

局部切空间排列算法用于轴承早期故障诊断*

杨 庆, 陈桂明, 何庆飞, 刘靖洁

(第二炮兵工程学院装备管理工程系 西安, 710025)

摘要 提出了一种基于经验模态分解(EMD)和局部切空间排列算法(LTSA)相结合的滚动轴承早期故障诊断方法。首先,利用经验模态分解算法分解滚动轴承不同模式下的振动信号,得到各阶本征模态分量和残余分量,提取各分量中的幅域参数和频域参数组成原始特征参数集;然后,建立基于类别可分性测度的邻域参数 k 选取方法,运用局部切空间排列算法实现敏感特征提取;最后,应用该方法对滚动轴承不同状态下的振动数据进行特征提取和模式识别,对比分析改进后的局部切空间排列算法与主成分分析、核主元分析以及传统局部切空间排列算法的故障模式识别能力。分析结果表明,该方法提取的滚动轴承故障特征敏感性较好,提高了故障模式识别能力,实现了滚动轴承的早期故障诊断。

关键词 特征提取; 局部切空间排列算法; 经验模态分解; 模式识别; 滚动轴承

中图分类号 TH17; TH113.1; TP206.3

引 言

滚动轴承的振动反映了其固有的振动特性、设计制造缺陷、安装维修误差、操作运行以及机器劣化时引起的振动特性^[1],滚动轴承早期故障的振动数据体现的非线性、非平稳时变的特点使得现有振动数据分析方法很难及时做出故障诊断和模式识别。采用不同方法提取的量化指标之间存在着内在关联,降低了特征的敏感性,如何有效实现特征降维,提高特征的敏感性,是实现微弱故障识别的必要手段。目前常用的数据降维方法主成分分析^[2](principal component analysis,简称 PCA)、多维尺度缩放^[3](multidimensional scaling,简称 MDS)以及核主元分析^[4](kernel principal component analysis,简称 KPCA)等,只涉及数据的低阶统计特性,忽略了数据的高阶统计特性中包含的重要特征信息,存在低维数据携带信息的不确定性,以及非线性映射函数选取主要依赖工程实践经验等不足,难以实现微弱故障敏感特征提取。流形学习作为一种新的非线性降维方法^[5-7]正应用于机械设备故障诊断与模式识别中。

笔者针对滚动轴承早期故障的特点,通过 EMD 对原始信号进行经验模态分解,从分解出的各阶本征模态分量(IMF)和残余分量中提取 10 个无量纲

参数以及各分量与原始振动数据的能量比值组成原始特征参数集。建立基于样本类内散度和类间距的评价方法,运用 LTSA 实现敏感特征提取。通过与主成分分析、核主元分析以及传统的 LTSA 的对比,验证了该方法的有效性。

1 局部切空间排列算法

LTSA 的基本思想是利用样本点邻域的切空间来表示局部的几何性质,并利用局部切空间排列构造流形的全局坐标。

1.1 局部坐标的拟合

对数据样本集 $X = \{x_1, x_2, \dots, x_n \in R^m\}$ 中的每个样本点 x_i 通过 K-NN 或 ϵ -ball 标准选择各样本点的近邻点,点 x_i 的近邻点组成的邻域矩阵 $X_{N_i} = [x_{i1}, x_{i2}, \dots, x_{ik}]$,在每个数据点 x_i 的邻域内选择一组正交基 Q_i 构成点 x_i 的 d 维切空间^[8-9],计算点 x_i 的邻域中每一个点 $x_{ij} (j=1, 2, \dots, k)$ 到切空间上的正交投影 $\theta_j^{(i)} = Q_i^T(x_{ij} - \bar{x}_i)$ 。其中: \bar{x}_i 为点 x_i 的邻域均值; Q_i 取 $X_{N_i} - \bar{x}_i \cdot 1_k$ 前 d 个最大的左奇异向量。 X_{N_i} 的局部坐标矩阵 $\Theta_i = [\theta_1^{(i)}, \theta_2^{(i)}, \dots, \theta_k^{(i)}]$ 。

1.2 全局坐标的构建

全局坐标系表示为 $T = [T_1, T_2, \dots, T_i, T_n]$,依据

* 收稿日期:2010-11-15;修改稿收到日期:2011-03-03

局部切空间排列算法思想,每个样本点局部坐标矩阵排列起来得到全局坐标系,并且全局坐标反映局部坐标矩阵的几何结构^[10]

$$T_{ij} = \bar{T}_i + L_i \Theta_{ij} + \varepsilon_{ij} \quad (i, j = 1, 2, \dots, k) \quad (1)$$

其中: L_i 为待定映射矩阵; ε_{ij} 为重构误差; \bar{T}_i 为 T_i 的中心化矩阵; $T_i = [T_{i1}, T_{i2}, \dots, T_{ik}]$ 。

式(1)的矩阵表示形式为

$$T_i = \frac{1}{k} T_i \mathbf{1}_k \mathbf{1}_k^T + L_i \Theta_i + E_i \quad (2)$$

依据式(1)和式(2),重构误差 E_i 表示为

$$E_i = T_i - \frac{1}{k} T_i \mathbf{e} \mathbf{e}^T - L_i \Theta_i \quad (3)$$

需要建立的映射关系能够极小化重构误差

$$\min \sum_i \|E_i\|^2 = \min \sum_i \left\| T_i - \frac{1}{k} T_i \mathbf{e} \mathbf{e}^T - L_i \Theta_i \right\|^2 \quad (4)$$

令 $H_i = I - \mathbf{e} \mathbf{e}^T / k$, 重构误差即可表示为

$$\begin{aligned} \min \sum_i \|E_i\|^2 &= \min \sum_i \|T_i H_i - L_i \Theta_i\|^2 = \\ &\sum_i \text{tr} \{ T_i H_i T_i^T - L_i \Theta_i H_i T_i^T - T_i H_i \Theta_i^T L_i^T + \\ &L_i \Theta_i \Theta_i^T L_i^T \} \end{aligned} \quad (5)$$

式(5)取最小值,即 $L_i = T_i H_i \Theta_i^+$, 令 $T_i = T S_i$, $E_i = T_i H_i (I - \Theta_i^+ \Theta_i)$, $W_i = H_i (I - \Theta_i^+ \Theta_i)$, 为得到惟一解,约束条件限制为 $T T^T = I_d$, 所以矩阵 $S W W^T S^T$ 的第 2 至第 $d+1$ 个最小特征值对应的特征向量即为 T 。

2 基于 LTSA 的故障特征提取

2.1 原始特征参数集的构建

自 1998 年 Norden E. Huang 提出了经验模态分解以来^[11], EMD 已经广泛应用于多领域的信号分析处理中。EMD 算法的本质是通过数据的特征时间尺度来获得固有波动模式,然后分解数据得到一组具有不同特征尺度的数据序列,即本征模态函数。本征模态函数必须满足两个条件^[12]: a. 对于待分解信号序列,极值点和过零点数目必须相等或至多差 1 个; b. 由极大值点和极小值点构成的待分解信号序列上、下包络线的平均值为 0。EMD 算法基本步骤如下^[13]。

1) 确定信号序列 $x(t)$ 的局部极大值点和极小值点,并分别将极大值点和极小值点拟合成信号序列的上、下包络线,求出上、下包络线均值 $m_1(t)$, 原信号序列 $x(t)$ 减去 $m_1(t)$ 得到 $h_1(t)$

$$h_1(t) = x(t) - m_1(t) \quad (6)$$

2) 重复上述过程 k 次,直到标准差 SD 满足

$$SD = \sum_{t=0}^T [|h_{1(k-1)}(t) - h_{1k}(t)|^2 / h_{1(k-1)}^2(t)] < \varepsilon \quad (7)$$

其中: T 为信号序列的长度。

当标准差 SD 的值小于设定值时停止,就得到第 1 个 IMF 分量 $c_1(t)$

$$c_1(t) = h_{1k}(t) \quad (8)$$

将原始数据序列 $x(t)$ 减去 $c_1(t)$, 可以得到一个去掉高频组分的差值数据序列 $r_1(t)$ 。对 $r_1(t)$ 进行上述平稳化处理过程可以得到第 2 个 IMF 分量 $c_2(t)$, 如此重复下去直到最后一个差值序列 $c_n(t)$ 不可再被分解为止,此时原始的数据序列即可由这些 IMF 分量以及一个残差 res 来表示

$$x(t) = \sum_{i=1}^n c_i(t) + \text{res} \quad (9)$$

将振动信号经 EMD 算法分解后,提取各阶模态分量和残余分量相应的能量特征参数、方根幅值、绝对平均幅值、歪度、峭度、波形指标、峰值指标、脉冲指标、裕度指标和峭度指标 10 个无量纲幅域参数,以及各分量与原始振动数据的能量比作为频域参数共同组成原始特征参数集。

2.2 邻域参数 k 的选取

LTSA 先是对数据样本集中的每一个样本点通过 k -NN 或 ε -ball 标准选择其近邻点,并通过每个样本点近邻点组成的邻域矩阵建立邻域切空间,再通过一定的映射关系在低维空间寻找局部重构误差最小的低维坐标;因此,样本数据集近邻点的选择成为影响局部重构误差的关键因素。笔者采用局部切空间排列算法的分类效果作为依据,综合考虑数据样本类间距和类内散度^[14],邻域参数 k 选取具体过程如下: 设 $L_1(l_{11}, l_{12}, \dots, l_{1i}), L_2(l_{21}, l_{22}, \dots, l_{2j}), L_3(l_{31}, l_{32}, \dots, l_{3k}), L_4(l_{41}, l_{42}, \dots, l_{4m})$ 是特征样本空间的 4 类特征样本,其中: $i = 1, 2, \dots, n_1; j = 1, 2, \dots, n_2; k = 1, 2, \dots, n_3; m = 1, 2, \dots, n_4; n_1, n_2, n_3, n_4$ 分别为各类特征样本总数。

各类样本在特征空间均值表达式为

$$\mu_i = \sum_{j=1}^{n_i} l_{ij} / n_i \quad (i = 1, 2, 3, 4) \quad (10)$$

类间距表达式为

$$s_{ij} = \|\mu_i - \mu_j\|^2 = \frac{1}{n_i^2} \sum_{k=1}^{n_i} \sum_{m=1}^{n_j} (l_{ik}, l_{jm}) -$$

$$\frac{2}{n_i n_j} \sum_{k=1}^{n_i} \sum_{m=1}^{n_j} (l_{ik}, l_{jm}) + \frac{1}{n_j^2} \sum_{k=1}^{n_j} \sum_{m=1}^{n_j} (l_{jk}, l_{jm}) \quad (11)$$

类内散度表达式为

$$S_i = \sum_{j=1}^{n_i} \|l_{ij} - \mu_i\|^2 = \sum_{j=1}^{n_i} \left\| l_{ij} - \frac{\sum_{j=1}^{n_i} l_{ij}}{n_i} \right\|^2 = \sum_{j=1}^{n_i} (l_{ij}, l_{ij}) - \frac{1}{n_i} \sum_{k=1}^{n_i} \sum_{m=1}^{n_i} (l_{ik}, l_{im}) \quad (12)$$

最佳分类效果应使不同类别的数据样本之间距离尽可能大,同时类别内的数据样本尽可能聚集,而类间距与类内散度比值取极大值即可同时满足上述条件,因此,邻域参数 k 优化评价函数为

$$F = \frac{s_{12} + s_{13} + s_{14} + s_{23} + s_{24} + s_{34}}{S_1 + S_2 + S_3 + S_4} \quad (13)$$

2.3 低维特征提取

提取各阶模态分量和残余分量相应的幅域参数和频域参数组成原始特征参数集。对于选定的邻域参数 k 值,计算每个样本点的近邻点并组成邻域矩阵。对每个样本点的邻域,计算中心化矩阵 $X_i - \frac{1}{k} X_i e e^T$ 的 d 个最大左奇异向量即为 Q_i ,构成点 x_i 的 d 维切空间。计算点 x_i 的邻域中每一个点 $x_{ij} (j=1, 2, \dots, k)$ 到切空间上的正交投影 $\theta_j^{(i)} = Q_i^T (x_{ij} - \bar{x}_i)$,依据式(5)计算矩阵 $SWW^T S^T$ 的第2至第 $d+1$ 个最小特征值对应的特征向量 T ,即为提取的嵌入结果。随机产生邻域参数 k 值,以邻域参数 k 优化公式作为适应度函数,采用遗传算法寻找输出最优个体及其代表的问题最优解。由 LTSA 基本原理可知,最佳邻域参数 k 值决定的特征样本空间结构即为最佳的模式识别方法。

3 应用实例

3.1 应用对象

选择来自美国凯斯西储大学电气工程实验室的滚动轴承实验数据^[15],滚动轴承型号为 6203-2RS JEM SKF,采样频率为 12 kHz。选择内环、外环和滚动体的损伤直径为 0.533 4 mm 的故障状态以及正常状态下的振动数据,抽取不同状态数据各 40 组,共 160 组数据。

图 1 为 4 种不同状态的振动波形。从图 1 中可知内圈故障与外圈故障均出现冲击分量,滚珠故障与正常状态振动波形极为相似,仅通过振动波形很难有效识别滚动轴承的状态,因此,要对滚动轴承振动数据进行进一步特征提取与分析。

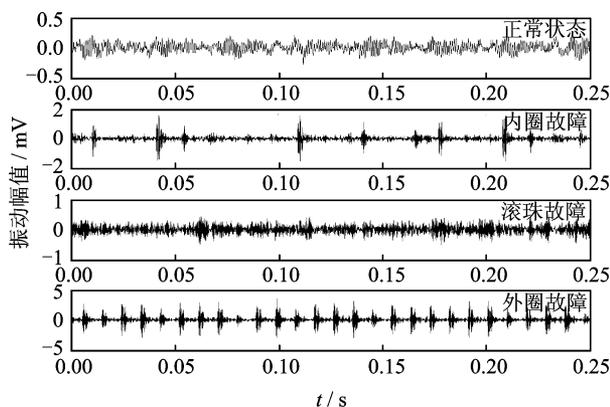


图 1 滚动轴承 4 种不同状态的振动波形

3.2 特征提取分析

选择主成分分析、核主元分析、传统的 LTSA 分析与本研究方法进行识别效果对比分析。对滚动轴承 4 种不同状态数据进行主成分分析的第 1 至第 3 主元投影如图 2 所示,核主元分析的第 1 至第 3 核主元投影如图 3 所示。

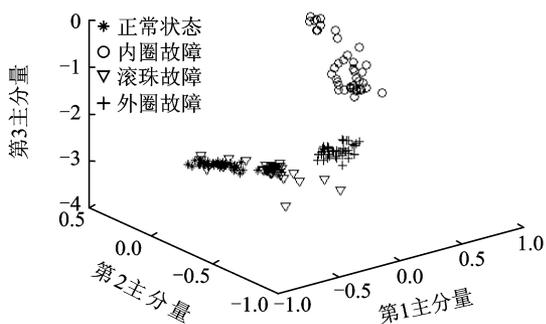


图 2 主成分分析投影图

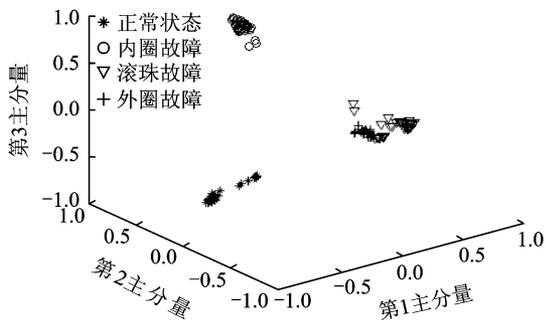


图 3 核主元分析投影图

从图 2 可看出,主成分分析能够有效识别内圈故障与外圈故障,但无法有效区分正常状态与滚珠故障,混叠现象较为严重,同时样本类内散度较大,不同类别的样本类间距较小。图 3 显示核主元分析能够区分 4 类不同状态样本,外圈故障与内圈故障样本在特征空间具有较好的聚集度,相对于主成分

分析样本类内散度减小,但滚珠故障与外圈故障样本类间距依然较小,有效识别两类故障模式困难较大。

为验证基于改进原始特征参数集提取方法的 LTSA 分析特征提取效果,与基于原始振动数据的特征参数集提取方法的 LTSA 分析进行了对比。图 4 为从原始振动数据中提取 10 个无量纲幅域参数以及采用 db4 小波包函数进行 3 层正交小波包分解出的各频带信号,与原始振动数据的能量比作为频域参数组成原始特征参数集,然后经过局部切空间排列算法提取的第 1 至第 3 主分量投影图。图 5 为从经验模态分解算法分解出的各阶本征模态分量和残余分量中提取幅域参数以及与原始振动数据的能量比作为频域参数组成特征参数集,然后经过局部切空间排列算法提取的第 1 至第 3 主分量投影图。

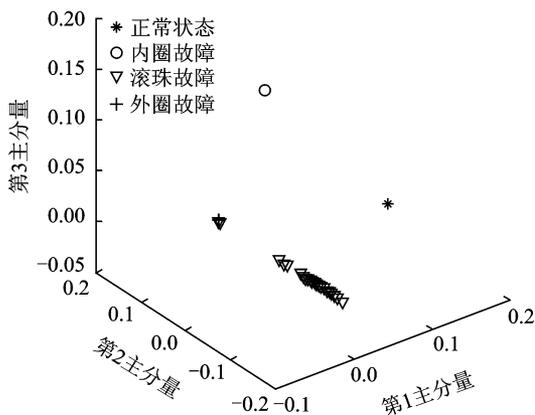


图 4 原始振动数据 LTSA 分析投影图

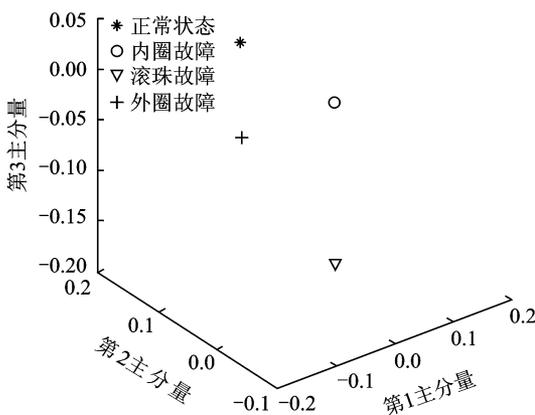


图 5 改进原始特征参数提取方法 LTSA 分析投影图

从图 4 可以发现,正常状态与内圈故障样本聚集程度远好于前两种方法,不同类别的样本类间距也较大,但外圈故障与滚珠故障有部分样本无法识别。从图 5 可看出,在改进原始特征参数集提取方法后各类样本均有效识别,同时类内散度与类间距均

达到 4 种方法中的最佳值。

由于滚动轴承早期故障特征微弱,因此,主成分分析和核主元分析只能有效提取部分故障模式的敏感特征,无法保证在同样的约束条件下对多故障状态与正常状态均有效提取敏感特征,故很难应用于滚动轴承早期故障特征提取。LTSA 分析能够有效提取滚动轴承早期故障中的微弱特征,同时在改进原始特征参数集提取方法后能够充分发挥 LTSA 分析的模式识别效果,达到最佳的样本类内散度与类间距。

3.3 样本特征空间聚集度分析

对比 4 种方法提取的样本特征空间类内散度及依据式(13)计算方法的类间距与类内散度比值。表 1 为 4 种方法提取的样本特征类内散度,其中:主成分分析提取的样本特征类内散度最大,样本聚集度不高;改进的 LTSA 提取的样本特征类内散度最小,样本高度聚集。LTSA 提取的样本特征类内散度优于主成分分析与核主元分析提取效果,改进的 LTSA 进一步提高了样本聚集度。4 种方法的类间距与类内散度比值分别为 6.3, 15.5, 1 316.6 和 4.3×10^{12} 。表明 LTSA 提取效果明显好于主成分分析与核主元分析,同时改进的 LTSA 进一步提高了样本类间距,所以 LTSA 能更有效地提取滚动轴承早期故障特征,在改进原始特征参数集的选取方法后能进一步发挥 LTSA 敏感特征的提取能力。

表 1 4 种方法提取的样本特征类内散度

状态模式	PCA	KPCA	LTSA	改进的 LTSA
正常状态	0.247 3	0.181 4	$1.419 4 \times 10^{-13}$	$2.500 5 \times 10^{-22}$
内圈故障	0.513 5	0.196 8	$0.177 7 \times 10^{-13}$	$2.148 1 \times 10^{-22}$
滚珠故障	4.861 9	1.034 8	1.399 3	$2.444 5 \times 10^{-22}$
外圈故障	1.787 3	0.314 6	$0.325 7 \times 10^{-13}$	$5.763 8 \times 10^{-22}$

4 结论

1) 经验模态分解算法提取的振动信号各阶模态分量携带了不同状态滚动轴承从低频到高频的局部特征信息,基于各分量幅域参数和频域参数建立的原始特征参数集提高了故障信息携带量。

2) 在保证样本特征空间具有最大类间距和最小类内散度的前提下,选取的邻域参数 k 能够保证不同状态样本具有最大的可分性和最佳的模式识别效果。

3) 基于改进原始特征参数集提取方法的 LTSA

能够应用于滚动轴承早期故障敏感特征的提取,提高了微弱故障的模式识别能力,实现了滚动轴承的早期故障诊断。

参 考 文 献

- [1] 盛兆顺,尹琦岭.设备状态监测与故障诊断技术及应用[M].北京:化学工业出版社,2003:224-226.
- [2] 李宏坤,马孝江.基于KPCA-SVM的柴油机状态识别方法的研究[J].振动、测试与诊断,2009,29(1):42-45.
Li Hongkun, Ma Xiaojiang. Pattern recognition of diesel engine by using kernel principle component analysis and support vector machine[J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(1): 42-45. (in Chinese)
- [3] Wang Xiong, Wang J T L, Lin K I, et al. An index structure for data mining and clustering[J]. Knowledge and Information Systems, 2000,12(2):161-184.
- [4] Wu Kuoping, Wang Shengde. Choosing the kernel parameters for support vector machines by the inter-cluster distance in the feature space [J]. Pattern Recognition, 2009,42:710-717.
- [5] 黎敏,徐金梧,阳建宏,等.一种基于流形拓扑结构的轴承故障分类方法[J].控制工程,2009,16(3):358-362.
Li Min, Xu Jinwu, Yang Jianhong, et al. Classification method of bearing faults based on topological structure of manifold [J]. Control Engineering of China, 2009,16(3):358-362. (in Chinese)
- [6] 蒋全胜,贾民平,胡建中,等.一种基于流形学习的故障模式识别方法[C]//第九届全国振动理论及应用学术会议论文集.杭州:浙江大学出版社,2007:177-182.
- [7] 王广斌,刘义伦,黄良沛.正交迭代局部 Fisher 判别转子故障诊断[J].振动、测试与诊断,2010,30(5):500-503.
Wang Guangbin, Liu Yilun, Huang Liangpei. Rotor fault diagnosis using orthogonal iteration local fisher discriminant[J]. Journal of Vibration, Measurement & Diagnosis, 2010,30(5):500-503. (in Chinese)
- [8] Sam T R, Lawrence K S. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000,290(22):2323-2326.
- [9] 栗茂林,王孙安,梁霖.利用非线性流形学习的轴承早期故障特征提取方法[J].西安交通大学学报,2010,44(5):45-49.
Li Maolin, Wang Sun'an, Liang Lin. Feature extraction for incipient fault diagnosis of rolling bearings

based on nonlinear manifold learning [J]. Journal of Xi'an Jiaotong University, 2010,44(5):45-49. (in Chinese)

- [10] 李波.基于流形学习的特征提取方法及其应用研究[D].合肥:中国科学技术大学,2008.
- [11] Huang N E, Shen Zheng, Steven R L, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society A, 1998,454: 903-995.
- [12] 杨洁明,田英.基于EMD和球结构SVM的滚动轴承故障诊断[J].振动、测试与诊断,2009,29(2):155-158.
Yang Jieming, Tian Ying. Roller bearing fault diagnosis by using empirical mode decomposition and sphere-structured support vector machine[J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(2):155-158. (in Chinese)
- [13] 夏天,王新晴,肖云魁,等.应用EMD-AR谱提取柴油机曲轴轴承故障特征[J].振动、测试与诊断,2010,30(3):318-321.
Xia Tian, Wang Xinqing, Xiao Yunkui, et al. Feature extraction from crank-shaft bearing fault of diesel engine using empirical mode decomposition and auto regressive model spectrum technology [J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(3): 318-321. (in Chinese)
- [14] 李敏,杨洁明,张晓平.基于类间可分性度量和SVM的多故障分类算法[J].振动、测试与诊断,2009,29(1):83-85.
Li Min, Yang Jieming, Zhang Xiaoping. Multi-fault classification algorithm based on inter-class separability and support vector machine[J]. Journal of Vibration, Measurement & Diagnosis, 2009,29(1):83-85. (in Chinese)
- [15] The case western reserve university bearing data center. Bearing data center fault test data [EB/OL]. [2007-11-27]http://www.eecs.cwru.edu/laboratory/bearing/.



第一作者简介:杨庆,男,1983年6月生,博士研究生。主要研究方向为机械设备状态监测与故障诊断。曾发表《一种改进的高精度超声测距方法研究》(《计算机技术与发展》2010年20卷第12期)等论文。

E-mail: yangqing20052204@163.com