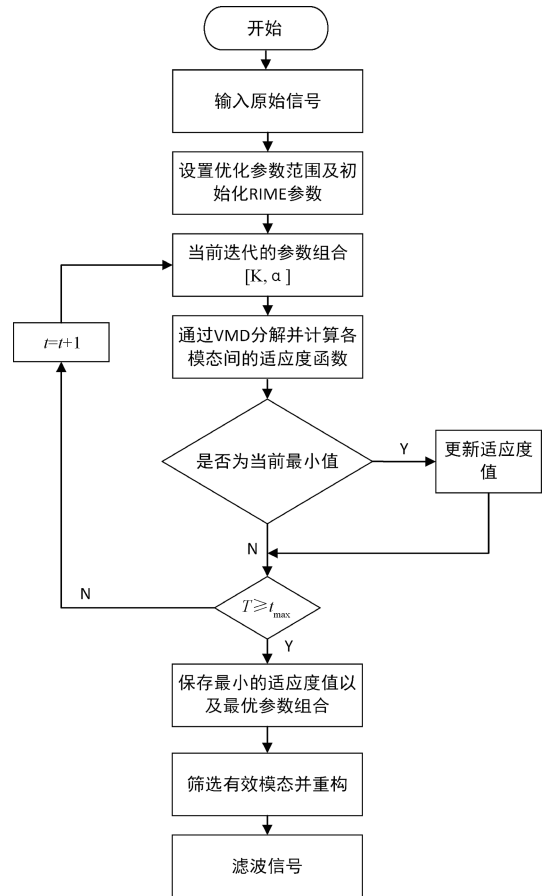


图 5 RIME 改进 VMD 去噪流程

Fig. 5 RIME improved VMD denoising process

算法1: RIME-VMD

初始化RIME算法参数,选择互信息熵作为适应度函数;

初始化RIME种群参数;

while  $t \leq T$  do:

黏附系数  $E = \sqrt{\frac{t}{T}}$

if  $r_2 \leq E$  then

    利用软霜搜索策略更新代理位置

end

if  $r_3 \leq F_{norm}(S_i)$  then

    使用硬霜穿刺机制更新最优解

end

if  $R_{new} \leq F(R_i)$  then

    使用积极贪婪机制更新最优解

end

$t = t + 1$

end

Output:  $K$ 和 $\alpha$ 的最优组合

应用变分模态分解

图 6 RIME-VMD 方法伪代码

Fig. 6 Pseudocode of the RIME-VMD method



### 1.4 RIME-VMD 算法处理管道泄漏信号

本节选取管道大孔径泄漏信号输入到 RIME-VMD 算法中进行去噪处理,其中管道泄漏信号的时域图和频域图如图 7 所示。




图 7 管道原始泄漏信号时域图和频域图  
Fig. 7 Time domain and frequency domain plots of original pipeline leakage signals

将原始信号输入到 RIME-VMD 算法程序中,设置  $K$  和  $\alpha$  的取值范围分别是  $[2, 10]$ 、 $[100, 7\ 000]$ ,初始化最大迭代次数为 10,种群规模为 10,VMD 分解得到各模态分量的样本熵作为适应度函数,经过 14.6 s 的迭代寻优,优化出的分解层数和惩罚因子收敛结果为  $K=8$  和  $\alpha=736$ ,互信息熵适应度函数收敛曲线如图 8 所示,分解得到如图 9(a) 所示的各模态时域图和图 9(b) 所示的各模态频域图。

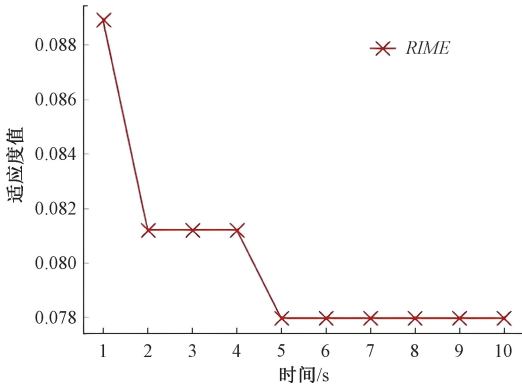


图 8 原始信号互信息熵最佳适应度曲线  
Fig. 8 Optimal fitness curve of mutual information entropy of the original signal

据图 8 可知,RIME-VMD 算法在第 5 次迭代时,更新出了对应最小互信息熵值的最佳群体,并将该群体对应的参数值作为 VMD 的最佳参数组合。根据图 9 可知,RIME-VMD 按照中心频率由高到低将原始信号依次分解为 8 个 IMF<sub>s</sub>,其中 IMF<sub>1</sub>、IMF<sub>2</sub>、IMF<sub>3</sub> 分解效果较好,没有

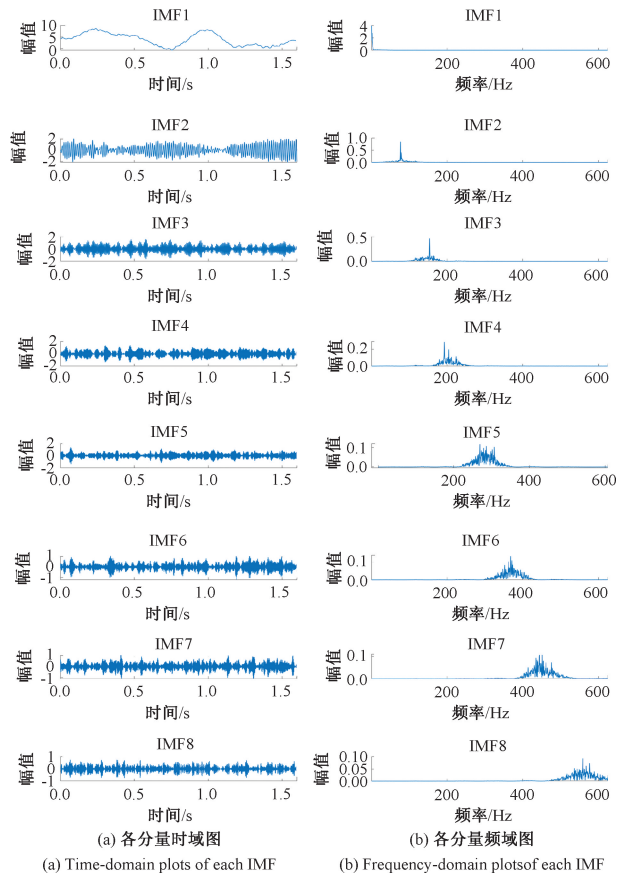


图 9 各模态的时域图和频域图  
Fig. 9 Time domain and frequency domain plots of each mode

出现模态混叠的现象。然后将出现模态混叠的中高频信 IMF<sub>4</sub>、IMF<sub>5</sub>、IMF<sub>6</sub>、IMF<sub>7</sub>、IMF<sub>8</sub> 去除,得到滤波信号。根据图 10 可知,原始泄漏信号中幅值较大的噪声信号被去除,初步验证了本节采取的 RIME-VMD 去噪算法处理实际的管道泄漏信号效果较好。




图 10 管道原始泄漏信号与重构泄漏信号对比图  
Fig. 10 Comparison plot of original pipeline leakage signal and reconstructed leakage signal

为了验证本章 RIME 霜冰优化算法的有效性和优越性,利用表 1 所示的多种元启式优化算法对 VMD 进行优化。将原始信号依次输入到表中的各种启发式优化算法中,进行 VMD 参数的优化选取。

表 1 各种启发式优化算法

**Table 1 Various heuristic optimization algorithms**

类别	优化方法
生物启发算法	GA(遗传优化算法,1975)、SMA(黏菌优化算法,2020)
	HHO(哈里斯鹰优化算法,2019)、CoatiOA(浣熊优化算法,2023)、SCSO(沙丘猫群优化算法,2022)、SSA(麻雀搜索算法,2020)、STO(西伯利亚虎优化算法,2022)
群体优化算法	SeaHO(海马优化算法,2022)、ServalOA(山猫优化算法,2022)、TDO(袋獾优化算法,2022)、TSO(金枪鱼优化算法,2021)、WaOA(海象优化算法,2022)
物理启发算法	HGS(饥饿游戏搜索算法,2021)、TWO(拔河优化算法,2016)
人类启发算法	WSO(战争策略优化算法,2022)、HCO(人类构想优化算法,2022)
数学启发算法	GBO(基于梯度的优化算法,2020)、PSS(帕累托最优性算法,2021)、CGO(混沌博弈优化算法,2021)
音乐启发算法	HS(和声搜索算法,2001)
系统启发算法	WCA(水循环优化算法,2012)、AEO(人工生态系统优化算法,2019)

为了证明提出的基于 RIME 优化的 VMD 算法去噪性能表现最好,将该算法与其他的优化算法进行比较,将同一种管道泄漏原始信号输入到各种算法中得到滤波信号。采用信噪比(signal-to-noise ratio, SNR)、平均绝对误差(mean absolute error, MAE)以及均方误差(mean squared error, MSE)3个评价指标对优化算法的去噪效果进行量化分析,采用满足收敛条件时的收敛时间、迭代次数和惩罚因子  $\alpha$  的变异系数3个评价指标对优化算法在优化过程中的表现进行量化分析,其结果如表 2 所示,SNR 的对比图如图 11 所示,MAE 和 MSE 的对比图如图 12 所示。




图 11 重构信号信噪比对比图

Fig. 11 Comparison plot of SNR of reconstructed signals

表 2 评价指标对比

Table 2 Denoising evaluation metrics SNR, MAE, MSE

优化算法	SNR/dB	MAE	MSE	收敛时间/s	迭代次数	变异系数/%
<b>RIME</b>	<b>23.922</b>	<b>0.187</b>	<b>0.056</b>	<b>19.71</b>	<b>5</b>	<b>7.48</b>
GA	18.955	0.351	0.175	41.78	8	11.72
HHO	22.85	0.212	0.071	66.23	8	9.92
CoatiOA	22.917	0.211	0.071	34.3	7	10.34
SCSO	23.221	0.204	0.065	22.1	6	12.31
GBO	22.873	0.212	0.071	23.6	5	19.88
PSS	18.662	0.363	0.187	65.78	6	27.12
HGS	23.331	0.201	0.064	20.11	6	29.94
SSA	23.294	0.202	0.065	28.2	5	17.29
CGO	22.858	0.213	0.072	66.11	9	11.33
SMA	18.726	0.361	0.185	49.81	6	20.05
TWO	18.707	0.361	0.186	30.3	6	13.89
STO	22.852	0.213	0.072	29.71	7	8.45
SeaHO	19.515	0.329	0.154	58.57	8	8.23
ServalOA	22.858	0.213	0.072	32.89	6	15.61
TDO	23.248	0.203	0.065	23.49	8	9.43
TSO	8.687	0.362	0.187	113.02	8	20.49
WaOA	2.985	0.209	0.069	37.38	5	25.45
WarSO	21.754	0.253	0.092	31.04	5	23.77
HCO	23.835	0.191	0.057	33.6	5	24.28
HS	18.646	0.364	0.189	10.61	8	30.89
WCA	18.661	0.363	0.188	10.08	8	19.95
AEO	23.141	0.209	0.067	34.59	7	28.74

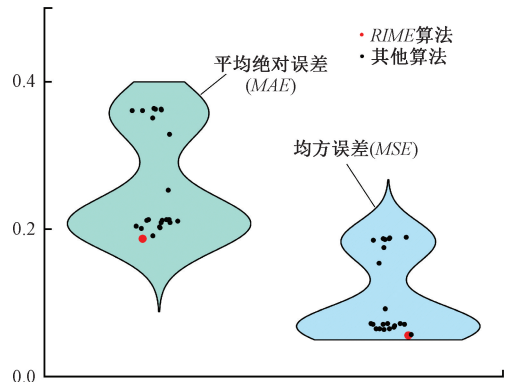


图 12 重构信号平均绝对误差和均方误差对比图

Fig. 12 Comparison plot of MAE and MSE of reconstructed signals

由表 2 可以看出,多种优化算法对比中,RIME 在收敛速度最快、迭代次数最小和变异系数最小,说明 RIME-VMD 方法具有更高的计算效率和稳定性。由图 11 可以看出 RIME-VMD 的 SNR 最大,说明利用经 RIME-VMD 方法滤波的得到的重构信号中有效信号的占比最大。而由图 12 可知,RIME-VMD 的 MAE、MSE 最小,说明重构信号中包含的噪声最小。由此可知,本章所提的 RIME-VMD 算法具有最佳的信号去噪能力和优化能力,验证了

RIME-VMD 应用在管道泄漏信号相对于其他算法去噪的优越性。

## 2 基于 Bubble 熵与 RIME-ELM 的识别方法

Bubble 熵是基于条件排列熵和 Reniy 排列熵而提出的,它通过冒泡排序算法来评估时间序列数据的复杂性和不规则性<sup>[17]</sup>。Bubble 熵的计算涉及以下几个步骤:

### 1) 时间序列的重构

将原始时间序列  $X = \{x_1, x_2, \dots, x_N\}$  通过嵌入过程转换为向量。这涉及选择一个嵌入维度  $m$  和时间延迟  $\tau$ , 从而创建一系列重构的向量。这些向量表示为:

$$Y_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad (10)$$

其中,  $i = 1, 2, \dots, N - (m - 1)$ 。

### 2) 向量的排序和匹配

对于每个嵌入维度  $m$ , 将通过计算任意两个重构向量之间的最大距离来确定它们是否匹配。这个过程涉及冒泡排序算法, 其中计算向量之间的距离并根据距离阈值  $\tau$  判断它们是否匹配。

### 3) 匹配向量的计数和概率计算

为每个嵌入维度  $m$  和  $m + 1$  计算匹配的向量对数量, 从而得到匹配的概率  $p_m$  和  $p_{m+1}$ 。

$$p_m = \frac{\text{Number of matching pairs for } m}{\text{Total possible pairs}} \quad (11)$$

### 4) Bubble 熵的计算

利用两个连续嵌入维度  $m$  和  $m + 1$  的匹配概率, 计算 Bubble 熵。

$$B(m, r) = -\log\left(\frac{p_{m+1}}{p_m}\right) \quad (12)$$

式中:  $B(m, r)$  表示给定阈值  $r$  和嵌入维度  $m$  下的 Bubble 熵值。

ELM 算法的核心思想是利用随机生成的输入权重和偏置, 通过线性输出权重的计算, 快速地训练单隐层前馈神经网络<sup>[18]</sup>(SLFN)。与传统的基于梯度下降的反向传播算法不同, ELM 不需要对隐藏层的权重进行迭代调整, 从而显著提高了训练速度, 这样做大大简化了训练过程, 并且降低了运算复杂性<sup>[19]</sup>。

所提的 RIME-ELM 模型产参数设置及调优过程如下:

#### 1) 数据预处理

数据集首先经过预处理, 包括归一化处理以确保模型输入的一致性。使用 mapminmax 函数将所有特征缩放到  $[-1, 1]$  区间内

#### 2) ELM 模配置

使用 Sigmoid 函数作为激活函数, 因其在分类任务中通常能提供良好的非线性数据映射能力; 数据随机分为

训练集和测试集两部分, 训练集与测试集的比例为 7 : 3, 以验证模型在未见数据上的表现。

### 3) RIME-ELM

采用 RIME 霜冰优化算法对极限学习机的关键超参数隐藏层节点数  $\beta$  进行优化选取, 其中以模型分类准确率作为适应度函数进行迭代寻优, RIME-ELM 的伪代码如图 13 所示。

```

算法2: RIME-ELM
初始化RIME算法参数, 选择分类准确率作为适应度函数;
初始化RIME种群参数;
while t ≤ T do:
    黏附系数 E = √(t/T)
    if r₂ ≤ E then
        | 利用软霜搜索策略更新代理位置
    end
    if r₃ ≤ F^{norm}(S_i) then
        | 使用硬霜穿刺机制更新最优解
    end
    if R_t^{new} ≤ F(R_t) then
        | 使用积极贪婪机制更新最优解
    end
    t = t + 1
end
Output: 最优隐藏层节点数β
应用极限学习机
    
```

图 13 RIME-ELM 方法伪代码

Fig. 13 Pseudocode of the RIME-ELM method

对于去噪后的信号特征困难和工况难以识别的问题, 提出了利用 Bubble 熵的对管道微小泄漏信号进行特征提取, 并将其输入到 RIME 优化 ELM 参数选取的模型中进行管道泄漏检测的方法, 如图 14 所示。其具体步骤如下:

步骤 1) 在不同工况下使用水听器对管道的声信号进行采集;

步骤 2) 根据所提的 RIME-VMD 的信号去噪方法进行去噪处理。利用 RIME-VMD 算法确定关键参数  $[K, \alpha]$ , 并应用到 VMD 算法进行分解, 获取原始泄漏信号的多个模态分量, 进行重构得到滤波信号;

步骤 3) 计算经过滤波处理后重构信号的 Bubble 熵值, 作为表征管道泄漏的特征向量;

步骤 4) 将步骤 3) 得到管道泄漏特征向量输入到 ELM 模型中进行管道工况识别, 利用 RIME 算法对 ELM 的隐藏层节点数  $\beta$  进行优化, 采用分类准确率作为适应度函数, 选择出分类准确率最高的种群对应的参数作为 ELM 的最佳隐藏层节点数  $\beta$ , 降低主观因素的影响, 最后并输出识别结果。

## 2.1 基于 Bubble 熵的特征提取方法

首先, 对本研究提出的 Bubble 熵针对噪声的鲁棒性进行初步验证。对式(5)的仿真信号增添不同分贝的高斯白噪声, 计算含噪声的复合信号的 Bubble 熵值并与原始信号的 Bubble 熵值对比, 鲁棒性验证曲线如图 15 所示。

由图 15 可以看出, 含噪信号的 Bubble 熵在噪声分贝较低(0~70 dB)时, 与原始信号的 Bubble 熵的一致性

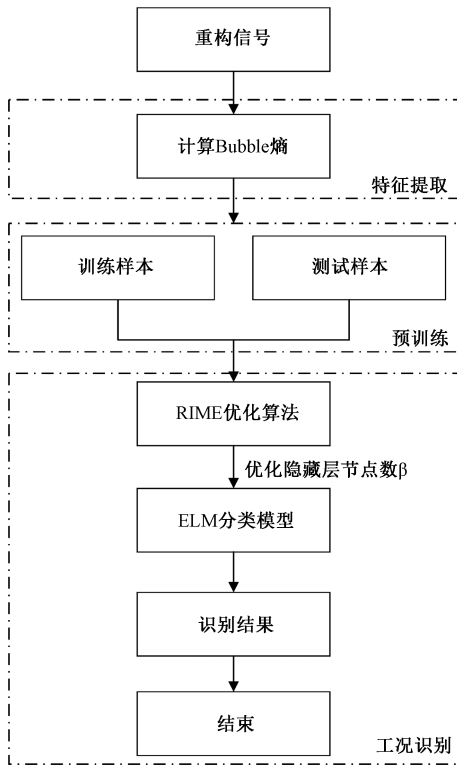


图 14 基于 Bubble-RIME-ELM 的泄漏识别流程

Fig. 14 Leakage identification process based on Bubble-RIME-ELM

管道信号经过 RIME-VMD 优化算法去噪处理前后的 Bubble 熵均值如图 16 和 17 所示。由图 16 可知,在去噪前,两种泄漏信号与敲击信号的 Bubble 熵均值存在交叉现象,且呈现出较大的波动。这种现象说明,原始信号中噪声成分较多,导致信号特征不稳定,可能给后续的管道信号识别带来困难<sup>[20]</sup>。然而经过去噪处理后,由图 17 可知,经过去噪处理后,4 种管道信号的 Bubble 熵均值并未出现交叉,各信号曲线之间距离较远,且波动幅度明显减小,表现出更为稳定的特性,有助于提高检测的准确性和可靠性。




图 16 RIME-VMD 方法去噪处理前的 Bubble 熵均值

Fig. 16 Mean Bubble entropy before denoising using the RIME-VMD method




图 15 Bubble 熵鲁棒性验证曲线

Fig. 15 Bubble entropy robustness verification curve




图 17 RIME-VMD 方法去噪处理后的 Bubble 熵均值

Fig. 17 Mean Bubble entropy after denoising using the RIME-VMD method

表 3 处理效果统计验证表

Table 3 Statistical validation table for treatment effects

	正常-敲击	敲击-小孔径泄漏	小孔径泄漏-大孔径泄漏
$t$ 统计量	优化前 -15.548 1	0.663 5	0.101 7
	优化后 -35.834 3	-8.355 1	-6.526 1
$p$ 值	优化前 $7.06 \times 10^{-12}$	0.515 4	0.920 1
	优化后 $3.44 \times 10^{-18}$	$1.31 \times 10^{-7}$	$3.91 \times 10^{-6}$

较好,两者的熵值差异非常小。这表明在较低的噪声水平下,Bubble 熵具有较强的鲁棒性,能够有效保持原始信号的特征,即使信号中加入了噪声,Bubble 熵值也没有明显的变化,能够应用于管道泄露信号的特征提取。

将正常、敲击、小口径泄漏和大孔径泄漏四种工作状态管道声学信号转化为 .mat 格式的矩阵文件输入到 RIME-VMD 算法中进行信号重构得到滤波信号,再计算去噪后的滤波信号的 Bubble 熵均值。



对数据组进行的独立样本  $t$  检验,如表 3 所示,在敲击-小孔径泄漏组( $t = 0.6635, p = 0.5154$ )和小孔径泄漏-大孔径泄漏组( $t = 0.1017, p = 0.9201$ )之间的均值差异不显著,表明去噪处理前这 3 种工况的数据在统计学上没有显著差异。然而,去噪处理后的正常-敲击组之间( $t = -35.8343, p = 3.44 \times 10^{-18}$ )、敲击-小孔径泄漏之间( $t = -8.3551, p = 1.31 \times 10^{-7}$ )以及小孔径泄漏-大孔径泄漏( $t = -6.5261, p = 3.91 \times 10^{-6}$ )表现出显著的差异,这表明去噪处理显著改善了数据的统计特性。

由此可以说明,利用本节提出的以 Bubble 熵为基础构建故障的特征向量,进一步验证了 RIME-VMD 去噪方法在实际应用中的优越性能。同时,也证明了通过提取滤波信号中的 Bubble 熵这一特征提取方法在处理给水管管道微小泄漏问题的可行性。

为验证本节提出的以 Bubble 熵为基础的特征提取方法的优越性,4 种管道声学信号进行去噪后,计算重构信号的均值、峭度、脉冲因素、波形因数、振幅因数共 5 类特征,与 Bubble 熵进行比较。

Bubble 熵、均值、峭度、脉冲因素、波形因数、振幅因数的曲线分别如图 18(a)~(f)所示,由图可以看出,在均值曲线中,敲击信号与正常信号出现严重混叠,难以区分。在峭度曲线、脉冲因子曲线、波形因子曲线、振幅因子曲线正常信号与两种泄漏信号均发生了重叠且发生较大幅度波动,不利于后续的管道信号识别。只有在 Bubble 熵曲线中,4 种管道信号的 Bubble 熵值并未出现交叉,各信号曲线之间距离较远,且波动幅度较小,表现出更为稳定的特性,适合作为管道泄漏特征描述指标。

### 2.2 基于 RIME 改进 ELM 的信号分类方法

采用 RIME-ELM 对 2.1 节中构建的 Bubble 熵特征向量进行识别,正常信号设置为一类标签,敲击信号设置为二类标签,小孔径泄漏信号设置为三类标签,大孔径泄漏信号设置为四类标签训练集与测试集的比例为 7 : 3。应用 RIME 优化 ELM 前后的识别结果如图 19、20 所示。为了定量评价 ELM 泄漏分类效果,采用准确率、精确率、召回率、 $F1$  分数 4 种指标进行评价,其中 ELM 工况识别结果如图 21 所示。

通过对管道泄漏原始信号应用 RIME-VMD 算法进行去噪,并利用 Bubble 熵构建故障的特征向量,进而评估了两种不同的 ELM 识别模式。初步模式中,特征向量直接输入到标准 ELM 识别算法中,得到的工况分辨准确率为 69.64%。而在 RIME 的优化模式中,工况分辨准确率显著提高至 95.71%。这一结果表明,所提的优化方法能显著提高 ELM 分类器的准确率。此外,模型在预测泄漏时的精确率达到 91.52%,说明当模型预测发生泄漏时,其预测结果具有较高的可靠性,误报的情况较少。模型的召回率为 92.86%,表明在捕捉实际泄漏事件方面表

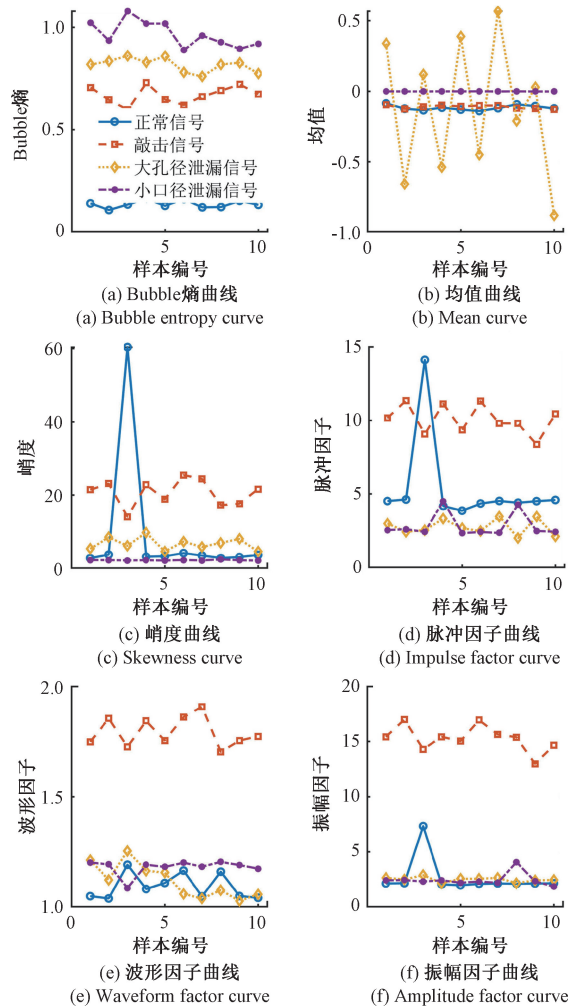


图 18 不同特征描述指标对比图

Fig. 18 Comparison plot of different feature description metrics




图 19 RIME-ELM 方法优化前的识别混淆矩阵

Fig. 19 Confusion matrix of recognition before optimization using the RIME-ELM method

现出色,漏报的情况较少。此外,模型的  $F1$  分数为




图 20 RIME-ELM 方法优化后的识别混淆矩阵  
Fig. 20 Confusion matrix of recognition after optimization using the RIME-ELM method




图 21 ELM 工况识别结果评价

Fig. 21 Evaluation of ELM condition recognition results

0.922, 这一指标综合反映了模型在精确性和完整性方面的表现, 表明模型在确保召回率的同时也维持了较高的精确率。

### 3 结 论

为了克服强噪声干扰环境下管道泄漏信号难以分离、微小泄漏特征提取困难的问题, 提出了一种基于 VMD 和 ELM 的管道微小泄漏检测技术。本文首先利用仿真实验分析 VMD 算法对处理非平稳非线性管道泄漏声信号的可行性。然后针对 VMD 算法中关键参数选择的难题, 引入 RIME 算法, 通过模拟自然界霜冰生长过程来优化参数选取, 从而提高 VMD 的分解效果。通过设计基于互信息熵的适应度函数, RIME 能够在迭代过程中自动寻找最优的 VMD 参数组合。最后, 针对去噪后的信号特征困难和工况难以识别的问题, 提出了利用基于 Bubble 熵的管道微小泄特征漏提取方法并对其鲁棒性进

行验证, 将构建的故障特征向量输入到 RIME 优化的 ELM 中进行工况识别, 最终实现了 4 种管道泄漏工况的精确识别。未来的研究将增加实际管道系统的实验验证, 并扩展本文提出的方法在其他复杂工况信号检测中的应用, 以实现更广泛的应用价值。

### 参考文献

[ 1 ] SUN C C, PARELLADA B, PUIG V, et al. Leak localization in water distribution networks using pressure and data-driven classifier approach [ J ]. Water, 2019, 12(1): 54.

[ 2 ] JARDER S L N, MARUYAMA O, GARCIANO L E O. A probabilistic estimation model for seismic physical portfolio loss of a water supply pipeline system [ J ]. Resilient Cities and Structures, 2024, 3(1): 44-54.

[ 3 ] HOU Y X, ZHANG Y, LU J Y, et al. Application of improved multi-strategy MPA-VMD in pipeline leakage detection [ J ]. Systems Science & Control Engineering, 2023, 11(1): 2177771.

[ 4 ] JIANG ZH, XIE J Y, ZHANG J, et al. Denoising method of pipeline leakage signal based on VMD and Hilbert transform [ J ]. Journal of Sensors, 2023, 2023(1): 1939606.

[ 5 ] 张勇, 邢鹏飞, 王明吉, 等. 基于 GAHE-VMD 与 SVD-SCEC 的管道信号联合去噪法 [ J ]. 噪声与振动控制, 2023, 43(5): 122-129.

ZHANG Y, XING P F, WANG M J, et al. Joint denoising method for pipeline signals based on GAHE-VMD and SVD-SCEC [ J ]. Noise and Vibration Control, 2023, 43(5): 122-129.

[ 6 ] 刘建锋, 刘梦琪, 董倩雯, 等. 基于改进 VMD 去噪和优化 ELM 方法的变压器早期故障诊断 [ J ]. 电力科学与技术学报, 2023, 38(6): 55-66.

LIU J F, LIU M Q, DONG Q W, et al. Transformer early fault diagnosis based on improved VMD denoising and optimized ELM method [ J ]. Journal of Electric Power Science and Technology, 2023, 38(6): 55-66.

[ 7 ] LU W J, YE CH L, ZHAO CH Y, et al. Leakage identification for mineral air supply pipeline system based on joint noise reduction and ELM [ J ]. Measurement, 2023, 219: 113304.

[ 8 ] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [ J ]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[ 9 ] 李俊卿, 刘若尧, 何玉灵, 等. VMD 和 SO 优化 SVM 的光纤复合海缆故障诊断研究 [ J ]. 电子测量技术, 2023, 46(22): 8-16.

LI J Q, LIU R Y, HE Y L, et al. Research on fault diagnosis of optical fiber composite submarine cables

- based on VMD and SO-optimized SVM [J]. *Electronic Measurement Technology*, 2023, 46(22): 8-16.
- [10] 王超, 蔺红, 庞晓虹. 基于 HPO-VMD 和 MISMA-DHKELM 的短期光伏功率组合预测[J]. *太阳能学报*, 2023, 44(12): 65-73.  
WANG CH, LIN H, PANG X H. Short-term photovoltaic power combined forecasting based on HPO-VMD and MISMA-DHKELM [J]. *Acta Energiæ Solaris Sinica*, 2023, 44(12): 65-73.
- [11] 褚丽鑫. 基于 SVD-VMD 的天然气管道泄漏检测研究[D]. 大庆: 东北石油大学, 2022.  
CHU L X. Research on natural gas pipeline leak detection based on SVD-VMD [D]. Daqing: Northeast Petroleum University, 2022.
- [12] GAN M, PAN H D, CHEN Y P, et al. Application of the variational mode decomposition (VMD) method to river tides [J]. *Estuarine, Coastal and Shelf Science*, 2021, 261: 107570.
- [13] 周静雷, 贺家琛, 崔琳. CNN-GRU 和 SSA-VMD 在扬声器异常声分类中的应用[J]. *电子测量与仪器学报*, 2023, 37(3): 161-168.  
ZHOU J L, HE J CH, CUI L. Application of CNN-GRU and SSA-VMD in the classification of abnormal speaker sounds [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(3): 161-168.
- [14] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization [J]. *Neurocomputing*, 2023, 532: 183-214.
- [15] 俎海东, 李晓波, 张万福, 等. 基于自适应变分模态分解的滚动轴承故障特征提取方法研究[J]. *热能动力工程*, 2024, 39(2): 194-204.  
ZU H D, LI X B, ZHANG W F, et al. Research on fault feature extraction method for rolling bearings based on adaptive variational mode decomposition [J]. *Journal of Thermal Science and Power Engineering*, 2024, 39(2): 194-204.
- [16] 赵嘉, 谷良, 吴瑶. 基于互信息和 GWB-LSSVM 的网络攻击检测模型[J]. *电子测量技术*, 2022, 45(24): 98-104.  
ZHAO J, GU L, WU Y. Network attack detection model based on mutual information and GWB-LSSVM [J]. *Electronic Measurement Technology*, 2022, 45(24): 98-104.
- [17] MANIS G, AKTARUZZAMAN M D, SASSI R. Bubble entropy: An entropy almost free of parameters [J]. *IEEE Transactions on Biomedical Engineering*, 2017, 64(11): 2711-2718.
- [18] TIAN ZH D, LI SH J, WANG Y H. A prediction approach using ensemble empirical mode decomposition-permutation entropy and regularized extreme learning machine for short-term wind speed [J]. *Wind Energy*, 2020, 23(2): 177-206.
- [19] 潘礼正, 王顺超, 丁忆, 等. 基于全视域特征表征与 ELM-Adaboost 方法的情绪辨识研究[J]. *仪器仪表学报*, 2022, 43(11): 162-171.  
PAN L ZH, WANG SH CH, DING Y, et al. Research on emotion recognition based on full-field feature representation and ELM-Adaboost method [J]. *Journal of Instrumentation*, 2022, 43(11): 162-171.
- [20] 邱小杰, 樊麟华, 陆正刚. 基于 WPT 和复合多尺度 Bubble 熵的轨道车辆轴箱轴承故障诊断[J]. *机电工程技术*, 2024, 53(5): 196-202.  
QIU X J, FAN L H, LU ZH G. Fault diagnosis of axle box bearings in railway vehicles based on WPT and composite multi-scale Bubble entropy [J]. *Mechanical & Electrical Engineering Technology*, 2024, 53(5): 196-202.

### 作者简介



刘文黎(通信作者), 于华中科技大学获得博士学位, 现为华中科技大学土木与水利工程学院副教授, 主要研究方向为城市基础设施建设、智慧运维、因果推理、结构可靠性分析等。

E-mail: liu\_wenli@hust.edu.cn

**Liu Wenli** (Corresponding author) received his Ph. D. degree from Huazhong University of Science and Technology. Now he is an associate professor at the School of Civil and Hydraulic Engineering of Huazhong University of Science and Technology. His main research interests include urban infrastructure development, smart operations and maintenance, causal inference, and structural reliability analysis.



马亮, 2024 年于华中科技大学获得学士学位, 现为华中科技大学土木与水利工程学院在读研究生, 主要研究方向为供水管道泄漏检测和因果推理。

E-mail: maliang0226@126.com

**Ma Liang** received his B. Sc. degree from Huazhong University of Science and Technology in 2024. Now he is a M. Sc. candidate at the School of Civil and Hydraulic Engineering of Huazhong University of Science and Technology. His main research interests include water supply pipeline leakage detection and causal inference.