

· 自动化技术 ·

基于结构健康监测系统的桥梁数据异常诊断研究

袁慎芳¹, 梁 栋¹, 高 宁², 张宇峰³

(1. 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; 2. 南京航空航天大学无人机研究院 南京 210016;
3. 长大桥梁健康检测与诊断技术交通行业重点实验室 南京 211112)

【摘要】桥梁结构监测主要集中在对桥梁结构损伤位置和损伤程度的研究,然而,这是以桥梁结构健康监测数据有效为前提的。在实际的环境里,由监测系统自身故障引起的异常往往会对监测数据有一定影响,使得监测系统产生损伤误报,增加了虚警率;同时,由某些外部荷载引起的突发事件,可能会对结构有严重破坏,不利于桥梁的安全维护和管理。为了保证桥梁的安全,提高桥梁结构监测的有效性,有必要对特殊事件进行异常诊断。该文将一类识别方法应用到桥梁数据诊断中,即通过核主成分分析和超球面一类支持向量机方法将一般监测数据和特殊事件数据有效区分,并利用江阴大桥的加速度传感器数据验证了该方法在船撞、台风、传感器装机噪声和传感器跳变信号下的有效性。

关键词 桥梁结构健康监测; 数据异常诊断; 核主成分分析; 超球面一类支持向量机

中图分类号 TP212; U446

文献标志码 A

doi:10.3969/j.issn.1001-0548.2013.01.016

The Bridge Data Diagnosis Research Based on Structural Health Monitoring System

YUAN Shen-fang¹, LIANG Dong¹, GAO Ning², and ZHANG Yu-feng³

(1. The Aeronautic Key Laboratory of Smart Material and Structure, Nanjing University of Aeronautics and Astronautics Nanjing 210016;
2. Research Institute of Unmanned Aircraft, Nanjing University of Aeronautics and Astronautics Nanjing 210016;
3. Key Laboratory of Long-Span Bridge Health Inspection & Diagnosis Technology of Ministry of Transport Nanjing 211112)

Abstract The research on the bridge structural monitoring focuses mainly on the identification of the structure damage position and degree. However, these researches are based on the data of the structural health monitoring system. In the actual environment, the abnormal data caused by the failure monitoring system can often make the false prognosis, increasing the false alarm rate. Meanwhile, the bridge may have serious structural damage from the unexpected events caused by some external loads. They are not conducive to the bridge safety maintenance and management. In order to ensure the bridge safety and improve the effectiveness of the bridge structure monitoring, it is necessary to diagnose these special events. In the paper, kernel principal component analysis (KPCA) and hyperspherical support vector machine method are employed to separate the general monitoring data from the event data. The acceleration sensor data in Jiangyin Bridge is used to validate the effectiveness of the method under the ship collision, typhoons, sensor installed noise, and sensor step signals.

Key words bridge structural health monitoring; data novelty diagnosis; kernel principal component analysis; hyperspherical one-class support vector machine

近20多年来随着交通事业的发展,有大量桥梁投入使用,悬索桥、斜拉桥等结构复杂的大跨度桥梁不断出现。保障桥梁安全减少维护费用是一个具有重大社会和经济意义的问题,受到政府和交通企业的密切关注,桥梁状态监测与健康评价技术也因此而成为当前一大研究热点^[1]。

利用实时监测数据进行结构异常和损伤诊断是桥梁健康监测的基本目的。但是,由于结构本身的

劣化和设备的老化损害可能导致传感器以及监测系统出现异常,从而严重影响了对损伤的监测,不能正常识别损伤,直接影响桥梁系统的安全性。同时,一些突发事件,如地震、船撞、大风、雨雪等,会影响桥梁结构,甚至可能对桥梁结构产生严重破坏。所以,有必要对该类特殊事件进行诊断分析,从而有利于管理部门对监测系统的实时维护,保证对桥梁损伤监测的准确性。

收稿日期: 2011-02-17; 修回日期: 2012-10-29

基金项目: 国家自然科学基金(60772072, 50830201); 江苏省普通高校研究生科研创新计划(CX10B_097Z); 江苏省自然科学基金(BK2008510)

作者简介: 袁慎芳(1968-), 女, 教授, 主要从事结构健康监测和信息信号处理方面的研究。

目前, 基于桥梁结构健康监测的特殊事件的数据异常诊断的研究还不多见。大部分的研究者主要集中在桥梁结构损伤的研究中, 主要涉及损伤的定位及损伤程度的确定等, 所使用的方法可以分为基于模型和基于特征两类。基于模型主要是通过测量数据不断更新模型结构参数, 但是模型与实际情况往往存在较大偏差^[2-3]; 而基于特征不需要结构模型, 只需从测量数据中提取相关特征, 包括模态频率、振型、刚性矩阵等, 从而实现对结构损伤识别^[4-8]。因本文的研究涉及桥梁结构和结构健康监测系统引起的数据异常的复杂性, 因此选择基于特征的方法进行研究。

在实际桥梁监测系统中, 由于监测系统或者突发事件的出现存在较大的随机性和不确定性以及季节性, 所以异常样本很难获取或者能够得到的数量很少。尽管如此, 桥梁健康监测系统可以获得整个桥梁的大量正常样本数据。如何从这些正常数据中找到区分异常的关键特征以及准确识别异常样本, 是数据异常诊断的两个关键问题。前者, 可以采用时域、频域等信号处理方法对信号进行研究, 然后利用特征选择或特征提取技术获得主要显著特征; 后者, 可以作为异常检测问题, 即用精确的、具有足够代表性的正常状态模式与在线得到的即时模式进行比较, 从而实现数据异常诊断。

本文针对桥梁结构健康监测系统特殊事件的数据异常问题, 提出一种核主成分分析和超球面一类支持向量机的桥梁数据异常诊断方法。

1 理论与方法

1.1 核主成分分析原理

对于桥梁信号的特征一般包括时域统计特征、频域以及自回归模型系数等诸多特征, 如何从这些特征中寻找最有效的特征可以通过特征提取技术加以解决。核主成分分析(KPCA)^[9]是特征提取的一种有效方法, 其基本思想是通过非线性变换将样本数据从输入空间映射到多维特征空间, 然后在多维特征空间利用主成分分析方法(principal component analysis, PCA)在 t 维空间中通过线性变换得到一组正交基, 从而使产生的新分量相关性为零; 忽略那些方差小的变量, 得到数据的低维空间表示, 从而保留原始数据的绝大部分信息, 实现数据的压缩降维。

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, 由非线性关系 Φ 将输入数据从原空间 R^n 映射到多维特征空间 R^t , 然后在多维

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

$\Phi(\mathbf{x}_i)$ 的协方差矩阵为:

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

式(1)中特征值和特征向量的关系为:

$$\lambda_k \mathbf{v}_k = \mathbf{C} \mathbf{v}_k \quad (2)$$

式中, 特征值 $\lambda_k \geq 0$, $\mathbf{v}_k (k=1, 2, \dots, t)$ 为特征向量。则将式(1)代入式(2)得:

$$\mathbf{C} \mathbf{v}_k = \frac{1}{N} \sum_{k=1}^N \Phi(\mathbf{x}_k) \langle \Phi(\mathbf{x}), \mathbf{v}_k \rangle = \lambda_k \mathbf{v}_k \quad (3)$$

式中, 内积 $\langle \Phi(\mathbf{x}), \mathbf{v}_k \rangle = \Phi(\mathbf{x})^T \mathbf{v}_k$, 则所有非零特征值 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:

$$\mathbf{v}_k = \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i) \quad (4)$$

这样由式(2)~式(4)得:

$$\begin{aligned} \lambda_k \langle \Phi(\mathbf{x}_i), \mathbf{v}_k \rangle &= \lambda_k \sum_{j=1}^N \alpha_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = \\ \langle \Phi(\mathbf{x}_i), \mathbf{C} \mathbf{v}_k \rangle &= \\ \frac{1}{N} \sum_{s=1}^N \{ \langle \Phi(\mathbf{x}_s), \Phi(\mathbf{x}_i) \rangle \sum_{j=1}^N \alpha_j \langle \Phi(\mathbf{x}_s), \Phi(\mathbf{x}_j) \rangle \} \end{aligned} \quad (5)$$

定义 $N \times N$ 维矩阵 $\mathbf{K}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$, 其中 $k(\mathbf{x}_i, \mathbf{x}_j)$ 是满足 Mercer 定理的核函数, 可将式(5)化简为 $N \lambda_k \mathbf{K} \boldsymbol{\alpha} = \mathbf{K}^2 \boldsymbol{\alpha}$, 于是得:

$$N \lambda_k \boldsymbol{\alpha} = \mathbf{K} \boldsymbol{\alpha} \quad (6)$$

式中, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$, 由此 \mathbf{K} 的特征值和特征向量分别为 $N \lambda_k$ 和 $\boldsymbol{\alpha}^k, k=1, 2, \dots, N$ 。将 λ_k 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 0.95, 确定主元个数为 m 。

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

$$t_k = \langle \mathbf{v}_k, \Phi(\mathbf{x}) \rangle = \sum_{i=1}^N \alpha_i^k K(\mathbf{x}, \mathbf{x}_i) \quad (7)$$

如果 $\sum_{i=1}^N \Phi(\mathbf{x}_i) \neq 0$, 数据需要在特征空间中心化。该工作可通过用 $\bar{\mathbf{K}}$ 取代 \mathbf{K} 实现:

$$\bar{\mathbf{K}} = \mathbf{K} - \mathbf{L} \mathbf{K} - \mathbf{K} \mathbf{L} + \mathbf{L} \mathbf{K} \mathbf{L} \quad (8)$$

其中 $L_{t,j} = 1/N$ 。

2.2 超球面一类支持向量机

用于异常检测问题的机器学习方法称为一类学习或异常检测算法。对于桥梁而言,漏报会导致巨大风险,而过多误报又会增加维护费用、妨碍正常交通。运用该算法可以在特征空间上建立正常样本分布区域的模型并构造尽可能紧凑地判决函数覆盖该区域,当未知样本落在判决区域外部时判为异常,从而达到异常检测的目的,减少误报漏报的发生。

一类支持向量机(One-class SVM)是一种无监督学习方法,文献[10]提出,利用原点作为负类的代表,通过最大化原点和目标数据间的最小欧式距离寻找最优超平面,使超平面尽量远离原点,从而最小化大部分目标数据所在的正半空间。文献[11]在此基础上提出了利用超球作为分界面的方法,通过寻找一个包含正常数据的最小超球来降低VC维以提高分类器性能。但他们的思想都是通过获得的大部分正常数据,寻找一个覆盖 $C(x)$ 来拟合该正常数据的分布区域,那些落在区域之外的点视为异常点。所以,只要找到 $C(x)$ 的边界曲线 $f(x)$, 就可以对任意特征向量 x 进行判别:

$$f(x) \geq 0, x \in C(x); f(x) < 0, x \notin C(x)$$

即将落在 $C(x)$ 之内的样本判决为正常状态; 否则判决为异常状态。

下面给出本文采用的超球面一类支持向量机原理。对于满足一般分布的样本集合 $\{x_i, i=1, 2, \dots, N\}$, 假设存在映射 $\Phi: R^m \rightarrow R^d$, 将 $\{x_i\}$ 影射为 R^d 上的球状分布 $\{\Phi(x_i)\}$, 即 $C(x)$ 为 R^d 上的超球体的情况。假定其半径为 R , 球心为 a , 则判别函数为:

$$f(x) = R^2 - \|\Phi(x) - a\|^2 \quad (9)$$

$C(x)$ 的覆盖误差定义为: 若样本 x_i 的像 $\Phi(x_i)$ 落在 $C(x)$ 之内, 则误差为0; 落在 $C(x)$ 之外, 则误差为 $\Phi(x_i)$ 与球面之间距离, 即:

$$\xi_i = \begin{cases} 0 & \Phi(x_i) \in C(x) \\ R - \|\Phi(x_i) - a\| & \Phi(x_i) \notin C(x) \end{cases}$$

显然, 误报和漏报概率尽可能小意味着 $C(x)$ 应该覆盖样本尽可能多而体积尽可能小, 将该条件表述为一个约束优化问题可得:

$$\begin{cases} \min R^2 + c \sum_{i=1}^N \xi_i \\ \text{s.t. } \|\Phi(x_i) - a\|^2 \leq R^2 + \xi_i \\ \xi_i \geq 0, i=1, 2, \dots, N \end{cases} \quad (10)$$

式中, $\sum \xi_i$ 为学习误差; 常数 c 用于权衡判决区域体积与学习误差之间关系。

通过式(10)可以得到约束优化问题的拉格朗日函数, 引入Lagrange乘子 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$, 对 R, α, ξ 求导得到KKT(Karush-Kuhn-Tucker)条件, 代入式(9), 并将像空间的内积运算用满足Mercer条件的核函数代替, 即 $k(x, y) = \langle \Phi(x), \Phi(y) \rangle$, 称为核函数(kernel function), 得到优化问题的对偶形式:

$$\begin{cases} \max \sum_{i=1}^N \alpha_i k(x_i, x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k(x_i, x_j) \\ \text{s.t. } \sum_{i=1}^N \alpha_i = 1, 0 \leq \alpha_i \leq c, i=1, 2, \dots, N \end{cases} \quad (11)$$

若 $\Phi(x_p) \in \{\Phi(x_i)\}$ 所对应的Lagrange乘子满足 $0 < \alpha_p \leq c$, 则所有这样的样本 $\Phi(x_p)$ 形成了 $C(x)$ 的支撑, 因此称为 $C(x)$ 的“支持向量(support vectors)集”, 记作 $\{\Phi(x_p)\}$, 其中, $0 < \alpha_p < c$ 所对应的支持向量称为非边界支持向量, 而 $\alpha_p = c$ 称为边界支持向量。可以证明, $C(x)$ 的球心 a 和半径 R 分别为:

$$\begin{cases} a = \sum_{i=1}^N \alpha_i \Phi(x_i) \\ R = \|\Phi(x_p) - a\| \end{cases} \quad (12)$$

将式(12)代入式(9)可得判决函数为:

$$f(x) = 2 \sum_{i=1}^N \alpha_i [k(x, x_i) - k(x_p, x_i)] - [k(x, x) - k(x_p, x_p)] \quad (13)$$

式中, $\{\Phi(x_p)\}$ 是 R^d 上的支持向量, 由此得到的 $C(x)$ 是 R^d 上的超球体, 而它在 R^m 上的原像的形状取决于核函数 $k(x, y)$ 的性质。

不同核函数可以得到不同性质的判决函数, 常用的核函数有径向基函数、多项式函数和Sigmoid函数等。

2 实际数据验证

2.1 江阴大桥在线监测数据


江阴大桥是一座钢箱梁悬索桥, 其在线监测系统包含38个加速度、80个光栅光纤应变、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^[12]。本文以主梁钢板上的加速度传感器信号为例, 说明桥梁监测系统故障或者外部荷载引起的数据异常诊断问题, 选用主梁钢板上的加速度传感器AD5WV, 对它进行一类识别。该桥结构及传感器分布如图1所示。每个加速度传感器通道以50 Hz 采样率采集数据。主梁加速度反映了桥梁在

表2 PCA、KPCA数据处理结果


特征值序号	PCA			KPCA(多项式核函数)		
	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/(%)
1	10.218	68.685 3	68.685 3	1 652 374	56.744 8	56.744 8
2	4.0453	27.190 9	95.876 2	833 998	28.648 6	85.385 4
3	0.3039	2.042 6	97.918 8	222 300.9	7.634 1	93.019 6
4	0.2708	1.820 4	99.739 2	80 202.81	2.754 2	95.773 8
5	0.0312	0.209 8	99.949 0	37 941.94	1.303 0	97.076 8
6	0.0070	0.047 0	99.996 0	19 361.45	0.664 8	97.741 7

2.5 基于超球面一类支持向量机的异常识别结果

通过对前面江阴大桥实测数据的预处理、特征选择和核主成分分析压缩后得到4维特征库,下面利用超球面一类支持向量机来对主梁加速度信号进行异常识别。



a. PCA处理后的模式特征空间分布



b. KPCA处理后的模式特征空间分布

图3 在两种特征提取方法下的模式特征空间分布 按照通常的做法,随机选择80%的正常样本作

为训练样本,剩余20%的正常样本和异常样本作为测试样本,采用5折交叉校验。

实验采用以错误率为中心指标。表3是异常分类的测试样本集合的可能结果汇总表,其中,TP、FN、FP、FN代表各自占测试样本数的比例。定义异常分类结果的平均错误率 $g_{mean} = (FP + FN) / 2$,则平均识别率为 $\varepsilon = 1 - g_{mean}$ 。

实验中,核函数为常用高斯核 $k(x, y) = e^{-\|x-y\|^2 / 2\sigma^2}$,核宽 σ 和参数 c 均通过网格搜索得到。根据式(11)的约束条件不难获知, $1/N \leq c \leq 1$ 。核宽分别选择 $\sigma = \beta_0 / 3, \beta_0 / 2, \beta_0, 2\beta_0, 3\beta_0$ [14], 其中, β_0 为目标数据各样本点间的平均距离。

表3 异常分类的可能结果汇总表

真实类别	分类为正常类	分类为异常类
正常类	True Positive(TP)	False Negative(FN)
异常类	False Positive(FP)	True Negative(TN)

表4给出了不同参数对下的异常分类结果的错误率。从表中可见,当 $\sigma = 2\beta_0, c = 0.3$ 时,误报率FN达到最小为0.031 6;当 $\sigma = \beta_0, c = 0.1$ 时,漏报率FP达到最小为0.063 2;当 $\sigma = 3\beta_0, c = 0.1$ 时,错误率 g_{mean} 达到最小为0.061 1。将 $\sigma = 3\beta_0, c = 0.1$ 作为最终的选择参数,这时,超球面一类支持向量机可以更好地识别异常。

表4 不同参数对(c,σ)对应的异常分类错误率FN/FP/g_{mean}

c	FN/FP/g _{mean}				
	$\sigma = \beta_0 / 3$	$\sigma = \beta_0 / 2$	$\sigma = \beta_0$	$\sigma = 2\beta_0$	$\sigma = 3\beta_0$
0.1	0.147 4/0.063 2/0.089 5	0.136 8/0.084 2/0.083 2	0.084 2/0.063 2/0.067 4	0.073 7/0.063 2/0.065 3	0.073 7/0.063 2/0.061 1
0.3	0.147 4/0.063 2/0.089 5	0.136 8/0.094 7/0.081 1	0.042 1/0.105 3/0.065 3	0.031 6/0.105 3/0.062 1	0.042 1/0.094 7/0.068 4
0.5	0.147 4/0.063 2/0.089 5	0.136 8/0.094 7/0.081 1	0.042 1/0.105 3/0.065 3	0.031 6/0.105 3/0.063 2	0.042 1/0.094 7/0.070 5
0.8	0.147 4/0.063 2/0.089 5	0.136 8/0.094 7/0.081 1	0.042 1/0.105 3/0.065 3	0.031 6/0.105 3/0.063 2	0.042 1/0.094 7/0.070 5
1.0	0.147 4/0.063 2/0.089 5	0.136 8/0.094 7/0.081 1	0.042 1/0.105 3/0.065 3	0.031 6/0.105 3/0.063 2	0.042 1/0.094 7/0.070 5

下面,给出核主成分分析对异常识别的影响。表5分别给出不使用KPCA降维以及利用KPCA降维为2、4、6共4种情况下按照交叉校验方法获得的异常识别率。不难看出,KPCA降维的识别率并不是总

比不降维效果好,当降维后的主元贡献率为4时,有较好的可分性,可以达到好的识别效果。

最后,用上述同样的方法可以得到超平面一类支持向量机的参数和平均准确率,与超球面一类支

持向量机对比结果如表6。从表中可见,超球面一类支持向量机的平均准确率略优于超平面一类支持向量机,可以更好地识别异常,防止误报漏报的发生。

表5 核主成分分析对异常识别的影响

维数	主元贡献率/(%)	超球面一类支持向量机		ε (%)
		核函数	核参数	
0	0	高斯核	$\sigma = 3.6692, c = 0.1$	93.79
2	85.39	高斯核	$\sigma = 12.5811, c = 0.1$	93.37
4	95.77	高斯核	$\sigma = 53.8134, c = 0.3$	93.89
6	97.74	高斯核	$\sigma = 37.2052, c = 0.1$	93.68

表6 两种方法的分类性能

方法	核函数	参数	ε (%)
超球面一类支持向量机	高斯核	$\sigma = 53.8134$ $c = 0.3$	93.89
超平面一类支持向量机	高斯核	$\sigma = 53.8134$ $\nu = 0.1$	93.16

5 结论

本文所采用的基于核主成分分析和超球面一类支持向量机的桥梁数据异常诊断方法,可以有效地提取桥梁数据的关键特征,识别由监测系统自身故障或者自然灾害以及外部荷载引起的一些特殊事件导致的数据异常,对于桥梁监测维护和结构安全是很有意义的。

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 Wan-cheng, CUI Fei, ZHANG Qi-wei. Current research and development of structural health monitoring[J]. Journal of Tongji University, 1999, 27(2): 184-188.
- [2] FRITZEN C P, JENNEWEIN D, KIEFER T. Damage detection based on model updating methods[J]. Mechanical Systems and Signal Process, 1998, 12(1): 163-186.
- [3] 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 Zhao-hui, FAN Ke-qing, LI Ting. Bridge condition monitoring using system identification[J]. Central South Highway Engineering, 2006, 31(3): 159-163.
- [4] ZHANG Q W. Statistical damage identification for bridge using ambient vibration data[J]. Computers & Structures, 2007, 85: 476-485.
- [5] 刘春城, 刘佼. 基于支持向量机的大跨度拱桥损伤识别方法研究[J]. 振动与冲击, 2010, 29(7): 174-178.

- LIU Chun-cheng, LIU Jiao. Damage identification of a long-span arch bridge based on support vector machine[J]. Journal of Vibration and Shock, 2010, 29(7): 174-178.
- [6] 唐和生, 薛松涛, 陈镨, 等. 序贯最小二乘支持向量机的结构系统识别[J]. 振动工程学报, 2006, 19(3): 382-387.
TANG He-sheng, XUE Song-tao, CHEN Rong, et al. Sequential LS-SVM for structural systems identification[J]. Journal of Vibration Engineering, 2006, 19(3): 382-387.
- [7] 何浩祥, 闫维明, 彭凌云. 基于支持向量机的钢筋混凝土桥梁损伤识别[J]. 公路交通科技, 2008, 25(3): 65-69.
HE Hao-xiang, YAN Wei-ming, PENG Ling-yun. Damage identification of reinforced concrete bridge based on support vector machine[J]. Journal of Highway and Transportation Research and Development, 2008, 25(3): 65-69.
- [8] 刘龙, 黄海, 孟光. 基于支持向量机的结构损伤分步识别研究[J]. 应用力学学报, 2007, 24(2): 313-317.
LIU Long, HUANG Hai, MENG Guang. Multi-step structure damage identification approach based on support vector machine[J]. Chinese Journal of Applied Mechanics, 2007, 24(2): 313-317.
- [9] SCHOLKOPF B, SMOLA A, MULLER K R. Kernel principal component analysis[D]. Cambridge, MA: MIT Press, 1999: 293-306.
- [10] SCHOLKOPF B, PLATT J C, SHAWE-TAYLOR J. Estimating the support of a high-dimensional distribution [J]. Neural Computation, 2001, 13(7): 1443-1471.
- [11] TAX D, DUIN R P. Support vector domain description[J]. Pattern Recognition Letters, 1999, 20 (11-13): 1191-1199.
- [12] ZHOU Hua-fei, NI Yi-qing, KO J M. Analysis of structural health monitoring data from the suspension jiangyin bridge[C]//Proceeding of the 3rd European Workshop on Structural Health Monitoring. Florida: DEStech Publication, 2006: 364-371.
- [13] 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(3): 918-928.
- [14] 冯爱民, 刘学军, 孙廷凯. 嵌入数据结构信息的单类支持向量机及其线性规划算法[J]. 中山大学学报, 2009, 48(6): 10-17.
FENG Ai-min, LIU Xue-jun, SUN Ting-kai. Embedding target data's structural distribution information into one-class SVM and its linear programming algorithm[J]. Acta Scientiarum Naturalium Universitatis Sunyatseni, 2009, 48(6): 10-17.

编辑 张俊