

一种基于经验模式分解与支持向量机的 转子故障诊断方法

于德介, 陈淼峰, 程军圣, 杨宇

(湖南大学机械与汽车工程学院, 湖南省长沙市 410082)

A Fault Diagnosis Approach for Rotor Systems Based on Empirical Mode Decomposition Method and Support Vector Machines

YU De-jie, CHEN Miao-feng, CHENG Jun-sheng, YANG Yu

(College of Mechanical and Automotive Engineering, Hunan University, Changsha 410082, Hunan Province, China)

ABSTRACT: A fault diagnosis approach for rotor systems based on EMD method and support vector machine is proposed. The EMD method is used to decompose the vibration signal of a rotor system into a number of intrinsic mode function components and then the autoregressive mode(AR) model of each IMF component is established. The main auto-regressive parameters and the variances of remnant are regarded as the feature vectors. Then, the support vector machines used as fault classifiers are established to identify the condition and fault pattern of the rotor system. Practical examples show that the proposed approach can be applied to the rotor system fault diagnosis effectively.

KEY WORDS: empirical mode decomposition; auto-regressive model; support vector machine; fault diagnosis; rotor systems

摘要: 转子系统故障诊断的关键是故障特征提取和状态识别, 在故障特征提取中, 采用自回归(AR)模型参数作为特征向量来分析系统的状态变化是十分有效的, 但 AR 模型只适用于平稳信号的分析, 而转子系统的振动信号表现出非平稳特征; 同时在状态识别中, 支持向量机(SVM)有效地改善了传统分类方法的缺陷。针对这些问题, 提出一种基于经验模式分解(empirical mode decomposition, EMD)和支持向量机的转子系统故障诊断方法。该方法对转子系统的振动信号进行经验模式分解, 将其分解为若干个固有模式函数(intrinsic mode function, IMF); 对每一个 IMF 分量建立 AR 模型, 取模型的自回归参数和残差的方差作为故障特征向量, 并以此作为输入来建立支持向量机分类器, 判断转子系统的工作状态和故障类型。实验结果分析表明, 文中提出的

方法能有效地应用于转子系统的故障诊断。

关键词: 经验模式分解; 自回归模型; 支持向量机; 故障诊断; 转子系统

0 引言

转子系统故障诊断过程基本上可以分 3 个步骤: ①故障信号的采集; ②故障特征的提取; ③状态识别和故障诊断。在故障特征提取中, 传统的转子系统故障诊断技术通过分析并提取振动信号时域或频域波形的特征量, 建立判别函数如神经网络等来识别转子系统的工作状态^[1-3]。但是, 由于转子系统结构及工作状态的复杂性, 载荷、间隙、摩擦力、刚度等非线性因素的影响程度不同, 有时很难仅通过时域或频谱分析来对转子系统的工作状态做出较为准确的评价。AR 模型是一种时间序列分析方法, 其模型参数凝聚了系统状态的重要信息, 准确的 AR 模型能够深刻、集中地表达动态系统的客观规律。同时大量研究表明, AR 模型的自回归参数对状态变化规律反映最敏感^[4-5], 因此采用 AR 模型的自回归参数作为特征向量来分析系统的状态变化是十分有效的。但 AR 模型只适用于平稳信号的分析, 而转子系统的振动信号表现出非平稳特征。针对上述问题, 在建立 AR 模型之前先采用经验模式分解(empirical mode decomposition, EMD)方法对信号进行预处理。EMD 方法^[6-7]是最近提出的一种新的信号分析方法, 该方法基于信号的局部特征时间尺度, 可以把信号分解成若干个固有模式函数(intrinsic mode function, IMF)之和, 分解出的各个 IMF 分量突出了数据的局部特征, 对其分析可

基金项目: 国家自然科学基金项目(50275050)。

Project Supported by National Natural Science Foundation of China (50275050).

以更准确有效地把握原始数据的特征信息。最重要的是分解后的各个 IMF 分量是经过平稳化处理的, 这样就可以对各个 IMF 分量建立 AR 模型, 提取 AR 模型的自回归参数和残差方差作为故障特征向量, 基于 EMD 的 AR 模型已经成功地应用于齿轮、轴承等部件的故障特征提取^[8-9]。

在状态识别中, 神经网络具有较强的自学习、非线性模式识别和联想能力并在旋转机械故障诊断中得到了较为广泛的应用^[2-3], 但其本身有着一些无法克服的缺点: 如神经网络中的结构选择和权重的初值设定需要借助于经验、网络训练速度慢、易陷入局部极小点、过学习等^[10], 因此制约了在机械故障诊断中的应用。支持向量机(SVM)是一种新的通用的学习方法, 该算法有效地改善了传统分类方法的缺陷, 如神经网络结构的选择、易陷入局部极小点、过学习问题等, 具有非常优异的预测推广能力^[11-12], 在轴承等机械部件故障诊断中取得了优良的效果^[13-15]。

本文提出了基于 EMD 和 SVM 的转子系统故障诊断方法。该方法首先对振动信号进行 EMD 分解, 得到若干个 IMF 分量, 然后利用 AR 模型对 IMF 分量进行建模, 用 AR 模型的自回归参数和残差方差作为特征向量, 输入支持向量机建立故障分类器, 进一步判断转子系统的工作状态和故障类型。通过对实验信号的分析, 验证了将 EMD 和 SVM 相结合能有效地应用于转子系统的故障诊断, 从而为转子系统的故障诊断提供了一种新的方法。

1 EMD 方法

EMD 把 1 个复杂的非平稳信号分解为有限个基本模式分量之和, 其中任何一个基本模式分量(IMF)都满足以下条件:

在整个数据段内, 极值点的个数和零交叉点的个数必须相等或相差最多不能超过 1 个。在任一点, 由局部极大值点形成的包络线和由局部极小值点形成的包络线的平均值为零。

运用 IMF 可以把任何信号 $x(t)$ 按如下步骤进行分解^[3-4]:

(1) 确定信号所有的局部极值点, 然后用 3 次样条线将所有的局部极大值点连接起来形成上包络线, 再用 3 次样条线将所有的局部极小值点连接起来形成下包络线, 上下包络线应该包络所有的数据点。上下包络线的平均值记为 m_1 , 求出

$$x(t) - m_1 = h_1 \quad (1)$$

理想地, 如果 h_1 是 1 个 IMF, 那么 h_1 就是 $x(t)$ 的第一个分量。

(2) 如果 h_1 不满足 IMF 的条件, 把 h_1 作为原始数据, 重复步骤(1), 得到上下包络线的平均值 m_{11} , 再判断 $h_{11} = h_1 - m_{11}$ 是否满足 IMF 的条件, 如不满足, 则重循环 k 次, 得到 $h_{1(k-1)} - m_{1k} = h_{1k}$, 使得 h_{1k} 满足 IMF 的条件。记 $c_1 = h_{1k}$, 则 c_1 为信号 $x(t)$ 的第一个满足 IMF 条件的分量。

(3) 将 c_1 从 $x(t)$ 中分离出来, 得到

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

将 r_1 作为原始数据重复步骤(1)、(2), 得到 $x(t)$ 的第二个满足 IMF 条件的分量 c_2 , 重复循环 n 次, 得到信号 $x(t)$ 的 n 个满足 IMF 的分量。这样就有

$$\begin{cases} r_1 - c_2 = r_2 \\ \vdots \\ r_{n-1} - c_n = r_n \end{cases} \quad (3)$$

当 r_n 成为一个单调函数不能再从中提取满足 IMF 的分量时, 循环结束。这样由式(2)、(3)得到

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (4)$$

因此, 可以把任何一个信号 $x(t)$ 分解为 n 个基本模式分量和一个残量 r_n 之和, 分量 c_1, c_2, \dots, c_n 分别包含了信号从高到低不同频率段的成分, r_n 则表示信号 $x(t)$ 的中心趋势。

2 支持向量机原理

若样本为 d 维向量, n 个样本及其所属类别表示为: $(x_i, y_i), y_i \in \{+1, -1\}, i = 1, \dots, n$ 。

超平面方程为 $wx + b = 0$, 使得对该线性可分的样本集满足^[7-8]:

$$y_i[w x_i + b] \geq 0 \quad i = 1, \dots, n \quad (5)$$

对判别函数进行归一化, 两类中所有的样本都满足

$$y_i(w x_i + b) - 1 \geq 0 \quad i = 1, \dots, n \quad (6)$$

此时分类间隔等于 $2/\|w\|$, 使间隔最大等价于使 $\|w\|$ 最小或 $\|w\|^2$ 最小。满足条件式(6)且使 $\|w\|^2/2$ 最小的分类面就叫作最优分类面。

这样求最优分类面的问题就可表示为: 在式(6)的约束下, 求下列函数的极小值(最小化泛函):

$f(w) \|w\|^2/2 = ww/2$ 。为此定义 Lagrange 函数为

$$L(w, b, a) = \frac{1}{2} ww - \sum_{i=1}^n a_i [y_i(w x_i + b) - 1] \quad (7)$$

这里的目的是将式(7)对 w 和 b 求 Lagrange 函数的极小值。将问题转化为其对偶问题, 即在约束条

件 $\sum_{i=1}^n y_i a_i = 0, a_i \geq 0 \quad i=1,2,\dots,n$ 对 a_i 求解下列目标函数的最大值

$$W(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j (x_i x_j) \quad (8)$$

设满足上述函数最大值的解为 a_i^* , 解中将只有一部分 a_i 不为零, 其对应的样本就是支持向量。求解出上述系数后, 就可以得到的最优分类函数是

$$f(x) = \text{sgn}(w^* x + b^*) \quad (9)$$

常用的核函数有线性核函数、多项式核函数、径向基核函数和 Sigmoid 核函数等。

3 基于 EMD 和 SVM 的转子系统故障诊断方法

假设采用 EMD 方法对采集的转子振动信号 $x(t)$ 进行分解得到了 n 个 IMF 分量 $c_1(t), c_2(t) \dots, c_n(t)$, 每一个 IMF 分量都包含了不同的特征尺度信息, 这样通过 EMD 分析, 信号 $x(t)$ 的特征就完全由这 n 个 IMF 分量 $c_1(t), c_2(t) \dots, c_n(t)$ 来刻画, 因此通过对 $c_1(t), c_2(t) \dots, c_n(t)$ 的特征提取, 就可以得到原始信号 $x(t)$ 的特征。

对任何一个 IMF 分量 $c_i(t)$ 建立如下的自回归

模型 $AR(m)$

$$c_i(t) + \sum_{k=1}^m j_{ik} c_i(t-k) = e_i(t) \quad (10)$$

其中: $j_{ik} (k=1,2,\dots,m)$ 、 m 分别为分量 $c_i(t)$ 的自回归模型 $AR(m)$ 的模型参数和模型阶数; $e_i(t)$ 为模型的残差, 是均值为零、方差为 s_i^2 的白噪声序列。由于自回归参数 $j_{ik} (k=1,2,\dots,m)$ 反映了转子系统的固有特性, 模型残差的方差 s^2 与转子系统的输出特性密切相关, 因此可以采用 $j_{ik} (k=1,2,\dots,m)$ 和 s_i^2 作为特征向量 $A_i = [j_{i1} j_{i2}, \dots, j_{im}, s_i^2]$ 来识别转子系统的工作状态。

因为支持向量机是 1 个两类分类器, 转子系统的运行状态通常有正常、不平衡、不对中、碰摩、油膜振荡等。所以建立对应 5 种故障的 5 个两类分类器(SVM1-SVM5), 将 5 个两类分类器按图 1 所示的二叉树形式组合, 便成为 1 个可以分离 5 种故障的多故障分类器。在分类测试中, 先将测试数据样本 x 的特征向量输入 SVM1, 若判别式 $f(x)$ 输出为 +1, 则确认为正常, 测试结束; 否则自动输入给 SVM2。依次类推, 直到 SVM5。若输出不为 +1, 说明测试样本可能属于其它故障。

基于 EMD 和 SVM 的转子系统故障诊断方法框

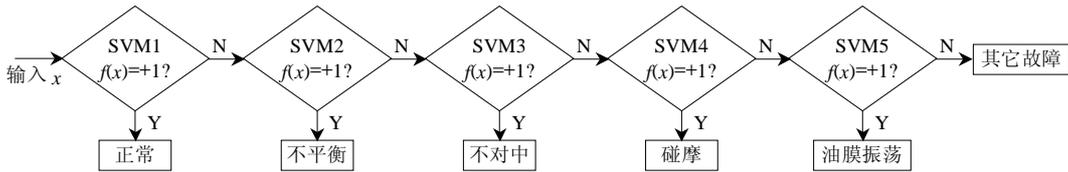


图 1 支持向量机多故障分类器
Fig.1 Multi-fault classifier of SVM

图如图 2 所示, 首先采用 EMD 方法对原始信号进行分解, 然后对每一个 IMF 分量 $c_i(t)$ 建立 AR 模型, 将自回归参数 $j_{ik} (k=1,2,\dots,m)$ 和模型的残差方差 s_i^2 组成特征向量 $A_i = [j_{i1} j_{i2}, \dots, j_{im}, s_i^2]$, 进行状态识别的工具是支持向量机。

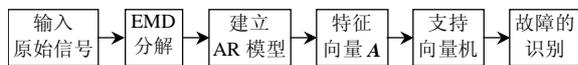


图 2 基于 EMD 和 SVM 的转子系统故障诊断方法流程图
Fig.2 The flow chart of fault diagnosis for rotor systems based on EMD and SVM

基于 EMD 和 SVM 的转子系统故障诊断方法如下:

(1) 分别在转子系统正常、不平衡故障、不对中故障、动静件碰摩故障和油膜振荡故障状态下, 按一定的采样频率 f_s 进行 N 次采样, 共获得 $5N$

个振动信号作为样本。

(2) 对每一种状态下的每一个振动信号进行 EMD 分解, 得到若干个 IMF 分量, 不同的振动信号的 IMF 分量个数 $n_1, n_2 \dots n_{5N}$ 不等, 设 $n_1, n_2 \dots n_{5N}$ 中的最大值为 n , 如果某个样本的 IMF 个数 $n_k < n (k=1,2,\dots,5N)$, 则补充零向量使其具有 n 个分量 $c_1(t), c_2(t) \dots c_n(t)$, 即令 $c_i(t) = [0] (i=n_k+1, n_k+2, \dots, n)$ 。

(3) 对每一个 IMF 分量 c_i 建立 AR 模型, 采用 FPE 准则^[11]确定模型的阶数 m , 由最小二乘法估计自回归参数 $j_{ik} (k=1,2,\dots,m)$ 和模型的残差方差 s_i^2 , 提取 j_{ik} 和 s_i^2 形成故障特征矢量 $A_i = [j_{i1} j_{i2}, \dots, j_{im}, s_i^2]$ 。

(4) 把由故障特征矢量 A_i 组成的训练样本输入支持向量机进行训练, 建立了由 5 个支持向量机

组成的多故障分类器，如图 1 所示。

(5) 采集转子系统的振动信号 $x(t)$ 作为被诊断信号，将测试样本进行 EMD 分解，对任何一个分量 $c_i(t)$ 建立 AR 模型，确定模型的残差方差 $S_{x,i}^2$ 和自回归参数 $j_{x,ik}$ ($k=1,2,\dots,m$)，组成被诊断信号 $x(t)$ 第 i 个分量的特征向量 $A_{x,i}=[j_{x,i1}, j_{x,i2}, \dots, j_{x,im}, S_{x,i}^2]$ (如阶数 $p < m$ ，自回归参数 $j_{x,ik}$ 用零来代替，且 $k = p+1, p+2, \dots, m$)。

(6) 进行故障模式识别，将由故障特征向量 $A_{x,i}$ 组成的测试样本输入支持向量机多故障分类器，如果 SVM1 输出为 +1，则为正常状态，否则输入下一个支持向量机进行判断，以此类推，从而可以判断转子系统的状态及故障类型。

4 应用实例与分析

对上述理论分析进行实验验证。试验装置采用的是南京东大测振仪器厂生产的 ZT-3 型转子振动模拟试验台，东方所的 DLF-3 和 INV-306 分别用于信号的调理与采集，采集软件使用 DASP 6.18。转子实验装置简图与传感器测点布置如图 3 所示，它能模拟不对中、不平衡、动静件的碰摩、油膜振荡等多种故障，用电涡流位移传感器和光电轴相传感

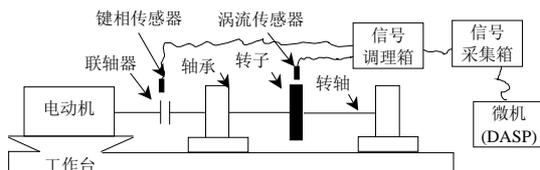


图 3 转子系统实验装置简图

Fig.3 The experimental device of the rotor system

器分别测量转子的振动量和轴的转速。在转子实验台上，对正常和故障转子的振动信号分别采样，实验时转子的转速为 6000r/min，采样频率为 4096Hz 时，分别采集正常、不平衡、不对中、动静件碰摩、油膜振荡故障 5 类状态下的转子振动信号各 9 组数据。在 5 类数据中分别随机抽取 6 组数据作为训练样本数据，将剩下的数据作为测试样本。按上节中的方法对振动信号进行 EMD 分解，因为 EMD 方法是一种主成分分析方法，主要的故障信息集中在前几个 IMF 分量中，因此本文选用了前 3 个 IMF 分量。对五类状态信号的前 3 个 IMF 分量分别建立 AR 模型，采用 FPE 准则确定模型的阶数 m ，序列的模型阶数 m 不相等，可以通过对模型阶数补零的方法加以解决。在本文的实验中，转子系统的故障信息主要包含在前几个 AR 模型参数中，为了简单起见，取前 5 个 AR 模型参数和残差方差作为特征参数，表 1 给出的是 5 种状态下各一个转子振动信号的特征向量(由于篇幅关系，其它特征向量未列出)，最后将提取的特征向量输入到由 5 个支持向量机组成的多故障分类器中进行故障的模式识别，结果如表 2 所示。从表 2 可以看出，支持向量机能够对测试样本进行正确率为 100% 的故障分类。说明对转子系统振动信号的 IMF 分量建立 AR 模型，使用 AR 模型参数和残差方差作为故障特征量，建立支持向量机分类器的转子故障诊断方法是有效的。

为了比较支持向量机与 BP 神经网络的收敛速度，取相同的 6 个训练样本对两种分类器进行训练，然后对剩下的 3 个测试样本进行分类，结果如表 3 所示。从表 3 可以看出，在样本较多的情况下，支

表 1 转子系统各种状态下的特征向量

Tab.1 The feature vectors of the rotor system in different conditions

被测信号及其状态	IMF 分量	特征向量						
		j_{i1}	j_{i2}	j_{i3}	j_{i4}	j_{i5}	S_i^2	
正常(X_1)	c_1	c_2	2.0409	0.0959	-1.0688	0.4908	0.03291	
	c_2	c_3	5.6222	-4.4459	1.8069	-0.2935	0.00292	
	c_3		-4.0615	6.6488	-5.4683	2.2479	-0.3652	0.00091
不平衡(X_4)	c_1		-2.5638	2.2738	-0.0269	-1.1109	0.5399	0.0204
	c_2		-3.8755	6.0555	-4.7211	1.7971	1.7971	0.0022
	c_3		-4.2577	7.1902	-6.0091	2.4792	-0.4026	0.0001
不对中(X_7)	c_1		-2.8031	2.7026	-0.3078	-1.1026	0.56899	0.0267
	c_2		-3.9114	6.2507	-5.1354	2.1995	-0.40195	0.0010
	c_3		-4.1891	7.1100	-6.1353	2.7051	-0.49090	0.0000
碰摩(X_{10})	c_1		-2.8757	2.9168	-0.9192	-0.3518	0.24194	0.3152
	c_2		-4.2012	6.9949	-5.7539	2.3293	-0.36991	0.0000
	c_3		-4.5186	8.1598	-7.3622	3.3196	-0.59896	0.0000
油膜振荡(X_{13})	c_1		-2.2432	1.6141	0.3637	-1.0044	0.38393	0.0285
	c_2		-3.7021	5.5903	-4.2357	1.5631	-0.20497	0.0025
	c_3		-3.9410	6.3587	-5.2887	2.2929	-0.41898	0.0001

表2 支持向量机测试分类结果
Tab.2 The test classification results of SVM

测试样本	故障分类	SVM1	SVM2	SVM3	SVM4	SVM5	分类结果
X ₁ ~X ₃	正常	+1	-	-	-	-	正常
X ₄ ~X ₆	不平衡	-1	+1	-	-	-	不平衡
X ₇ ~X ₉	不对中	-1	-1	+1	-	-	不对中
X ₁₀ ~X ₁₂	碰摩	-1	-1	-1	+1	-	碰摩
X ₁₃ ~X ₁₅	油膜振荡	-1	-1	-1	-1	+1	油膜振荡

表3 BP与支持向量机性能比较
Tab.3 The performance comparison of BP network and SVM

网络种类	训练样本/个	测试样本/个	训练时间/s	测试精度/%				
				正常	不平衡	不对中	碰摩	振荡
BP 网络	6	3	43.42	100	100	100	100	100
SVM	6	3	0.51	100	100	100	100	100

表4 小样本时BP与支持向量机性能比较
Tab.4 The performance comparison of BP network and SVM where only limited training data is available

网络种类	训练样本/个	测试样本/个	训练时间/s	测试精度/%				
				正常	不平衡	不对中	碰摩	振荡
BP 网络	3	6	35.58	50.00	66.67	83.33	83.33	100
SVM	3	6	0.43	100	100	100	100	100

持向量机与BP神经网络都能对故障类别进行准确地判别,但支持向量机与BP网络相比,节省了大量的训练时间,可对故障进行在线分类。

为了说明支持向量机更加适应小样本情况,取相同的3个的训练样本对两种分类器进行训练,再对剩下的6个测试样本进行分类,结果如表4所示。从表4可以看出,当训练样本减少时,BP网络分类性能急剧下降,而支持向量机仍然能够对测试样本的故障类别做出准确的诊断,显然支持向量机在小样本情况下仍然具有良好的预测推广能力。

5 结论

AR模型是一个信息的凝聚器,可将转子系统振动信号的特性及工作状态都凝聚于其中,因而可依据它对转子系统的工作状态进行识别。但是,AR模型只能分析平稳信号,对具有非平稳特征的转子故障振动信号的分析效果不好。因此,本文在建立AR模型之前先采用EMD方法分解,分解得到的各个IMF分量是经过平稳化处理的,然后就可以对各个IMF分量建立AR模型,以AR模型的自回归参数和残差的方差作为特征向量,支持向量机与神经网络相比,具有训练时间短和鲁棒性强等优点,并能有效的解决故障诊断中的少样本问题,特别适合于故障诊断中的故障模式的识别,因此本文利用支持向量机分类器来识别转子系统的运行状态及判断故障类型。通过对实验信号的分析,所得结果可

靠,识别率高,验证了将EMD和SVM相结合能有效地应用于转子系统的故障诊断,为转子系统的故障诊断提供了一种新的方法。

参考文献

- 高金吉. 旋转机械振动故障原因及识别特征研究[J]. 振动、测试与诊断, 1995, 15(3): 1-8.
Gao Jinji. Approach to mechanical vibration faults and distinctive symptoms in rotating machinery[J]. Journal of Vibration, Measurement & Diagnosis, 1995, 15(3): 1-8(in Chinese).
- 颜廷虎, 钟秉林, 黄仁, 等. 神经网络技术及其在旋转机械故障诊断中的应用[J]. 振动工程学报, 1993, 6(3): 205-212.
Yan Tinghu, Zhong Binglin, Huang Ren, et al. Artificial neural network technique and its applications to rotating machinery fault diagnosis[J]. Journal of Vibration Engineering, 1993, 6(3): 205-212(in Chinese).
- 陈岳东, 屈梁生. 神经网络在大型回转机械故障诊断中的应用[J]. 西安交通大学学报. 1992, 26(4): 53-59.
Chen Yuedong, Qu liangsheng. The application of artificial neural network to the fault diagnosis of large rotating machinery[J]. Journal of Xi'An Jiaotong University, 1992, 26(4): 53-59(in Chinese).
- 丁玉兰, 石来德. 机械设备故障诊断技术[M]. 上海: 上海科学技术文献出版社, 1994.
- 刘天雄, 郑明刚, 陈兆能, 等. AR模型和分形几何在设备状态监测中的应用研究[J]. 机械强度, 2001, 23(1): 61-65.
Liu Tianxiong, Zheng Minggang, Chen Zhaoneng, et al. Using AR model and fractal geometry for condition monitoring of working machinery[J]. Journal of Mechanical Strength, 2001, 23(1): 61-65(in Chinese).
- 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]. Proc. R. Soc. Lond. A, 1998,

- 454: 903-995.
- [7] Huang N E, Shen Z, Long S R. A new view of nonlinear water waves: The Hilbert spectrum[J]. *Annu. Rev. Fluid Mech.*, 1999, 31: 417-457.
- [8] 于德介, 程军圣, 杨宇. 基于 EMD 和 AR 模型的滚动轴承故障诊断方法[J]. *振动工程学报*, 2004, 17(3): 332-335.
Yu Dejie, Cheng Junsheng, Yang Yu. A fault diagnosis approach for roller bearings based on EMD method and AR model[J]. *Journal of Vibration Engineering*, 2004, 17(3): 332-335(in Chinese).
- [9] 程军圣, 于德介, 杨宇. 基于 EMD 和 AR 模型的汽车变速器齿轮故障诊断方法[J]. *汽车工程*, 2005, 27(1): 107-110.
Cheng Junsheng, Yu Dejie, Yang Yu. A fault diagnosis approach for gears in automotive transmission based on EMD method and AR model[J]. *Automotive Engineering*, 2005, 27(1): 107-110(in Chinese).
- [10] 闻新, 周露, 王丹力, 等. *Matlab 神经网络应用设计*[M]. 北京: 科学出版社, 2002.
- [11] Gunn S. Support vector machines for classification and regression [R]. University of Southampton, : ISIS Technical Report, 1998: 1-28.
- [12] Vapnik V. *The nature of statistical learning theory*[M]. New York: Springer-verlag, 1999.
- [13] 李凌均, 张周锁, 何正嘉. 支持向量机在机械故障诊断中的应用研究[J]. *计算机工程与应用*, 2002, 38(19): 19-21.
Li Lingjun, Zhang Zhousuo, He Zhengjia. Application research on support vector machines in mechanical fault diagnosis[J]. *Computer Engineering and Applications*, 2002, 38(19): 19-21(in Chinese).
- [14] Ge Ming, Du R, Zhang Guicai, Xu Yangsheng. Fault diagnosis using support vector machine with an application in sheet metal stamping operation[J]. *Mechanical System and Signal Processing*, 2004, 18(1): 143-159.
- [15] 翟永杰, 韩璞, 王东风, 等. 基于损失函数的 SVM 算法及其在轻微故障诊断中的应用[J]. *中国电机工程学报*, 2003, 38(9): 198-203.
Zhai Yongjie, Han Pu, Wang Dongfeng, et al. Risk function based algorithm and its application to a slight malfunction diagnosis [J]. *Proceedings of the CSEE*, 2003, 38(9): 198-203(in Chinese).

收稿日期: 2006-05-05。

作者简介:

于德介(1957—), 男, 博士, 教授, 博士生导师, 从事机械故障诊断及振动分析研究, chenmiaofengbee@sohu.com;

陈森峰(1981—), 男, 硕士研究生, 主要从事转子系统故障诊断;
程军圣(1968—), 男, 博士, 教授, 从事机械故障诊断及振动分析研究;

杨宇(1971—), 女, 博士, 副教授, 研究方向为机械故障诊断及测控技术。

(责任编辑 云爱霞)