

基于 EMD 熵特征融合的滚动轴承故障诊断方法

向 丹, 岑 健

(广东技术师范学院 自动化学院, 广州 510635)

摘 要: 研究了滚动轴承故障诊断单一故障信号的局限性和故障特征的非线性, 从信息融合的理论出发, 利用非线性动力学参数熵作为特征, 提出了基于经验模态分解(EMD)熵特征融合的方法来解决滚动轴承故障诊断问题. 首先将原始信号进行 EMD, 利用 EMD 的自适应多分辨率的特点计算 EMD 得到的固有模式函数(IMF)信号的多种熵值, 然后采用核主元分析(KPCA)对提取的状态特征进行信息融合, 从而得到互补的特征, 最后将提取的融合特征通过支持向量机(SVM)进行故障诊断. 滚动轴承故障诊断实验表明: 该方法结合了 EMD、信息熵理论和 KPCA 强大的非线性处理能力的特点, 可以进行滚动轴承故障诊断.

关 键 词: 滚动轴承; 故障诊断; 熵; 核主元分析; 支持向量机

中图分类号: V233; TH165.3

文献标志码: A

Method of roller bearing fault diagnosis based on feature fusion of EMD entropy

XIANG Dan, CEN Jian

(School of Automatization,

Guangdong Polytechnic Normal University, Guangzhou 510635, China)

Abstract: The limitation of single fault signal for roller bearing fault diagnosis and non-linear relation of fault features were studied. Starting from theory of information fusion, the method based on feature fusion of empirical mode decomposition (EMD) entropy was proposed using nonlinear dynamics parameters of entropy as features to deal with roller bearing fault diagnosis problem. Firstly, EMD was conducted for original signal, and on the basis of the property of adaptive multi-resolution for the EMD, different entropies of the intrinsic mode function (IMF) signal reconstructed by using the EMD were calculated. Secondly, the information fusion of the state features was further implemented by using the kernel principal component analysis (KPCA) to extract the complementary feature. Finally, the support vector machine (SVM) was employed to diagnose the fault by using the extracted fusion features. The experiment of rolling bearing fault diagnosis shows that the proposed method combines EMD, information entropy theory and strong nonlinear processing of KPAC, so it can be used for roller bearing fault diagnosis.

Key words: roller bearing; fault diagnosis; entropy;

kernel principal component analysis; support vector machine

滚动轴承是机械设备中最常见的、最易损坏的器件之一, 其运行状态将直接影响整个机械设

收稿日期: 2013-11-20

基金项目: 广东优秀青年教师培养计划(Yq2013110); 广东省教育厅特色创新项目(自然科学类)(2014KTSCX146);

广东省教育厅科技创新项目(2013KJCX0121); 广东省自然科学基金(2014A030313639)

作者简介: 向丹(1980—), 女, 湖北宜昌人, 副教授, 博士, 主要从事控制工程、测试技术与自动化的研究.

备的性能.如何有效地分析利用滚动轴承的振动信号,提取可以反映滚动轴承故障状态的普遍适用的特征量,对滚动轴承故障诊断方法的研究具有十分重要的现实意义^[1].

虽然利用滚动轴承的振动信号对其进行状态监测和故障诊断是一种有效手段,但是滚动轴承的振动信号通常具有故障特征微弱、非线性和非平稳的特点,使得目前对于非线性非平稳信号处理方法,如快速傅里叶变换(FFT),Wigner-Ville,小波变换等不能够准确反映信号的本质特征.EMD是由Huang等^[2]提出的一种非平稳信号处理方法,该方法可将信号局部时变特征自适应地分解成若干个IMF之和,降低了信号间特征信息的耦合,因此,利用EMD方法对信号进行分解,可以准确有效地把握原始数据的特征信息,非常有利于更深层次的信息特征挖掘.熵表示为信息不确定程度的一种度量,包括Shannon熵、Renyi熵、能量熵、奇异熵、Kolmogorov-Shannon(K-S)熵和近似熵等(以上统称信息熵)^[3-4],熵的值越大,表明系统的复杂程度越高,近年来开始在信号处理和特征提取领域得到了广泛的应用.EMD熵正是结合这两种方法在信号处理方面的独特优势,对于提取非平稳、非线性复杂信号的统计特征具有很好的效果.目前,EMD熵理论开始应用于机械故障诊断领域中^[5-7].文献[5]将EMD方法和奇异熵结合,提出了一种基于EMD和奇异值的转子系统故障诊断方法,并在实验中证明了该方法的有效性.

由于各种不同的故障特征之间存在着很强的非线性关系,故障特征之间的模糊性和重叠性直接影响着系统的准确性和可靠性^[8],因此,本文在基于EMD熵特征提取的基础上,利用EMD对信号自适应分解及准确性高的特点,以及利用信息熵强容错性的特点,对滚动轴承各种工作状态信号进行EMD熵特征提取,利用KPCA较强的非线性处理能力对提取的EMD熵进行综合处理,得到滚动轴承各种状态信息互补的特征量,以减少故障特征之间的模糊性和重叠性,采用SVM对这种熵特征融合的效果进行模式识别,最后通过滚动轴承状态实验验证本文所提方法的有效性.

1 信号的EMD熵特征

1.1 EMD方法

EMD方法是由美国国家宇航局Huang等提

出的一种自适应信号时频处理方法^[2],非常适用于非线性非平稳信号的分析处理^[9].从本质上讲,EMD方法是将信号中不同特征尺度的冲击或趋势逐层分离出来,产生一系列具有不同特征尺度的信号分量,称之为IMF.这种不同特征尺度的信号分量应满足以下两个特征:①函数极值点个数和过零点个数应相同或最多相差一个;②函数局部极大值点和局部极小值点的两条上下包络线的均值在任一点处为零.

对信号进行不同特征尺度的EMD的具体步骤如下^[10]:

1) 首先求出原始信号 $x(t)$ 的所有局部极大值点和局部极小值点,对所求局部极大值点和局部极小值点分别进行三次样条函数插值,形成上下包络线,求出该上下包络线的平均值,记为 m_1 ,并求出

$$r_1 = x(t) - m_1 \quad (1)$$

2) 根据IMF两个特征条件判断 r_1 是否满足.如果满足,则 r_1 为第1个IMF分量,如果不满足,则需把 r_1 作为新的 $x(t)$,重复步骤1),直到所得 $r_{i-1} - m_{i-1} = r_i$ 满足以上两个特征为止.

3) 从原始信号 $x(t)$ 分解出第1个IMF分量之后,将 r_1 从 $x(t)$ 中分离出来,得到

$$r_1 = x(t) - c_1 \quad (2)$$

将 r_1 作为原始数据重复以上步骤,即可以得到原始信号 $x(t)$ 的第2个IMF分量,随后再重复循环,求出 $r_2, r_3, \dots$,直到 r_n 成为一个单调函数或 r_n 很小时,则结束循环.

这样可以将原始信号 $x(t)$ 分解为若干个IMF分量和一个余项之和

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (3)$$

式中IMF分量 c_j 包含了原始信号 $x(t)$ 从高到低的不同频段的成分,余项 r_n 代表原始信号 $x(t)$ 的中心趋势.

1.2 EMD熵特征提取

由于EMD方法所得的若干个IMF分量可以使信号特征自适应地在不同的分辨率下显示出来,非常有利于非线性非平稳信号的分析处理,且和小波的多分辨率相比,采用EMD方法具有适应能力强、稳定性高和准确性高等特点,因为EMD方法不受基函数的局限,能准确有效地把握原始数据的微小特征,有效地避免了信号能量的扩散和泄漏^[11].信息熵则是对系统的随机性和不确定程度的描述,具有较好的抗干扰能力.EMD

熵正是结合了这两种方法在信号处理方面的优势,适用于提取无规则非线性信号的复杂度统计特征.对于不同的振动信号,由于其包含的频率成分不同以及所受干扰不同,对其进行 EMD 所求 IMF 分量数量也不同,但是 EMD 结果中前几个 IMF 分量已经足以反映原始信号的主要特征,所以本文对不同状态下滚动轴承的信号只用前 9 个 IMF 分量求取 EMD 熵来表征各种不同状态的特征.根据振动信号的特点,选取两种 EMD 熵来对滚动轴承故障特征进行提取,分别为 EMD 能量熵和 EMD 奇异熵.下面简要给出这两种 EMD 熵特征的计算方法.

1.2.1 EMD 能量熵

原始信号 $x(t)$ 在进行 EMD 后得到前 9 个 IMF 分量,计算出 9 个 IMF 分量的能量

$$E_i = \int (\cdot)^2 d = \sum_{i=1}^9 \cdot^2 \quad (4)$$

式中 $i=1, \dots, 9$; $\cdot$ 为各离散点的幅值.

设 $p_i = \cdot$, 且 $\sum_{i=1}^9 \cdot = 1$, 其中 $\cdot = \sum_{i=1}^9 \cdot$, 则 EMD 能量熵的计算公式为

$$e_e = - \sum_{i=1}^9 \lg$$

1.2.2 EMD 奇异熵

EMD 奇异熵是用来描述被分析信号的频率组成成分及各频率成分的分布特征的. EMD 奇异熵的表达式为

$$e_s = - \sum_{i=1}^9 (\ln \cdot) \quad (5)$$

式中 $E_i = \frac{\sigma_i}{E}$, σ_i 为将 9 个 IMF 分量组成的初始特征向量矩阵进行奇异值分解得到的奇异值,

$$E = \sum_{i=1}^9 \sigma_i.$$

2 基于 KPCA 的特征融合

2.1 KPCA 基本原理

KPCA 的核心是通过非线性函数 $\varphi(\cdot)$ 将所给的样本数据从低维特征空间映射到高维特征空间,利用主元分析(PCA)在高维特征空间提取数据的非线性结构特征^[12-13],它是 PCA 的非线性的一种推广.

假设给定一组样本数据: $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l \in \mathbf{R}^n$, 利用非线性函数 $\varphi(\cdot)$ 将该数据从低维特征空间映射到高维特征空间 F , $\varphi(\mathbf{x}_j)$ 的协方差矩阵 $\mathbf{C}$ 为

$$\mathbf{C} = \frac{1}{l} \sum_{j=1}^l \varphi(\mathbf{x}_j) \varphi(\mathbf{x}_j)^T \quad (6)$$

式(6)的特征值和特征向量为

$$\lambda \mathbf{V} = \mathbf{C} \mathbf{V} \quad (7)$$

其中特征值 $\lambda \geq 0$, $\mathbf{V}$ 为特征向量.

特征向量 $\mathbf{V}$ 可由特征空间的样本映射形成

$$\mathbf{V} = \sum_{i=1}^l \alpha_i \varphi(\mathbf{x}_i) \quad (8)$$

定义 $l \times l$ 矩阵 $\mathbf{K}_{ij} = \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j)$, 由式(8)和式(9)得

$$l \lambda \alpha = \mathbf{K} \alpha \quad (9)$$

归一化特征向量 $\mathbf{V}_k$, 即 $(\mathbf{V}_k, \mathbf{V}_k) = 1$, 则可得样本 $\mathbf{x}$ 在特征空间中的第 k ($k=1, 2, \dots, l$) 个主元 t_k

$$= \cdot (\cdot) = \sum_{i=1}^l (\cdot, \cdot) \quad (10)$$

可以认为特征值较小的主元是由于噪声引起的. 在计算过程中,主元数量的选取一般依据规则

$$\left[\sum_{i=1}^l \sum_{j=1}^l \right] > \quad (11)$$

式中 $\cdot$ 为既定常数,代表噪声的影响程度.

由确定的主元可在高维特征空间中重构变量 $(\cdot_r)$

$$(\cdot_r) = \sum_{i=1}^l \cdot = \sum_{i=1}^l \sum_{j=1}^l (\cdot) \quad (12)$$

式中 $\cdot_r$ 为重构变量.

但是 $(\cdot)$ 不存在具体函数形式,使得 $\mathbf{x}_r$ 很难直接求出. 因此,将式(12)右乘 $(\cdot)$, 由核函数 $\mathbf{K}$ 得

$$\mathbf{K}(\mathbf{x}_r, \mathbf{x}_j) = \sum_{k=1}^p t_k \sum_{i=1}^l \alpha_i^k \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) \quad (13)$$

式(13)中所有的特征空间变量均值都是以 $\sum_{k=1}^l \varphi(\mathbf{x}_k) = \mathbf{0}$ 为前提条件的,而在实际情况中,所

采用的样本数据并不一定满足 $\sum_{k=1}^l \varphi(\mathbf{x}_k) = \mathbf{0}$ 这一条件,此时式(11)中的 $\mathbf{K}$ 取 $\bar{\mathbf{K}} = \mathbf{K} - \mathbf{L}_{l \times l} \mathbf{K} - \mathbf{K} \mathbf{L}_{l \times l} + \mathbf{L}_{l \times l} \mathbf{K} \mathbf{L}_{l \times l}$ 其中 $\mathbf{L}_{l \times l}$ 为系数为 $1/l$ 的 $l \times l$ 阶单位矩阵.

2.2 特征融合与模式识别

EMD 能量熵和 EMD 奇异熵可以从不同角度反映信号的时频分布统计特征,因此能为机械设备的故障诊断提供基本的前提条件^[14]. 由于故障特征之间存在一定的重叠性和不确定性^[15],不

存在一种 EMD 熵能准确完整地提取信号的时频特征,对于不同类型的信号,各种 EMD 熵反映信号特征是不同的,如对于频变信号的分析,EMD 奇异熵更能反映信号的特征,而对于时变信号分析,EMD 能量熵更能反映信号的特征.机械设备往往是个复杂的系统,采用单一的 EMD 熵对故障信号进行特征提取和故障诊断,难以应对信号的不确定性和多变性,从而难以保证故障诊断率.

基于此,本文提出了利用两种不同 EMD 熵来分别提取信号的故障特征,然后利用 KPCA 方法将提取的这两种故障特征进行融合,得到信息互补的特征量,最后采用 SVM 进行模式识别.该方法不仅有利于准确提取故障特征,而且便于从不确定的故障特征融合中得到正确的诊断决策,从而提高了故障诊断率.具体步骤如下(见图 1):




图1 EMD 熵特征融合故障诊断流程

Fig.1 Flow chart of fault diagnosis of EMD entropy feature fusion

1) 对故障信号做 EMD,按式(4)和式(5)提取 IMF 分量的 EMD 熵.

2) 将所求的各 IMF 分量的 EMD 能量熵 X 和 EMD 奇异熵 Y 串行组合为 $S = (X^T, Y^T)^T$,得到组合特征集.

3) 组合特征集的归一化处理.

$$\bar{S}_i = S_i / S' \quad S' = \sum_{j=1}^{27} S_j$$

4) 利用 KPCA 进行特征融合,根据累计贡

献率 $\sum_{i=1}^m \lambda_i / \sum_{k=1}^n \lambda_k \geq 90\%$ 选取前 m 个主元.这 m 个主元基本上反映了原始特征信息.

5) 求得特征融合子集为样本后,选择合适的核参数和惩罚因子,利用 SVM 对其进行训练和故障模式识别.

3 实验结果与分析

3.1 数据来源

本文通过对齿轮箱滚动轴承故障诊断实验来证明所提基于 EMD 熵特征融合的故障诊断方法的有效性.实验所用滚动轴承振动实验台如图 2 所示,其中,变速箱型号为 JZQ-250,负载大小可通过磁粉加载器调节,滚动轴承的各种细微故障是通过人为制造的(故障直径都约为 0.2 mm 左右),用以模拟真实故障.




图2 滚动轴承振动实验台

Fig.2 Vibration experiment bench of roller bearing

实验主要采集驱动电动机在 $100 \text{ N} \cdot \text{m}$ 负载情况下,利用加速度振动传感器采集滚动轴承正常状态、外圈故障、滚动体故障和内圈故障 4 种状态的振动信号,振动的测试点位于齿轮箱轴承处,信号的采样频率为 12 kHz,电动机转速为 2400 r/min.

3.2 EMD 熵特征提取分析

齿轮箱滚动轴承各种状态的振动信号经过 EMD 后,可以得到一系列的 IMF 分量和一个余项,鉴于 EMD 结果中前几个 IMF 分量足以反映原始信号的主要特征,所以图 3 只列出滚动轴承外圈故障的原始信号和分解后的 9 个 IMF 分量(记为 $c_1 \sim c_9$)信号.图中 a 表示振动加速度.从图中各 IMF 分量中可以明显看出周期性的冲击信号,所以,分解的各 IMF 分量中包含了不同的时间尺度,使信号特征从高到低在不同的分辨率下显露出来,非常有利于滚动轴承各种状态信号的特征提取.




图 3 滚动轴承外圈故障信号与 EMD 结果

Fig. 3 Signal of outer race fault of roller bearing and EMD results

EMD 后,分别计算各 IMF 分量的能量熵和奇异熵,图 4 是滚动轴承外圈故障下信号在不同 IMF 分量下的 EMD 能量熵和 EMD 奇异熵对比。




图 4 滚动轴承外圈故障下 EMD 熵对比

Fig. 4 Comparison of EMD entropy for outer race fault of roller bearing

从图 4 中可以看出,滚动轴承外圈故障信号的两 EMD 熵特征值的整体趋势都是减小的,

但是特征值波动的范围不尽相同,这说明从不同的角度分析同一信号复杂度是不同的. EMD 能量熵描述的是信号在时域和频域空间振动能量分布情况;而 EMD 奇异熵是衡量信号在时频空间上能量分布不确定和复杂度的参数. 然而单独某一 EMD 熵不能够很好地区分滚动轴承的工作状态,因此提出利用多种 EMD 熵融合作为故障特征,利用各 EMD 熵特征之间的互补性提高故障诊断率。

3.3 EMD 熵特征融合与故障诊断

振动信号的 EMD 熵包含了不同状态空间的故障信息,如果将之进行融合,利用它们之间互补性,将能得到比单一信号特征更为丰富的信息特征. 最直接、最简单的特征融合方法是这两类特征串行组合,结合成一个 18 维的特征数组. 但这种组合下的高维特征数据将大大降低系统的识别能力. 因此本文选择 KPCA 方法对特征进行处理,利用其强大的降维融合和消除冗余信息的能力对核主元特征进行融合。

对 18 维 EMD 熵特征进行 KPCA 融合,根据累计贡献率 $\sum_{i=1}^m \lambda_i / \sum_{k=1}^n \lambda_k \geq 90\%$ 选取主元个数为

6. 在进行特征融合时,径向基函数(RBF)核函数的参数 σ 对 KPCA 性能影响很大,通过交叉验证的方法对核函数的参数寻优,本文选择的最优核函数的参数为 13.428. 图 5 为原始特征和核主元融合特征的前 3 个特征在三维空间的投影.




图 5 原始特征和核主元融合特征在三维空间的投影
Fig. 5 Projection of original features and kernel principal component fusion features in three-dimensional space

由图 5 可以看出,对于原始特征,滚动轴承 4 种状态特征都存在不同程度的重叠,且各种状态特征的聚类性能很差. 而经过核主元融合之后,滚动轴承常见的 4 种状态特征基本分离,而且,所提取的熵特征具有很好的聚类性能.

为了验证本文所提滚动轴承故障诊断方法的有效性,对采集的滚动轴承不同状态下的信号进行 EMD 熵特征提取,并利用 SVM 对故障特征进行训练和诊断. 作为比较,实验将原始 EMD 熵特征和融合后的 EMD 熵特征进行 SVM 识别,实验是将 50 个样本数据分成训练样本和测试样本两类,其中训练样本包含 20 个样本数据,测试样本包含 30 个样本数据. 实验中 SVM 核函数采用常用的高斯核函数,核函数高度控制参数为 1,惩罚因子为 10. 滚动轴承各种状态特征识别结果如表 1 所示.

表 1 SVM 识别结果

Table 1 Recognition results of SVM

项目	正常	内圈故障	外圈故障	滚动体故障
训练标签	1	2	3	4
训练样本/个	20	20	20	20
测试样本/个	30	30	30	30
EMD 能量熵特征故障诊断率/%	86	94	76	88
EMD 奇异熵特征故障诊断率/%	67	89	62	91
KPCA 融合特征故障诊断率/%	100	100	98	100

由表 1 可知,经过 KPCA 融合特征的故障诊断率接近 100%,明显高于单一信号的原始特征的故障诊断率. 这说明了特征融合方法能够充分利用熵特征冗余互补信息和其间的非线性关系,更简洁而全面地表征滚动轴承各种运行状态特征,最终证明了本文所提方法具有很好的故障模式分类性能.

4 结 论

本文研究了两种 EMD 熵和 KPCA 特征融合理论的原理,提出了基于 EMD 熵特征融合的滚动轴承故障诊断方法,得到如下结论:

1) EMD 熵融合了 EMD 和信息熵在信号特

征提取中的优势,能有效提取滚动轴承故障信息.

2) 利用 KPCA 融合两种 EMD 熵进行综合处理,提取两种 EMD 熵特征信息的互补量,有效减少了故障特征之间的模糊性和重叠性,提高了系统的故障诊断率,增强了系统的容错能力.

3) 滚动轴承故障诊断实验证明该方法提取的特征具有很好的聚类性,且具有很好的诊断效果,故障诊断率达到 98% 以上.

参考文献:

- [1] McInerny S A, Dai Y. Basic vibration signal processing for bearing fault detection[J]. IEEE Transactions on Education, 2003, 4(1): 149-156.
- [2] Huang N E, Shen Z, Long S R, 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: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [3] YAN Ruqiang, GAO R X. Approximate entropy as a diagnostic tool for machine health monitoring[J]. Mechanical Systems and Signal Processing, 2007, 21(2): 824-839.
- [4] Pincus S M. Approximate entropy as a complexity measure[J]. Chaos, 1995, 5(1): 110-117.
- [5] 于德介, 陈森峰, 程军圣, 等. 基于 EMD 的奇异值熵在转子系统故障诊断中的应用[J]. 振动与冲击, 2006, 25(2): 24-26.
YU Dejie, CHEN Miaofeng, CHENG Junsheng, et al. Fault diagnosis approach for rotor system based on EMD method and singular value entropy[J]. Journal of Vibration and Shock, 2006, 25(2): 24-26. (in Chinese)
- [6] 张超, 陈建军, 郭迅. 基于 EMD 能量熵和支持向量机的齿轮故障诊断方法[J]. 振动与冲击, 2010, 29(10): 216-219.
ZHANG Chao, CHEN Jianjun, GUO Xun. Gear fault diagnosis method based on EMD energy entropy and SVM[J]. Journal of Vibration and Shock, 2010, 29(10): 216-219. (in Chinese)
- [7] 张超, 陈建军, 郭迅. 基于 EEMD 能量熵和支持向量机的齿轮故障诊断方法[J]. 中南大学学报, 2012, 43(3): 932-939.
ZHANG Chao, CHEN Jianjun, GUO Xun. Gear fault diagnosis method based on ensemble empirical mode decomposition energy entropy and support vector machine[J]. Journal of Central South University, 2012, 43(3): 932-939. (in Chinese)
- [8] 何柯峰, 高隼. 一种基于主分量分析的融合识别方法[J]. 仪器仪表学报, 2004, 25(4): 440-444.
HE Kefeng, GAO Jun. A method of fusion recognition based on PCA[J]. Chinese Journal of Scientific Instrument, 2004, 25(4): 440-444. (in Chinese)
- [9] 向丹, 葛爽. 一种基于小波包样本熵和流形学习的故障特征提取模型[J]. 振动与冲击, 2014, 33(11): 1-5.
XIANG Dan, GE Shuang. A model of fault feature extraction based on wavelet packet sample entropy and manifold learning[J]. Journal of Vibration and Shock, 2014, 33(11): 1-5. (in Chinese)
- [10] Fegeant O. Closed form solutions for the point mobilities of axi-symmetrically excited cylindrical shells[J]. Journal of Sound and Vibration, 2001, 243(1): 89-115.
- [11] 鞠萍华, 秦树人, 秦毅, 等. 多分辨 EMD 方法与频域平均在齿轮早期故障诊断的研究[J]. 振动与冲击, 2009, 28(5): 97-101.
JU Pinghua, QIN Shuren, QIN Yi, et al. Study of the average in the early fault diagnosis of gear multiresolution and frequency domain EMD method[J]. Journal of Vibration and Shock, 2009, 28(5): 97-101. (in Chinese)
- [12] Scholkopf B, Smola A, Muller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299-1319.
- [13] 许洁, 胡寿涛. 基于 KPCA 和 MKL-SVM 的非线性过程监控与故障诊断[J]. 仪器仪表学报, 2010, 31(11): 2428-2433.
XU Jie, HU Shoutao. Nonlinear process monitoring and fault diagnosis based on KPCA and MKL-SVM[J]. Chinese Journal of Scientific Instrument, 2010, 31(11): 2428-2433. (in Chinese)
- [14] 向丹, 葛爽. 基于样本熵和流形学习的故障特征提取方法[J]. 航空动力学报, 2014, 29(7): 1535-1542.
XIANG Dan, GE Shuang. Method of fault feature extraction based on EMD sample entropy and manifold learning[J]. Journal of Aerospace Power, 2014, 29(7): 1535-1542. (in Chinese)
- [15] 张熠卓, 徐光华, 梁霖, 等. 利用增量式非线性流形学习的状态监测方法[J]. 西安交通大学学报, 2011, 45(1): 64-68. (in Chinese)
ZHANG Yizhuo, XU Guanghua, LIANG Lin, et al. Condition monitoring method for mechanical equipments based on incremental nonlinear manifold learning[J]. Journal of Xi'an Jiaotong University, 2011, 45(1): 64-68. (in Chinese)