

基于GOA优化VMD参数联合动态小波阈值的 抽油管漏磁信号去噪方法研究

郭畅达¹ 杨勇² 任旭虎¹ 宋华军¹ 葛文博¹

(1. 中国石油大学(华东)海洋与空间信息学院 青岛 266580; 2. 中国石化胜利油田分公司技术检测中心 东营 257000)

摘要: 抽油管漏磁(MFL)检测过程中接收的漏磁信号信噪比(SNR)较低,且常与其他频率成分相近的低频噪声混叠,现常见的去噪算法无法有效地将漏磁信号与其他噪声成分有效筛选。为提高漏磁信号提取准确性,提出了一种基于瞪羚优化算法(GOA)优化的变分模态分解(VMD)与动态小波阈值去噪(DWTD)相结合的方法来识别漏磁信号。首先,使用GOA算法来选择VMD中的输入参数。然后,VMD根据优化后的参数对信号进行自适应分解,得到一定的模态分量,并通过相关系数将其划分为有效信号分量和噪声分量。最后,对有效信号分量进行动态小波阈值去噪处理,得到去除噪声的漏磁信号。对不同强度下的仿真信号和实测漏磁信号进行了测试和分析,仿真信号指标分析本文方法至少比其他方法在SNR上提高了20%,实测漏磁信号比其他方法平滑度提高了10%。结果表明,基于GOA优化的VMD参数与DWTD相结合的去噪方法可以有效地去除干扰噪声,更完整地还原原始漏磁信号特征,适用于油井油管漏磁信号的去噪。

关键词: MFL;GOA;VMD;DWTD**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Reduce the noise of magnetic flux leakage signal based on the method of GOA-VMD-DWTD

Guo Changda¹ Yang Yong² Ren Xuhu¹ Song Huajun¹ Ge Wenbo¹

(1. School of Ocean and Spatial Information, China University of Petroleum (East China), Qingdao 266580, China;

2. Technical Inspection Center of Sinopec Shengli Oilfield Company, Dongying 257000, China)

Abstract: In the magnetic flux leakage (MFL) detection process of oil pipelines, the received MFL signals have a relatively low signal-to-noise ratio (SNR) and are often aliased with other low-frequency noises that have similar frequency components. Currently, common denoising algorithms cannot effectively separate MFL signals from other noise components. To improve the accuracy of MFL signal extraction, this paper proposes a method combining variational mode decomposition (VMD) optimized by the giraffe optimization algorithm (GOA) and dynamic wavelet threshold denoising (DWTD) for MFL signal identification. Firstly, the GOA algorithm is used to select the input parameters of VMD. Then, VMD performs adaptive decomposition on the signal based on the optimized parameters to obtain a certain number of modal components, which are divided into effective signal components and noise components using correlation coefficients. Finally, dynamic wavelet threshold denoising is applied to the effective signal components to obtain the noise-removed MFL signals. Tests and analyses were conducted on simulated signals with different intensities and actual measured MFL signals. The index analysis of simulated signals shows that the SNR of the proposed method is at least 20% higher than that of other methods, and the smoothness of actual measured MFL signals is 10% higher than that of other methods. The results indicate that the denoising method combining GOA-optimized VMD parameters and DWTD can effectively remove interference noise and retain the original signal waveform more completely. This method outperforms other commonly used denoising methods and is suitable for denoising MFL signals of oil well pipelines.

Keywords: MFL;GOA;VMD;DWTD

0 引言

随着石油资源的不断开采,抽油管长期工作在恶劣的

环境中,会导致不同程度的损伤,鉴于抽油管损伤造成的事故频繁发生,对抽油管存在的缺陷进行检测和评估成了亟待解决的问题^[1]。为检测抽油管缺陷信息,利用多路霍尔

传感器来采集缺陷的漏磁信号。然而在实际检测过程中,漏磁信号会受到机械干扰噪声和工频电磁场等干扰,使采集的漏磁信号无法准确对缺陷进行识别和定位,在机械干扰较大的情况下还可能造成缺陷误判等现象^[2-4]。因此,设计一种有效、合理的漏磁信号去噪算法是至关重要的。

漏磁信号预处理传统降噪算法主要包括傅里叶变换法、自适应滤波、卡尔曼滤波和中值滤波等。这些传统方法具有计算量小且易于设计的特点,然而在处理高度非线性非静态数据时,它们的效果并不理想,且适应性较弱。此外,这些方法对于实际应用中广泛存在的白噪声的去噪效果也较差,同时会导致漏磁信号中一些有用特征信息的损失^[5]。1974年Zhang等^[6]提出了一种信号处理方法——小波变换(wavelet transform, WT)。针对漏磁信号,Zhang等^[6]提出的基于小波阈值滤波方法能有效减小漏磁信号中存在的噪声。针对漏磁信号降噪等问题,Yao等^[7]设计了一种离散小波变换的方法,该方法提供了较好的漏磁信号特征识别效果。Yu等^[8]提出一种改进经验小波变换(empirical wavelet transform, EWT),将其应用于轨道表面缺陷漏磁(magnetic flux leakage, MFL)信号滤波,该方法基于互信息(mutual information, MI)的边界优化方法来减少自适应频谱划分带来的边界冗余,能够有效滤除MFL信号中的干扰,效果优于互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)和WT等传统方法。

然而,使用小波变换进行去噪时,选择小波基函数和阈值不能自适应选取,从而限制了该方法在信号降噪领域的发展。文献[9-10]提出了一种自适应信号处理方法——经验模态分解(empirical mode decomposition, EMD),该方法在处理非线性和非平稳信号方面得到了广泛应用。文献[11]提出了一种基于EMD联合小波阈值的信号去噪方法,该方法对小缺陷信号信息的提取效果较好,且信噪比(signal-to-noise ratio, SNR)得到了改善。Shi等^[12-14]提出了一种具有自适应噪声的CEEMD联合小波阈值的漏磁信号降噪处理方法,该方法能够有效去除漏磁信号中的噪声分量,且相比小波阈值去噪后,SNR提高了17%。然而,在EMD或CEEMD分解过程中,模态分量的中心频率容易产生模态混叠现象,导致信息丢失^[11,14]。

2014年夏焰坤等^[15-16]提出一种更加高效自适应的信号处理方法——变分模态分解(variational mode decomposition, VMD),该方法具备自适应性,能够智能地选择每种模态的最佳中心频率和有限带宽。此外,该方法还能有效地分离固有模态分量(intrinsic mode function, IMF),从而获得给定信号的有效分解成分,通过这一过程,能够优化解决变分问题,克服了EMD存在的模态混叠等缺陷^[17]。Ma等^[18-20]提出一种基于VMD和小波阈值去噪的方法,该方法可有效去除微弱信号中的噪声,但在VMD分解中的 K 值靠经验选取,不能够自适应分解。Wang

等^[21-22]提出一种将VMD和深度学习结合的算法用于信号降噪和故障诊断,该方法能够有效识别出信号的故障信息。

VMD将信号分解成各分量时,输入参数中的模态量和筛选因子的选择直接影响信号分解质量;为了根据输入信号选择出合适的参数,研究人员在分解的前置步骤使用了麻雀搜索算法、微分搜索算法等算法^[23-24];但是这些算法对于信号的局限性很强,往往只能局限于某一特定类型信号,同时,以上几种算法的优化过程中对于频率分量复杂的信号的模态分解效果较差。为了解决以上问题,Zhang等^[25-26]提出一种用改进的鲸鱼优化算法(whale optimization, WO)与粒子群优化算法(particle swarm optimization, PSO)优化VMD参数,有效地提取故障信息和提高了有用信号的SNR,但这几种优化算法的收敛速度较慢,影响算法的效率。同时VMD输出信号的质量也受限于模态筛选的过程^[27]。低SNR条件下,提取有效模态的准确率会更低,为了在低SNR的条件下有效筛选模态,通过互谱分析的方法,取得信号的主要频率范围,提高模态选取的准确率^[28-29]。但是这种方法在有效信号与噪声的频率范围相近时,例如在管道漏磁信号与环境噪声频率相近的情况下仍然不能有效地筛选出有效模态,去噪效果变差。

针对漏磁信号实际采集过程中存在的频率成分复杂、有效信号与噪声频谱相近,低SNR工况下模态筛选难度大、VMD分解输入参数难以优选等问题,本文在以上方法基础上,提出一种基于瞪羚优化算法(gazelle optimization algorithm, GOA)优化VMD参数、联合动态小波阈值的降噪算法。首先采用GOA优化算法找出VMD分解最优的参数组合 K 和 α ,然后进行VMD的分解,通过相关系数选择模态分量,将选择的模态分量进行动态小波阈值降噪处理,之后重构信号,得到去噪后漏磁信号。通过对仿真信号处理分析验证了该方法的可行性,最后对实测漏磁信号进行处理分析,利用平滑度指标(root of variance ratio, RVR)和噪声模(modal noise, MN)进行评价,与其他方法相比,本文方法能够保留更多的细节分量,评价指标都优于其他方法。因此,本文方法对漏磁信号的降噪效果更加显著。

1 VMD原理

VMD是一种自适应信号分解方法。它使用迭代解来求解变分模型的最优解,以获得每个有限带宽的IMF,并根据其各自的中心频率自适应地分离模态分量。具体步骤如下:

1)对于每个模态函数,通过希尔伯特变换获得分析信号,以获得边缘谱。

2)每个模态的中心频率由指数 $e^{-j\omega_k t}$ 混合,每个模态函数的频谱被调制到相应的基带。

3)每个模态函数的带宽是通过解调信号的高斯平滑度

和梯度平方准则来获得的。

通过上述步骤得到的约束变化问题为：

$$\begin{cases} \min_{\{u_k, w_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ s.t. \sum_k u_k = f \end{cases} \quad (1)$$

式中： $u_k = \{u_1, u_2, \dots, u_k\}$ 是 K 个模态分量； $w_k = \{w_1, w_2, \dots, w_k\}$ 是 K 个模态的中心频率； $*$ 表示卷积； $\delta(t)$ 是单位脉冲函数； ∂_t 表示 t 的偏导数； f 是原始信号。

4) 通过引入拉格朗日 30 乘子 $\lambda(t)$ 和二次惩罚因子 α ，将约束变分问题转化为无约束的变分问题，即：

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \\ & \| f(t) - \sum_k u_k(t) \|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (2)$$

式中： $\| f(t) - \sum_k u_k(t) \|_2^2$ 为二次惩罚项， α 为二次惩罚因子，来调节变分模态分解的完备性。

5) 可得到约束变分模型的二次最优化解为：

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

同理，求解 w_k^{n+1} 的最小值问题，把中心频率取值问题转移到频域，最终解得中心频率的更新方法为：

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (4)$$

因此，原始信号 f 经过变分模态分解被分解为 K 个 IMF 分量，实施步骤如下：

- (1) 初始化 $\{u_k^1\}, \{w_k^1\}, \{\lambda_k\}$ ，令 $n = 0$ ；
- (2) $n = n + 1$ ，执行整个循环；
- (3) $k = k + 1$ ，直到 $k = K$ ，对所有 $w \geq 0$ ，更新 $\hat{u}_k$ ，

$\hat{w}_k$ ；

$$\begin{cases} \hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \\ w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \end{cases} \quad (5)$$

(4) 对所有 $w \geq 0$ ，更新拉格朗日算子：

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \gamma \left[\hat{f}(w) - \sum_{k=1}^K \hat{u}_k^{n+1}(w) \right] \quad (6)$$

(5) 重复步骤 2)~4) 直到满足收敛条件，则终止迭代：

$$\sum_{k=1}^K \frac{\| \hat{u}_k^{n+1} - \hat{u}_k^n \|_2^2}{\| \hat{u}_k^n \|_2^2} < \epsilon \quad (7)$$

2 基于 GOA-VMD-TWTD 方法的漏磁信号降噪算法模型

2.1 GOA 优化 VMD 参数

VMD 可以克服基于 EMD 去噪方法引起的模态混叠现象，这有助于有效成分和噪声成分之间的分离。VMD 分解中最关键的两个参数为分解层数 K 和二次惩罚因子 α ，当输入不同的 K 和 α 时，得到的分解结果也会不同。若 K 值过大，则同一频率的模态响应容易被分离成不同的 IMF 分量；若 K 值过小，则无法准确分离出所有的模态响应；而 α 值同样高度影响 VMD 的分解效果。因此，找出最佳的 K 和 α 参数组合是 VMD 分解的关键。

GOA 是 Agushaka 等^[30]于 2022 年提出的一种新的基于种群的优化方法，该算法灵感来源于瞪羚在大自然中的行为，通过迭代更新瞪羚的位置和速度来寻找最优解。算法包括初始化种群、运动更新、边界检查、适应度评估、群体更新和终止条件等步骤。瞪羚优化算法具有全局收敛性和较好的探索能力，适用于多种优化问题。该算法将瞪羚的搜索过程逻辑上分为两个方面：探索和利用，瞪羚的集群行为在数学上建模如下：

假设瞪羚在放牧时以布朗运动的方式运动，这种行为的数学模型如式(8)所示。

$$\overrightarrow{\text{gazelle}}_{i+1} = \overrightarrow{\text{gazelle}}_i + s \cdot \overrightarrow{R} * \overrightarrow{R}_B * (\overrightarrow{\text{Elite}}_i - \overrightarrow{R}_B * \overrightarrow{\text{gazelle}}_i) \quad (8)$$

式中： $\cdot$ 为标量乘法和向量点积； $*$ 为向量逐元素乘法，如向量 $A = [a_1, a_2]$ ，向量 $B = [b_1, b_2]$ ，对 A 和 B 逐元素乘法运算 $A * B = [a_1 b_1, a_2 b_2]$ 。 $\overrightarrow{\text{gazelle}}_{i+1}$ 是下一次迭代的解， $\overrightarrow{\text{gazelle}}_i$ 是当前迭代的解， s 表示瞪羚的掠食速度， $\overrightarrow{R}_B$ 是包含表示布朗运动的随机数的向量， $\overrightarrow{R}$ 是均匀随机数 $[0, 1]$ 的向量。

瞪羚一旦发现捕食者，它就进入了探索阶段。面对危险，瞪羚采取甩尾巴、跺脚或用 4 只脚在空中蹲 2 m，通过将 2 m 的高度映射到 0~1 的数字，采用勒维飞行算法模拟这一过程，这个过程包括小步和偶尔的跳远。在逃跑阶段，瞪羚和捕食者之间的特征都是方向的突然变化，用 i 表示。本研究假设这种方向变化发生在每次迭代中，当迭代次数为奇数时，瞪羚会向一个方向移动；而当迭代为偶数时，则会移向另一个方向。瞪羚首先做出反应，所以假设它使用勒维飞行；捕食者反应较慢，因此研究假设其起初采用布朗运动，然后切换为勒维飞行。瞪羚行为的数学模型如式(9)所示。

$$\overrightarrow{\text{gazelle}}_{i+1} = \overrightarrow{\text{gazelle}}_i + s \cdot u \cdot \overrightarrow{R} * \overrightarrow{R}_L * (\overrightarrow{\text{Elite}}_i - \overrightarrow{R}_L * \overrightarrow{\text{gazelle}}_i) \quad (9)$$

式中： s 是瞪羚可以达到的最大速度， $\overrightarrow{R}_L$ 表示基于勒维分布的随机数的向量。捕食者追逐瞪羚行为的数学模型如式(10)所示。

$$\overrightarrow{\text{gazelle}}_{i+1} = \overrightarrow{\text{gazelle}}_i + s. u. CF. \overrightarrow{R_L} * . (\overrightarrow{\text{Elite}}_i - \overrightarrow{R_L} * . \overrightarrow{\text{gazelle}}_i)$$

(10)

式中: $CF = (1 - \frac{\text{iter}}{\text{Max_iter}})^{(\frac{2 - \text{iter}}{\text{Max_iter}})}$ 表示捕食者的累积效应。

PSRs(packet success rate)是捕食者的成功率,其影响瞪羚的逃跑能力,这意味着算法避免陷入局部极小值。PSRs 效应建模如式(11)所示。

$$\overrightarrow{\text{gazelle}}_{i+1} = \begin{cases} \overrightarrow{\text{gazelle}}_i + CF[\overrightarrow{LB} + \overrightarrow{R} * . (\overrightarrow{UB} - \overrightarrow{LB})] * . \overrightarrow{U}, & r \leq \text{PSRs} \\ \overrightarrow{\text{gazelle}}_i + [\text{PSRs}(1 - r) + r](\overrightarrow{\text{gazelle}}_{r_1} - \overrightarrow{\text{gazelle}}_{r_2}), & \text{其他} \end{cases}$$

(11)

式中: $\overrightarrow{U}$ 为二进制向量,其通过在 $[0, 1]$ 中生成随机数 r 来构造,使得 $\overrightarrow{U} = \begin{cases} 0, & r < 0.34 \\ 1, & \text{其他} \end{cases}$, r_1 和 r_2 是瞪羚矩阵的随机索引。

在 GOA 优化中,历次迭代的过程只是根据输入参数和信号通过迭代输出一组优化 VMD 的参数,但是哪一轮迭代的输出参数为最优解没有给出定义。为确认最优迭代次数,在迭代进行后需要一个指标确认当前迭代结果是否为最优解;如果为最优解,停止迭代,反之将已有迭代解和其他参数加入下一轮的迭代过程。因此,在这个优化过程中,选择了能量损失系数作为最佳值的目标(即最适者的瞪羚)函数,能量损失系数定义如式(12)所示。

$$f_{\text{obj}} = \frac{\|f - \sum \text{IMF}_K\|_2^2}{\|f\|_2^2}$$

(12)

式中: $\sum \text{IMF}_K$ 表示 VMD 分解的模态分量 IMF 的相加, f 是带有噪声的漏磁数据。

因此,利用 GOA 优化 VMD 的参数,选择能量损失系数作为适应度函数,VMD 的分解层数和二次惩罚因子的寻优范围分别取为 K 取 $[2, 15]$ 、 α 取 $[500, 10\ 000]$,在完成所有迭代之后,获得最优参数 K 和 α ,将最优参数组合用作 VMD 分解的输入参数,其优化过程如图 1 所示。

2.2 有效模态分量的筛选

VMD 的相关参数 K 和 α 通过 GOA 优化确定后,经过 VMD 分解得到 K 个分解合适的 IMF 分量,但如何有效选择出合适的模态分量进行重构仍是非常关键的问题,因此本文采用相关系数进行有效模态分量的选取。相关系数表示两个变量之间的相关程度,两个变量 u_i 与 f 之间的相关系数 R 的计算公式如下:

$$R = \frac{E(u_i, f) - E(u_i)E(f)}{\sqrt{D(u_i)} \sqrt{D(f)}}$$

(13)

式中: f 和 u_i 表示原始信号和通过模式分解获得的 IMF 分量; D 和 E 对应于数学期望和方差。相关系数 R 的取值范围在 $0 \sim 1$,当变量 A 与变量 B 的相关程度越大,相关系数 R 的值越接近 1;当变量 A 与变量 B 的相关程度越小,相




图 1 基于 GOA 优化 VMD 参数流程

Fig. 1 Flowchart of the VMD parameter optimization based on GOA

关系系数 R 的值越接近 0。相关系数 R 与相关性之间的关系如表 1 所示。本文选取有效模态分量的原则为:首先计算各个模态分量与原始信号之间的相关系数 R_i ,然后求出相关系数 R_i 的均值 mean ,选取 $R_i \geq \text{mean}$ 的分量为有效模态分量, $R_i < \text{mean}$ 的分量为噪声模态分量。

表格 1 相关系数 R 与相关性之间的关系

Table 1 The relationship between the correlation coefficient R and correlation

相关性	R
无关	$0 \sim 0.1$
弱相关	$0.1 \sim 0.3$
中等相关	$0.3 \sim 0.5$
强相关	$0.5 \sim 1.0$

2.3 有效模态分量的降噪处理

小波阈值降噪是一种常用的信号处理技术,用于去除图像或信号中的噪声。它基于小波变换的特性,通过将信号进行小波变换,然后根据设定的阈值将小波系数进行处理,最后再进行逆变换恢复原始信号。小波阈值降噪流程如图 2 所示。

虽然传统的小波阈值降噪算法可以有效消除信号中包含的噪声,但是去噪后的信号会在奇异点(不连续点)和某些突变的点附近出现伪吉布斯(pseudo-Gibbs)现象,导致




图 2 小波阈值降噪流程

Fig. 2 Small wavelet threshold denoising flowchart

小波阈值降噪的效果降低。因此,针对漏磁信号非线性、非平稳的典型随机信号特性,同时为了改善降噪效果,本文采用动态小波阈值降噪算法,关键步骤归纳如下:

1) 小波阈值函数选择

硬阈值函数:

$$\hat{W}_{j,k} = \begin{cases} W_{j,k}, & |W_{j,k}| > \text{thr} \\ 0, & |W_{j,k}| \leq \text{thr} \end{cases} \quad (14)$$

软阈值函数:

$$\hat{W}_{j,k} = \begin{cases} \text{sgn}(W_{j,k})(W_{j,k} - \text{thr}), & |W_{j,k}| > \text{thr} \\ 0, & |W_{j,k}| \leq \text{thr} \end{cases} \quad (15)$$

式中: $W_{j,k}$ 为小波系数, thr 为阈值。

在应用小波阈值降噪算法时选取合适的阈值函数是信号降噪处理过程中的重要研究内容。硬阈值函数存在不连续性,导致重构后的信号存在产生一定震荡的可能性,这就制约了其在信号处理领域的应用;软阈值函数没有出现间断,有较好的平滑降噪效果,因此本文选择软阈值函数对漏磁信号进行降噪。

2) 小波阈值选取

小波阈值降噪算法的一个关键问题是阈值的选取,阈值选取过大,信号损失较大;阈值选取过小,则噪声滤除不完全,影响降噪效果。因此,结合小波变换后各尺度小波系数中包含的噪声信号会随着尺度的增大而减小的特点,引入校正因子对阈值进行动态调整,对分解后各尺度下的信号分别进行处理,针对不同的分解尺度采用更适合的阈值,可以有效提高降噪效果,基于校正因子的阈值调整方法如式(16)所示。

$$\text{thr}_{L,k} = \delta_k \sqrt{2 \lg n} / (S_{L,k} + b) \quad (16)$$

式中: $S_{L,k} = 2^{(L-k/L)}$ (L 为小波分解的层数, k 为当前的分解层数); $\delta_k = \text{median} |x| / 0.6745$; b 为调节因子。

本文采用的动态小波阈值降噪算法中,阈值的选取主要是根据分解层数动态调整,计算方法如式(17)所示。

$$\text{thr}_{L,k} = \theta \times \delta_k \sqrt{2 \lg n} / (S_{L,k} + b) \quad (17)$$

式中: $\theta = k/L$ 为收敛因子,在对阈值进行动态调整的过程中,通过收敛因子对阈值进行进一步调整,随着小波分解层数的不断增加逐渐减小阈值的振幅,使低频信号子带的分辨率得以提高。由于漏磁信号中的有效信号主要集中在低频部分,因此这种动态阈值调整的方法能够有效地应用于漏磁信号的降噪处理中,提高对漏磁信号的降噪效果。

3) 小波基与分解层数的选择

对漏磁信号去噪处理时,小波基和分解层数的选择也是非常重要的,分解层数过多,去掉的噪声也会越多,但超过临界值时,可能会去除一部分有用信号;其中小波基不同降噪效果也不同。在本文中,选择 sym8 作为小波基,分解层数 6 层。

2.4 基于 GOA-VMD-DWTD 方法的漏磁信号降噪步骤

在本节中,本文将使用所提出的 GOA-VMD-DWTD 方法来研究漏磁信号去噪。首先,使用 GOA 来优化 VMD 参数 K 和 α ,以实现准确的信号分解;然后,本文计算了各本征模函数与原始信号之间的互相关系数,并移除相关系数较低的分量;最后对剩余的信号进行动态小波阈值处理来提高降噪性能,图 3 描述了所提出方法的框图。

图 4 描述了该框图具体降噪实现过程。具体的降噪步骤如下:

1) 针对输入信号,使用具有适应度函数能量损失系数极小值的 GOA 优化算法来寻找 VMD 算法中最优的 K 和 α 组合。

2) 使用第 1 步中获得的最优参数 K 和 α ,通过 VMD 对原始信号进行分解,获得 K 个 IMF 分量。

3) 计算每个 IMF 和原始信号之间的相关系数 R 。将 R 的阈值设置为各相关系数的均值, $R <$ 阈值的 IMF 为噪声 IMF,舍去噪声分量; $R \geq$ 阈值的 IMF 是有用的 IMF,保留有用分量。将有用的 IMF 分量使用动态软阈值去噪,获得去噪后的 IMF 分量。

4) 将去噪后的 IMF 分量进行重构,得到原始信号去噪后的结果 y 。




图 3 所提出方法 GOA-VMD-DWTD 的框图
Fig. 3 Proposed method GOA-VMD-DWTD block diagram




图 4 GOA-VMD-TIDWT 去噪详细流程
Fig. 4 GOA-VMD-TIDWT denoising detailed flowchart

3 算法测试与仿真分析

3.1 仿真信号实验分析

本文使用 MATLAB 对实测漏磁信号进行试验,验证本文提出方法在识别有效模式时对噪声条件的鲁棒性。为还原实际工作环境下实际采集到的混合多种环境噪声成分的漏磁信号,仿真环境的信号成分应与实际采集到的信号频率成分相近。通过实际采集与分析,抽油管缺陷的原始漏磁信号是一个含有多分量噪声的非线性和非平稳随机信号,其中环境噪声可分为 150 Hz 左右的机械噪声、50 Hz 的工频干扰噪声、全频带高斯白噪声,且漏磁信号的主频率比较低,在 1~20 Hz。因此,在纯净的漏磁信号中叠加全频带白噪声、中心频率为 150 Hz 的窄带噪声模拟机械干扰和中心频率为 50 Hz 的窄带噪声模拟工频干扰,分别添加具有不同输入 SNR(0、5、10 dB)的高斯白噪声,其构造仿真信号如图 5 所示。通过向基本漏磁信号中加

入以上多种环境噪声,拟真在实际工作环境下采集漏磁信号的抗干扰场景。




图 5 仿真信号时频
Fig. 5 Simulated signal time-frequency

使用 GOA 优化算法寻找最优的分解层数 K 和惩罚因子 α 参数组合。

图 6 为最佳适应度函数随迭代次数变化曲线。由图 6 可知,在第 4 次迭代时获得局部包络熵极小值为 2.977 56,此时,分解层数 K 为 10, α 为 1 990。

分别使用小波阈值去噪、EMD-WTD 去噪、EEMD-WTD 去噪以及本文算法进行去噪。其中设置 VMD 的输入参数为 $\tau = 0, DC = 0, tol = 10^{-7}, \omega = 1$, 并使用 SNR、均方根误差 (root mean square error, RMSE) 以及相关系数 (correlation coefficient, CC) 作为噪声鲁棒性的评价标准。

$$SNR = 10 \times \lg \left(\frac{\sum_{i=1}^N x^2(i)}{\sum_{i=1}^N (x(i) - f'(i))^2} \right) \quad (18)$$




图 6 仿真信号最佳适应度函数

Fig. 6 Optimal fitness function for simulation signals

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i) - f'(i))^2} \quad (19)$$

$$CC = \frac{\sum_{i=1}^n [x(i) - \bar{x}] [f'(i) - \bar{f}']}{\sqrt{\sum_{i=1}^n [x(i) - \bar{x}]^2 \cdot \sum_{i=1}^n [f'(i) - \bar{f}']^2}} \quad (20)$$

式中: $x(i)$ 为原始信号, $\bar{x}$ 是原始信号的均值, $f'(i)$ 为重构信号, $\bar{f}'$ 为重构信号均值, n 为信号长度。

将 GOA 优化算法优化的参数输入到 MATLAB 中, 经 VMD 最优化分解后得到 10 个 IMF 分量, 如图 7 所示。

当阈值设置过高时将会导致有用 IMF 分量被滤除, 而阈值设置过低时将导致噪声的 IMF 分量无法滤除从而导致降噪效果不佳。研究人员认为当 IMF 分量与原始信号的互相关系数低于相关系数的平均值时, 可认为是噪声,





图 7 VMD 分解后各 IMF 分量

Fig. 7 Each IMF component after VMD decomposition

将这些 IMF 分量去除, 保留下来的 IMF 分量能够以最小的信息损失来表达原始信号的特征。

原始信号和降噪后的信号如图 8 所示。结果表明, 使用上述 4 种降噪算法都能去除大部分的噪声, 经过本文方法降噪后的信号与原始信号对比如图 8(d) 所示, 虽然在一些位置仍然有较小的波动, 但信号特征基本保持一致, 说明本文方法有较好的降噪效果; 其他 3 种降噪效果如图 8(a)~(c) 所示, 3 种算法降噪后的信号峰值部分与未加噪声的信号有明显的偏离以及信号波动较大, 其降噪效果不理想; 总之, 与其他 3 种降噪方案相比, 本文的降噪方案对漏磁信号有较好的降噪效果。

针对降噪后的信号进行评价, 降噪后信号 SNR 的值






图 8 4 种算法降噪效果

Fig. 8 Four types of algorithms noise reduction effect

表 2 不同噪声强度下 4 种方法降噪效果 RSE 与 RMSE 评价


Table 2 Evaluation of RSE and RMSE for noise reduction effects of four methods under different noise intensity

去噪方法	−5 dB		0 dB		5 dB		10 dB	
	SNR	RMSE	SNR	RMSE	SNR	RMSE	SNR	RMSE
DWT	2.064 2	0.682 2	5.455 5	0.548 5	11.325 6	0.695 4	13.845 6	0.597 0
EMD-DWT	1.641 5	0.790 1	5.696 5	0.537 5	10.987 0	0.589 2	17.348 2	0.428 5
EEMD-DWT	2.980 6	0.650 2	7.010 2	0.479 8	12.862 3	0.585 5	16.596 5	0.310 5
本文方法	3.454 3	0.324 3	9.852 4	0.269 8	14.512 1	0.225 5	19.855 2	0.190 5


表 3 不同噪声强度下 4 种方法降噪效果 CC 评价

Table 3 CC evaluation of denoising effects of four methods under different noise intensities

去噪方法	CC/%			
	−5 dB	0 dB	5 dB	10 dB
DWT	92.894 0	94.387 4	93.529 6	94.895 6
EMD-DWT	92.561 8	95.650 3	94.389 6	96.884 5
EEMD-DWT	95.617 5	97.210 5	95.689 2	98.015 2
本文方法	98.378 6	98.797 3	98.914 5	99.230 5



(a) 4种算法降噪后SNR对比
(a) Comparison of SNR after denoising with four algorithms



(b) 4种算法降噪后RMSE对比
(b) Comparison of RMSE after denoising with four algorithms

图 9 4 种算法降噪后 SNR 与 RMSE 对比

Fig. 9 Comparison of SNR and RMSE after denoising with four algorithms

本文去噪方法在不同噪声水平下的 CC 值分别为 98.378 6%、98.797 3%、98.914 5%和 99.230 5%，在 4 种降噪方法中均为最大。本文方法的 CC 指标在几种噪声环境下均优于其他方法，4 种算法降噪后 CC 对比如图 10

越高,RSME 的值越小,降噪效果越好;CC 越大,表明降噪后的漏磁信号与干净的漏磁信号偏差越小。将噪声强度分别为−5、0、5、10 dB 的 4 组含噪模拟随机信号用 3 种不同的降噪方法以及本文提出的方法进行降噪,得到 4 种降噪方法的评价指标值,如表 2、3 所示。

本文去噪方法在不同噪声水平下的 RMSE 值分别为 0.324 3、0.269 8、0.225 5 和 0.190 5,在 4 种降噪方法中均为最小。RSME 值反映了降噪后信号与原信号间的相似程度,说明本文去噪方法与其他去噪方法相比,能够更好地保留原始信号信息。

本文的去噪方法在不同噪声水平下的漏磁信号上进行了 4 种分析,结果显示,其在各个噪声强度下都实现了较高的 SNR 改善,具体数值分别为 3.454 3、9.852 4、14.512 1 和 19.855 2。这意味着去噪后的信号在 SNR 上都有 6~10 dB 的提高,该方法适用于各种噪声强度下的模拟信号。4 种算法降噪后 SNR 与 RMSE 对比如图 9 所示。

所示。
综上所述,本文的去噪方法在信号处理方面具有显著的优势,能够有效地改善信号的质量,并在不同噪声强度下取得更高的 SNR,具备更强的鲁棒性。




图 10 4 种算法降噪后 CC 对比

Fig. 10 Comparison of CC after noise reduction by four algorithms




图 11 管道人工缺陷示意

Fig. 11 Schematic of artificial defects in pipelines




图 12 实测人工缺陷漏磁信号时域

Fig. 12 Measured time-domain of artificial defect leakage magnetic signal

原始含噪的漏磁信号通过使用本文所提出的降噪方法处理后的信号如图 13 所示。由降噪结果可直观分析得出,本文所提出的降噪方法对于管道中 4 种不同类型的缺陷均有不错的降噪效果,能去除 4 种漏磁信号中的各种噪声分量,且信号的幅值基本无衰减。

图 12 中信号 2 显示了实验平台收集的漏磁信号,图 14 显示了 4 种滤波效果的比较。其中小波阈值降噪方

3.2 实测漏磁信号实验分析

为验证系统的可靠性,在试验环境中使用型号为 N80、长度为 10 m 的 4 根人工损伤和 1 根自然损伤抽油管进行测试。在管道 1 和 2 上分别切割 2 个不同深度的横向和纵向缺陷,在管道 3 和 4 上分别切割 2 个不同深度的斜向缺陷,管道 1~4 人工损伤示意如图 11 所示。

通过使用漏磁检测系统分别对以上含有不同缺陷的管道进行检测,在管道检测过程中机械振动、传感器提离值变化以及白噪声的干扰将会导致漏磁信号中夹杂着许多干扰,这些干扰将会影响缺陷的识别与定位等。系统测得两根人工缺陷管道漏磁信号如图 12 所示。可见漏磁信号中夹杂着噪声干扰,因此需要对漏磁信号进行降噪预处理。

法的滤波波形产生失真,滤波效果差;通过 EMD-DWTD 降噪对噪声信号进行滤波以产生大幅度失真;EEMD-DWTD 降噪方法在滤波后的信号开始时产生幅度失真,去噪效果较差;GOA-VMD-DWTD 方法在滤除噪声之后保留了原始信号的特性。

由于实际检测的漏磁信号受到各种噪声的干扰,无法获取干净的漏磁信号,因此无法使用 SNR 和 RMSE 来评




图 13 实测漏磁信号 GOA-VMD-TIDWT 降噪效果

Fig. 13 Measured leakage magnetic signal GOA-VMD-TIDWT denoising effect

价该方法降噪效果。针对实际的漏磁信号采用以下降噪效果评价指标：

1) 相对变化率(relative variation rate, RVR)

本文将该相对变化率定义为平滑度评价指标,平滑度用于衡量时间序列平滑度或稳定性。RVR 通过计算相邻观测值之间差异的方差与整个时间序列的方差之比,并取其平方根来得出。RVR 提供了一个相对于整体方差的时间序列波动程度的度量。较低的 RVR 值表示时间序列更加平滑和稳定,而较高的 RVR 值则暗示着更大的波动性和较少的平滑性。

$$RVR = \frac{\sqrt{\sum_{t=1}^{n-1} [\hat{x}(t+1) - \hat{x}(t)]^2}}{\sqrt{\sum_{t=1}^{n-1} [x(t+1) - x(t)]^2}} \quad (21)$$

2) 信号能量比(signal energy ratio, SER)

信号能量比是从能量的角度进行定量评估,反映去噪前后能量的相似性。




图 14 实测漏磁信号 2 四种方法降噪效果对比

Fig. 14 Comparison of noise reduction effects of four methods on measured leakage magnetic signals

$$SER = \frac{\sqrt{\sum_{t=1}^n [\hat{x}(t)]^2}}{\sqrt{\sum_{t=1}^n [x(t)]^2}} \quad (22)$$

其中, $x(t)$ 表示原始信号, $\hat{x}(t)$ 表示去噪后的信号, n 为采样点数。

不同信号下 4 种方法降噪效果评价如表 4 所示。

去噪效果可以通过信号图像的 RVR 来评价,此指标反映去噪后信号的平滑程度。RVR 值越接近于 0,表明去噪后的信号更加平滑,如信号 1 中 4 种方法的 RVR 分别为 0.225、0.206、0.198、0.167,其中基于 GOA 改进 VMD 降噪算法的 RVR 最小,说明该方法的去噪方法保留了更多的细节信息,且去噪后的信号更平滑。

根据能量角度评价去噪效果时,通过 SER,本文可以观察到 4 种去噪方法的 SER 值均大于 99.7%。这意味着这些方法成功去除了噪声,表明基于 GOA 改进 VMD 的降噪方法在保留原始信号细节的前提下,能够获得最佳的去噪效果。

表 4 不同信号下 4 种方法降噪效果评价

Table 4 Evaluation of the noise reduction effects of four methods under different signals

去噪方法	−5 dB		0 dB		5 dB		10 dB	
	RVR	SER	RVR	SER	RVR	SER	RVR	SER
DWT	0.225	0.999 9	0.242	0.999 5	0.215	0.999 7	0.235	0.999 8
EMD-DWT	0.206	0.999 6	0.208	0.999 5	0.204	0.999 5	0.199	0.999 7
EEMD-DWT	0.198	0.999 3	0.203	0.999 3	0.199	0.999 3	0.178	0.999 5
本文方法	0.167	0.999 2	0.187	0.999 1	0.179	0.999 2	0.165	0.999 3

3.3 泛化钢轨漏磁信号实验分析

为了验证本文方法的适用性和泛化性,基于钢轨漏磁信号部分数据集,在不同噪声强度下进行了实验,如图 15 所示。图 15 中对钢轨信号在 0 dB 噪声强度下有效地保留了峰值信号,剔除了其他多余成分并且减少了信号的扰动。由于钢轨漏磁信号仍为实际环境采集信号,SNR 较低,仍选用 SER 和 RVR 衡量本文算法处理信号的泛化能力。实验结果如表 5 所示,由表 5 实验结果可知,本文算法对于其他类型的漏磁信号也能相对有效地筛选相关模态、去除噪声以及还原信号。




图 15 钢轨漏磁信号降噪效果

Fig. 15 The denoising effect of rail magnetic flux leakage signals

表 5 泛化漏磁信号下 4 种噪声强度降噪效果评价

Table 5 Evaluation of denoising effects under four noise intensities for generalized magnetic flux leakage signals

去噪方法	−5 dB		0 dB		5 dB		10 dB	
	RVR	SER	RVR	SER	RVR	SER	RVR	SER
本文方法	0.275 0	0.894 7	0.229 0	0.918 5	0.197 4	0.942 6	0.165 2	0.963 6

4 结 论

本文提出基于 GOA 算法优化 VMD 参数联合动态小波阈值的漏磁信号降噪方法,针对漏磁系统中非线性、非平稳随机信号的降噪难题提供了有效解决方案,显著降低了漏磁信号的误判率,为管道缺陷精准识别提出一种解决方案。从研究价值来看,该方法突破了传统降噪算法(如 WTD、EMD-DWTD、EEMD-DWTD)在复杂噪声环境下的局限性——通过 GOA 算法对 VMD 参数的自适应优化,实现了噪声与有用信号的高效分离,既保留了漏磁信号的关键特征分量,又对不同强度噪声具备良好鲁棒性。仿真信号测试过程中,在 SNR 指标上比传统方法平均提高 11.4%;在均方根误差上比传统方法平均优化了 8.5%;在实测信号上在平滑度指标上比传统方法优化了 9.4%;同时对钢轨、抽油管等不同场景的漏磁信号展现出一定泛化处理能力,验证了其在工业漏磁信号检测的泛化能力。然而,当前研究仍存在可完善之处:方法的实际应用范围暂时限于抽油管漏磁信号,对实际工况中更复杂的自然损伤信号(如腐蚀、裂纹扩展等)的降噪效果尚未充分验证。未来研究可围绕拓展实测信号的覆盖范围展开,针对抽油管自然损伤及其他管道类型(如输气管道、水管)的漏磁信号

进行深入测试。

参考文献

[1] KUMAR A, UPADHYAY R, KUMAR S, et al. Tubing and rod failure analysis in rod pumped wells in an Indian Western oil field[J]. SPE Journal, 2023, 28(3): 1481-1501.

[2] 黎会鹏,徐波,黄璞. 一种自适应的机械振动信号变分模态分析方法[J]. 电子测量技术, 2025, 48(8): 116-125.

LI H P, XU B, HUANG P. An adaptive variational mode analysis method for mechanical vibration signals [J]. Electronic Measurement Technology, 2025, 48(8): 116-125.

[3] 万佳诚,曾宪文,李靖超. 基于参数优化 VMD 与宽卷积神经网络的齿轮箱故障诊断[J]. 电子测量技术, 2025, 48(10): 25-32.

WAN J C, ZENG X W, LI J C. Fault diagnosis of gearbox based on parameter-optimized VMD and wide convolutional neural network[J]. Electronic Measurement Technology, 2025, 48(10): 25-32.

[4] 张仕忠,李红梅,赵春田. 漏磁检测多排传感器的数据

- 修正理论及方法[J]. 仪器仪表学报, 2023, 44(11): 243-251.
- ZHANG S Z, LI H M, ZHAO C T, et al. Theory and method of data correction for multi-row sensors in MFL detection[J]. Chinese Journal of Scientific Instrument, 2023, 44(11): 243-251.
- [5] 刘耀, 刘继兵, 井陆阳, 等. 基于组合滤波的起重机钢丝绳断丝损伤漏磁信号降噪方法[J]. 机电工程, 2025, 42(5): 866-875.
- LIU Y, LIU J B, JING L Y, et al. Denoising method for magnetic flux leakage signal of broken wires damage in crane steel wire rope based on combined filtering[J]. Journal of Mechanical & Electrical Engineering, 2025, 42(5): 866-875.
- [6] ZHANG O, WEI X Y. Denoising of magnetic flux leakage signals based on wavelet filtering method[J]. Research in Nondestructive Evaluation, 2019, 30(5): 269-286.
- [7] YAO Y, LI G P, ZHANG X F, et al. Research on wavelet denoising method based on soft threshold in wire rope damage detection[C]//2020 IEEE 8th International Conference on Computer Science and Network Technology (ICCSNT), 2020: 165-170.
- [8] YU J M, ZHANG Z. Research on the seismic signal denoising with the LMD and EMD method[C]//2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2017: 767-771.
- [9] 白毅翔, 陈志英, 张修伦, 等. 基于改进 VMD-WT 的油浸式变压器局部放电超声信号去噪方法[J]. 电子测量与仪器学报, 2024, 38(12): 237-249.
- BAI Y X, CHEN Z Y, ZHANG X L, et al. Denoising method for partial discharge ultrasonic signals of oil-immersed transformers based on improved VMD-WT[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 237-249.
- [10] 杨帆, 徐春雨, 李肃义. 基于 IPSO-VMD 联合小波阈值的超低空磁异常信号去噪方法[J]. 电子测量与仪器学报, 2025, 39(6): 204-211.
- YANG F, XU C Y, LI S Y. Denoising method for ultra-low altitude magnetic anomaly signals based on IPSO-VMD combined with wavelet threshold[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 204-211.
- [11] LONG L, WEN X L, LIN Y X. Denoising of seismic signals based on empirical mode decomposition-wavelet thresholding[J]. Journal of Vibration and Control, 2021, 27(3/4): 311-322.
- [12] SHI M J, ZHAO H H, HUANG Z Q, et al. Signal extraction using complementary ensemble empirical mode in pipeline magnetic flux leakage nondestructive evaluation[J]. Review of Scientific Instruments, 2019, 90(7): 075101.
- [13] 于元湛, 杨光永, 晏婷, 等. 基于 CEEMD 和 MOMEDA 的滚动轴承故障提取[J]. 电子测量技术, 2021, 44(22): 96-101.
- YU Y J, YANG G Y, YAN T, et al. Fault extraction of rolling bearing based on CEEMD and MOMEDA[J]. Electronic Measurement Technology, 2021, 44(22): 96-101.
- [14] 夏焰坤, 王宛婷, 黄鹏. 基于 PSO-VMD 的永磁同步电机匝间短路振动信号故障特征提取研究[J]. 电子测量与仪器学报, 2024, 38(7): 196-207.
- XIA Y K, WANG W T, HUANG P. Fault feature extraction of inter-turn short-circuit vibration signals in permanent magnet synchronous motors based on PSO-VMD[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 196-207.
- [15] 夏焰坤, 寇坚强, 李欣洋. 基于 IWOA-VMD 的永磁同步电机匝间短路故障振动信号去噪方法[J]. 电子测量与仪器学报, 2024, 38(4): 202-216.
- XIA Y K, KOU J Q, LI X Y. Denoising method for vibration signal of inter-turn short circuit fault in PMSM based on IWOA-VMD[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 202-216.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [17] ZHANG M, GUO Y B, ZHANG Z, et al. Extraction of pipeline defect feature based on variational mode and optimal singular value decomposition[J]. Petroleum Science, 2023, 20(2): 1200-1216.
- [18] MA W P, YIN S X, JIANG C L, et al. Variational mode decomposition denoising combined with the Hausdorff distance[J]. Review of Scientific Instruments, 2017, 88(3): 035109.
- [19] YAO X Y, ZHOU Q Z, WANG C, et al. An adaptive seismic signal denoising method based on variational mode decomposition[J]. Measurement, 2021, 177: 109277.
- [20] HE D Q, LIU C Y, JIN Z Z, et al. Fault diagnosis of flywheel bearing based on parameter optimization variational mode decomposition energy entropy and deep learning[J]. Energy, 2022, 239: 122108.
- [21] WANG Y W, CHEN P, ZHAO Y M, et al. A denoising

- method for mining cable PD signal based on genetic algorithm optimization of VMD and wavelet threshold[J]. *Sensors*, 2022, 22(23): 9386.
- [22] 王君瑞,吴新举,赵东琦,等. 基于 WOA-VMD 与 PSO-SVM 的锂离子电池内短路故障诊断方法[J]. *工程科学学报*, 2023, 45(12): 2162-2172.
- WANG J R, WU X J, ZHAO D Q, et al. Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA-VMD and PSO-SVM [J]. *Chinese Journal of Engineering*, 2023, 45(12): 2162-2172.
- [23] 杨森,王恒迪,崔永存,等. 基于改进 SSA 的参数优化 VMD 和 ELM 的轴承故障诊断[J]. *机械传动*, 2023, 47(10): 162-168.
- YANG S, WANG H D, CUI Y C, et al. Bearing fault diagnosis based on parameter optimized VMD and ELM with improved SSA [J]. *Journal of Mechanical Transmission*, 2023, 47(10): 162-168.
- [24] WANG H L, WU F, ZHANG L. Application of variational mode decomposition optimized with improved whale optimization algorithm in bearing failure diagnosis[J]. *Alexandria Engineering Journal*, 2021, 60(5): 4689-4699.
- [25] ZHANG Q, CHEN S, FAN Z P. Bearing fault diagnosis based on improved particle swarm optimized VMD and SVM models [J]. *Advances in Mechanical Engineering*, 2021, 13(6), DOI:10.1177/16878140211028451.
- [26] LI J M, CHENG X, LI Q, et al. Adaptive energy-constrained variational mode decomposition based on spectrum segmentation and its application in fault detection of rolling bearing [J]. *Signal Processing*, 2021, 183: 108025.
- [27] MENG Q, LANG X M, LIN M Q, et al. Leak localization of gas pipeline based on the combination of EEMD and cross-spectrum analysis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 71: 1-9.
- [28] 李帅永,夏传强,程振华,等. 基于 VMD 和互谱分析的供水管道泄漏定位方法[J]. *仪器仪表学报*, 2019, 40(7): 195-205.
- LI S Y, XIA C Q, CHENG Z H, et al. Leak location method in water-supply pipeline based on combination of VMD and cross-spectrum analysis [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(7): 195-205.
- [29] 薛生,谢晓贤,郑晓亮,等. 多工况输气管道泄漏声波信号自适应去噪[J]. *仪器仪表学报*, 2024, 45(3): 227-239.
- XUE S, XIE X X, ZHENG X L, et al. Adaptive denoising for leak-induced acoustic in gas pipe under multiple conditions [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(3): 227-239.
- [30] AGUSHAKA J O, EZUGWU A E, ABUALIGAH L. Gazelle optimization algorithm: A novel nature-inspired metaheuristic optimizer [J]. *Neural Computing and Applications*, 2023, 35(5): 4099-4131.

作者简介

郭畅达, 硕士研究生, 主要研究方向为管道无损检测与智能信息处理。

E-mail: 2067004202@qq.com

杨勇, 博士, 高级工程师, 主要研究方向为装置研发及非平稳信号处理技术。

E-mail: yangyong056.slyt@sinopec.com

任旭虎(通信作者), 博士, 副教授, 主要研究方向智能测控技术、智能信息处理。

E-mail: z23160115@s.upc.edu.cn

宋华军, 博士, 副教授, 主要研究领域为 VNA 设计研究、硬件系统设计以及智能信息处理。

E-mail: huajunsong@upc.edu.cn

葛文博, 硕士研究生, 主要研究方向为电缆故障检测。

E-mail: 1722204316@qq.com