

DOI:10.19651/j.cnki.emt.2416426

# 融合趋势评估 VMD 和 MSSE<sub>2D</sub> 的 往复压缩机故障诊断方法 \*

李颖 杨宝凯 孙国涵 巴鹏 马小英

(沈阳理工大学机械工程学院 沈阳 110159)

**摘要:** 针对在强噪声干扰环境下提取往复压缩机故障特征以及 VMD 算法参数设置对先验知识的过度依赖的问题,提出了融合趋势评估 VMD 算法和 MSSE<sub>2D</sub> 的往复压缩机故障诊断方法。本文选取往复压缩机的气阀故障数据作为研究对象,首先通过应用经过频谱趋势评估优化的 VMD 技术对信号进行深入分析与处理,然后使用 MSSE<sub>2D</sub> 进行分析计算,最后使用支持向量机进行验证测试,实验结果表明此方法相较于其他方法可以有效提取往复压缩机气阀故障特征,能够快速的对气阀各种状态进行精确的诊断与区分。

**关键词:** 往复压缩机;故障诊断;MSSE<sub>2D</sub>;趋势评估;VMD

中图分类号: TH457; TN911.7 文献标识码: A 国家标准学科分类代码: 460.5599

## Reciprocating compressor troubleshooting method integrating trend evaluation VMD and MSSE<sub>2D</sub>

Li Ying Yang Baokai Sun Guohan Ba Peng Ma Xiaoying

(School of Mechanical Engineering, Shenyang Ligong University, Shenyang 110159, China)

**Abstract:** Aiming at the problems of extracting the fault features of reciprocating compressors under the strong noise interference environment and the over-reliance on the a priori knowledge in the parameter setting of the VMD algorithm, a reciprocating compressor fault diagnosis method that integrates the VMD algorithm of trend evaluation and MSSE<sub>2D</sub> is proposed. In this paper, the valve fault data of reciprocating compressor is selected as the research object, firstly, the signal is analyzed and processed in depth by applying the VMD technique optimized by spectral trend evaluation, then the MSSE<sub>2D</sub> is used for analysis and calculation, and finally the support vector machine is used for validation test, and the experimental results show that this method can extract the fault characteristics of the reciprocating compressor valve efficiently compared with other methods, and it can quickly and accurately diagnose the various states of the valve, the results show that this method can effectively extract the fault characteristics of reciprocating compressor valves compared with other methods, and can quickly and accurately diagnose and distinguish between various states of valves.

**Keywords:** reciprocating compressors; fault diagnosis; MSSE<sub>2D</sub>; trend assessment; VMD

## 0 引言

往复压缩机作为一种关键的工业设备,被广泛应用于天然气输送、石油炼化、煤化工以及制冷等重要领域,这些设备的稳定运行和安全性直接关系到整个工业生产的效率<sup>[1]</sup>。因此,往复压缩机的故障诊断与预测技术显得尤为重要,它们是确保设备可靠运行和维护生产安全的关键所

在。然而,由于往复压缩机在运行过程中涉及大量机械运动和高压环境,其故障风险也相对较高。常见的故障包括阀门损坏、活塞磨损、连杆故障、轴承损坏、密封件泄漏等。气阀是往复压缩机中至关重要的组成部分,工作在一种高频冲击、高温和高压的严苛环境中,因此非常容易受到损害。当往复压缩机的气阀发生故障时,所生成的振动信号将表现出显著的非平稳性和非线性特征,而且故障特征信

收稿日期:2024-07-13

\* 基金项目:国家自然科学基金(51934002)、辽宁省属本科高校基本科研业务费专项资金(LJ212410144039)、辽宁省教育厅青年科技人才“育苗”项目(LJKZ0259)资助

息通常与背景噪声混合,使得从振动信号中准确提取故障特征变得更具挑战性。在这种情况下,传统的信号分析方法往往难以有效地从复杂的信号中准确提取出往复压缩机气阀的故障特征。因此,需要采用更先进的信号处理技术来解决这个问题,以确保往复压缩机的正常运行和生产安全。

在处理具有非平稳性和多分量耦合特性的振动信号时,研究者们普遍采用了信号自适应分解技术进行特征分析。文献[2]结合了经验模态分解(empirical modal decomposition, EMD)和信息熵理论,创新性地提出了一种新方法,即通过分析蕴含气阀故障特征的能量向量,将其作为诊断往复压缩机气阀故障的依据。文献[3]则提出了一种基于有理 Hermite 插值的最小平均平方误差(local mean decomposition, LMD)方法,并验证了该方法在往复压缩机故障诊断领域的有效性。然而,EMD 和 LMD 方法也存在不足,其都依赖于包络分析来处理振动信号,这会导致由于极值点分布不均匀而产生的模态混叠现象<sup>[4-5]</sup>,从而影响故障诊断的准确性。为了解决这一问题,研究者们提出了一种基于维纳滤波器的新型自适应分析方法——变分模态分解(variational modal decomposition, VMD)<sup>[6]</sup>。VMD 方法克服了 EMD 和 LMD 方法中固有的模态混叠问题,使得其更适合处理含有随机噪声和高频噪声的现场实测信号,但 VMD 方法也有局限性,其自适应性允许根据信号调整  $k$  值,但无法直接确定最佳的分解层数  $k$ ,文献[7]得益于 AO 的强大快速搜索和开发能力,故障分类性能显著优于原始的 VMD 分解方法。本文提出的趋势评估 VMD 方法采用一种创新的频谱趋势算法来自动识别共振频带的边界,从而确定合适的中心频率数量  $k$  以及每个频带的带宽,实现 VMD 算法参数的智能获取。

同时,为了细致描述非线性振动信号的复杂性,引入了熵的概念并应用于信号处理领域。文献[8]提出了基于散布熵的往复压缩机气阀故障特征提取方法,其方法具有较强的抗工频干扰能力,可以有效区分气阀正常、阀片断裂及弹簧失效 3 种状态。文献[9]提出了一种基于修正多尺度熵和全局距离评价的往复式压缩机阀故障诊断方法,该方法能够有效地识别往复式压缩机气的故障类型。文献[10]提出了基于 VMD 和改进多尺度熵的往复压缩机气阀故障诊断方法,进一步提高了识别的准确率。文献[11]提出多尺度排列熵的滚动轴承故障诊断,使得训练时间更短、准确率更高。文献[12]使用样本分位数排列熵实现了实现轴承故障类型的准确区分。一维多尺度熵只考虑信号在时域的复杂性,却忽略了时间序列在频域的信息,为了克服这一局限性,研究者们提出了二维多尺度样本熵,其虽然能够提取气阀振动信号的时频图像特征,但其计算效率低,且在信号中存在较大干扰噪声时,特征提取效果会受到影响。为了解决这些问题,研究者们开始探索新的分析途径。本文借鉴了符号化思想,并结合符号动态滤波,提出了一种二维多

尺度符号样本熵(two-dimensional multi-scale symbol sample entropy, MSSE<sub>2D</sub>)方法。

综上所述,本文依据往复压缩机气阀故障诊断信号的特点,提出融合趋势评估 VMD 算法和 MSSE<sub>2D</sub> 的故障诊断方法,并首次成功应用于往复压缩机故障诊断中。该算法的核心原理在于,首先采用一种创新的频谱趋势算法来自动识别共振频带的边界,从而智能地确定合适的中心频率数量  $k$  以及每个频带的带宽。在此基础上,依据特定的准则来预测与每个频带相对应的惩罚因子。在确定了这些关键参数之后,便可以将它们应用于 VMD 算法中,以实现对信号的精确分解。最终,通过二维多尺度符号样本熵分析,使用支持向量机进行验证实现对故障类型的分类识别。

## 1 趋势评估 VMD 算法

### 1.1 VMD 算法原理

VMD 算法核心在于通过变分约束求解极值,从而找到最合适的本征模态函数(intrinsic mode function, IMF)分量。相较于经验模态分解(EMD),变分模态分解(VMD)在凸显信号局部特性和抑制模态混叠现象方面表现出更出色的能力,从而达到更优秀的信号处理效果<sup>[13]</sup>。在进行信号分解之前,需要预先设定一个参数——预分解层数  $k$ 。设定完毕后,VMD 将对原始信号  $y(t)$  进行约束变分处理。其表达式如下:

$$\min_{\{\nu_k\}, \{\omega_k\}} \left\{ \sum_k \|\partial_t [(\delta(t) + j/\pi t) \times v_k(t)] e^{-j\omega_k t} \|_2^2 \right\} \quad (1)$$

$$\text{s.t. } \sum_k v_k = y(t) \quad (2)$$

式中:  $\{\nu_k\} = \{\nu_1, \nu_2, \dots, \nu_k\}$  为分解后得到的  $k$  个模态;  $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$  为各分量的中心频率;  $[\delta(t) + j/\pi t] * v_k(t) - v_k(t)$  的希尔伯特变化,\* 为卷积运算。

在有约束条件下求最优化问题时,通过引入二次惩罚系数  $\alpha$  和拉格朗日乘数,可以将带约束的问题转化为无约束问题。所得的拉格朗日表达式如下:

$$L(\{\nu_k\}, \{\omega_k\}, \tau) = \alpha \sum_k \|\partial_t \{[\delta(t) + \frac{j}{\pi t}] e^{-j\omega_k t}\}\|_2^2 +$$

$$\|y(t) - \sum_k v_k(t)\| + \langle \tau(t), y(t) - \sum_k v_k(t) \rangle \quad (3)$$

式中:二阶惩罚因子  $\alpha$  可以有效降低高斯噪声带来的干扰。

采用交替方向乘子法来求解问题,通过迭代更新各个模态函数及其相应的中心频率,直到确定出所设定的  $k$  个分量的最优解方案。最终,这些解可以通过如下公式得出:

$$\hat{v}_k^{n+1}(\omega) = \frac{\hat{y}(\omega) - \sum_{i \neq k} \hat{v}_i(\omega) + \frac{\hat{\tau}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

式中: $\omega$  代表所对应的频率; $\hat{v}_k^{n+1}(\omega)$  为  $\hat{v}_k^n(t)$  傅里叶变换; $\hat{y}(\omega)$  为  $y(t)$  傅里叶变换; $\hat{\tau}(\omega)$  为  $\tau(t)$  傅里叶变换。

VMD 方法具体迭代过程如下:

- 1) 初始化  $\{\hat{v}_k^1\} \{\hat{\omega}_k^1\} \{\hat{\tau}_k^1\}$  及  $n$ ,均置零;

- 2) 设置最大迭代次数  $N$ ;
- 3) 开始迭代  $n = n + 1$ ;
- 4) 当  $\omega > 0$ , 由上述公式更新  $\hat{v}_k$ ,
- 5) 更新  $\hat{\omega}_k$  由式(5)所示。

$$\hat{\omega}_k^{n+1} = \frac{\int_0^{\infty} \omega |v_k^{n+1}(\omega)|^2 d\omega}{\int_0^{\infty} |v_k^{n+1}(\omega)|^2 d\omega} \quad (5)$$

- 6) 更新  $\hat{\tau}$ , 由式(6)所示。

$$\hat{\tau}^{n+1}(\omega) = \hat{\tau}^n + \tau(ss(\omega) - \sum_k \hat{v}_k^{n+1}(\omega)) \quad (6)$$

7) 复执行步骤 3)~6), 直到满足式(7), 循环结束, 输出各分量。

$$\sum_k \| \hat{v}_k^{n+1} - \hat{v}_k^n \|_2^2 / \| v_k^n \|_2^2 < \epsilon \quad (7)$$

## 1.2 趋势评估 VMD 算法

频谱趋势估计算法在信号处理领域中的应用日益广泛, 尤其是在非平稳信号分析和趋势预测方面展现出独特的优势。在众多频谱趋势估计算法中, Hilbert-Huang 变换(HHT)是一种备受关注的方法, 它包括经验模态分解(EMD)和 Hilbert 变换两个步骤。

首先, 需要理解频谱趋势的概念。在时域分析中, Hilbert 解调是一种常用的方法, 它可以帮助获取信号的瞬时频率和幅度, 从而揭示信号的趋势。类似地, 当把分析目标转向频域时, 就可以获得频谱趋势。频谱趋势反映了信号在不同频率成分上的分布和变化情况, 这对于理解信号的特性和预测其未来走势具有重要意义。

作为一种数据驱动的自适应分解技术, EMD 算法的独特优势在于能够将错综复杂的信号分解为多个固有模态分量(IMF)。这些 IMF 各自代表着信号中的某个特定频率成分, 且它们以从高频至低频的顺序有序排列。随着分解层次的递增, 各 IMF 中包含的低频元素逐渐增多。考虑到低频成分在时域内的变化相对平稳, 它们能够有效地揭示信号的发展趋势。在确定分解层数  $k$  的过程中, 可以通过分析信号与各分量均值之间的关系, 并结合数据的整体趋势, 来评估所需的合适分解频带数量。遵循这一思路, 可以利用 EMD 算法来提取信号的趋势信息。这样的方法能够更准确地把握信号的本质特征, 从而提高信号处理的效率和精度。具体过程如下:

- 1) 对信号进行 EMD 分解, 得到一系列 IMF, 记为  $IMF_1, IMF_2, \dots, IMF_k$ 。
- 2) 从低频 IMF 开始, 逐渐累加到高频 IMF, 形成新的信号序列。
- 3) 对于每个累加信号, 计算其极大值的数量, 记作  $n_m$ 。
- 4) 当累加信号中  $n_{m+1}/n_m$  首次出现极大值时, 记录此时的 IMF 序号  $m+1$ 。
- 5) 将两个极大值之间的极小值作为频带划分点, 从而确定分解层数  $k$ 。

通过上述过程, 可以有效地提取出信号的趋势信息, 并为 VMD 算法中分解层数  $k$  的确定提供参考。VMD 算法是一种新的变分模态分解方法, 它在处理非平稳信号时具有较好的性能。通过结合 EMD 和 VMD 算法, 可以更准确地分析和预测信号的频谱趋势。

VMD 算法通过应用一组  $k$  个滤波器来进行信号处理, 其效果在很大程度上取决于分解层数  $k$  的选择。为了解决这一问题, 本文提出了一种优化的变分模态分解算法。该算法创新性地融入了频谱趋势估计算法, 能够智能地分析信号频谱结构, 并据此精确地确定频带划分点。这些划分点信息被进一步用于预测各个分解模态相应的惩罚因子  $\alpha_k$ , 进而构建一个惩罚因子的初始矩阵。这种方法能够更合理地确定分解层数  $k$ , 提高 VMD 算法的性能和准确性<sup>[14]</sup>, 这里的惩罚因子取值模型, 其表达式如式(8)所示。

$$\alpha_k = \beta \left( \frac{f_s - B_k}{f_s} \right) \quad (8)$$

式中:  $B_k$  为模态对应的带宽;  $f_s$  为信号的采样频率;  $\beta$  为初始惩罚因子。

在变分模态分解(VMD)算法中, 惩罚因子的选择对于分解结果的准确性至关重要。惩罚因子与各模态分量 IMF 的带宽成反比关系, 这一参数的设定直接影响到算法的效率和分解质量。如果惩罚因子  $\alpha$  设定得过小, 会导致分解出的频带过宽, 从而可能引起模态混叠现象。这种现象指的是, 不同的模态分量在频谱上相互重叠, 导致信号的高频部分和低频部分无法清晰地区分开来。这样的混叠会使得 VMD 算法无法有效地分离出原始信号中不同的频率成分, 降低了信号分解的准确性。

相反, 如果惩罚因子  $\alpha$  设定得过大, 频带会变得非常窄, 这虽然能够保证各个模态分量之间的分离度, 但同时也增加算法的迭代次数, 影响算法的收敛速度。过多的迭代次数会导致计算资源的大量消耗, 降低算法的实用性。此外, 过窄的频带可能会过分细化信号的频率成分, 导致一些重要的频率特征被忽略, 从而影响对信号的整体理解。

为了解决这一问题, 通常需要根据信号的特性来合理选择惩罚因子  $\alpha$  的值。在实际应用中, 一个信号的  $\alpha$  值通常存在一个合适的范围, 这个范围可以根据信号的复杂度和应用需求进行调整。不同的信号可能会有不同的最佳  $\alpha$  值, 因此, 惩罚因子的选择需要根据具体情况进行调整, 以达到最佳的分解效果。

为了简化计算并提供一个初始的参考值, 可以将公式中的初始惩罚因子  $\beta$  设定为一个经验值, 如 2 000。这个值通常能够在大多数情况下提供一个良好的起点, 但它并不是固定不变的。在实际应用中, 可能需要根据信号的特性和分解的目标来调整  $\beta$  的值, 以获得更好的分解效果。通过这种方式, VMD 算法能够更加灵活地适应不同的信号处理需求, 提高其在信号分析、故障诊断、图像处理等领域中的应用价值。

### 1.3 基于 EMD 方法的频谱趋势估计算法可行性验证

为了对基于 EMD 方法的频谱趋势估计 VMD 方法的可行性,这里采用往复压缩机气阀正常运行的振动信号作为分解处理对象,来展示基于 EMD 方法的频谱趋势估计 VMD 方法的分解效果。基于 EMD 方法的频谱趋势估计 VMD 方法的分解效果分别如图 1、2 所示。

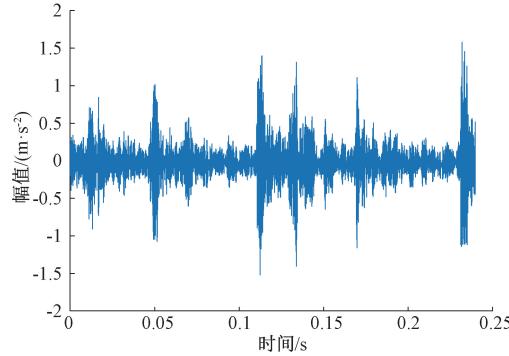


图 1 往复压缩机气阀正常运行信号时域图像

Fig. 1 Time domain image of normal operation signal of reciprocating compressor valve

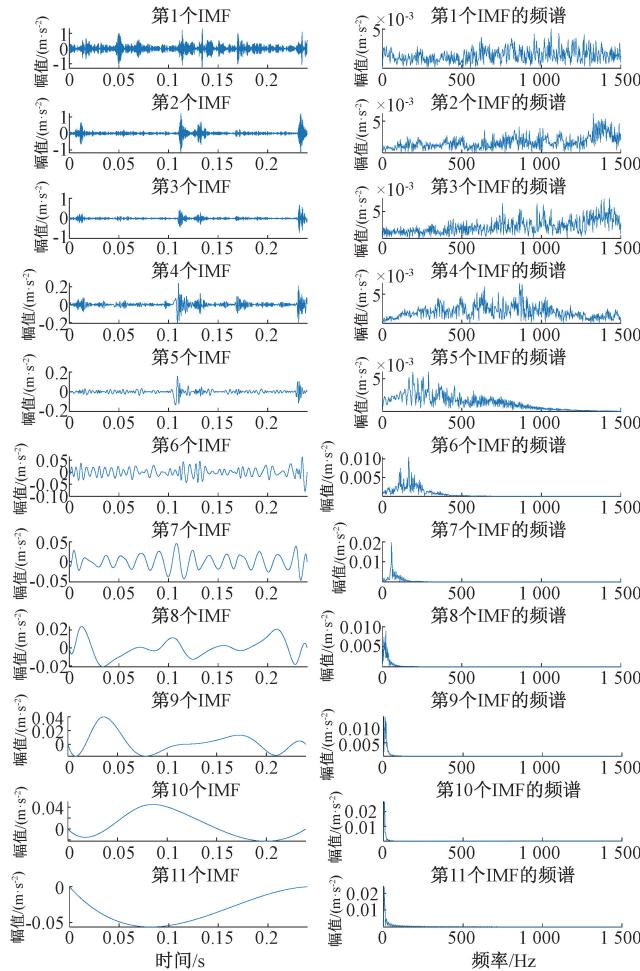


图 2 往复压缩机气阀正常运行各分量信号时域图像及频谱

Fig. 2 Time domain image and spectrum of signals of each component in normal operation of reciprocating compressor valve

基于 EMD 方法的频谱趋势估计算法可以得到分解层数  $k=3$  和惩罚因子  $\alpha_k$  分别为 526.4, 1 481.1, 1 997.2, 并将数据代入 VMD 方法中完成分解,结果如图 3 所示。

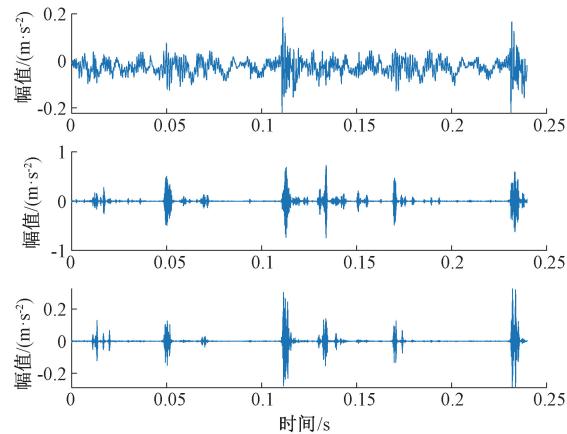


图 3 往复压缩机气阀正常运行各分量信号时域图像

Fig. 3 Reciprocating compressor gas valve normal operation of each component signal time domain image

由如图 3 可以看出基于 EMD 方法的频谱趋势估计 VMD 方法是可行的。

## 2 二维多尺度符号样本熵

### 2.1 二维多尺度符号样本熵原理

二维符号样本熵 (two-dimensional symbol sample entropy, SSE<sub>2D</sub>) 是在样本熵的基础上通过对二维时间图像序列的符号化消除噪音处理,对样本熵进行多尺度分析,本文使用符号动态滤波进行序列的符号化。利用符号动态滤波 (symbolic dynamic filtering, SDF) 消除与噪声相关联的其他波动,从而减少噪音对信号处理的干扰。符号动态滤波的原理如图 4 所示,  $X_1 = \{x_{11}, x_{12}, x_{13}\}$  表示一组数据的初始序列,序列  $X_2 = \{x_{21}, x_{22}, x_{23}\}$  和序列  $X_3 = \{x_{31}, x_{32}, x_{33}\}$  由其他噪音干扰后得到的序列,因为噪音影响,序列  $X_2, X_3$  会在序列  $X_1$  附近上下波动,序列经过符号动态滤波转换为  $\{\beta, \beta, \beta\}$  因此,符号动态滤波具有抗噪的性能。另一序列  $X_4 = \{x_{41}, x_{42}, x_{43}\}$  在符号动态滤波下转化为  $\{\beta, \alpha, \beta\}$ ,保留了原序列的幅值信息。符号动态滤波原理图如图 4 所示。

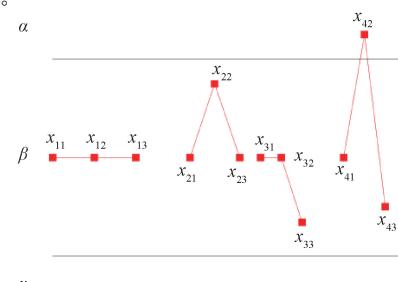


图 4 符号动态滤波原理图

Fig. 4 Symbolic dynamic filter schematic

综合上述各种方法结合,得出  $SSE_{2D}$  的定义如下:

1)首先根据对时间信号进行二值化处理得到长度为  $W \times H$  的二维序列:

$$\{u(i,j); 1 \leq i \leq W, 1 \leq j \leq H\} \quad (9)$$

2)然后将二维序列进行符号化,得到新的序列:

$$S = \{s(i,j); 1 \leq i \leq W, 1 \leq j \leq H\} \quad (10)$$

3)对新序列  $S$  嵌入  $m$  维构造序列:

$$S' = \begin{Bmatrix} s(i,j) & s(i,j+1) & \cdots & s(i,j+m-1) \\ s(i+1,j) & s(i+1,j+1) & \cdots & s(i+1,j+m-1) \\ \vdots & \vdots & \vdots & \vdots \\ s(i+m-1,j) & s(i+m-1,j+1) & \cdots & s(i+m-1,j+m-1) \end{Bmatrix}$$

其中,  $1 \leq i \leq W, 1 \leq j \leq H$  (11)

4)定义  $s_m(i,j)$  与  $s_m(k,l)$  直接的距离  $d$  为对应元素差值的最大值,记为  $d_{ij-kl}^m$ :

$$d_{ij-kl}^m = d[s_m(i,j), s_m(k,l)] = \max_{n \in \{0, m-1\}} |s(i+n, j+n) - s(k+n, l+n)| \quad (12)$$

式中:  $i, k=1, 2, \dots, H-m, i \neq k$

$$j, l = 1, 2, \dots, W-m, j \neq l$$

5)然后给定一个相似容限  $r$ ,对于计算得到的所有  $d$ ,统计其中的所有  $s(i,j)$  对应得到的所有  $d[s_m(i,j), s_m(k, l)] \leq r$  的数目,记为  $A_{ij}$ ,然后将所有的  $A_{ij}$  与

$$\frac{1}{(H-m-1) \times (W-m-1)} \text{ 的比值记为 } B_{ij}^m(r), \text{ 即:}$$

$$B_{ij}^m(r) = \frac{A_{ij}}{(H-m-1) \times (W-m-1)} \quad (13)$$

6)计算  $B_{ij}^m(r)$  的平均值  $B^m(r)$ 。

$$B^m(r) = \frac{1}{(H-m) \times (W-m)} \sum_{i=1}^{H-m} \sum_{j=1}^{W-m} B_{ij}^m(r) \quad (14)$$

在将维数  $m$  增加 1,重复步骤 2)~6),得到新的平均值  $B^{m+1}(r)$ 。

则根据样本熵计算公式,得出  $SSE_{2D}$  的计算公式为:

$$SSampEn_{2D} = (\epsilon, m, r) = \lim_{\substack{H \rightarrow \infty \\ W \rightarrow \infty}} \left[ -\ln \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (15)$$

另外,当  $H$  与  $W$  为有限值时,  $SSE_{2D}$  计算公式为:

$$SSampEn_{2D} = (\epsilon, m, r, H, W) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (16)$$

$SSE_{2D}$  的核心思想是通过对图像序列进行符号动态滤波处理,将其转换成符号表示,并计算转换后图像的二维样本熵。此方法的主要优势有两方面:一方面,它能够高效地剔除与噪声相关的不稳定波动,净化信号;另一方面,在计算过程中,由于图像中存在众多由少量符号组成的重复序列,这些序列的计算可以重复利用,从而极大地提升了整体计算的效率。

$SSE_{2D}$  作为一种单尺度分析工具,虽然在处理图像序列时具有一定的优势,但其局限性在于无法全面捕捉信号在不同尺度上的复杂性。为了克服这一局限,本文受到了二维粗粒化思想的启发,进而提出了一种新的分析方

法——二维多尺度符号样本熵( $MSSE_{2D}$ )方法<sup>[15]</sup>,计算步骤如下:

1)粗粒化过程。对于  $W \times H$  图像序列  $\{u(i,j); 1 \leq i \leq W, 1 \leq j \leq H\}$  的二维粗粒化为:

$$y_{i,j}^\tau = \frac{1}{\tau^2} \sum_{k=(i-1)\tau+1}^{k=i\tau} \sum_{l=(j-1)\tau+1}^{l=j\tau} u(i,j) \quad (17)$$

式中: $i$  和  $j$  的取值范围分别为  $1 \leq i \leq \lfloor \frac{H}{\tau} \rfloor, 1 \leq j \leq \lfloor \frac{W}{\tau} \rfloor$ ,  $\tau$  为尺度因子,必须是整数。 $\tau=1, \{y^{(\tau)}\}$  为原始图像。粗粒化图像序列  $\{y^{(\tau)}\}$  大小为  $\lfloor \frac{H}{\tau} \rfloor \times \lfloor \frac{W}{\tau} \rfloor$ ,  $\lfloor \cdot \rfloor$  表示取整。

2)符号化。对粗粒化图像序列  $\{y^{(\tau)}\}$  使用原始符号序列进行符号化,求符号序列  $\{s^\tau\}$  的二维样本熵,即尺度因子  $\tau$  的二维符号样本熵。

$$MSSE_{2D}(u, \tau, \epsilon, m, r) = SSampEn_{2D}(y^\tau, \epsilon, m, r) \quad (18)$$

$MSSE_{2D}$  采用符号动态滤波技术对图像数据进行符号化转换,有效地清除了背景噪声并优化了计算过程。这种方法在概念上与二维多尺度样本熵相似,通过计算图像序列在不同尺度上新模式出现的概率,对序列的复杂性进行量化。

## 2.2 二维多尺度符号样本熵验证

在模拟  $MSSE_{2D}$  时需要设定 3 个参数,即嵌入模数  $m$ ,相似容限  $r$  和符号尺度  $\epsilon$ 。参考文献[16],本文取相似容限  $r=0.15SD$ ( $SD$  为二维图像序列的标准差),模数  $m=2$ ,符号尺度  $\epsilon=20$ ,探究白噪声与粉红噪声的  $MSSE_{2D}$ ,如图 5 和 6 所示。

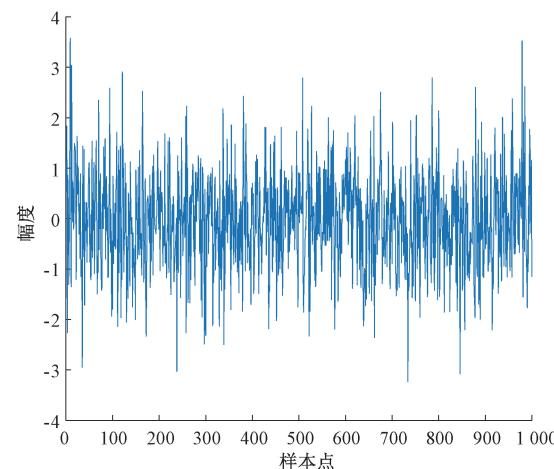


图 5 白噪声模拟信号

Fig. 5 White noise analog signal

利用白噪声和粉红噪声分析不同尺度下的  $MSSE_{2D}$ ,对白噪声和粉红噪声进行分析,得出图 7。

## 3 故障诊断方法的流程

本文提到的融合趋势评估 VMD 算法和  $MSSE_{2D}$  的往

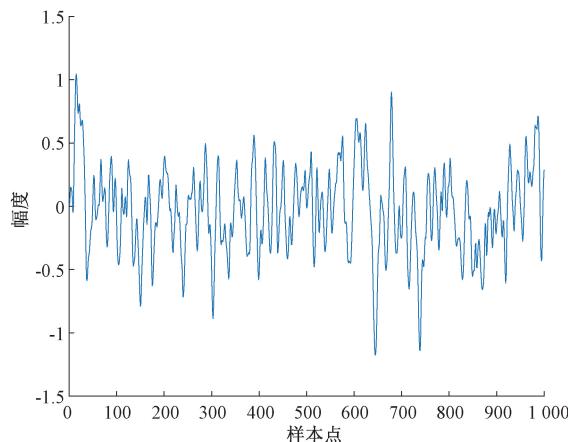


图 6 粉红噪声模拟信号  
Fig. 6 Pink noise analog signal

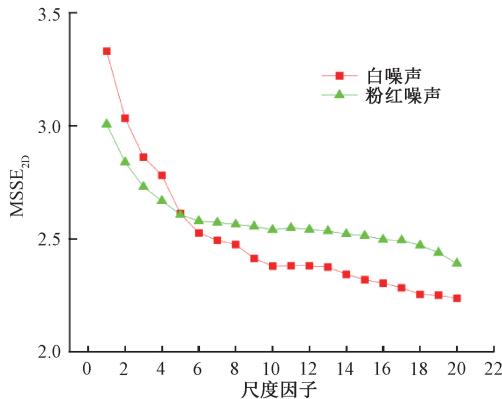


图 7 模拟图像在不同  $\epsilon$  下的 MSSE<sub>2D</sub>  
Fig. 7 Simulate the MSSE<sub>2D</sub> of an image at different  $\epsilon$

往复压缩机故障诊断方法,具体诊断步骤如下:

- 1) 采集往复压缩机气阀的振动信号  $f(t)$ 。
- 2) 利用频谱趋势估计方法来确定信号分解层数  $k$ , 并据此确定相应的频带划分点。
- 3) 根据既定公式, 计算出每个频带对应的惩罚因子  $\alpha_k$ 。
- 4) 将步骤 3) 中得到的参数应用于 VMD 算法中, 完成信号的分解过程。
- 5) 对重构后的信号进行二维多尺度符号样本熵分析, 使用支持向量机进行验证测试, 获取故障诊断结果。

#### 4 实验分析

遵循振动信号采集的标准,本文对 2D12 型往复压缩机进行了多种故障模拟实验,并成功收集了气阀在各类故障状态下的振动数据。在研究过程中对工作系统中的气阀进行了故障模拟,其中包括阀体损伤、阀片断裂和阀弹簧缺失等多种情况。在实验过程中,本文以 50 kHz 的采样率对模拟实验产生的振动信号进行了为期 4 秒的连续采集。随后,从这些采集到的振动数据中选取了两个周期的信号样

本进行对比分析。由于在实际信号收集中,环境噪声是不可避免的,为了减轻噪声对信号解析的影响,本文运用了小波阈值降噪技术对数据进行预处理,从而显著减少了噪声对信号的干扰。信号时域图像如图 8~11。

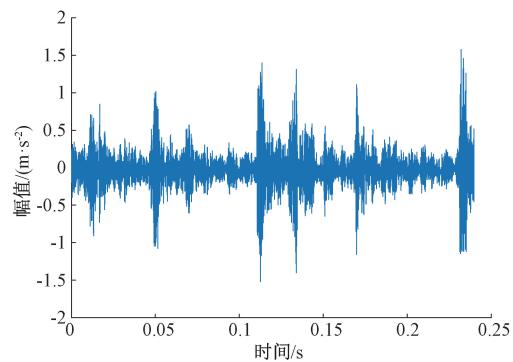


图 8 往复压缩机气阀正常运行信号时域图像  
Fig. 8 Time domain image of normal operation signal of reciprocating compressor valve

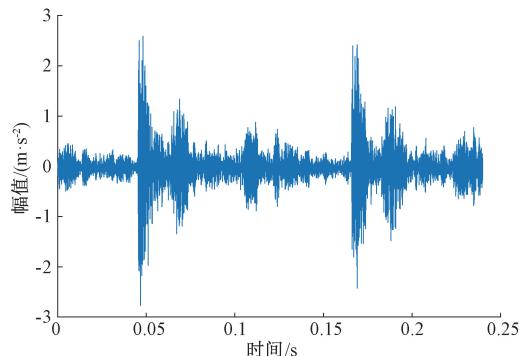


图 9 往复压缩机阀片有两个缺口信号时域图像  
Fig. 9 Reciprocating compressor valve plate has two notch signal time domain image

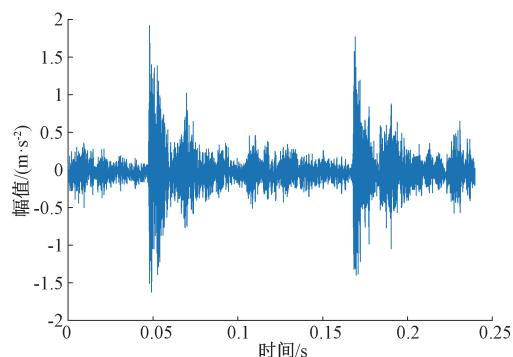


图 10 往复压缩机中间阀片断裂信号时域图像  
Fig. 10 Reciprocating compressor intermediate valve plate fracture signal time domain image

采用基于 EMD 方法的频谱趋势估计算法分别对上述往复压缩机气阀的 4 种状态进行分解,各状态下由 EMD 方法确定的分解层数  $k$  及惩罚因子  $\alpha_k$  的具体数值如表 1 所示。

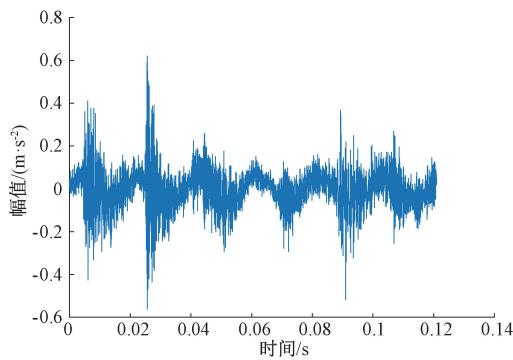


图 11 往复压缩机气阀缺少弹簧信号时域图像

Fig. 11 Reciprocating compressor valve missing spring signal time domain image

表 1 各状态下经 EMD 方法确定的  $k$ 、惩罚因子  $\alpha_k$ Table 1 K and penalty factor  $\alpha_k$  determined by

EMD method in each state

故障状态	固有模态( $k$ )	惩罚因子 $\alpha_k$			
		IMF1	IMF2	IMF3	IMF4
气阀正常状态	3	526.4	1 481.1	1 997.2	
气阀阀体缺口状态	3	105.1	1 785.6	1 949.3	
气阀阀片断裂状态	3	942.2	1 520.5	1 901.8	
气阀缺弹簧状态	4	1.4	361.5	1 580.3	1 976.7

将已确定的分解层数  $k$  及惩罚因子  $\alpha_k$  带入 VMD 方法中, 分解结果图 12~15 所示。

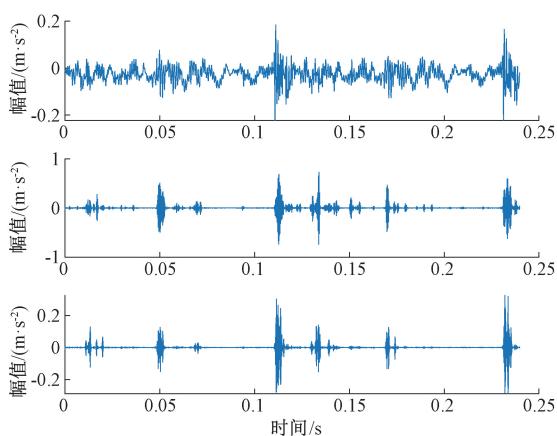


图 12 往复压缩机气阀正常运行各分量信号时域图像

Fig. 12 Reciprocating compressor gas valve normal operation of each component signal time domain image

对分解后的信号进行重构, 利用短时傅里叶变换对图像进行时频分析, 得到 4 种状态的二维时频图像, 然后对得

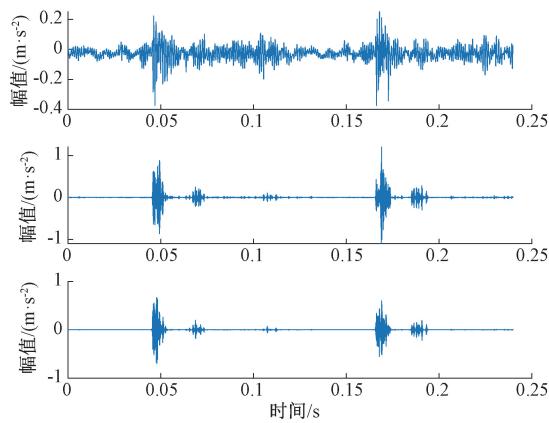


图 13 往复压缩机阀片缺口故障各分量信号时域图像

Fig. 13 Time domain image of each component signal of reciprocating compressor valve plate notched fault

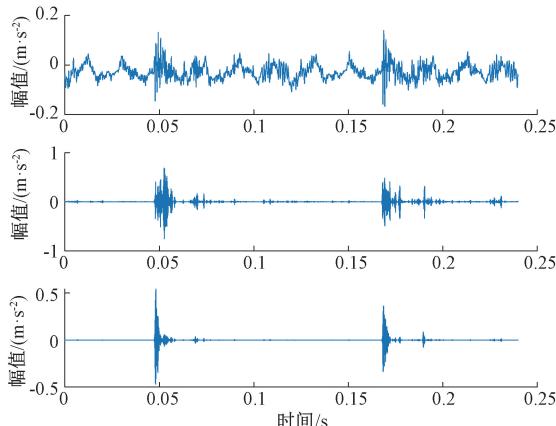


图 14 往复压缩机阀片断裂各分量信号时域图像

Fig. 14 Time domain image of each component signal of reciprocating compressor valve plate fracture

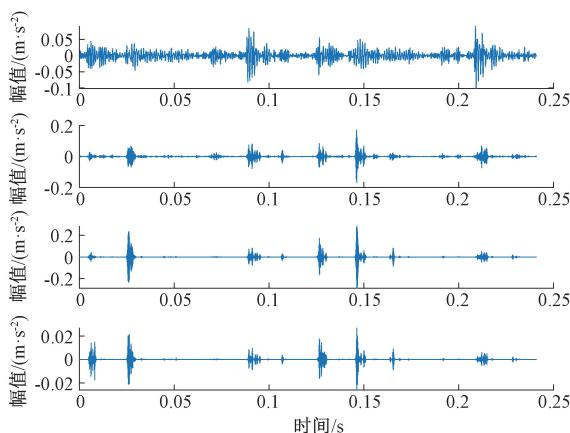


图 15 往复压缩机气阀缺少弹簧各分量信号时域图像

Fig. 15 The reciprocating compressor valve lacks the time-domain image of the spring component signal

到的二维时间序列进行动态符号滤波的符号化处理, 得到

4 种状态的符号化后图像,接下来对时频图像进行符号化消噪,用动态滤波进行符号化处理得到符号化后的图像,符号动态滤波符号化消除噪音后的时频图像如图 16~19 所示。

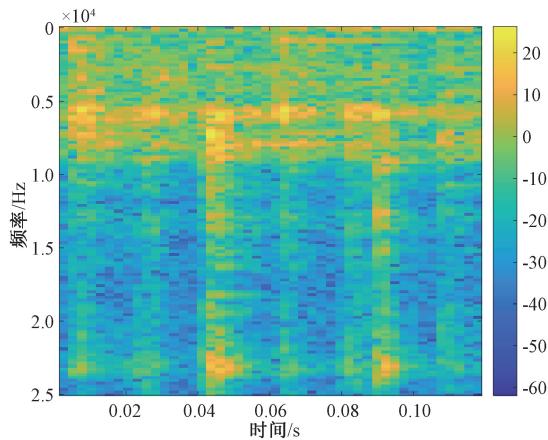


图 16 正常运行时频图像符号化后图像

Fig. 16 Normal running time frequency image after symbolized image

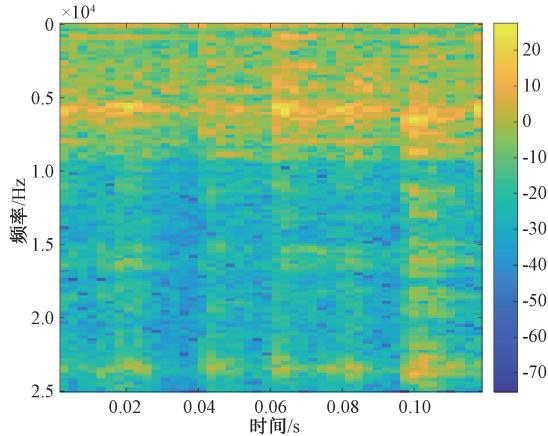


图 17 阀片有两个缺口故障时频图像符号化后图像

Fig. 17 Valve plate has two notches fault time frequency image after symbolized image

符号化后的图像保留了原图像的图像序列特征,在方便计算的同时还能确保准确无误,减少噪音对原序列的影响。对其进行 MSSE<sub>2D</sub> 的计算并且绘制熵值曲线,如图 20 所示。

图 20 中可以反应出气阀正常运行时候的熵值曲线图像,随着尺度增加,趋于平滑,表明正常运行状态下,振动信号的复杂性和随机性较低,呈现出规律性和可预测性。气阀缺口故障的熵值曲线在较低尺度时,与正常运行状态相似,随着尺度增加,熵值曲线有明显的波动,阀缺口故障可能导致气体泄漏,以至于振动信号出现一些不规则性和随机性。气阀阀片断裂故障的熵值曲线整体波动较大,而且在尺度为 6~14 时非常剧烈。这表明阀片断裂导致的振动信号出现大幅度的不稳定性,阀片断裂会使气阀无法正常

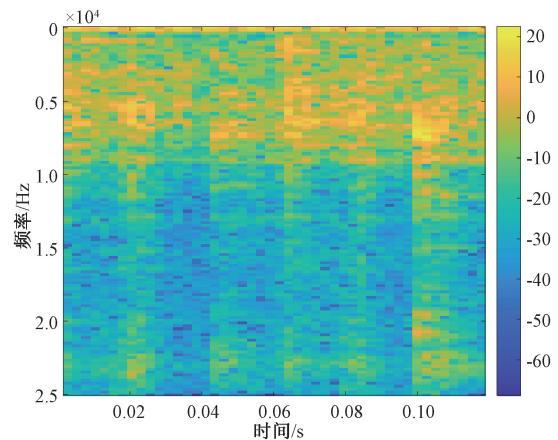


图 18 阀片断裂时频图像符号化后图像

Fig. 18 Valve plate break time frequency image after symbolization image

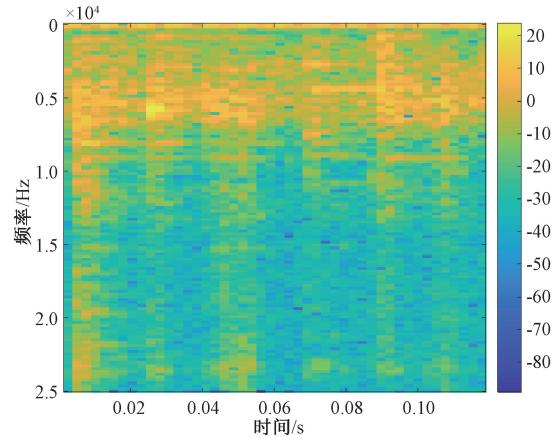


图 19 气阀弹簧缺失时频图像符号化后图像

Fig. 19 Valve spring missing time frequency image after symbolization image

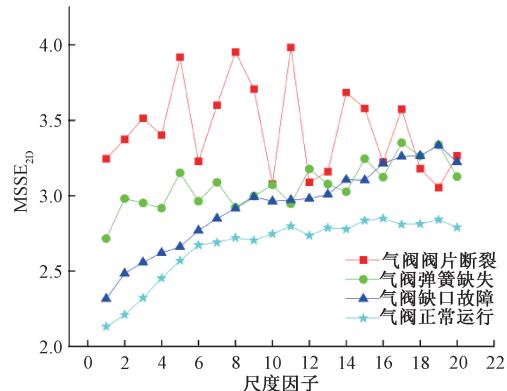


图 20 气阀各状态 MSSE<sub>2D</sub> 图像

Fig. 20 MSSE<sub>2D</sub> image of each state of air valve

关闭,从而导致更严重的信号异常。气阀弹簧缺失故障的熵值曲线出现明显的周期性波动,而且不同尺度均存在,可能是由于气阀无法正常复位,受到周期性冲击导致信号出

现周期性波动。

为证明该方法的可行性,本文使用  $MSE_{2D}$  和  $MPE_{2D}$  进行对比分析,并利用支持向量机进行验证测试,表明  $MSSE_{2D}$  相较于  $MSE_{2D}$  和  $MPE_{2D}$  的优势。

图 21 和图 22 为另外两种方法的均值方差图像,其中参数设置和  $MSSE_{2D}$  相同,由图 21 可知当气阀出现故障时,其熵值曲线波动程度相较于气阀正常运行的熵值曲线较大,且不容易区分。由图 22 可知在尺度因子从 1 增加到 5 的过程中,气阀在不同状态下的曲线随着尺度因子的增大而逐渐上升。当尺度因子继续增加到 7~20 的范围时,气阀正常状态下的  $MPE_{2D}$  熵值曲线在特定区间内呈现出上下波动的模式。与此同时,其他状态下的  $MPE_{2D}$  熵值曲线则显示出随着尺度因子的增加而逐渐下降的趋势。然而,需要注意的是,有两组故障类型的区分度并不明显,这可能会对故障诊断的准确性产生影响。

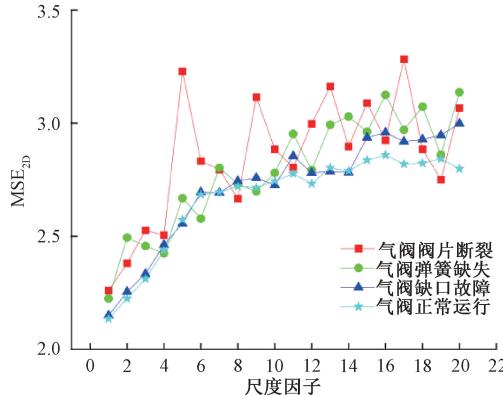


图 21 气阀各状态的二维  $MSE_{2D}$  图像

Fig. 21 2D  $MSE_{2D}$  images of each state of the air valve

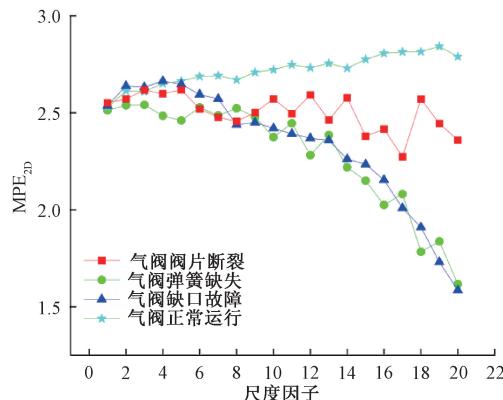


图 22 气阀各状态二维  $MPE_{2D}$  图像

Fig. 22 2D  $MPE_{2D}$  images of each state of the air valve

为更深入证明趋势评估 VMD 和  $MSSE_{2D}$  的优势,本文将采用支持向量机进行分类训练,从 40 个样本中选取 15 组样本作为训练样本,然后剩余 25 组样本作为测试样本进行 20 次测试,图 23 为 3 种不同熵方法的测试结果,表 2 为不同组合算法的识别率和计算时间。图 24~26 为

3 种不同熵方法的多类混淆矩阵图。

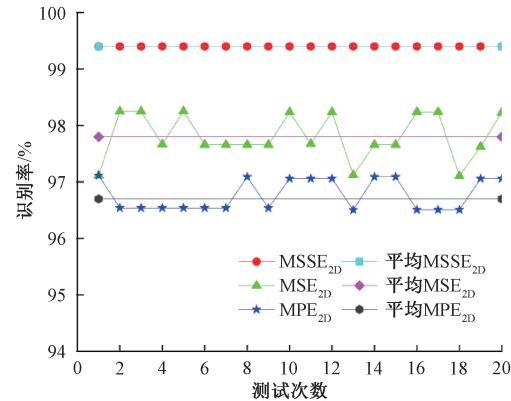


图 23 3 种不同熵方法的气阀故障识别率

Fig. 23 Valve fault recognition rates for three different entropy methods

表 2 不同组合算法的识别率和计算时间

Table 2 Recognition rate and computation time for different combinations of algorithms

方法	识别率/%			计算时间/s
	最大值	最小值	平均值	
趋势 + $MSSE_{2D}$	99.42	99.42	99.42	37.3
评估 + $MSE_{2D}$	98.24	97.16	97.85	665.5
VMD + $MPE_{2D}$	97.16	96.58	96.81	57.2
VMD + $MSSE_{2D}$	90.16	89.42	89.76	895
VMD + MSE	84.24	82.16	83.15	1079



图 24  $MSSE_{2D}$  的多类混淆矩阵

Fig. 24 Multiclass confusion matrix of  $MSSE_{2D}$

从以上各个图像和列表可知这 3 种方法对往复式压缩机的故障识别率从高到低排列顺序为  $MSSE_{2D}$ ,  $MSE_{2D}$ ,  $MPE_{2D}$ 。其中相比较  $MPE_{2D}$  来说,  $MSSE_{2D}$  有更高的识别率, 和  $MSE_{2D}$  相比,  $MSSE_{2D}$  的计算时间更短, 效率更高。根据 3 种训练结果得到的混淆矩阵图像可知, 虽然  $MSSE_{2D}$  和  $MSE_{2D}$  都将二类标签错误分配到三类标签,  $MSSE_{2D}$  但是有更小的错误分配率, 而  $MPE_{2D}$  不但将二类标签错误分配到了三类标签, 还有六类标签也被错误分配, 三类标签错

1	1	0	0	0	0	0	0
2	0	1	0	0	0	0	0
3	0	0.12	0.88	0	0	0	0
4	0	0	0	1	0	0	0
5	0	0	0	0	1	0	0
6	0	0	0	0	0	1	0
7	0	0	0	0	0	0	1

预测标签

图 25 MSE<sub>2D</sub>的多类混淆矩阵Fig. 25 Multiclass confusion matrix of MSE<sub>2D</sub>

1	1	0	0	0	0	0	0
2	0	0.84	0.12	0	0	0.04	0
3	0	0.04	0.96	0	0	0	0
4	0	0	0	1	0	0	0
5	0	0	0	0	1	0	0
6	0	0	0	0	0	1	0
7	0	0	0	0	0	0	1

预测标签

图 26 MPE<sub>2D</sub>的多类混淆矩阵Fig. 26 Multiclass confusion matrix of MPE<sub>2D</sub>

误分配到二类标签。这些结果能够有力证实了 MSSE<sub>2D</sub> 的对计算效率,对往复式压缩机故障诊断的优越性。

本文先通过趋势评估 VMD 方法对信号进行处理,然后通过不同的熵进行计算,结果证实了 MSSE<sub>2D</sub> 的优越性。为了进一步证实趋势评估 VMD 方法的准确性,在对信号进行处理时使用 VMD 和 MSSE<sub>2D</sub> 方法、VMD 和 MSE 方法与本文提出的方法比较。两种方法的识别率和计算时间也如表 2 所示,可以看出,融合趋势评估 VMD 算法和 MSSE<sub>2D</sub> 的往复压缩机故障诊断方法相较于其他组合算法具有更高的识别率,且计算时间较短,能够对往复压缩机气阀故障进行精确的区分,充分显示出本文提出方法的准确性和优越性。

## 5 结 论

本文以诊断往复压缩机的气阀故障为重点,提出了融合趋势评估 VMD 和 MSSE<sub>2D</sub> 的故障诊断方法,并首次应用于往复压缩机故障诊断中。

趋势评估 VMD 方法能够通过 EMD 算法提取出信号的趋势信息,且在噪音环境下能够准确的识别到共振频带,为早期气阀故障诊断提供一种思路。

基于符号动态滤波的 MSSE<sub>2D</sub> 通过与 MPE<sub>2D</sub> 和 MSE<sub>2D</sub> 相比,MSSE<sub>2D</sub> 在特征提取和计算效率方面都比其他两种方式有明显优势。

融合趋势评估 VMD 算法和 MSSE<sub>2D</sub> 的组合算法与其他组合算法通过支持向量机进行测试,将得到的结果进行比对分析,能体现出相融合的两种方法在往复压缩机故障诊断中具有显著的优势,它不仅能够提高故障诊断的准确率和可靠性,还能够实现快速响应。

## 参考文献

- [1] 舒悦,张谦,王乐,等.往复压缩机气阀泄漏故障试验模拟与诊断分析[J].流体机械,2018,46(11):1-7.  
SHU Y, ZHANG Q, WANG L, et al. Test simulation and diagnosis analysis of reciprocating compressor gas valve leakage fault[J]. Fluid Machinery, 2018, 46(11): 1-7.
- [2] 王金东,代梅,杜永军,等.基于 EMD 和信息熵的往复压缩机气阀故障特征提取[J].压缩机技术,2013,4:37-40.  
WANG J D, DAI M, DU Y J, et al. Fault feature extraction of reciprocating compressor gas valve based on EMD and information entropy [J]. Compressor Technology, 2013, 4:37-40.
- [3] 赵海洋,徐敏强,王金东.有理 Hermite 插值 LMD 方法及其往复压缩机故障诊断[J].机械工程学报,2015,51(1):83-89.  
ZHAO H Y, XU M Q, WANG J D. Rational Hermite interpolation LMD method and fault diagnosis of reciprocating compressor[J]. Journal of Mechanical Engineering, 2015, 51(1): 83-89.
- [4] 程皓,张志杰,张浩,等.改进 EMD 算法在爆炸冲击波后处理中的应用[J].电子测量技术,2018,41(23):78-81.  
CHENG H, ZHANG ZH J, ZHANG H, et al. Application of improved EMD algorithm in explosion shock wave postprocessing [J]. Electronic Measurement Technology, 2018, 41(23):78-81.
- [5] 周涛涛,朱显明,彭伟才,等.基于 CEEMD 和排列熵的故障数据小波阈值降噪方法[J].振动与冲击,2015,34(23):207-211.  
ZHOU T T, ZHU X M, PENG W C, et al. Wavelet thresholding noise reduction method for fault data based on CEEMD and alignment entropy[J]. Vibration and Shock, 2015, 34(23):207-211.
- [6] KONSTANTIN D, DOMINIQUE Z. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62 (3):531-544.
- [7] 李颖,王鹏,吴仕虎,等.基于 AO-VMD 的往复压缩机故障特征提取方法[J].机电工程,2023,40 (5):673-681.  
LI Y, WANG P, WU SH H, et al. Fault feature extraction method of reciprocating compressor based

- on AO-VMD [J]. Mechanical and Electrical Engineering, 2023, 40(5): 673-681.
- [8] 赵海峰, 张家骏, 吕建卓. 基于散布熵的往复压缩机气阀故障特征提取方法 [J]. 流体机械, 2022, 50(6): 84-89.
- ZHAO H F, ZHANG J J, LYU J ZH. Scattered entropy based fault feature extraction method for reciprocating compressor valves [J]. Fluid Machinery, 2022, 50(6): 84-89.
- [9] LI Y, WANG J D, ZHAO H Y, et al. Fault diagnosis method based on modified multiscale entropy and global distance evaluation for valve fault of reciprocating compressor [J]. Strojniški Vestnik-Journal of Mechanical Engineering, 2019, 65 (2): 123-135.
- [10] 王金东, 李颖, 赵海洋, 等. 基于 VMD 和改进多尺度熵的往复压缩机气阀故障诊断方法 [J]. 压缩机技术, 2018(3): 1-8.
- WANG J D, LI Y, ZHAO H Y, et al. Reciprocating compressor gas valve fault diagnosis method based on VMD and improved multi-scale entropy [J]. Compressor Technology, 2018(3): 1-8.
- [11] 张炎亮, 李营. 基于多尺度排列熵和 IWOA-SVM 的滚动轴承故障诊断 [J]. 电子测量技术, 2023, 46(19): 29-34.
- ZHANG Y L, LI Y. Rolling bearing fault diagnosis based on multi-scale arrangement entropy and IWOA-SVM [J]. Electronic Measurement Technology, 2023, 46(19): 29-34.
- [12] 潘云杰, 李颖, 王欣威, 等. 基于 SPA 和 SQPE 的往复压缩机滑动轴承故障特征提取方法 [J]. 沈阳理工大学学报, 2022, 41(4): 20-25.
- PAN Y J, LI Y, WANG X W, et al. Fault feature extraction method of plain bearing for reciprocating compressor based on SPA and SQPE [J]. Journal of Shenyang Polytechnic University, 2022, 41(4): 20-25.
- [13] 吴震, 李欢, 王涛. 趋势引导 VMD 算法的滚动轴承故障诊断方法研究 [J]. 机械设计与制造, 2024(7): 72-76, 83.
- WU ZH, LI H, WANG T. Research on rolling bearing fault diagnosis based on trend-guided VMD algorithm [J]. Mechanical Design and Manufacturing, 2024 (7): 72-76, 83.
- [14] 李嘉绮, 郑近德, 潘海洋, 等. 一种二维时频多尺度熵的滚动轴承故障诊断方法 [J]. 机械科学与技术, 2023, 42(12): 2011-2020.
- LI J Q, ZHENG J D, PAN H Y, et al. A two-dimensional time-frequency multi-scale entropy method for rolling bearing fault diagnosis [J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(12): 2011-2020.
- [15] 孙壮壮, 郑近德, 童靳于, 等. 二维多尺度符号样本熵在滚动轴承故障诊断中的应用 [J/OL]. 机械科学与技术, 2024: 1-11 [2024-06-27]. <https://doi.org/10.13433/j.cnki.1003-8728.20230294>.
- SUN ZH ZH, ZHENG J D, TONG J Y, et al. Application of two-dimensional multi-scale symbolic sample entropy in rolling bearing fault diagnosis [J/OL]. Mechanical Science and Technology, 2024: 1-11 [2024-06-27]. <https://doi.org/10.13433/j.cnki.1003-8728.20230294>.
- [16] SILVA L E V, FILHO A C S, FAZAN V P S, et al. Junior, Two-dimensional sample entropy: assessing image texture through irregularity [J]. Biomedical Physics & Engineering Express, 2016, 2(4): 1-11.

### 作者简介

李颖, 博士, 副教授, 主要研究方向为机械设备故障诊断。E-mail: liyingnpu@126.com

杨宝凯(通信作者), 硕士研究生, 主要研究方向为机械设备故障诊断。

E-mail: 2511032782@qq.com