

# 经验模态分解结合包络谱 LSSVM 的 滚动轴承故障诊断

郝勇<sup>1,2</sup>, 商庆园<sup>1</sup>, 温钦华<sup>1</sup>, 赵翔<sup>1</sup>, 陈斌<sup>2</sup>

(1. 华东交通大学 机电与车辆工程学院, 南昌 330013;

2. 江苏大学 食品与生物工程学院, 江苏 镇江 212013)

**摘要:** 针对滚动轴承故障诊断问题, 提出了经验模态分解 (EMD) 包络谱分析结合最小二乘支持向量机 (LSSVM) 方法用于滚动轴承的故障诊断; EMD 具有自适应性, 可以有效分析非平稳、非线性信号; 利用 EMD 将轴承信号分解为由高频到低频的固有模态函数 (IMF), 选取前 4 个主要包含轴承故障频率的 IMF 函数进行包络谱分析, 采用每个分量函数的特征频率和轴承的时域特征作为轴承故障的识别特征, 结合 LSSVM 方法建立轴承故障诊断定性识别模型; 结果表明: 单独采用频率特征的 LSSVM 判别模型无法实现轴承故障的准确识别, 其正确识别率仅为 82.5%; 采用频率特征结合时域特征的 LSSVM 模型可以实现轴承故障类型的 100% 准确识别; EMD 包络谱分析结合模式识别的方法可以实现轴承故障类型的有效识别。

**关键词:** 滚动轴承; 故障诊断; 经验模态分解; 包络谱分析; 最小二乘支持向量机

## Rolling Bearing Fault Diagnosis Based on EMD Combined with Envelope Spectrum Analysis and LSSVM Methods

Hao Yong<sup>1,2</sup>, Shang Qingyuan<sup>1</sup>, Wen Qinhu<sup>1</sup>, Zhao Xiang<sup>1</sup>, Chen Bin<sup>2</sup>

(1. School of Mechatronics & Vehicle Engineering, East China Jiaotong University, Nanchang 330013, China;

2. School of Food and Biological Engineering, Jiangsu University, Zhenjiang 212013, China)

**Abstract:** In order to solve the problem of rolling bearing fault diagnosis, empirical mode decomposition (EMD) and envelope spectrum combined with least square support vector machine (LSSVM) were used to diagnose rolling bearing fault. EMD is a self-adaptive method, can analyze nonlinear and non-stationary signal effectively. The signals of rolling bearing can be decomposed into intrinsic mode function (IMF) from high frequency to low frequency by using EMD. Bearing fault diagnosis models can be established by its features including time-domain features and frequency features extracted from the first four IMFs by using envelope analysis and LSSVM methods. The results show that the LSSVM model established only using frequency features cannot realize accurate identification of bearing fault with the correct recognition rate of 82.5%. The LSSVM model with correct recognition rate of 100% can be built by using frequency and time-domain features. Bearing faults can be identified effectively by using EMD and envelope analysis combined with pattern recognition method.

**Keywords:** rolling bearing; fault diagnosis; EMD; envelope spectrum; LSSVM

## 0 引言

滚动轴承是机械设备组成的重要部件之一, 其运行状态直接影响设备的精度、稳定性和寿命。滚动轴承常见的故障有内圈故障、外圈故障和滚动体故障, 其故障信号一般表现为非平稳、非线性, 且易受到随机信号的干扰, 使故障信号信噪比较低, 致使故障特征难以提取<sup>[1]</sup>。机械故障诊断领域中非平稳、非线性参数的识别方法已有多种。当前, 包络谱分析是最有效的滚动轴承故障诊断方法之一。在进行包络谱分析时, 由于轴承的振动信号含有噪声, 因此对包络谱分析结果带来严重影响。由此, 在进行包络谱分析前, 需要对轴承振动信号进行处

理, 减弱或者去除噪声的干扰。经验模态分解 (empirical mode decomposition, EMD) 方法是近年来发展比较成熟, 广泛应用于机械振动信号的处理。EMD 是有效的提取非平稳、非线性特征的方法, 它可以根据振动信号的本身特点, 自适应地选择频带, 确定不同频段的分辨率<sup>[2-4]</sup>。EMD 把原信号分解为若干固有模态函数 (intrinsic mode function, IMF) 之和, 对每一个 IMF 进行分析可以更准确的解析原信号的特征信息。各 IMF 的频率成份不仅与采样频率有关, 还随原信号本身变化而变化, 摆脱了传统傅里叶变换的局限性<sup>[5]</sup>。

支持向量机 (support vector machine, SVM) 是根据统计学习理论提出的一种有监督的学习方法。SVM 能较好解决小样本、非线性和高维数等实际难题, 可以使在小样本情况下建立的分类器具有很强的推广能力。但是 SVM 模型计算比较困难, 因为其需要二次规划的解决方案。为了解决此问题, Suykens 基于 SVM 算法提出了最小二乘支持向量机 (least square SVM, LSSVM) 算法, 只需求解一组一次线性方程, 同时也避免了维数灾难<sup>[6-9]</sup>。

本文采用经验模态分解包络谱分析对滚动轴承信号进行分

收稿日期:2017-07-04; 修回日期:2017-07-24。

基金项目:国家自然科学基金项目(21265006)。

作者简介:郝勇(1979-),男,内蒙古呼和浩特人,副教授,硕士研究生导师,主要从事光谱分析及化学计量学方法方向的研究。

陈斌(1960-),男,江苏镇江人,教授,硕士研究生导师,主要从事近红外光谱分析方向的研究。

解,分别以信号的时域特征和频率特征作为LSSVM的输入变量建立故障诊断模型,期望实现轴承的正常、内圈故障、外圈故障和滚动体故障4种状态的有效识别。

## 1 算法与理论

### 1.1 EMD算法理论

EMD分解是基于被分解信号本身,其分解的IMF函数随着被分解信号变化而变化,自适应选择频带。其IMF函数可以是线性的,也可以是非线性的。IMF函数必须满足两个条件<sup>[10-11]</sup>:

1) 对于一系列数据,极值点和过零点数目必须相等或至多相差一点;

2) 在任意点,由局部极大点构成的包络线和局部极小点构成的包络线的平均值为零。

IMF函数的获取是通过EMD进行分解筛选出来的。其分解过程如下<sup>[12-14]</sup>:

1) 将获取的所有局部极大值用三次样条插值函数插值形成上包络,同样用局部极小值通过插值形成下包络。原数据减去上包络和下包络的平均值 $m_{11}$ 得到 $h_{11}$ :

$$h_{11} = X(t) - m_{11} \quad (1)$$

理想的情况下, $h_{11}$ 应是第一个分量函数,但是由于实际拟合过冲或者不足,会产生新的极值点,位移或者放大已存在的极值点。

2) 由于通常情况下 $h_{11}$ 不是分量函数,需要把第一次的 $h_{11}$ 看做数据, $m_{11}$ 为 $h_{11}$ 的包络平均,再次分解筛选:

$$h_{111} = h_{11} - m_{111} \quad (2)$$

若 $h_{111}$ 还存在局部极大值在零点以下,重复分解计算, $h_{11k} = h_{11k-1} - m_{11k}$ ,直到符合IMF条件为止,把分离出来的第一个IMF函数记为 $c_1$ 。

3) 由上面分解筛选过程可以看出 $c_1$ 包含了原信号数据的最小尺度或划分最短周期成分。把原始数据 $X(t)$ 减去第一个分量函数 $c_1$ ,则得到残余 $r_1$ :

$$r_1 = X(t) - c_1 \quad (3)$$

将 $r_1$ 作为原始数据,重复以上步骤,得到 $c_2$ 。重复 $n$ 次,得到 $n$ 个分量函数 $c_n$ ,于是:

$$r_2 = r_1 - c_2, \dots, r_n = r_{n-1} - c_n \quad (4)$$

当 $r_n$ 为一个单调函数时,则停止分解,因为单调函数不能再分解出IMF函数。由此,可得:

$$X(t) = \sum_{i=1}^n c_i + r_n \quad (5)$$

其中, $r_n$ 为残余函数。

### 1.2 IMF包络谱分析

EMD分解出来的IMF分量函数包含了信号从高到低不同频率段的成分,对每个IMF分量函数包络谱<sup>[15-16]</sup>分析步骤如下:

1) 对IMF分量函数作Hilbert变换,即:

$$H[c_i(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{c_i(\tau)}{t - \tau} d\tau \quad (6)$$

2) 构建解析信号在 $z(t)$ ,即:

$$z(t) = c_i(t) + jH[c_i(t)] \quad (7)$$

3) 解析信号在 $z(t)$ 求模即可得到包络信号 $B(t)$ :

$$B(t) = \sqrt{c_i^2(t) + H^2[c_i(t)]} \quad (8)$$

4) 对包络信号进行分析,即可得到IMF的包络谱。

## 2 轴承振动信号的获取

### 2.1 数据来源

轴承振动数据的采集是轴承故障诊断的重要环节,为了保证实验数据的准确性和实验结果的可重复性,本实验数据采用的是美国凯斯西储大学电气工程实验室滚动轴承数据中心提供的轴承故障数据(www.csegroups.case.edu/bearingdata-center/pages/download-data-file)。待测的轴承分为4种状态:正常状态、内圈故障、外圈故障和滚动体故障。轴承用电火花加工单点损伤,故障深度均为0.28 mm,损伤直径分别为0.1778 mm、0.3556 mm、0.5334 mm、0.7112 mm和1.016 mm。其中,轴承外圈的损伤点在时钟的3点钟、6点钟和12点钟的不同位置。轴承振动信号在4种工作载荷(0 kW, 0.75 kW, 1.5 kW, 2.25 kW)下进行测取,其采样频率为12 kHz<sup>[17]</sup>。

### 2.2 轴承振动信号

本文是对轴承的轻微故障进行识别,选用的是故障直径为0.1778 mm,工作载荷为0 kW,采集频率为12 kHz的轴承振动信号为研究对象。轴承4种状态下的振动信号如图1所示,可以看出,正常振动信号变化缓慢,无冲击存在;当出现故障时,可以看出不同信号波形出现周期性的波动,故障类型不同,冲击强度不同。

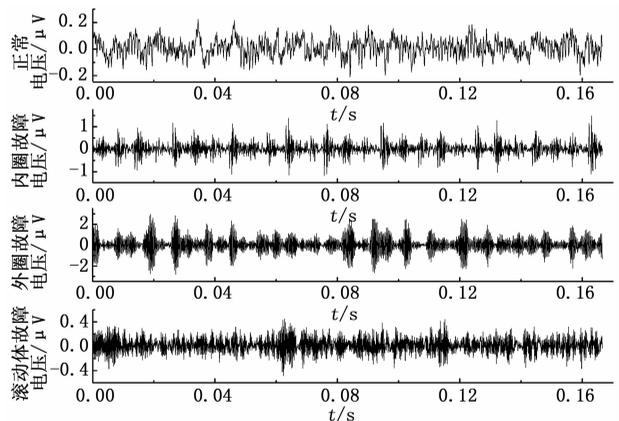


图1 滚动轴承4种状态原始数据图

## 3 轴承振动信号的分析

分别选取4种状态的轴承振动信号各60个样本,共计240个样本,每个样本包含2000个数据点。对轴承振动信号进行时域分析,选取时域特征;时域处理完成后,进行EMD分解处理,将得到的前4个IMF函数进行包络分析,每个IMF函数再根据其特征峰找出两个对应的特征频率,这样每个样本可以得到8个特征频率;其后将包络分析的频率特征与时域特征结合组成识别特征,利用以欧氏距离为基础,具有选择代表性强的Kennard-Stone(KS)算法将每种状态的60个样本分为40个样本用于校正集和20个样本用于测试集<sup>[18]</sup>。

### 3.1 轴承振动信号的时域分析

信号的时域分析采用了4个指标:有效值、峰值指标、裕度指标和峭度指标<sup>[19-21]</sup>。

有效值  $X_{rms}$  又称为均方根值，用于描述振动信号的能量，是机械故障诊断系统中用于判别运转状态是否正常的重要指标。当轴承产生异常后，其振动增大，能量增强。使用有效值可以对轴承是否异常做出评价。若信号为  $x(t)$ ，采样点数为  $N$ ，则有效值表达式为：

$$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2(t)} \quad (9)$$

峰值指标是用于检测振动信号是否存在冲击的统计指标。通常峰值是指单峰最大值，但是在振动信号中它是一个时不稳参数。在故障诊断时为了提高稳定性，一般找出绝对值最大的 10 个峰值，求其算术平均值作为峰值  $X_p$ 。峰值指标的表达式为：

$$I_p = \frac{X_p}{X_{rms}} \quad (10)$$

裕度指标是无量纲指标，是常用的轴承故障诊断指标，其反映了轴承的磨损情况。裕度指标的表达式为：

$$C_c = \frac{X_{rms}}{\bar{X}} \quad (11)$$

其中： $\bar{X}$  为信号的平均值。

峭度是概率密度分布尖峭程度的度量，是无量纲参数。它反映了振动信号的冲击特征，正常情况下振动信号的峭度值为 3 左右，如果接近或者超过 4，则说明机械运动中存在冲击性振动。其表达式为：

$$K = \frac{\sum_{i=1}^N (|x_i| - \bar{x})^4}{N \cdot X_{rms}^4} \quad (12)$$

校正集 40 组样本，测试集 20 组样本，其样本的时域指标分析结果如表 1~表 4 所示。

表 1 正常轴承校正集与测试集时域指标

指标	校正集				测试集			
	最大值	最小值	平均值	标准差	最大值	最小值	平均值	标准差
有效值	0.070	0.061	0.064	0.002	0.067	0.059	0.0644	0.002
峰值指标	3.350	2.732	3.023	0.139	3.172	2.807	3.004	0.105
裕度指标	7.645	4.091	5.463	0.723	6.773	4.150	5.223	0.676
峭度指标	2.335	1.704	2.027	0.142	2.277	1.777	2.005	0.133

表 2 内圈故障轴承校正集与测试集时域指标

指标	校正集				测试集			
	最大值	最小值	平均值	标准差	最大值	最小值	平均值	标准差
有效值	0.300	0.285	0.291	0.003	0.295	0.2886	0.290	0.003
峰值指标	4.351	3.870	4.120	0.133	4.394	3.948	4.136	0.127
裕度指标	24.945	18.403	21.925	1.951	24.15	19.472	21.503	0.043
峭度指标	5.515	4.573	5.046	0.277	5.576	4.634	5.116	0.270

表 3 外圈故障轴承校正集与测试集时域指标

指标	校正集				测试集			
	最大值	最小值	平均值	标准差	最大值	最小值	平均值	标准差
有效值	0.794	0.740	0.770	0.016	0.795	0.741	0.766	0.016
峰值指标	3.717	3.288	3.533	0.092	3.615	3.416	3.527	0.061
裕度指标	121.390	93.254	108.444	7.587	130.800	92.455	105.708	8.661
峭度指标	4.341	3.966	4.162	0.097	4.301	4.043	4.161	0.087

表 4 滚动体故障轴承校正集与测试集时域指标

指标	校正集				测试集			
	最大值	最小值	平均值	标准差	最大值	最小值	平均值	标准差
有效值	0.148	0.129	0.139	0.004	0.151	0.129	0.138	0.006
峰值指标	3.301	2.671	3.041	0.147	3.600	2.914	3.080	0.155
裕度指标	14.688	8.501	11.196	1.490	13.461	8.741	10.906	1.427
峭度指标	2.852	2.021	2.457	0.165	2.973	2.303	2.500	0.155

通过以上 4 个表格可以看出轴承在 4 种不同状态下校正集与测试集时域参数。同种状态的轴承的时域指标经过 KS 算法划分后，校正集中各项指标的范围大部分均包含了测试集中对应的各项指标。同种类型信号的校正集与测试集各指标的平均值相差甚小，同时标准差较小，可以反应出同种状态的信号是稳定的。

不同故障状态轴承的振动信号与正常轴承对比可以看出，不同的时域指标对不同故障敏感程度是不一样的。与正常轴承相比，内圈出现故障的轴承其裕度指标、峰值指标和峭度指标都有明显增加，有效值也稍有增加；外圈故障的轴承其裕度指标显著增大，且其他的指标也有变化；滚动体故障的轴承其所有指标值都增大。由此可以看出，4 个时域指标对 3 种故障都有不同程度的反映，其中裕度指标对 3 种故障敏感程度较高，峭度指标对内圈和外圈故障敏感程度较高。

### 3.2 轴承振动信号的 EMD 分解

EMD 对轴承信号进行分解，首先会分解出高频信号，然后会依次分解出低频，较低频，即分解后得到从高频到低频的 IMF 分量函数，每一个 IMF 分量函数都是原信号的一个调幅信号，且频率成分都是不同的。EMD 对不同的信号具有自适应分解能力，分解的结果是唯一的，通常前几层的 IMF 分量函数集中了原始信号的主要信息<sup>[22]</sup>。

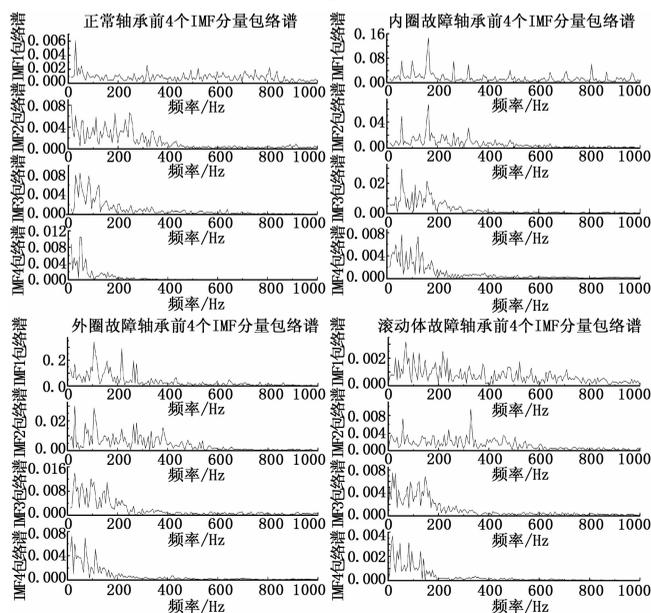


图 2 滚动轴承 4 种故障状态的前 4 个 IMF 分量函数图

EMD 方法分解出来的前几个 IMF 分量函数往往集中了原信号中最显著、最重要的信息，而越靠后的分量函数能量越微弱、信息含量越少，从这个角度分析，EMD 方法就是一种

新的主成分分析法<sup>[5]</sup>。经 EMD 分解后, 轴承信号可以被分解出若干个 IMF 分量和一个残余分量, 这里采用 EMD 分解后的前 4 个分量作为包络分析的对象。如图是轴承 4 种不同状态下的经过 EMD 分解后的前 4 个 IMF 分量。从图中可以看出, EMD 把信号分解成了若干个 IMF 分量之和, 每个 IMF 分量都具有调幅特征, 越靠前的 IMF 分量其幅值越大、频率越高、能量越高且信息熵越大。4 种信号经过 EMD 分解后, 其各个分量波形各不相同, 可以得知各个信号的频率成分是不同的。

### 3.3 轴承振动信号的包络谱分析

轴承振动信号的包络谱分析是对经 EMD 分解后的前 4 个包含重要信息的 IMF 分量进行 Hilbert 变换获取包络信号, 再对包络信号进行谱分析, 找出其特征频率。本文轴承为深沟球, 其损伤直径为 0.1 778 mm, 振动信号的采样频率为 12 000 Hz, 电机转速为 1 797 rpm, 负载功率为 0 W。通过计算可以到的其正常的特征频率为 29.95 Hz, 内圈故障频率为 162.13 Hz, 外圈故障频率为 107.42 Hz, 滚动体故障频率为 70.65 Hz。

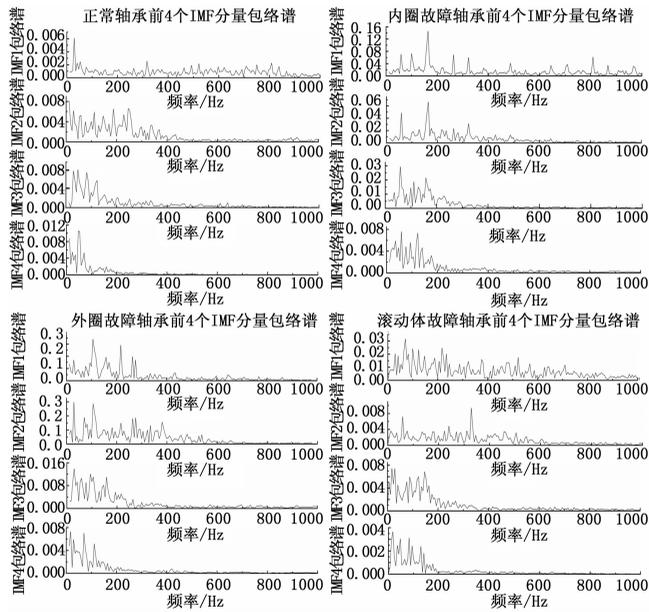


图 3 滚动轴承 4 种状态的前 4 个 IMF 分量函数包络谱图

如图为轴承 4 种状态下的前 4 个 IMF 包络谱, 通过包络谱可以看出各 IMF 分量的能量集中在 0~400 Hz 的频率范围内。正常轴承的包络谱幅值小, 信号的波动幅度较小, 其 IMF1 包络谱的特征频率为 29.30 Hz 与实际特征频率 29.95 Hz 只相差 0.05 Hz; 内圈故障的 IMF1 和 IMF2 包络谱中的峰值所对应的频率相同, 均为 164.06 Hz 与实际特征频率 162.13 Hz 相差 2 Hz 左右; 外圈故障的 IMF1 和 IMF2 特征频率对应相同, 都为 105.47 Hz, 较实际 107.42 Hz 相比差约 2 Hz; 滚动体 IMF1 包络谱的特征频率为 70.31 Hz, 而实际滚动体故障频率为 70.65 Hz。

通过上图故障频率分析可知, 轴承的缺陷故障信息基本包含在经 EMD 分解后的 IMF1 和 IMF2 中。对前 4 个 IMF 分量的进行包络分析获取的故障频率与实际轴承经理论计算的故障频率几乎相同, 这说明 EMD 分解方法结合包络分析法对轴承故障信息的提取是有效的。通过 4 种状态的包络谱对比可以看

出, 外圈轴承的 IMF 分量的包络幅值较其他 3 种幅值大, 说明外圈故障的振动冲击要大于其他故障的冲击, 因此外圈故障也更容易监测。

为了简化数据计算, 同时又能确保轴承的包络分析后的特征不丢失, 这里选取每个 IMF 分量的 2 个特征频率作为轴承的故障识别的频率特征。由于信号存在干扰, 故选取的特征频率也会存在差异, 如图为轴承 4 种状态下的前 4 个 IMF 函数的频率范围分布, 每种状态的轴承其样本数为 60 个。

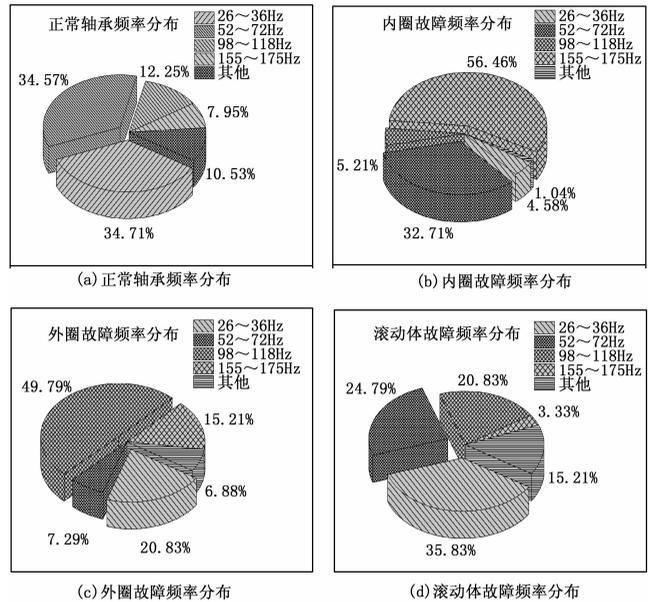


图 4 滚动轴承 4 种状态前 4 个 IMF 函数包络谱特征频率分布图

轴承的振动频率主要分布在这 4 个频率段内: 26~36 Hz, 52~72 Hz, 98~118 Hz 和 155~175 Hz。因为轴承正常与故障情况下的转动频率在此范围内。其中, 在 26~36 Hz 频率范围内, 轴承的频率主要集中在 29.30 Hz, 部分在 35.16 Hz; 在 52~72 Hz 频率范围内, 轴承的频率主要集中在 70 Hz, 部分集中在 52.73 Hz 和 58.60 Hz; 在 98~118 Hz 范围内, 轴承的频率主要集中在 105.49 Hz, 部分集中在 99.60 Hz 和 117.18 Hz; 在 155~175 Hz 范围内, 轴承频率主要集中在 164.06 Hz, 少数集中在 158.20 Hz。由图 4 可知, 轴承在正常状态下其转动频率主要集中在前两个低频范围内, 越到高频所占比例越少, 这是由于轴承正常状态的转频为 29.95 Hz。当轴承出现内圈故障时, 其频率主要为 164.06 Hz, 分布在 155~175 Hz 范围内, 且占了 56.46%, 其次 52~72 Hz 范围内占据了 32.71%。外圈出现故障的轴承其故障频率为 107.42 Hz, 而实际测得多数为 105.49 Hz, 且占总体分布的 49.79%, 26~36 Hz 范围内占据了 20.83%。滚动体故障的轴承其频率分布在 26~36 Hz 最多, 在 52~72 Hz 范围内略低为 24.79%, 再者为 98~118 Hz 范围内。

由图 4 可以看出, 轴承内圈故障和外圈故障频率分布明显区别与正常轴承和滚动体故障轴承。这是由于轴承内圈故障和外圈故障比较明显, 这样更易于区分其他故障。从饼状图可以清楚看出内圈和外圈故障轴承其频率主要分布在其故障频率范围内, 占特征频率的 50% 左右, 另一半频率是轴承的其他成分频率和振动信号采集时外界的调制频率。而正常轴承与滚动

体故障的轴承其频率分布极其相像，前两低频范围占据主要频率分布，达 60% 左右。这两种状态轴承频率分布相像是由于滚动体是轻微故障，滚动体损伤直径只有 0.1778 mm，这就导致滚动体故障信息很微弱，容易被其他信号淹没。因此，这也导致了正常轴承与轻微滚动体故障轴承难以区分。

#### 4 轴承故障类型的识别模型构建

轴承的特征提取包括时域特征与经过 EMD 分解包络谱分析后得到的频率特征。其中时域为有效值、峰值指标、裕度指标和峭度指标构成，将构成的时域特征向量归一化在 0-1 之间；频域为对轴承前 4 个 IMF 函数进行包络分析后得到的每个 IMF 函数的 2 个特征频率，这样一组信号分解后可以得到 8 个特征频率，组成特征频率向量，并归一化在 0~1 之间。

不同的故障类型用不同的类别标签进行标记，其中正常、内圈故障、外圈故障和滚动体故障分别为 1、2、3 和 4。校正集用于输入 LSSVM 进行模型建立，测试集用于模型的验证。其中，LSSVM 采用的核函数为径向基核函数 (radial basis function, RBF)，惩罚参数 C 和核函数参数 g 则是通过网格搜索寻优方法获取最优值<sup>[23-25]</sup>。经过实验验证单独利用前 4 个 IMF 函数的频率特征无法准确将全部轴承故障进行识别，其识别率只有 82.5%。

将两组特征合在一起，并再次进行归一化后组成轴承的识别特征。分别进行两次归一化是由于时域特征的值较小，而频域的值相对较大，若组合一起后统一归一化处理，将可能会使较小的时域特征值近似为 0，将失去时域特征的作用。同样分别将正常、内圈故障、外圈故障、滚动体故障进行类别标记为 1、2、3 和 4。再对每种故障类型进行 KS 算法计算，分为校正集 40 个，测试集 20 个。将校正集的 160 组样本输入 LSSVM 进行建模训练，模型建立后利用建立的模型对 80 组测试集样本进行识别，其识别结果如图 5。

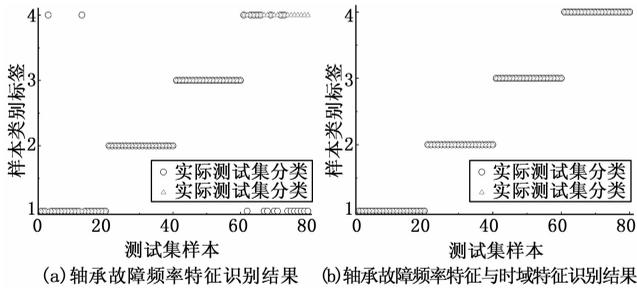


图 5 轴承故障识别结果图

通过频率识别结果图可看出其识别率较低，主要是正常轴承与滚动体故障的轴承未正确识别所导致，内圈故障与外圈故障则可以完全准确识别。而将时域特征与频率特征结合起来通过 LSSVM 对轴承故障进行识别，其识别率达到了 100%。由时域指标表可以看出正常轴承与滚动体故障的轴承其裕度指标和峭度指标存在明显差异，于是时域特征结合频率特征便实现了轴承故障的准确识别。

#### 5 结语

滚动轴承在工作受载时，缺陷损伤部位会产生冲击振动，且由于噪声的干扰，包络分析难于提取出故障特征。轴承的振动信号时非线性、非平稳的，将具有自适应分解的 EMD 方法

结合包络谱分析法应用于滚动轴承的故障检测，将获取的轴承振动信号先进行 EMD 分解，得到若干从高频到低频 IMF 分量函数。再利用包络谱分析利用 Hilbert 变换对前 4 个高频 IMF 分量求取包络信号并提取特征频率信息。最后将频率特征结合时域特征共同构成轴承故障识别特征，利用 LSSVM 对故障进行识别，实现了轴承故障类型的准确判断。

#### 参考文献:

- [1] 孙伟, 熊邦书, 黄建萍, 等. 小波包降噪与 LMD 相结合的滚动轴承故障诊断方法 [J]. 振动与冲击, 2012, 31 (18): 153-156.
- [2] 唐宏宾, 吴运新, 滑广军, 等. 基于 EMD 包络谱分析的液压泵故障诊断方法 [J]. 振动与冲击, 2012, 31 (09): 44-48.
- [3] Yang G L, Liu Y Y, Wang Y Y, et al. EMD interval thresholding denoising based on similarity measure to select relevant modes [J]. Signal Processing, 2015 (109): 95-109.
- [4] Lv L, Yuan R, Song G B. Multivariate empirical mode decomposition and its application to fault diagnosis of rolling bearing [J]. Mechanical Systems and Signal Processing, 2016 (81): 219-234.
- [5] 焦卫东, 朱有剑. 基于 EMD 的轴承故障包络谱分析 [J]. 轴承, 2009 (1): 47-49.
- [6] 孟云闪, 余洁, 刘利敏, 等. LSSVM 算法在极化 SAR 影像分类中的应用 [J]. 地理空间信息, 2012, 10 (03): 43-45.
- [7] 黎兴宝, 潘丰. 基于遗传混沌算法的 LSSVM 参数优化及应用 [J]. 计算机与应用化学, 2010, 27 (10): 1380-1382.
- [8] 孔波, 王红蔚. 基于最小二乘法的无监督支持向量机 [J]. 河南教育学院学报 (自然科学版), 2014 (4): 17-19.
- [9] 曾文韬, 张华, 鄢威. 近似熵与支持向量机在发动机故障识别中的应用研究 [J]. 机械设计与制造, 2016 (11): 46-49.
- [10] 陈刚, 左成, 邢宗义, 等. 基于 EMD 和包络分析的城轨列车滚动轴承故障诊断 [J]. 铁路计算机应用, 2016, 25 (07): 57-60.
- [11] 李建毅, 石林锁, 滕明春, 等. 基于 EMD 细化包络谱分析的齿轮箱故障诊断 [J]. 机械传动, 2013, 37 (3): 15-18, 44.
- [12] 王传菲, 安钢, 胡易平, 等. 基于 EMD 和相关的滚动轴承故障包络谱分析 [J]. 煤矿机械, 2010, 31 (06): 237-240.
- [13] Liu X F, Bo L, Luo H L. Bearing faults diagnostics based on hybrid LS-SVM and EMD method [J]. Measurement, 2015, (59): 145-166.
- [14] Babu N R, Mohan B J. Fault classification in power systems using EMD and SVM [J]. Ain Shams Engineering Journal, 2015: 1-9.
- [15] 李丹丹, 杨智良, 李昌林. 基于 EEMD 和包络分析的滚动轴承故障诊断研究 [J]. 现代制造工程, 2014 (2): 129-134.
- [16] 韩业锋, 仲涛, 石磊. 基于包络谱分析的滚动轴承故障诊断分析 [J]. 机械研究与应用, 2010, (04): 118-119.
- [17] Chebil J, Noel G, Mesbah M, et al. Wavelet Decomposition for the Detection and Diagnosis of Faults in Rolling Element Bearings [J]. Jordan Journal of Mechanical and Industrial Engineering, 2009 (3): 260-267.
- [18] 李华, 王菊香, 邢志娜, 等. 改进的 K/S 算法对近红外光谱模型传递影响的研究 [J]. 光谱学与光谱分析, 2011, 02: 362-365.
- [19] 王柏杨, 刘永强, 廖英英. 滚动轴承故障信号时域特征指标的敏感性分析 [J]. 轴承, 2015, (10): 45-48.