

基于异常识别和关联分析的桥梁数据复合诊断*

梁 栋¹, 张宇峰², 袁慎芳¹, 吴 键¹

(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. 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 提出了一种基于异常识别和多传感器关联分析的桥梁数据复合诊断方法。该方法利用超球面一类支持向量机对传感器数据特征进行异常识别,通过 ϵ -支持向量回归机对多传感器测量值进行位置关联分析,从而判定该传感器数据异常是由外部荷载还是传感器自身故障引起。通过江阴大桥主梁加速度传感器的相关测量数据,表明了该方法的有效性。

关键词 桥梁结构健康监测; 异常识别; 超球面一类支持向量机; 关联分析; ϵ -支持向量回归机

中图分类号 U446; TH123

引言

随着桥梁建设的快速发展,大量结构复杂的大跨度桥梁相继投入使用,桥梁状态监测与健康评价技术成为当前一大研究热点^[1]。在实际环境中,桥梁结构经常受到某些外部荷载,比如地震、船撞、大风、雨雪等的作用,这些特殊事件往往会影响结构,甚至可能对桥梁结构产生严重破坏。所以,通过桥梁传感器数据监测这些事件引起的异常,对于桥梁结构的安全和大桥管理部门的正常维护具有重大意义。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故障异常,从而严重影响了监测数据的准确性,直接影响桥梁的安全监测。笔者研究了桥梁外部特殊事件和传感器故障引起的异常识别问题。

桥梁结构特殊事件和传感器故障的数据异常诊断大都针对桥梁损伤异常诊断进行研究^[2-4],主要涉及基于特征的模式分类方法和基于模型的方法。在实际桥梁监测系统中,外部荷载异常或传感器故障样本很难获得,对桥梁系统进行建模精度有限,所以缺乏具体桥梁异常和传感器故障的先验知识是有效数据异常诊断的最大困难。尽管如此,桥梁健康监测系统可以获得整个桥梁的大量数据,为建立桥梁正常状态的模型提供了充分依据。桥梁结构异常和传感器故障是小概率事件,所以可以利用一类模式识别方法拟合正常样本的空间分布,从而识别数据异

常。同时,为了排除传感器故障引起的异常,需要进一步区分外部荷载和传感器故障异常,而多传感器关联分析是一种有效识别传感器故障的方法。

针对桥梁数据异常诊断问题,笔者提出了一种基于异常识别和多传感器关联分析的桥梁数据复合诊断方法。首先,利用超球面一类支持向量机对数据特征进行异常模式识别;然后,通过 ϵ -支持向量回归机对多传感器进行位置关联分析,从而判定该传感器数据异常是由结构还是传感器自身故障所引起。

1 基于异常识别和多传感器关联分析的桥梁数据复合诊断方法原理

数据复合诊断方法是桥梁结构状态监测与故障诊断中的关键环节,通过分析各种传感器及仪器输出数据,结合数据挖掘、神经网络等理论与技术,识别数据异常,并利用多传感器数据关联分析和融合技术,探索数据失真的原因及其规律,从而实现对桥梁结构安全的监测。其原理如图 1 所示。

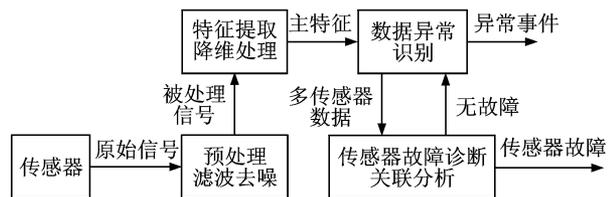


图 1 桥梁数据复合诊断方法原理框图

* 国家自然科学基金资助项目(编号:50830201);江苏省自然科学基金资助项目(编号:BK2008510);江苏省普通高校研究生科研创新计划资助项目(编号:CX10B_097Z)

收稿日期:2010-10-07;修改稿收到日期:2011-04-04

1.1 基于超球面一类支持向量机的异常识别原理

一类支持向量机(one-class support vector machine)是一种无监督学习方法,它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氏距离来寻找最优超平面,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^[5]。Tax在此基础上提出了利用超球体作为分界面的方法,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^[6]。他们的思想都是通过获得大部分正常数据,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

$$f(x) \leq 0, x \in C(x); \quad f(x) > 0, x \notin C(x)$$

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。

下面给出笔者采用的超球面一类支持向量机的原理。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 $\{x_i\}$ 映射为 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 ,球心位于 a ,则判别函数为

$$f(x) = \|\Phi(x) - a\|^2 - R^2 \quad (1)$$

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

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

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,将这条件表述为一个约束优化问题,得到

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

其中: $\sum \xi_i$ 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的关系。

通过式(2)可以得到约束优化问题的拉格郎日函数,引入Lagrange乘子 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$,对 R, a, ξ 求导得到KKT条件(karush-kuhn-tucker条件),代入式(1),并将象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

$$\begin{cases} \min - \sum_{i=1}^N \alpha_i k(x_i, x_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k(x_i, x_j) \\ \text{s. t. } \sum_{i=1}^N \alpha_i = 1 \\ (0 \leq \alpha_i \leq c, i = 1, 2, \dots, N) \end{cases} \quad (3)$$

若 $\Phi(x_p) \in \{\Phi(x_i)\}$ 所对应的Lagrange乘子满足 $0 < \alpha_p \leq c$,则 $\Phi(x_p)$ 恰好位于球面上,所有这样的样本形成了 $C(x)$ 的支撑,因此称为 $C(x)$ 的“支持向量集”,记作 $\Phi(x_p)$ 。

可以证明, $C(x)$ 的球心 a 和 R 半径分别为

$$a = \sum_{i=1}^N \alpha_i \Phi(x_i), \quad R = \|\Phi(x_p) - a\| \quad (4)$$

将式(4)带入式(1)可得判决函数为

$$f(x) = [k(x, x) - k(x_p, x_p)] - 2 \sum_{i=1}^N \alpha_i [k(x, x_i) - k(x_p, x_i)] \quad (5)$$

$\Phi(x_p)$ 为 R^d 上的支持向量,由此得到的 $C(x)$ 为 R^d 上的超球体,而它在 R^m 上的原象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。

1.2 基于 ϵ -支持向量回归机的多传感器关联分析原理

桥梁是一个复杂的结构系统,当受到外部激励时,结构各个测点之间的测量参数在时间和空间上都存在一定的相关性。一般来说,测试点之间的关联性主要是从物理位置来考虑,如将桥梁结构同一截面上测试点的传感器认为是关联的^[7]。如果某一个传感器有故障,那么它的测量参数和周围的正常传感器的测量参数相关性变低,从而可以识别出传感器故障。

笔者采用回归方法拟合空间位置相近的传感器投影到某一平面上的坐标位置所对应的测点参数曲面,通过传感器实测值与对应曲面上的拟合值的误差判别传感器之间的关联性,从而识别传感器故障。所使用的支持向量回归机是一种非参数方法,对拟合模型的形式没有限制,同时对样本点的位置也没有严格要求,因此对于复杂过程拟合具有明显的优势。同时,根据结构风险最小化原则可以使模型在拟合性能与模型复杂程度之间取得折衷,从而保证了学习性能和泛化能力。下面给出笔者选取的 ϵ -支持向量回归机的简单原理^[8-9]。

假定一个样本集合 $\{(x_1, z_1), \dots, (x_L, z_L)\}$,其中 $x_i \in R^n$ 是输入, $z_i \in R$ 为目标输出。假设所有训练数据在精度 ϵ 下,允许拟合误差 ξ, ξ^* 下用非线性回

归函数 $f(x) = w^T \Phi(x) + b$ 拟合, 根据结构风险最小化理论^[10], 可等价于优化问题

$$\begin{cases} \min_{w, b, \xi, \xi^*} \frac{1}{2} w^T w + c \sum_{i=1}^L (\xi_i + \xi_i^*) \\ \text{s. t. } w^T \Phi(x_i) + b - z_i \leq \epsilon + \xi_i \\ z_i - w^T \Phi(x_i) - b \leq \epsilon + \xi_i^* \\ (\xi_i, \xi_i^* \geq 0, i = 1, \dots, L) \end{cases} \quad (6)$$

类似于超球面一类支持向量机, 由约束优化问题的拉格朗日函数得到 KKT 条件, 获得其对偶形式

$$\begin{cases} \min_{\alpha, \alpha^*} \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L (\alpha_i + \alpha_i^*)(\alpha_j - \alpha_j^*) k(x_i, x_j) + \\ \epsilon \sum_{i=1}^L (\alpha_i + \alpha_i^*) + \sum_{i=1}^L z_i (\alpha_i - \alpha_i^*) \\ \text{s. t. } \sum_{i=1}^L (\alpha_i - \alpha_i^*) = 0 \\ (0 \leq \alpha_i, \alpha_i^* \leq c, i = 1, \dots, L) \end{cases} \quad (7)$$

求解优化问题, 获得 α_i, α_i^* , 其中不为 0 的对应样本就是支持向量, 所以回归函数为

$$f(x) = \sum_{i=1}^L (-\alpha_i + \alpha_i^*) k(x_i, x) + b \quad (8)$$

其中核函数的选择方式与超球面一类支持向量机相同。

2 实际数据验证

2.1 江阴大桥在线监测系统

江阴大桥是一座钢箱梁悬索桥, 其在线监测系统包含 38 个加速度传感器、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^[11]。笔者以主梁钢板上的传感器信号监测外部荷载引起的结构异常和传感器自身异常为例, 说明桥梁数据异常复合诊断问题。选用主梁钢板上的加速度传感器 AD5WV, 通过对它进行一类识别和与其他 14 个传感器进行关联分析来区分特殊事件和传感器故障引起的数据异常。该桥结构及传感器分布如图 2 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动态荷载作用下的结构竖向振动响应, 荷载来自车辆或者台风、船撞等。图 3 是桥梁加速度信号波形及其功率谱, 从加速度的功率谱可以看出, 桥梁的竖向振动主频集中在 5 Hz 以下。

2.2 预处理

笔者采用的加速度数据来自江阴大桥 19 h 的监测数据。首先, 利用 MATLAB 软件对数据进行小波阈值去噪处理; 然后, 对数据进行分段、加窗处理。通过加速度的时域波形可知, 该信号具有周期性和平稳性。根据动力试验, 该桥自振特性属于低频振动, 从功率谱分析可知主梁振动主频应为 0.21 Hz, 对应周期的 3 倍大约为 15 s, 所以每小时信号可以分成 240 段进行处理, 每段 750 点作为一个数据样本, 共选用 1 680 个样本。

2.3 特征向量的获取

笔者选择振动信号分析时常用的域、频域和 AR 模型系数特征^[12], 时域包括均值、方差、偏斜、峰度、直方图上下界、有效值、波形因数和振幅因数; 频

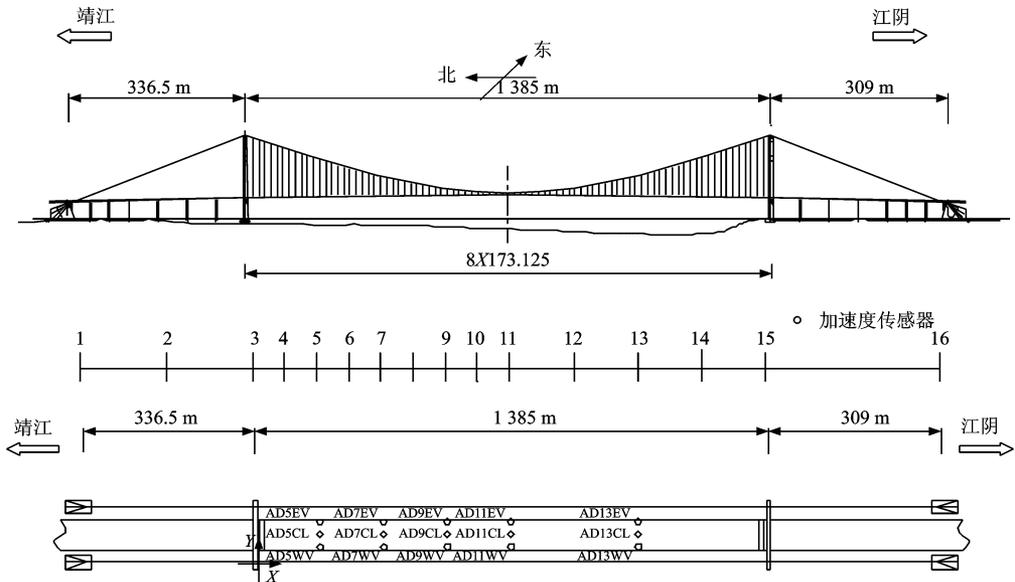


图 2 江阴大桥主梁加速度传感器分布示意图

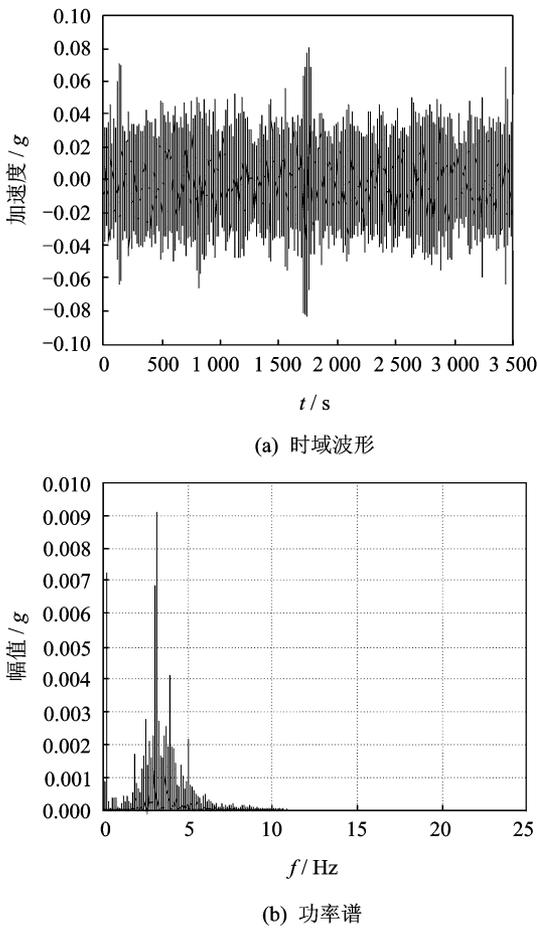


图 3 加速度信号

域包括频率中心、均方根频率和根方差频率;自回归模型包括 5 阶系数。总共得到 17 个特征,于是可得到 17 维的特征向量,所以将江阴大桥该加速度的状态映射到一个 17 维特征空间上。

由于存在随机因素,从大量数据样本得到的特征向量集在特征空间上形成一定形式的分布。一类学习的目的,就是要找到这个分布。

2.4 基于主成分分析的特征提取

通过前面对样本的特征选择与计算,可以得到 17 维的特征向量,如果直接对这些数据进行识别处理会碰到很多困难,比如计算量大、特征间相关性高、特征的可分性不好以及不宜设计出性能优良的分分类器等问题,因此分类前有必要进行特征提取,获取关键特征。

这里应用主成分分析对样本集数据进行处理。主成分分析是一种典型的统计学分析方法,其目的是在 n 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,可以得到数据的一个低维空间表示,它保留了

原始数据的绝大部分信息^[13-15]。应用主成分分析方法对 17 维特征空间进行特征提取,第一主成分的贡献率为 66.95%,前 4 个主成分的累积贡献率为 99.22%,贡献率比较集中。如果将累积贡献率阈值 e 取为 98%,则可以将输入空间数据的维数降为 4 维,不失太多原始信息。

2.5 基于超球面一类支持向量机的异常识别

笔者使用 MTLAB 软件,将主成分分析和超球面一类支持向量机结合起来对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、特征选择和主成分分析压缩后得到 4 维特征库,共 1 680 个样本,其中有 1 538 个正常样本和 142 个异常样本,异常样本包括传感器短路故障、船撞事件、台风和车载共振异常。下面利用超球面一类支持向量机进行异常识别。

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。

试验中采用错误率为中心的指标,即正常类错分为异常类的个数占测试样本的比例为 FN,异常类错分为正常类的个数占测试样本的比例为 FP,定义异常分类结果的平均错误率 $g_{\text{mean}} = (FP + FN) / 2$,则平均准确率为 $\epsilon_{\text{mean}} = 1 - g_{\text{mean}}$ 。

试验中,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(6)的约束条件可知, $1/N \leq c \leq 1$ 。核宽分别选择 $\sigma = \beta_0/3, \beta_0/2, \beta_0, 2\beta_0, 3\beta_0$ ^[16]。表 1 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, σ 越大, c 对错误率的影响越大。同时, σ 过大或过小都会提高错误率。当 $\sigma = \beta_0, c = 0.3$ 时,错误率达到最小,为 0.013 7,将它作为最终的选择参数。

表 1 不同参数对 (c, σ) 对应的异常分类错误率

g_{mean}	$\sigma = \beta_0/3$	$\sigma = \beta_0/2$	$\sigma = \beta_0$	$\sigma = 2\beta_0$	$\sigma = 3\beta_0$
$c = 0.1$	0.042 1	0.028 4	0.017 9	0.028 4	0.032 6
$c = 0.3$	0.042 1	0.027 4	0.013 7	0.024 2	0.021 1
$c = 0.5$	0.042 1	0.027 4	0.013 7	0.024 2	0.020 0
$c = 0.8$	0.042 1	0.027 4	0.013 7	0.024 2	0.020 0
$c = 1.0$	0.042 1	0.027 4	0.013 7	0.024 2	0.020 0

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见表 2。从表中可见,超球面一类支持向量机的平均准确率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2 两种方法的分类性能

方法	核函数	参数	$\epsilon_{\text{mean}}/\%$
超球面一类支持向量机	高斯核	$\sigma=1.0675, c=0.3$	98.63
超平面一类支持向量机	高斯核	$\sigma=1.0675, \nu=0.1$	96.32

最后,给出主成分分析对异常识别的影响。在表3中,分别给出利用主成分分析降维为2,4以及不使用主成分分析降维3种情况下按照交叉校验方法获得的异常识别率,不难看出,降维的识别率并非总比不降维效果好,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。

表3 主成分分析对异常识别的影响

主成分分析		超球面一类支持向量机		
维数	主元贡献率/%	核类型	核参数	$\epsilon_{\text{mean}}/\%$
2	93.80	高斯核	$\sigma=2.6662, c=0.5$	93.26
4	99.22	高斯核	$\sigma=1.0675, c=0.3$	98.63
17	100	高斯核	$\sigma=3.6692, c=0.1$	93.79

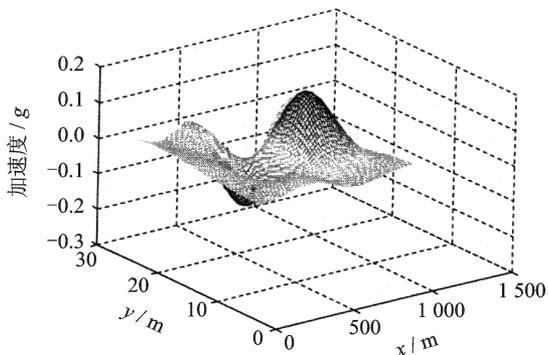
2.6 基于 ϵ -支持向量回归机的多传感器关联分析

为了分析传感器AD5WV和其周围14个传感器位置关联度,在主梁上建立坐标系,如图2所示。对传感器AD5WV每15s的数据进行分析,当超球面一类支持向量机发现异常时,利用周围14个传感器的对应15s的加速度数据平均值关于坐标位置进行曲面拟合,预测主梁平面在区间 $x[138.5\text{ m}, 1108\text{ m}]$, $y[6.76\text{ m}, 27.04\text{ m}]$ 内的各个位置对应的加速度分布曲面。其中,选择径向基核作为核函数,核宽 $\sigma=0.1291$,正则化常数 $c=0.5$,误差 $\epsilon=0.001$ 。

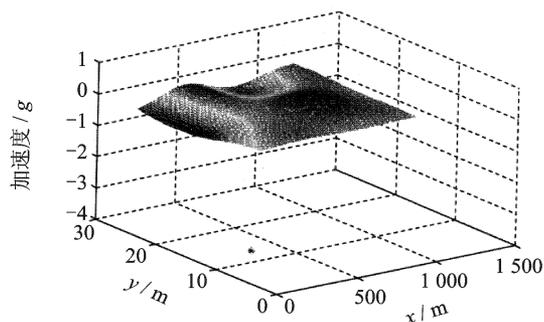
根据AD5WV位置(181.6 m, 9.099 m)处的拟合值和AD5WV实测15s的均值的差的绝对值 δ ,判定传感器是否出现故障。统计1200个样本数据可知,当 $\delta \geq 0.055$ 时,该传感器出现故障;否则,认为传感器没有故障,这时如果出现数据异常,则认为是结构引起的异常。试验结果见图4,其中“*”对应传感器AD5WV的实测值。从图中不难看出,在正常情况下,传感器实测值与拟合值误差 δ 为0.0166,小于0.055;当传感器出现短路故障时, δ 为3.4174,超过阈值0.055;对于船撞引起的结构异常,因为各个传感器的信号都有变化,在传感器不出现故障的情况下,依然保持好的关联性, δ 为0.0164,而台风和车载共振异常的 δ 分别为0.0288,0.0362。

纵上所述,基于 ϵ -支持向量回归机的多传感器

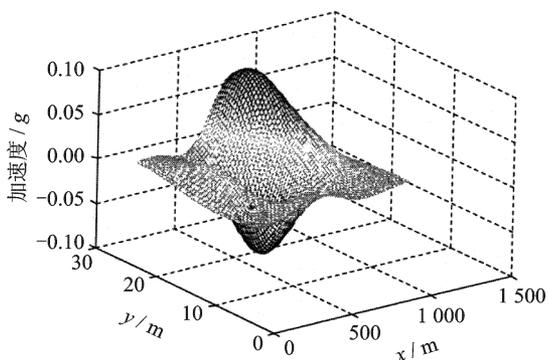
关联分析可以有效识别单个传感器故障,从传感器获得可信数据,准确识别一些外部荷载的异常。对于多个传感器同时故障的情况,如果故障传感器的数量远少于总的传感器数目,利用该方法可以实现多传感器故障的识别。



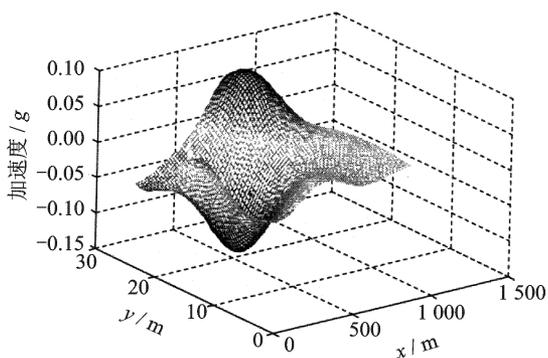
(a) 正常情况下的加速度分布曲面



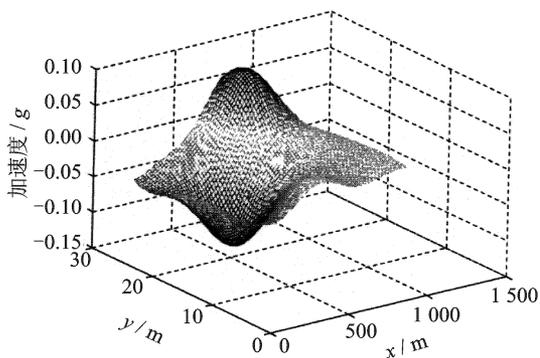
(b) 传感器短路故障情况下的加速度分布曲面



(c) 船撞正常情况下的加速度分布曲面



(d) 台风情况下的加速度分布曲面



(e) 车载共振情况下的加速度分布曲面

图4 5种情况下的加速度分布曲面

3 结束语

提出了一种基于异常识别和多传感器关联分析的桥梁数据复合诊断方法,通过江阴大桥主梁加速度传感器的相关测量数据表明,该方法可以较好地识别桥梁结构响应中的一些特殊异常事件,排除传感器故障干扰,对桥梁的维护管理具有一定意义。

参 考 文 献

- [1] Gibson J D. Inspection and maintenance of Hong Kong's Long Span Bridges[C]//Current and Future Trends in Bridge Design, Construction and Maintenance. London: Thomas Telford, 2001:349-358.
- [2] Doebling S W, Farrar C R, Prime M B. A summary review of vibration based damage identification methods[J]. The Shock and Vibration Digest, 1998, 30(2):91-105.
- [3] Yeung W T, Smith J W. Damage detection in bridges using neural networks for pattern recognition of vibration signatures[J]. Engineering Structures, 2005, 27(5):685-698.
- [4] Zhang Qiwei. Statistical damage identification for bridges using ambient vibration data[J]. Computers & Structures, 2007, 85(7-8):476-485.
- [5] Scholkopf B, Platt J C, Shawe-Taylor J. Estimating the support of a high-dimensional distribution[J]. Neural Computation, 2001, 13(7):1443-1471.
- [6] Tax D, Duin R P. Support vector domain description[J]. Pattern Recognition Letters, 1999, 20(11-13):1191-1199.
- [7] Agrawal R, Imielinski T, Swami A. Mining association rules between sets of items in large databases[C]//Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data. New York: ACM Press, 1993:207-216.
- [8] Smola A J, Scholkopf B. A tutorial on support vector

regression[J]. Statistics and Computing, 2004, 14: 199-222.

- [9] Scholkopf B, Smola A J. Learning with kernels-support vector machines, regularization, optimization, and beyond[M]. [S.l]: The MIT Press, 2002:251-274.
- [10] Vapnik V, Chervonenkis A. The necessary and sufficient conditions for consistency in the empirical risk minimization method[J]. Pattern Recognition and Image Analysis, 1991, 1(3):283-305.
- [11] Zhou Huafei, Ni Yiqing, 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.
- [12] Niu G, Lee S S, Yang B S, et al. Decision fusion system for fault diagnosis of elevator traction machine[J]. Journal of Mechanical Science and Technology, 2008, 22:85-95.
- [13] Servie C, Fabry P. Principal component analysis and blind source separation of modulated sources for electro-mechanical systems diagnostic[J]. Mechanical Systems and Signal Processing, 2005, 19(6):1293-1311.
- [14] 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)
- [15] 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)
- [16] 冯爱民,陈松灿.基于核的单分类器研究[J].南京师范大学学报, 2008, 8(4):1-6.
Feng Aimin, Chen Songcan. Study on one-class classifiers based on kernel method[J]. Journal of Nanjing Normal University, 2008, 8(4):1-6. (in Chinese)



第一作者简介:梁栋,男,1982年12月生,博士研究生。主要研究方向为测试计量技术及仪器。曾发表《基于黑板协作的多区域冲击监测》(《系统工程与电子技术》2011年第33卷第3期)等论文。

E-mail:ld19821213@126.com