

文章编号:1001-2060(2022)03-0176-10

基于改进变分模态分解与流形学习的滚动轴承故障诊断

孙康¹,岳敏楠¹,金江涛¹,李春^{1,2}

(1. 上海理工大学 能源与动力工程学院,上海 200093; 2. 上海市动力工程多项流动与传热重点实验室,上海 200093)

摘要:滚动轴承早期损伤信号特征量缺失且易被环境噪声掩盖,根据分形理论,结合灰狼优化算法(GWO)提出改进变分模态分解方法(Improved Variational Mode Decomposition,IVMD),求解各模态多种非线性特征量,并采用随机近邻嵌入理论(t -distributed Stochastic Neighbor Embedding, t -SNE)进行降维分类,以实现无监督故障诊断。基于轴承损伤实验数据,验证所提方法的可靠性。结果表明:采用IVMD所获模态与多种非线性值构建的特征矩阵更具代表性,可诊断轴承微弱故障;与现有方法相比,所提方法聚类表现更清晰,分类准确率更高,且具有良好的鲁棒性。

关键词:变分模态分解;灰狼算法;轴承;分形;随机近邻嵌入;故障诊断

中图分类号:TH133

文献标识码:A

DOI:10.16146/j.cnki.rndlgec.2022.03.025

[引用本文格式]孙康,岳敏楠,金江涛,等. 基于改进变分模态分解与流形学习的滚动轴承故障诊断[J]. 热能动力工程,2022,37(3):176-185. SUN Kang, YUE Min-nan, JIN Jiang-tao, et al. Fault diagnosis of rolling bearing based on improved variational mode decomposition and manifold learning[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(3): 176-185.

Fault Diagnosis of Rolling Bearing based on Improved Variational Mode Decomposition and Manifold Learning

SUN Kang¹, YUE Min-nan¹, JIN Jiang-tao¹, LI Chun^{1,2}

(1. School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China, Post Code:200093;

2. Shanghai Key Laboratory of Multiphase Flow and Heat Transfer in Power Engineering, Shanghai, China, Post Code:200093)

Abstract: Early damage of rolling bearing lacks characteristic signals and such signals are drown out easily by environmental noise. Based on the fractal theory and the grey wolf optimization algorithm(GWO), the improved variational mode decomposition (IVMD) is proposed to solve nonlinear characteristics in different modes. The theory of t -distributed stochastic neighbor embedding(t -SNE) is applied to carry out dimension reduction and classification, in order to achieve fault diagnosis without supervision. Based on the experimental data of bearing damage, the reliability of the proposed method is verified. The results show that the eigenmatrix constructed by the modes obtained from IVMD and a variety of nonlinear values are more representative, and the proposed method can be used to diagnose weak faults of bearings. Compared with the existing methods, the proposed method has clearer clustering performance and higher classifica-

收稿日期:2021-03-31; 修订日期:2021-04-05

基金项目:国家自然科学基金(52006148,51976131);上海“科技创新行动计划”地方院校能力建设项目(19060502200)

Fund-supported Project:National Natural Science Foundation of China(52006148,51976131);Shanghai University Science and Technology Innovation

Action Plan Local University Capacity Building Project(19060502200)

作者简介:孙康(1997-),男,安徽芜湖人,上海理工大学硕士研究生.

通讯作者:李春(1963-),男,北京人,上海理工大学教授.

tion accuracy, as well as good robustness.

Key words: variational mode decomposition, greywolf algorithm, bearing, fractal, t-distributed stochastic neighbor embedding, fault diagnosis

引言

滚动轴承作为旋转机械中的重要元件,其复杂的工作环境易导致部件损坏^[1]。检测其运行状态及进行早期故障诊断对设备的安全运行和使用寿命延长具有重要意义^[2]。滚动轴承早期故障产生的冲击十分微弱,易受噪声干扰,加之振动传递路径复杂,使其故障特征提取困难。对轴承原始信号进行降噪并增强信号中微弱冲击成分是开展该类部件早期故障诊断的关键^[3]。但轴承故障信号具有非线性、非平稳特点,单一非线性特征值已无法准确判断设备运行状态。因此,提取准确有效特征值和可靠的状态分类方法与故障诊断效果息息相关^[4]。

文献[5]采用改进小波阈值及多重分形对风力机轴承振动信号进行分析。文献[6]基于经验模态分解(Empirical Mode Decomposition, EMD)与最大峭度解卷积增强故障信息获得轴承故障特征频率信息。文献[7]提出分形理论,采用集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)对信号进行降噪处理。上述方法虽在轴承故障诊断中取得一定成效,但仍存在问题:小波分解是基于频率的线性分解,对于非线性、非平稳特征故障信号难以取得理想效果;EMD 存在端点效应、模态混叠现象,且计算量较大;EEMD 虽有效削弱了 EMD 模态混叠问题,但由于迭代次数增加,导致运算量更大,效率低。为此,Dragomiretskiy 等人^[8]提出了一种新的非递归式模态分解算法,变分模态分解(Variational Mode Decomposition, VMD)算法,改善了端点效应和模态混叠现象,有效地避免了 EMD、EEMD 等信号分解产生的问题。

但传统 VMD 算法需人为设置模态分解数 K 和惩罚因子 c ,本文结合灰狼算法(Grey Wolf Optimization, GWO)提出改进变分模态分解算法(Improved Variational Mode Decomposition, IVMD),并引入分形理论^[9],获取最佳参数组合 $[c, K]$ 。采用 IVMD 方法分解原信号并基于多种非线性值构建高维特征矩阵,基于随机近邻嵌入理论(t-distributed Stochastic

Neighbor Embedding, t-SNE)进行降维分类以实现无监督故障诊断^[10]。

1 算法基础

1.1 VMD 基本原理

通过求解约束变分问题,不断更新各本征模态函数(Intrinsic Mode Function, IMF)的中心频率 ω_k 及带宽,获得最佳分量,变分模型如下:

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

式中: u_k —IMF 分量; ∂_t —偏导运算; ω_k —中心频率; $\sigma(t)$ —单位脉冲函数; j —虚数单位; K —模态分解数; \otimes —卷积运算; $f(t)$ —输入信号。

引入惩罚因子 c 及 Lagrange 乘法算子 λ 得到扩展 Lagrange 表达式,采用惩罚算子交替方向法获取最优解。

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

式中: $L(\cdot)$ —扩展 Lagrange 表达式。

利用傅里叶等距变换,完成信号频域特性的自适应分离,再通过傅里叶逆变换转换到时域。

VMD 的流程如图 1 所示。

1.2 GWO 算法寻优

GWO 是由 Mirjalili 等人^[11]提出的一种群体智能启发式算法。较之鲸鱼算法,模型简单,能应用于不同的复杂问题。采用 GWO 算法,以分形盒维数最小作为优化目标,对 VMD 参数 $[c, K]$ 寻优, $c \in [3, 10], K \in [0, 2000]$, 寻优过程如图 2 所示^[11]。

GWO 算法主要有 3 个步骤:追踪猎物;包围猎物;攻击猎物。获取最佳 c 和 K 的流程如图 3 所示。

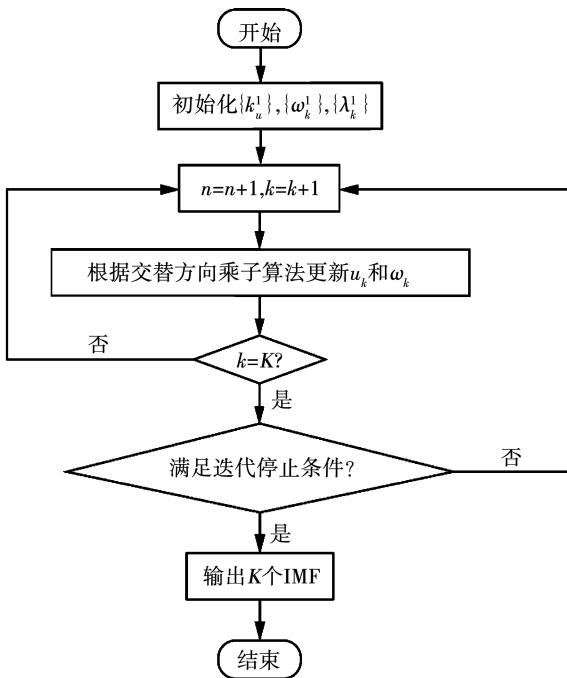


图 1 VMD 流程图

Fig. 1 Flow chart of VMD

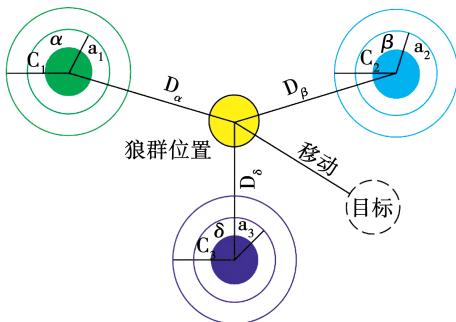


图 2 灰狼算法模型

Fig. 2 Grey wolf algorithm model

2 高维特征矩阵

2.1 特征量

单一特征值难以反映故障特征,为准确提取轴承早期故障信息,采用IVMD方法获取在不同频段的时域信号,基于近似熵、样本熵及排列熵等非线性特征量构建高维特征向量。计算方法参见文献[12–14]。

2.2 特征聚类

采用多种非线性特征熵可更好地反映信号在不同尺度上的细节复杂度特征。对于非线性问题,引入t-SNE^[15]对高维数据内部结构降维聚类,实现低

维空间可视化。引入具有对称性的联合概率描述原空间中的数据相似度,高低维样本点分别服从高斯分布与t分布。

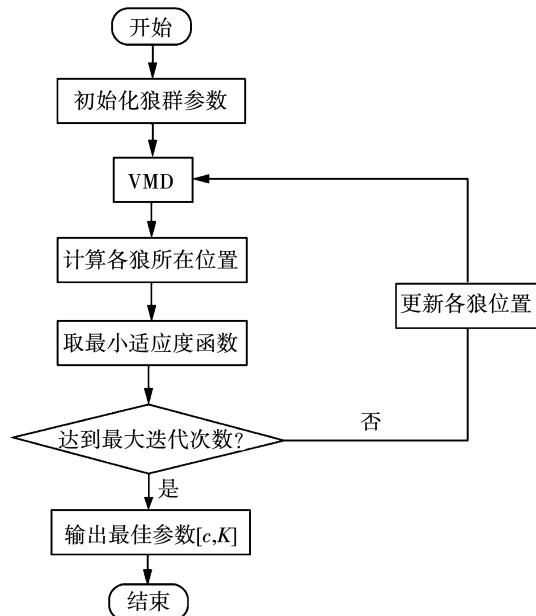


图 3 GWO-VMD 流程图

Fig. 3 Flow chart of GWO-VMD

2.3 故障诊断流程

基于GWO算法寻找最优参数 $[c, K]$,采用IVMD分解原信号,以分形盒维数最小分量为最佳信号,基于近似熵等构建高维特征矩阵,采用t-SNE对特征矩阵聚类,其聚类特性可实现轴承的故障分类。基于IVMD与t-SNE的轴承故障诊断流程如图4所示。

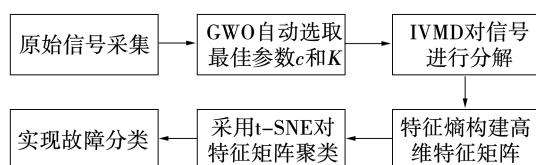


图 4 故障诊断流程图

Fig. 4 Flow chart of fault diagnosis

3 仿真信号验证

为验证IVMD算法在早期轴承故障诊断中的有效性,采用一段正弦信号模拟冲击信号,并添加高斯白噪声模拟实际工况。设置采样频率为1 000 Hz,采样点数为1 000点。仿真信号表达式为:

$$\begin{cases} x = \sin(2\pi \cdot t) + 0.5\sin(2\pi \cdot 5t) \\ y = x + n(t) \end{cases} \quad (3)$$

式中: $n(t)$ —高斯白噪声。

冲击信号并添加噪声后的仿真信号时域波形及包络谱如图 5 所示。原信号呈明显周期波动,加入噪声后,信号被完全淹没。包络谱图中成分杂乱,无法辨别故障频率及其倍率,表明传统谱已无法分析此信号。

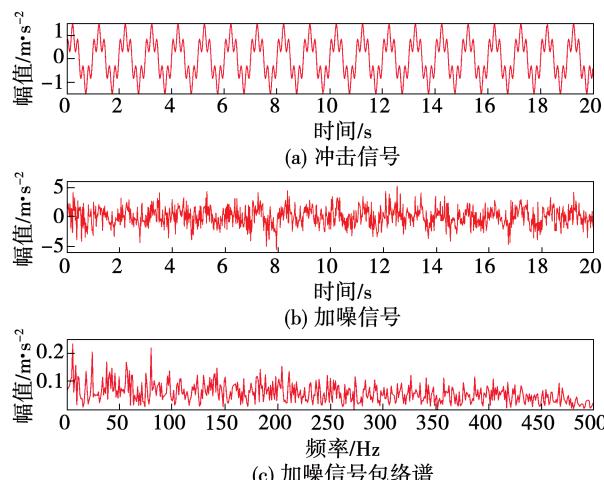


图 5 时域波形及包络谱图

Fig. 5 Time domain waveform and spectral envelope diagram

为从含噪信号中筛选特征信息,基于 GWO 算法求出 VMD 最佳参数组合, $K = 10$, $c = 2000$, 对加噪信号进行分解,得到 10 个分量,计算每个分量的分形盒维数及其与原信号的相关系数,结果如表 1 及图 6 所示。

表 1 分量与原信号相关系数(%)

Tab. 1 Correlation coefficient between component and original signal(%)

模态分量	相关系数
IMF1	94.19
IMF2	90.23
IMF3	88.71
IMF4	87.90
IMF5	85.41
IMF6	85.11
IMF7	85.07
IMF8	84.83
IMF9	86.16
IMF10	88.29

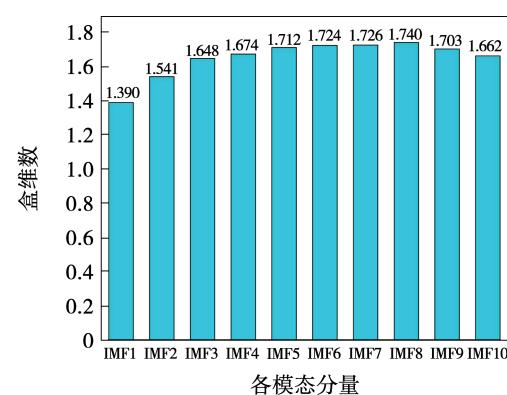


图 6 分形盒维数

Fig. 6 Fractal box dimension

由图 6 可知,IMF1 分量的分形盒维数最小,选此为最佳分量,由表 1 可知,其与原信号相关性最大,包含大部分原信号信息。为进一步验证其准确性,绘制包络谱图,结果如图 7 所示。

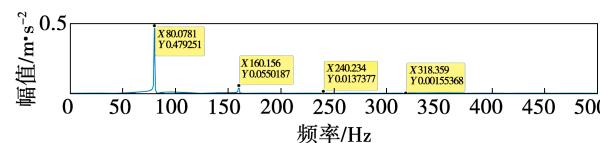


图 7 包络谱图

Fig. 7 Spectral envelope diagram

图中 X 为特征频率, Y 为振幅。由图 7 可知,故障频率 f 为 80 Hz, 其 2 倍、3 倍及 4 倍频均清晰可见, 表明 IVMD 结合分形盒维数可有效提取故障特征分量。

为凸显 IVMD 的优越性,对仿真信号进行 EEMD 和 VMD 分析,分别计算两种方法所得分量的分形盒维数,取其最小值为最优分量,进行包络谱分析,结果如图 8 所示。

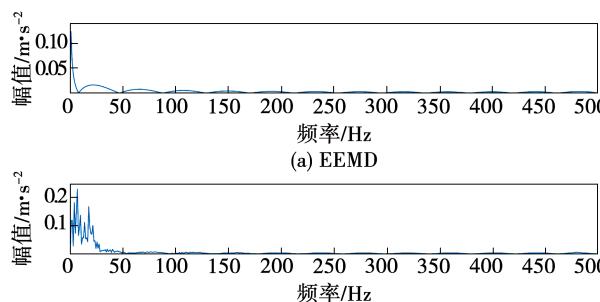


图 8 最佳分量包络谱图

Fig. 8 Diagram of optimal component envelope spectrum

由图 8 可知, 突出频率均为低值频率, 并非故障频率及其倍率, 反向证明了所提方法的有效性。

4 实验信号分析

4.1 实验数据

采用西安交通大学轴承数据中心提供的实验数据验证本方法的有效性^[16]。该平台主要由交流电动机、液压加载系统、转速控制器、传感器、轴承和转轴等组成, 如图 9 所示。

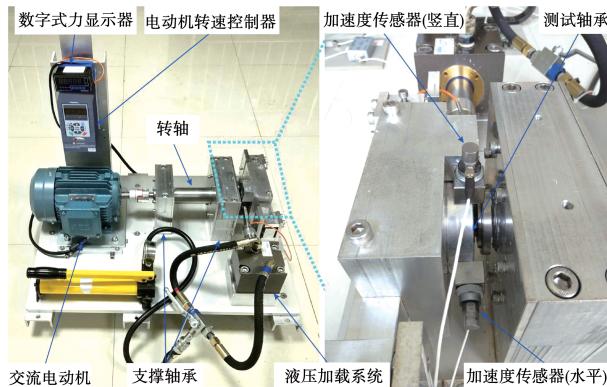


图 9 轴承实验平台装置图

Fig. 9 Diagram of experimental bearing platform

该实验平台可获取测试轴承全寿命周期监测数据。设置采样频率为 25.6 kHz, 将加速度传感器固定于轴承的竖直方向上, 采集轴承 4 种故障下的振动信号。滚动轴承相关参数如表 2 所示, 试验工况如表 3 所示^[17]。

表 2 滚动轴承参数

Tab. 2 Parameters of rolling bearing

参数	数值
内圈直径/mm	29.30
滚珠直径/mm	7.92
滚珠数量	8
静态负载/kN	12.82
外圈直径/mm	39.80
轴承中径/mm	34.55
接触角/(°)	0
动态负载/kN	6.65

4.2 时域及频域

原信号 4 种故障的时域及频域特性如图 10

所示。

表 3 轴承试验工况

Tab. 3 Test conditions of bearing

故障类型	转速/r·min ⁻¹	径向力/kN
混合损伤	2 100	12
内圈磨损	2 250	11
保持架磨损	2 250	11
外圈磨损	2 250	11

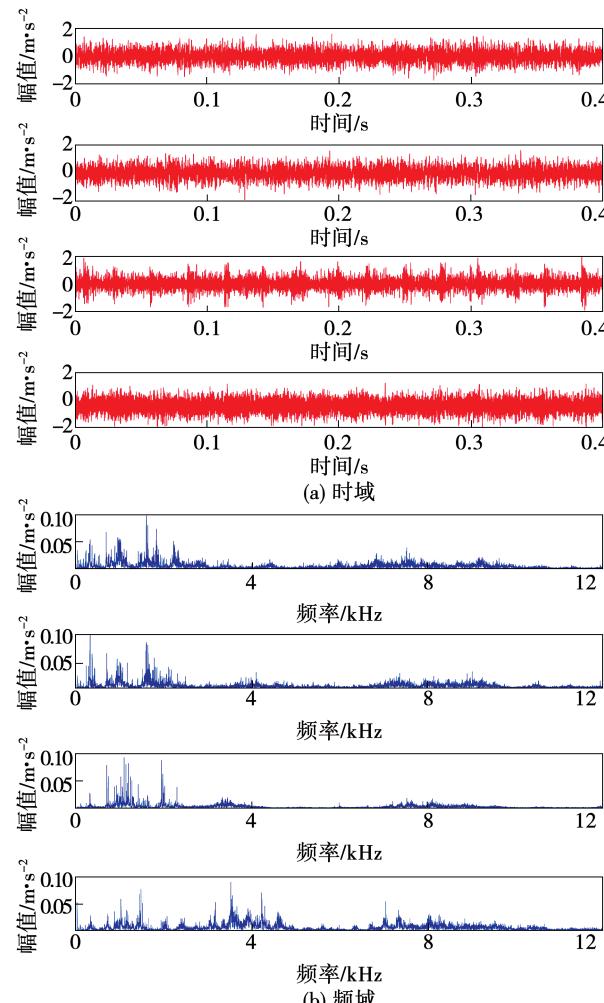


图 10 时域频域分析图

Fig. 10 Analysis diagram of time and frequency domains

由图 10 可知, 各分量时域及频域图并无明显区别, 难以判断故障类型。为准确进行故障分类, 需对原信号进行分解处理, 找出掩盖在噪声下的特征信号。基于 GWO 算法寻找 4 种故障信号最佳分解参数组合 $[c, K]$, 结果如表 4 所示。

表4 最佳分解参数

Tab. 4 Optimum decomposition parameters

故障类型	模态分解数 K	惩罚因子 c
混合损伤	4	2 000
内圈磨损	3	1 116
保持架磨损	3	584
外圈磨损	2	715

分形盒维数可反映信号复杂度,其值越小,信号越规则。采用IVMD分解计算4种故障IMF分量的分形盒维数,结果如表5所示。

表5 分形盒维数

Tab. 5 Fractal box dimension

故障类型	模态分量	分形盒维数
混合损伤	IMF1	1.403
	IMF2	1.563
	IMF3	1.706
	IMF4	1.689
内圈磨损	IMF1	1.431
	IMF2	1.550
	IMF3	1.623
保持架磨损	IMF1	1.492
	IMF2	1.629
	IMF3	1.702
外圈磨损	IMF1	1.530
	IMF2	1.691

表6 线性特征矩阵
Tab. 6 Linear characteristic matrix

故障类型	近似熵	模糊熵	样本熵	香农熵	条件熵	盒维数	包络熵	排列熵
混合损伤	1.624	0.508	0.144	1.287	0.123	1.662	7.369	1.780
	1.651	0.538	0.143	1.336	0.148	1.659	7.342	1.776

	1.662	0.532	0.134	1.324	0.138	1.659	7.349	1.779
内圈磨损	1.674	0.539	0.147	1.321	0.134	1.667	7.328	1.781
	1.624	0.533	0.145	1.239	0.147	1.672	7.395	1.784

	1.640	0.492	0.147	1.176	0.145	1.664	7.346	1.776
保持架磨损	1.560	0.333	0.087	1.221	0.089	1.608	7.151	1.760
	1.557	0.357	0.092	1.230	0.089	1.610	7.104	1.747

	1.496	0.354	0.089	1.217	0.089	1.579	7.124	1.743
外圈磨损	1.601	0.652	0.150	1.366	0.157	1.678	7.273	1.751
	1.647	0.645	0.157	1.362	0.156	1.688	7.268	1.760

	1.616	0.645	0.148	1.321	0.151	1.686	7.286	1.752

计算4种故障盒维数最小的模态分量与原信号的相关系数,结果如图11所示。

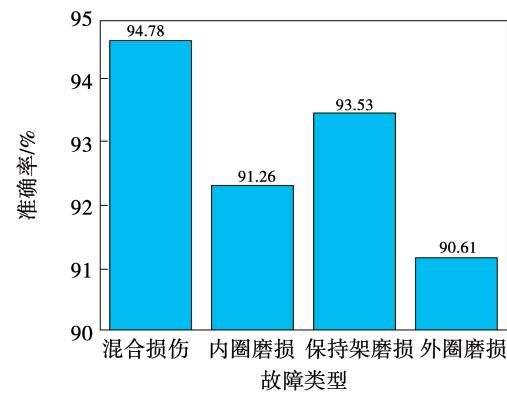


图11 相关系数图

Fig. 11 Diagram of correlation coefficients

由图11可知,各分量与原信号相关性高达90%以上,表明在保留原故障信息整体性的同时提取了特征信号。分别计算50组各故障信号特征分量的近似熵、模糊熵等熵值,构建 200×8 的多模态特征矩阵,部分结果如表6所示。

4.3 t-SNE 聚类特性

为解决高维特征矩阵导致的聚类特性不明显问题,采用t-SNE对其进行降维聚类,图12为低维空间聚类结果。

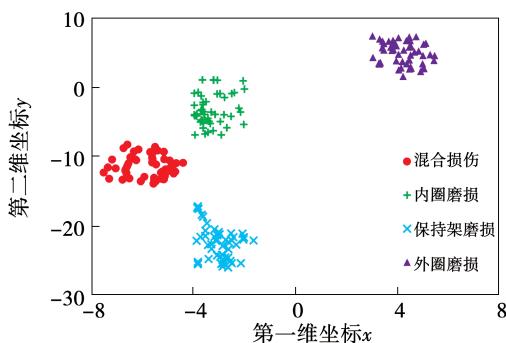


图 12 低维空间聚类结果

Fig. 12 Clustering results of low dimensional space

由图 12 可知, 低维空间的流形表现可明显区分工作状态, 未产生混叠现象和类间距过小的情况, 具有良好的聚类特性。表明经 t-SNE 降维所得特征矩阵可较好地反映轴承工作状态, 其聚类特性可实现轴承故障分类, 准确性较高。

4.4 有效性验证

为进一步说明 IVMD 方法在故障诊断领域的有效性, 采用齿轮箱轴承进行实验^[18], 实验装置如图 13 所示。

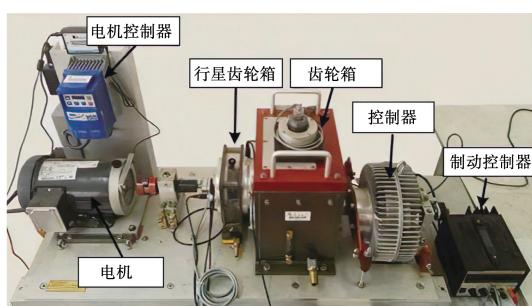


图 13 实验装置图

Fig. 13 Diagram of experimental apparatus

基于该平台模拟轴承两种工况下的 5 种运行状态、分别为健康状态、滚珠裂纹、内圈裂纹、外圈裂纹和内外圈裂纹, 两种工况实验参数如表 7 所示。

表 7 实验参数

Tab. 7 Experimental parameters

工况	频率/Hz	负载/V
1	20	0
2	30	2

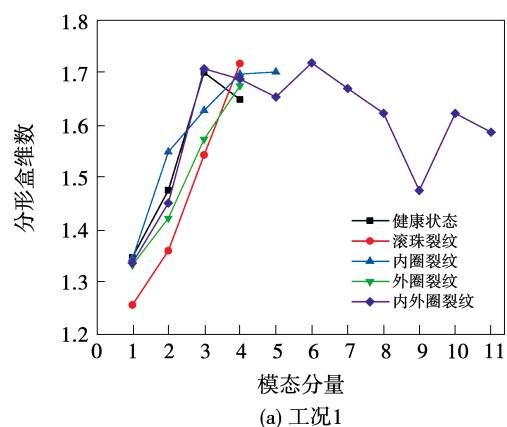
采用 IVMD 方法寻找振动信号最佳分解参数组合 $[c, K]$, 结果如表 8 所示。

表 8 最佳分解参数

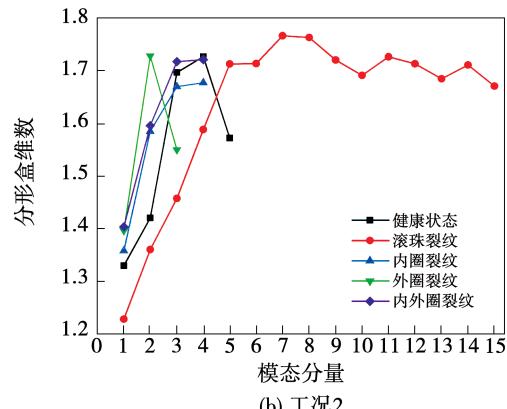
Tab. 8 Optimum decomposition parameters

故障类型	工况	模态分解数 K	惩罚因子 c
健康状态	1	4	1 693
	2	5	1 167
滚珠裂纹	1	4	1 121
	2	15	1 959
内圈裂纹	1	5	699
	2	4	1 030
外圈裂纹	1	4	1 311
	2	3	509
内外圈裂纹	1	11	270
	2	4	1 222

计算各分量的分形盒维数, 结果如图 14 所示, 以分形盒维数最小的分量为特征信号。



(a) 工况1



(b) 工况2

图 14 不同工况下各故障轴承分形盒维数

Fig. 14 Fractal box dimension of each malfunctioning bearing under different working conditions

故障识别具体步骤如 4.2 节所述,其低维空间聚类结果如图 15 所示。

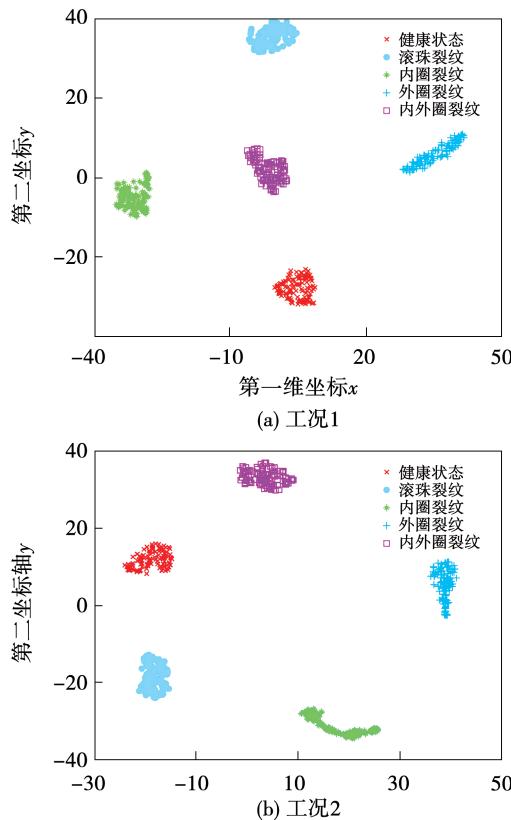


图 15 不同工况下各故障轴承聚类结果

Fig. 15 Clustering results of each malfunctioning bearing under different working conditions

由图 15 可知,轴承 5 种故障可明显区分,具有良好的聚类特性。进一步说明 IVMD 方法的有效性及优越性,可较好地进行故障识别。

4.5 方法对比

为进一步验证所提方法的可靠性,将其与 EEMD + t-SNE^[19], VMD + t-SNE^[20], IVMD + PCA^[20] 3 种方法进行对比。

- (1) 基于 EEMD 分解原始数据特征熵,构成高维特征矩阵,采用 t-SNE 降维得到其聚类特性;
- (2) 对原始数据采用 VMD 分解构成高维特征矩阵,经 t-SNE 降维获得可视化结果;
- (3) 采用 IVMD 对原始样本数据进行处理,利用 PCA 算法降维得到低维特征空间。

不同方法的分类结果如图 16 所示。

由图 16(a)可知,原始数据经 EEMD 处理后,其特征熵组成的特征矩阵经 t-SNE 降维后,4 种故障

分类效果比较明显,但混合损伤和内圈磨损有混叠现象,无法准确判断二者的故障类型。

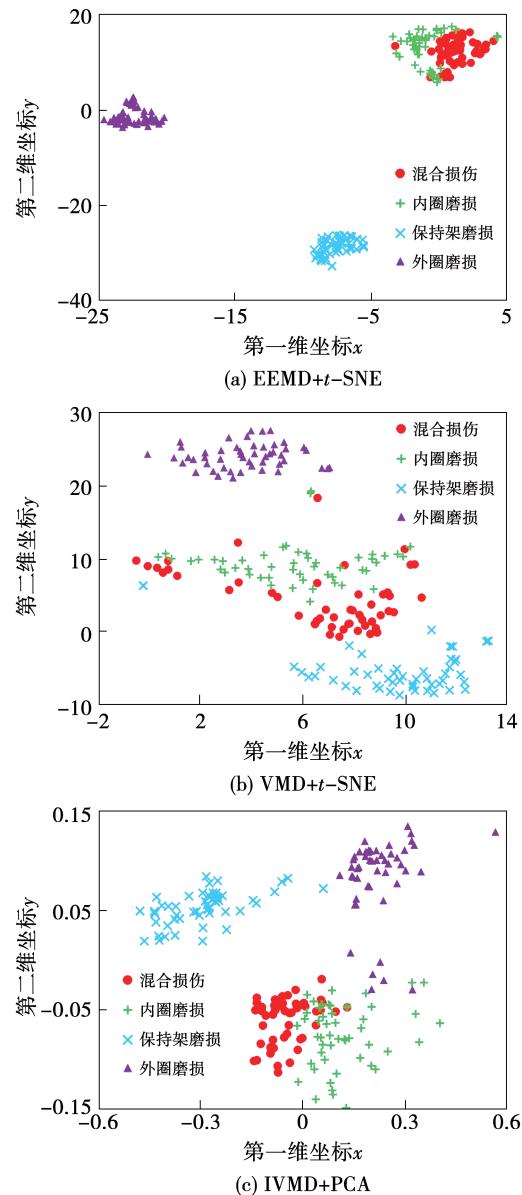


图 16 不同方法的分类结果

Fig. 16 Classification results by different methods

由图 16(b)可知,原始数据经 VMD 处理后,其特征熵组成的特征矩阵经 t-SNE 降维后,只有外圈磨损分类明显,其他 3 种故障存在明显的混叠现象和类间距过小的情况,且有多个离群点,影响轴承的故障分类。

图 16(c)采用 IVMD 对原始样本数据进行处理,使用 PCA 算法对高维矩阵降维,保持架磨损和外圈磨损分类明显,但外圈磨损有多个离群点,混合损伤和内圈磨损存在混叠现象和类间距过小的

状况。

为准确输出轴承工作状态及识别准确度,以所获低维特征向量作为数据样本,采用 4 个神经元,经 Softmax 分类器输出诊断准确率,结果如表 9 所示。

表 9 不同方法的准确率

Tab. 9 Accuracy of different methods

分类方法	准确率/%
EEMD + t-SNE	85
VMD + t-SNE	90
IVMD + PCA	82.5
IVMD + t-SNE	100

由表 9 可知,IVMD + t-SNE 的特征值提取和诊断方法与其他 3 种方法相比,准确率高达 100%,能够准确地实现轴承故障分类。

4.6 鲁棒性验证

为测试实际工作环境中噪声对 IVMD 方法的影响,在原信号中添加信噪比(Signal Noise Ration, SNR)为 -4 ~ 4 dB 的高斯白噪声,分类准确率如图 17 所示,以 4 dB 噪声为例,其聚类特性如图 18 所示。

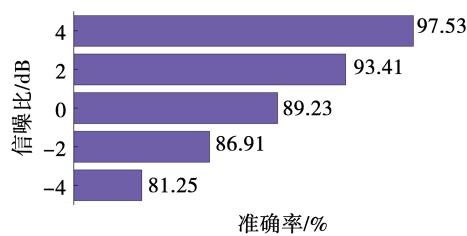


图 17 不同噪声时的分类准确率

Fig. 17 Classification accuracy under conditions of different noises

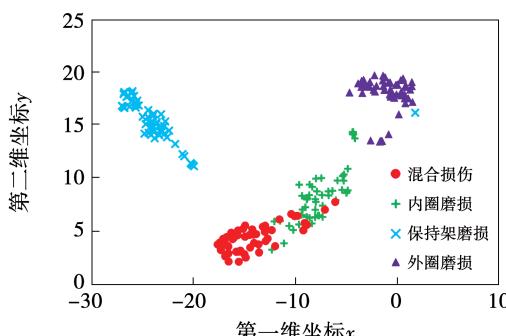


图 18 SNR 为 4 dB 时的分类结果

Fig. 18 Classification results when SNR = 4 dB

由图 18 可知,存在噪声时,IVMD + t-SNE 仍可较准确地进行故障分类,噪声为 -4 dB 时,准确率高达 81.25%,表明 IVMD 方法具有较好的鲁棒性。

4.7 运行效率

为提升故障诊断效率,更符合实际工程应用,体现基于 t-SNE 可视化构建诊断模型的计算效率,与上述 3 种方法进行对比,运行时间如表 10 示。

表 10 不同方法的运行时间

Tab. 10 Running time of different methods

分类方法	运行时间/s
EEMD + t-SNE	1.593
VMD + t-SNE	1.373
IVMD + PCA	1.108
IVMD + t-SNE	1.023

由表 10 可知,IVMD + t-SNE 平均运行时间为 1.023 s,相比其他几种算法运行速度更快,说明此方法不仅能准确地判断滚动轴承的故障类型,运行效率也最高。

5 结论

采用 IVMD 算法与特征熵构建高维特征矩阵,采用 t-SNE 降维得到特征聚类实现轴承故障诊断。基于轴承损伤实验数据,得出结论:

- (1) IVMD 算法在信号分解精度上较 VMD 有明显优势。
- (2) IVMD 算法与特征熵构建高维特征矩阵可在不同尺度上反映故障特征。
- (3) t-SNE 对高维特征矩阵降维后的聚类表现更清晰,分类准确率更高。
- (4) IVMD + t-SNE 分类方法具有良好的鲁棒性。
- (5) 相对于同一种故障,IVMD + t-SNE 较 EEMD + t-SNE、VMD + t-SNE 和 IVMD + PCA 运行效率更高。

参考文献:

- [1] LIU W Y, GAO Q W, YE G, et al. A novel wind turbine bearing fault diagnosis method based on Integral Extension LMD[J]. Measurement, 2015, 74: 70–77.
- [2] 林江刚,胡正新,李晶,等.低转速下基于 AE 信号与 LMD 的

- 滚动轴承故障诊断 [J]. 动力工程学报, 2019, 39 (4): 293–298.
- LIN Jiang-gang, HU Zheng-xin, LI Jing, et al. Fault diagnosis of rolling bearings based on AE signals and LMD under low speed conditions [J]. Journal of Chinese Society of Power Engineering, 2019, 39(4): 293–298.
- [3] 吕中亮, 汤宝平, 周 忆, 等. 基于网格搜索法优化最大相关峭度反卷积的滚动轴承早期故障诊断方法 [J]. 振动与冲击, 2016, 35(15): 29–34.
- LYU Zhong-liang, TANG Bao-ping, ZHOU Yi, et al. An early fault diagnosis method for rolling bearings based on grid search optimization for maximum correlation kurticity deconvolution [J]. Journal of Vibration and Shock, 2016, 35(15): 29–34.
- [4] SUGUMARAN V, RAMACHANDRAN K I. Fault diagnosis of roller bearing using fuzzy classifier and histogram features with focus on automatic rule learning [J]. Expert Systems with Applications, 2011, 38(5): 4901–4907.
- [5] 许子非, 李 春, 杨 阳, 等. 基于改进小波阈值及多重分形的风力机轴承振动信号分析 [J]. 热能动力工程, 2019, 34(9): 191–198.
- XU Zi-fei, LI Chun, YANG Yang, et al. Vibration signal analysis of wind turbine bearing based on improved wavelet threshold and multifractal [J]. Journal of Engineering for Thermal Energy and Power, 2019, 34(9): 191–198.
- [6] 隋文涛, 张 丹, WILSON Wang. 基于 EMD 和 MKD 的滚动轴承故障诊断方法 [J]. 振动与冲击, 2015, 34(9): 55–64.
- SUI Wen-tao, ZHANG Dan, WILSON Wang. Rolling bearing fault diagnosis method based on EMD and MKD [J]. Journal of Vibration and Shock, 2015, 34(9): 55–64.
- [7] 李 洋, 李 春, 杨 阳. 基于 EEMD 及分形方法的轴承振动信号分析 [J]. 热能动力工程, 2018, 33(8): 38–44.
- LI Yang, LI Chun, YANG Yang. Analysis of bearing vibration signal based on EEMD and fractal method [J]. Journal of Engineering for Thermal Energy and Power, 2018, 33(8): 38–44.
- [8] DRAGOMIRETSKIY K, ZOSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531–544.
- [9] 许子非, 岳敏楠, 李 春. 基于改进变分模态分解与支持向量机的风力机轴承故障诊断 [J]. 热能动力工程, 2020, 35(6): 233–241.
- XU Zi-fei, YUE Min-nan, LI Chun. Fault diagnosis of wind turbine bearing based on improved variational mode decomposition and support vector machine [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(6): 233–241.
- [10] LAURENS V D M. Accelerating t-SNE using tree-based algorithms [J]. Journal of Machine Learning Research, 2014, 15(1): 3221–3245.
- [11] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014(69): 46–61.
- [12] 许 凡, 方彦军, 张 荣. 基于 EEMD 模糊熵的 PCA-GG 滚动轴承聚类故障诊断 [J]. 计算机集成制造系统, 2016, 22(11): 2631–2642.
- XU Fan, FANG Yan-jun, ZHANG Rong. PCA-GG rolling bearing clustering fault diagnosis based on EEMD fuzzy entropy [J]. Computer Integrated Manufacturing Systems, 2016, 22(11): 2631–2642.
- [13] PORTA A, BASELLI G, LIBERATI D, et al. Measuring regularity by means of a corrected conditional entropy in sympathetic outflow [J]. Biological Cybernetics, 1998, 78(1): 71–78.
- [14] BENETTIN G, GALGANI L, STRELCYN J M. Kolmogorov entropy and numerical experiments [J]. Physical Review A, 1976, 14(6): 2338–2345.
- [15] MAATEN L V D. Accelerating t-SNE using tree-based algorithms [J]. Journal of Machine Learning Research, 2014, 15(1): 3221–3245.
- [16] WANG Biao, LEI Ya-guo, LI Nai-peng, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2018, 69(1): 401–412.
- [17] SHAO S, MCALEER S, YAN R, et al. Highly-accurate machine fault diagnosis using deep transfer learning [J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446–2455.
- [18] 邵 杰, 庞新宇, 杨兆建, 等. 转子系统三维轴心轨迹和流形学习的故障诊断方法 [J]. 机械科学与技术, 2018, 37(6): 873–878.
- SHAO Jie, PANG Xin-yu, YANG Zhao-jian, et al. A fault diagnosis method for three dimensional axis locus and manifold learning of rotor system [J]. Mechanical Science and Technology for Aerospace Engineering, 2018, 37(6): 873–878.
- [19] 丁承君, 张 良, 冯玉伯, 等. VMD 和 t-SNE 相结合的滚动轴承故障诊断 [J]. 机械科学与技术, 2020, 39(5): 758–764.
- DING Cheng-jun, ZHANG Liang, FENG Yu-bo, et al. VMD and t-SNE combined rolling bearing fault diagnosis [J]. Mechanical Science and Technology for Aerospace Engineering, 2020, 39(5): 758–764.
- [20] 齐咏生, 白 宇, 高胜利, 等. 基于 AVMD 和谱相关分析的风电机组轴承故障诊断 [J]. 太阳能学报, 2019, 40(7): 2053–2063.
- QI Yong-sheng, BAI Yu, GAO Sheng-li, et al. Bearing fault diagnosis of wind turbine based on AVMD and spectral correlation analysis [J]. Acta Energiae Solaris Sinica, 2019, 40(7): 2053–2063.