

桥梁健康监测系统的异常数据特征库构建*

吴 键¹, 张宇峰², 袁慎芳³, 梁 栋³

(1. 南京理工大学机械工程学院 南京, 210094)

(2. 江苏省交通科学研究院股份有限公司 南京, 211112)

(3. 南京航空航天大学智能材料与结构航空科技重点实验室 南京, 210016)

摘要 针对实际桥梁健康监测系统的异常数据识别和诊断问题, 提出了一种异常数据特征库的构建方法。首先, 对监测数据进行去噪处理, 选取统计信号的时域、频域以及AR模型系数特征; 然后, 利用核主元分析的方法进行特征提取, 建立包括传感器短路、拍波和船撞等异常数据的特征库; 最后, 通过BP神经网络方法识别桥梁监测系统的异常状态, 以验证特征库构建的有效性。江阴长江大桥主梁振动监测数据的分析表明, 桥梁异常数据特征库构建方法能够用于诊断桥梁振动。

关键词 桥梁健康监测; 数据异常识别; 特征库建立; 核主元分析; 特征提取

中图分类号 TP18

引 言

随着交通网络的迅速发展, 桥梁建设更加复杂多样化。建桥在国民经济发展中的重要作用, 使得桥梁安全评估工作受到重视。近年来, 测量、通信和计算机硬件技术的发展, 高精度数据采集、数值通信和实时计算机软件技术的发展以及结构分析理论的进步, 为桥梁结构的在线健康监测创造了条件。目前, 国内的香港青马大桥、虎门大桥、徐浦大桥、苏通大桥、江阴长江大桥和润扬大桥等在施工阶段已安装健康监测用的传感设备, 以备运营期间的实时监测。

由于真实桥梁结构尺寸大、质量重, 结构响应极易受到环境以及非结构构件等因素的影响。目前的桥梁健康监测系统大多能够实现数据的自动采集和传输, 但实际工程条件导致了桥梁结构的劣化和健康监测系统的性能退化, 系统监测数据变异性较大, 给损伤识别和状态评估带来了困难。笔者着重研究基于桥梁健康监测数据的异常特征库构建, 用于监测和识别桥梁结构异常和监测系统本身的异常。

目前针对实际桥梁健康监测系统的异常数据识别与诊断的研究报道较少, 相关工作多集中在桥梁整体结构损伤的特征选择和识别研究上^[1-5], 文献[2]分别讨论了在桥路结构损伤状态监测中利用时频域系统辨识方法选择模型特征, 从而识别结构损

伤; 文献[3]利用相似系数, 使用修正的欧式距离方法对桥路运营结构状态进行监测; 文献[4]利用动态参数模型残差法提取结构损伤特征, 进而通过统计方法进行异常识别。大致可分为无模型方法与有模型方法两大类: 无模型方法不需要结构自身的有限元等数值模型, 而从监测信号的直接处理入手发现数据中的异常特征并对异常情况进行分析与评估; 有模型方法则需要借助数值模型建立结构损伤与结构响应变化之间的联系, 通过监测数据分析结构响应的变化, 获得特征信息进而找出损伤部位与程度。

考虑到健康监测自身异常的诊断, 选择无模型的基于信号处理的特征选择提取方法。针对桥梁健康监测数据的异常状态识别问题, 提出了一种基于时频域特征、AR模型系数以及核主元分析的异常状态特征库建立方法。首先, 对监测数据进行去噪处理, 选取统计信号的时域、频域以及AR模型系数特征; 然后, 利用核主元分析的方法进行特征提取, 建立异常状态特征库; 最后, 通过BP神经网络来识别桥梁结构或者监测系统异常, 以验证特征库建立方法的有效性。

1 江阴长江大桥结构健康监测系统

以江阴长江大桥及其结构健康监测系统为对

* 江苏省自然科学基金资助项目(编号: BK2008510); 国家自然科学基金资助项目(编号: 50830201)

收稿日期: 2010-09-06; 修改稿收到日期: 2010-11-29

象,通过构建异常状态数据的特征库,识别、诊断大桥结构和系统的异常状态。该桥是我国20世纪末建成的特大钢箱梁悬索桥,2004年升级改造后的结构健康监测系统包含38个加速度传感器、80个光栅光

纤应变传感器、36个光栅光纤温度传感器、9个GPS传感器、4个位移传感器、2个风速传感器、2个温湿度大气压传感器和1个大气气压传感器。该桥的结构示意及加速度传感器分布如图1所示。

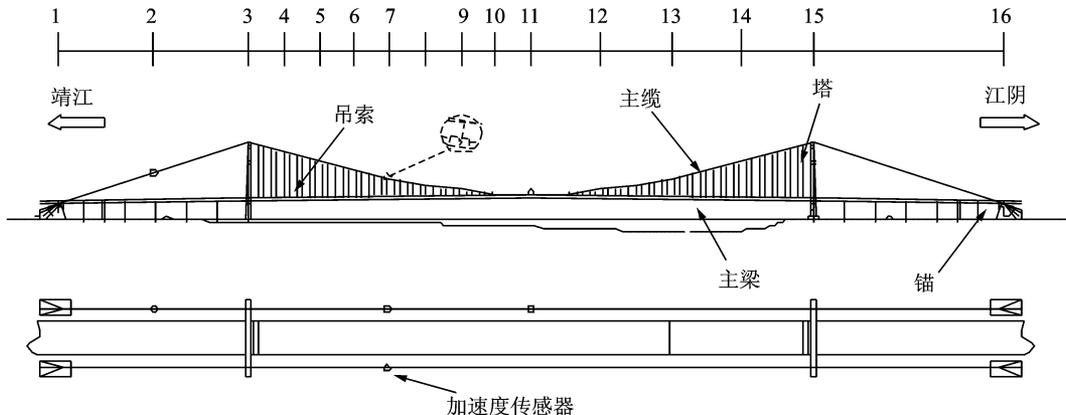


图1 江阴长江大桥及主梁加速度传感器分布示意图

以主梁加速度传感器监测外部载荷引起的结构异常和监测系统自身异常为例说明桥梁异常数据特征库的构建过程,选用主梁3号监测站连接的加速度传感器,其信号波形及其功率谱如图2所示。从功率谱中可见,该信号为线谱,它反应了桥梁结构在风、车辆等荷载作用下的模态频率。每个加速度传感器通道以50 Hz采样率采集数据。实际工程条件使得该健康监测系统的监测数据耦合了环境和测量噪声,因此首先需要对数据进行去噪处理,采用小波阈值去噪处理方法^[2],滤除掉一些不重要的信息以及噪声,然后对数据进行分段和加窗处理。为了构建特征库并检验其有效性,选取2 347段样本数据,其中2 299个正常数据和48个异常数据,异常样本包括20个传感器开路数据、5个船撞事件数据和23个车载共振异常数据。

2 异常数据的特征选择

2.1 时域统计特征

将监测数据近似看成服从高斯分布的随机信号,对时域信号数据分析,可以得到监测数据的某些统计特征。统计参数特征可供多种处理,例如,对信号进行整形、滤波,计算数据的均值、绝对值积分平均值(IAV)、幅值的直方图、过零次数(ZC)、均方根(RMS)、方差(VAR)、3阶原点矩的绝对值、4阶原点矩、波形因数、振幅因数和自相关函数等作为特征量。其中,工程应用得最多的统计特征是矩函数,其计算表达式为

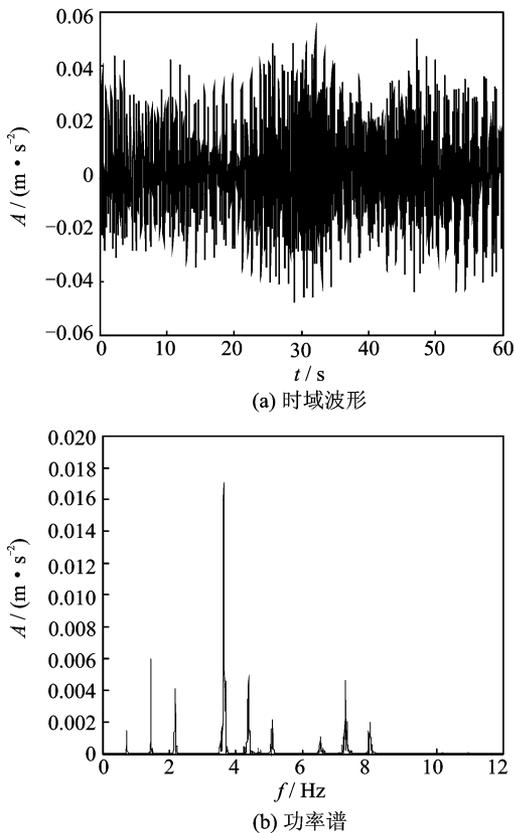


图2 主梁加速度监测信号

$$m_n = E\{x^n\} = \frac{1}{N} \sum_{i=1}^N x_i^n \quad (1)$$

当 $n=1, 2, 3$ 和4时,即分别选取监测信号的均值、方差、偏度和峭度特征。如果桥梁结构和监测系统状态的变化导致了信号概率密度函数的变化,矩函数也可能变化,因此矩函数可作为异常数据特征选择的时域统计特征。

2.2 频域特征

频域分析是将监测数据转换为频域信号,对其进行频谱或功率谱分析,将监测数据由随时间变化的幅值转变为随频率变化的功率,可以直接观察其频段的分布与变化情况。这里的频域分析主要应用功率谱估计方法,主要特征参数有频率中心 f_{FC} 、均方根频率 f_{RMSF} 和根方差频率 f_{RVF} ,分别表征了信号主频位置、主频变化和功率谱的集中程度。对信号进行频域分析之前,先对信号进行 FFT 变换,得到 $X(f)$,然后再求功率谱 $S(f)$ 。它是用 $X(f)$ 的幅值二次方来表示的,即 $S(f) = |X(f)|^2$,从而有

$$\begin{cases} f_{FC} = \int_0^{+\infty} fS(f)df / \int_0^{+\infty} S(f)df \\ f_{RMSF} = \left[\int_0^{+\infty} f^2 S(f)df / \int_0^{+\infty} S(f)df \right]^{1/2} \\ f_{RVF} = \left[\int_0^{+\infty} (f - f_{FC})^2 S(f)df / \int_0^{+\infty} S(f)df \right]^{1/2} \end{cases} \quad (2)$$

2.3 自回归 AR 模型参数特征

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。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^[5],反映了被测系统的固有特性。模型残差方差与系统的输出特性密切相关,因此采用 AR 模型的自回归参数作为特征向量分析系统的状态变化十分有效。

AR 模型可描述如下

$$x(t) = \sum_{k=1}^n \phi_k x(t-k) + e(t) \quad (3)$$

其中: ϕ_k 为 AR 系数; n 为模型阶数; $e(t)$ 为残差白噪声。

这里 AR 模型的阶次判定方法采用最终预测误差(FPE)法。

3 基于核主成分分析的特征提取

时、频域分析和 AR 模型方法对健康监测数据进行处理后,每一个监测信号的模式特征都可以用一个特征向量表示,这里把由上述特征向量所组成的空间称为特征空间。一般来说,通过时、频域分析等特征选择方法直接获得的特征空间有比较高的维数,将其直接作为系统状态识别的输入矢量,将会影响识别率。为了提高系统异常状态的正确识别率、改进系统状态分类器的泛化性能和方便分类器的设

计,特征空间维数降低显得尤为重要。

通过上述时域、频域和 AR 模型分析为每段信号选取了包含 17 个模式特征的特征向量,分别为均值、方差、偏斜、峰度、直方图上下界、有效值、波形因数、振幅因数、频率中心、均方根频率、根方差频率和 AR 模型的 4 阶系数和残差。将江阴大桥主梁振动监测的状态影射到一个 17 维的特征空间上。采用核主元分析方法对该特征空间进行降维处理,实现特征提取和特征库的构建。

核主元分析(KPCA)^[6]是主元分析(PCA)的非线性推广,其基本思想是通过非线性变换 $\varphi(\cdot)$ 将样本数据从输入空间映射到高维特征空间,然后在高维特征空间利用 PCA 进行特征提取。

假设 \mathbf{x} 是 n 维随机向量, $\{\mathbf{x}_i, i=1, 2, \dots, N\}$ 是随机向量 \mathbf{x} 的一个样本集,由非线性 Φ 将输入数据从原空间 R^n 映射到高维特征空间 R' ,然后在这个高维特征空间中进行主成分分析。

假设 $\Phi(\mathbf{x}_i)$ 已经去均值 $\sum_{i=1}^N \Phi(\mathbf{x}_i) = 0$, 那么 $\Phi(\mathbf{x}_i)$ 的协方差矩阵 C 为

$$C = \frac{1}{N} \sum_{i=1}^N \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_i)^T \quad (4)$$

式(4)特征值和特征向量为

$$\lambda_k \mathbf{v}_k = C \mathbf{v}_k \quad (5)$$

其中:特征值 $\lambda_k \geq 0$, $\mathbf{v}_k (k=1, 2, \dots, t)$ 为特征向量。

将式(4)代入式(5)得

$$C \mathbf{v}_k = \frac{1}{N} \sum_{k=1}^N \Phi(\mathbf{x}_k) \langle \Phi(\mathbf{x}), \mathbf{v}_k \rangle = \lambda_k \mathbf{v}_k \quad (6)$$

其中:内积 $\langle \Phi(\mathbf{x}), \mathbf{v}_k \rangle = \underline{\Delta} \Phi(\mathbf{x})^T \mathbf{v}_k$ 。

所有非零特征值 λ_k 对应的特征向量 \mathbf{v}_k 在 $\{\Phi(\mathbf{x}_i), i=1, 2, \dots, N\}$ 张成的平面内,从而存在不全为 0 的系数 $\{\alpha_i, i=1, 2, \dots, N\}$,使得

$$\mathbf{v}_k = \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i) \quad (7)$$

由式(5)~式(7)可得

$$\begin{aligned} \lambda_k \langle \Phi(\mathbf{x}_i), \mathbf{v}_k \rangle &= \lambda_k \sum_{j=1}^N \alpha_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle, \\ \langle \Phi(\mathbf{x}_i), \mathbf{v}_k \rangle &= \langle \Phi(\mathbf{x}_i), C \mathbf{v}_k \rangle = \\ \frac{1}{N} \sum_{s=1}^N \{ \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_s) \rangle & \sum_{j=1}^N \alpha_j \langle \Phi(\mathbf{x}_s), \Phi(\mathbf{x}_j) \rangle \} \end{aligned} \quad (8)$$

定义 $N \times N$ 矩阵 $\mathbf{K}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$, 其中 $k(\mathbf{x}_i, \mathbf{x}_j)$ 是满足 Mercer 定理的核函数,可将式(8)化简为 $N \lambda_k \mathbf{K} \alpha = \mathbf{K}^2 \alpha$, 于是得

$$N \lambda_k \alpha = \mathbf{K} \alpha \quad (9)$$

其中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$ 。

由此 \mathbf{K} 的特征值和特征向量分别为 $N \lambda_k$ 和 α^k 。

$k=1,2,\dots,N$ 。将特征值按照降序排列,根据前 m 个特征值和占总特征值和的比值大于某阈值,如0.98,确定主元个数为 m 。

为了归一化特征向量 \mathbf{v}_k , 还需对 α 规范化, $\bar{\alpha}^k = \alpha^k / \sqrt{\lambda_k}$, 则可得测试样本 x 在 R^m 空间中的第 k 个主向量 \mathbf{v}_k 上的投影, 即第 k 个非线性主成分

$$t_k = \langle \mathbf{v}_k, \Phi(\mathbf{x}) \rangle = \sum_{i=1}^N \alpha_i^k \mathbf{K}(\mathbf{x}, x_i) \quad (10)$$

如果 $\sum \Phi(x_i) \neq 0$, 数据需要在特征空间中心化。这个工作可通过用 $\bar{\mathbf{K}}$ 取代 \mathbf{K} 来实现

$$\bar{\mathbf{K}} = \mathbf{K} - \mathbf{L}\mathbf{K} - \mathbf{K}\mathbf{L} + \mathbf{L}\mathbf{K}\mathbf{L} \quad (11)$$

其中: $L_{i,j} = 1/N$ 。

PCA 与 KPCA 方法进行对比, KPCA 方法采用如下两种核函数:

1) KPCA1 为多项式核函数

$$k(\mathbf{x}, \mathbf{y}) = (\mathbf{x}^T \mathbf{y} + 1)^p, p = 5$$

2) KPCA2 为高斯核函数

$$k(\mathbf{x}, \mathbf{y}) = e^{-\|\mathbf{x}-\mathbf{y}\|^2/2\sigma^2}, \sigma = 10$$

由表1不难看出, 利用PCA和KCA方法, 贡献率都比较集中。如果累积贡献率取99%, 那么3种方法都可以将原始数据维数降低到4维。同时, PCA与KPCA2的降维效果相似。比较而言, KPCA1贡献率更为集中, 主要分散在第一主元上, 所以选择KPCA1作为本文降维方法。同时, 为了尽可能保留原始数据中的信息, 将输入空间数据的维数降为3维。

表1 样本集 KPCA 数据处理结果

特征值 序号	PCA			KPCA1(多项式核函数)			KPCA2(高斯核函数)		
	特征值 λ_i	贡献 率/%	累计 贡献率/%	特征值 λ_i	贡献 率/%	累计 贡献率/%	特征值 λ_i	贡献 率/%	累计 贡献率/%
1	0.224 9	81.287 3	81.287 3	20 180 228	95.299 8	95.299 8	5.598 0	81.219 5	81.219 5
2	0.031 5	11.389 4	92.676 7	211 038.2	0.031 3	98.432 1	0.795 8	11.545 4	92.765 0
3	0.014 1	5.081 4	97.758 1	54 312.24	0.009 9	99.428 8	0.320 4	4.648 9	97.413 9
4	0.006 1	2.209 7	99.967 7	39 332.44	0.002 6	99.685 3	0.157 2	2.280 4	99.694 4
5	0.000 1	0.019 2	99.986 9	19 061.50	0.001 9	99.871 0	0.017 9	0.260 0	99.954 4

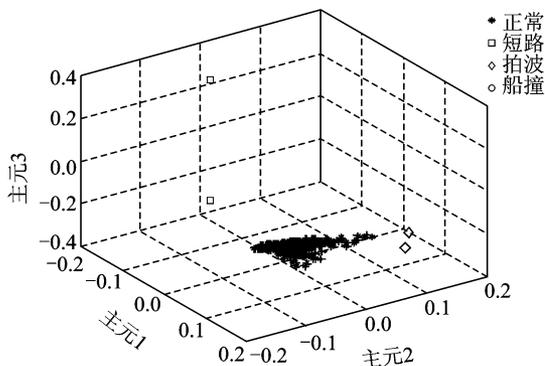


图3 正常数据和短路、拍波和船撞等异常特征的空间分布

图3为降维后得到的包括短路、拍波和船撞等异常特征数据和正常数据的特征空间分布情况。

4 主梁振动数据异常的状态识别

为了验证上述特征库构建方法的有效性, 利用BP神经网络对主梁加速度信号进行异常识别, 通过对前面江阴大桥实测数据的预处理、特征选择和核主元分析压缩后得到3维特征库。

BP网络可看作是一个从输入到输出的高度非线性映射, 即可对系统实现由 R^n 空间 (n 为输入节点数) 到 R^m 空间 (m 为输出节点数) 的高度非线性映射, $F: R^n \rightarrow R^m, f(X) = Y$ 。对于样本集合: 输入 $x_i (\in R^n)$ 和输出 $y_i (\in R^m)$, 可认为存在某一映射 g , 使得

$$g(x_i) = y_i \quad (i = 1, 2, \dots, n) \quad (12)$$

根据Kolmogrov多层神经网络映射存在定理, M 维单位立方体 $E_m = [0, 1]$ 中的任意一个连续函数 $\Phi: E_m \rightarrow R^n, \Phi(x) = Y$, 都可用一个3层神经网络精确实现, 并且该网络的输入层是 m 个单元, 中间隐层为 $2m+1$ 个单元, 输出层为 n 个单元。这一定理证明了网络是可以实现任何映射关系。笔者采用BP网络因其映射功能, 可对实际桥梁健康监测系统的数据异常状态进行识别, 从而寻找出从系统监测响应数据到短路、拍波和船撞等异常状态的映射关系。

因为降维后的特征个数为3, 有4种模式需要区分, 所以BP神经网络结构为3-7-3, BP的输出故障模式见表2。隐层和输出层传输函数都采用S型函数, 采用后向传播梯度下降法进行训练。从样本集合中取出48个异常模式和14个正常模式, 从4种模式

表2 BP神经网络输出模式

异常类型	神经网络输出模式		
正常	0	0	1
短路	0	1	0
拍波	0	1	1
船撞	1	0	0

中分别随机抽取4个样本进行训练,从其他样本中抽取10个进行测试,可以得到实际输出样本的正确数为8,可知BP神经网络的分类正确率为80%,神经网络的输入输出结果如表3所示。

表3 BP神经网络的测试结果

神经网络输入样本			神经网络输出		
主特征1	主特征2	主特征3	输出分量1	输出分量2	输出分量3
-1.816	-0.161	-0.102	0.033 5	0.189 0	0.895 8
-1.788	-0.228	-0.091	0.027 2	0.185 3	0.906 9
-1.765	-0.293	-0.089	0.013 3	0.241 9	0.944 2
-1.816	-0.166	-0.094	0.044 2	0.166 3	0.873 9
-1.800	-0.246	-0.085	0.014 0	0.283 7	0.947 2
-2.532	1.520	-0.127	0.998 1	0.063 4	0.002 3
-2.040	-0.017	0.088	0.834 5	0.141 1	0.329 5
-1.960	-0.066	0.031	0.670 4	0.101 3	0.401 7
-1.846	-0.142	-0.050	0.312 0	0.072 6	0.557 2
-1.938	-0.034	-0.030	0.268 5	0.172 8	0.694 0

5 结束语

针对江阴长江大桥振动数据的成因分析识别问题,提出了一种基于时频域特征、AR模型系数以及核主元分析的异常数据特征库的构建方法。该方法利用核方法将数据中的非线性关系转换为线性关系进行处理。首先,对原始信号进行小波阈值去噪;然后,统计信号的时域、频域以及AR模型系数特征,利用核主成分分析进行特征提取,得到非线性主元特征库;最后,利用BP神经网络将特征数据非线性映射到高维空间进行线性异常模式识别。江阴大桥振动数据分析表明,该方法有较好的效果。

参 考 文 献

[1] 袁万成,崔飞,张启伟. 桥梁健康监测与状态评估的研究现状与发展[J]. 同济大学学报,1999,27(2):184-188.
Yuan Wancheng, Cui Fei, Zhang Qiwei. Current research and development of structural health monitoring and condition assessment for bridges[J]. Journal of Tongji University, 1999, 27(2): 184-188. (in Chinese)

[2] 王兆辉,樊可清,李霆. 系统辨识在桥梁状态监测中的应用[J]. 中南公路工程,2006,31(3):159-163.
Wang Zhaohui, Fan Keqing, Li Ting. Bridge condition monitoring using system identification[J]. Journal of Central South Highway Engineering, 2006, 31(3):

159-163. (in Chinese)

[3] 张启伟. 桥梁健康监测中的损伤特征提取与异常诊断[J]. 同济大学学报,2003,31(3):258-262.
Zhang Qiwei. Damage feature extraction and novelty detection for bridge health monitoring[J]. Journal of Tongji University, 2003, 31(3): 258-262. (in Chinese)

[4] 樊可清,倪一清,高赞明. 基于SVM的桥梁状态监测方法[J]. 公路交通科技,2004,21(1):67-70.
Fan Keqing, Ni Yiqing, Gao Zanning. Bridge condition monitoring approach using SVM based novelty detection algorithm[J]. Journal of Highway and Transportation Research and Development, 2004, 21(1): 67-70. (in Chinese)

[5] 滕龙,曾储惠. 模式识别技术在桥路状态评估与安全监测中的应用[J]. 中国铁道科学,2005,26(4):47-51.
Teng Long, Zeng Chuhui. Application of mode recognition technique in the evaluation of bridge state and safety inspection[J]. China Railway Science, 2005, 26(4): 47-51. (in Chinese)

[6] Niu G, Widodo A, Son J D, et al. Decision-level fusion based on wavelet decomposition for induction motor fault diagnosis using transient current signal[J]. Expert Systems with Application, 2008(35): 918-928.

[7] Knox R, Brooks D, Markogiannakis S, et al. New features based on alternative representations of AR models for upper limb emg recognition, in Engineering in Medicine and Biology Society[C]//Proceedings of the 15th Annual International Conference of the IEEE. San Diego, CA: [s. n.], 1993: 1137-1138.

[8] 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)

[9] 邹东升,余龙华. 改进的主成分分析方法在磁浮系统中的应用[J]. 振动、测试与诊断,2009,29(1):96-100.
Zou Dongsheng, She Longhua. An improved principle components analysis method and its application to maglev system[J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(1): 96-100. (in Chinese)

第一作者简介:吴键,男,1979年11月生,博士生。主要研究方向为结构健康监测无线传感技术。曾发表《无线传感器网络节点的设计和实现》(《仪器仪表学报》2006年第127卷第19期)等论文。
E-mail: wujian@nuaa.edu.cn