

# 一种基于支持向量机的结构损伤识别方法

周绮凤<sup>1\*</sup>, 宁永鹏<sup>1</sup>, 周青青<sup>1</sup>, 杨帆<sup>1</sup>, 雷家艳<sup>2</sup>

(1. 厦门大学信息科学与技术学院; 2. 厦门大学建筑与土木工程学院, 福建 厦门 361005)

**摘要:** 提出了结合随机振动响应互相关函数、小波包分解和支持向量机(support vector machine, SVM)的结构损伤识别方法, 计算了相邻测点响应的互相关函数幅值. 采用小波包对得到的幅值进行分解, 得到各个频带上的总能量; 利用各频带上能量值存在的差异性作为输入到分类器的特征向量, 训练 SVM 模型并对结构的损伤进行识别. 应用该方法对 Benchmark 模型结构进行损伤判别, 实验通过对比其他基于 SVM 的方法, 结果表明该方法具有较好的识别精度.

**关键词:** 损伤识别; 互相关函数; 小波包分解; 支持向量机

中图分类号: TP 391; O 327

文献标志码: A

文章编号: 0438-0479(2013)01-0057-06

建筑物在长期使用过程中, 经历老化或是受到地震、台风等因素的影响, 结构会受到不同程度的损伤. 近年来, 基于振动测试的结构损伤识别的研究取得了飞快的发展<sup>[1-2]</sup>, 很多数据挖掘的方法被应用到该领域, 其中主要有神经网络、遗传算法和支持向量机(support vector machine, SVM)等机器学习算法<sup>[3-9]</sup>.

根据结构动力学理论可知, 结构损伤的存在必然会影响到结构本身的动态特性, 通过分析损伤对结构动力学参数(包括模态参数和结构参数)的改变就可以识别损伤. 利用结构随机振动的动力实测数据进行损伤检测是一种有效的方法, 而基于随机振动响应的互相关分析能有效避免测试噪声对响应信号的污染. 在损伤识别中, 提取敏感信号有利于提高识别的精度, 而传统的信号处理方法难以提取对损伤敏感的特征. 小波分析是一种全新的时频分析方法, 对非平稳信号具有宽频响应的特点, 在低频处有较高的频率分辨率, 在高频处有较高的时间分辨率, 适合分析非平稳信号<sup>[10]</sup>. 而小波包分解技术是从小波分析延伸出来的一种对信号进行更加细致的分析和重构的方法, 它将频带进行多层次划分, 对多分辨分析没有细分的高频部分进一步分解, 这些分解频带信号都具有一定的能量, 不同损伤的频带能量分布不同, 所以用能量的相对变换可以反映损伤类型. Vapnik 等<sup>[11]</sup>提出的 SVM 算法是一种基于统计学习理论的机器学习算法, 通过寻求

结构风险最小化来实现实际风险最小化, 从而在样本量较少的情况下亦能获得很好的学习效果. 由于 SVM 算法是一个二次优化问题, 所以所得到的解就是全局最优, 避免了人工神经网络等方法的网络结构难于确定、过学习、欠学习以及局部极小化等问题.

本文将随机振动响应互相关函数、小波包分解和 SVM 相结合, 应用到损伤识别, 并对 Benchmark 模型结构进行损伤诊断.

## 1 互相关函数幅值的定义<sup>[12]</sup>

互相关函数描述了随机振动过程中 2 个样本函数在不同瞬时幅值之间的依赖关系, 它可以反映 2 条随机振动信号波形随时间坐标移动时相互关联的紧密性. 结构在随机振动下(如地震、风作用、交通荷载及其他随机激励), 两相邻测点的响应可视为 2 个实平稳随机过程  $x_1$  和  $x_2$ , 它们之间的互相关函数为

$$\varphi_{x_1 x_2}(\tau) = E[x_1(t)x_2(t+\tau)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 p(x_1, x_2) dx_1 dx_2, \quad (1)$$

假定随机振动响应满足各态历经性, 互相关函数可用单个样本的时间历程来平均, 即

$$\varphi_{x_1 x_2}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x_1(t)x_2(t+\tau) dt, \quad (2)$$

试验中各测点响应是一系列不连续的时间序列, 相关函数不能用数学式表达, 则积分式可用有限求和式来代替, 将样本函数用时间间隔  $\Delta t$  分成一系列不连续的离散值, 设采样时间为  $T$ , 则样点数为  $N = \frac{T}{\Delta t} + 1$ , 互相关函数可以表示为

收稿日期: 2012-09-09

基金项目: 中央高校基本科研业务费(2010121065)

\* 通信作者: zhouqf@xmu.edu.cn

$$\varphi_{x_1 x_2}(k) = \frac{1}{N} \sum_{i=1}^{N-k} x_1(i)x_2(i+k), (k = 0, 1, \dots, N). \tag{3}$$

定义两相邻测点间的互相关函数幅值为

$$r_{i,i+1} = |\varphi_{x_i x_{i+1}}(\tau)| = |\varphi_{x_i x_{i+1}}(k)|. \tag{4}$$

### 2 小波包分解

小波包具有多维多分辨率分析的特点. 通过把频带进行多层次划分, 可对多分辨分析中没有细分的高频部分进一步分解, 并可根据被分析信号的特征, 自适应地选择相应频段, 使之与信号频谱相匹配, 从而提高时频分辨率. 记

$$\begin{cases} \mu_0(t) = \varphi(t), \\ \mu_1(t) = \psi(t), \end{cases} \tag{5}$$

其中,  $\varphi(t)$  为尺度函数,  $\psi(t)$  为小波函数. 小波包定义为由正交尺度函数确定的函数簇

$$\begin{cases} \mu_{2m}(t) = \sum_k h_k \mu_m(2t-k) \\ \mu_{2m+1}(t) = \sum_k g_k \mu_m(2t-k) \end{cases} \quad m \in \mathbf{Z}, \tag{6}$$

其中,  $h_k, g_k$  分别为低通滤波器与高通滤波器系数. 小波包分解和重构递增公式为

$$\begin{cases} d_k^{2m} = \frac{1}{2} \sum_L d_L^m h_{L-2k}, \\ d_k^{2m+1} = \frac{1}{2} \sum_L d_L^m g_{L-2k}, \end{cases} \tag{7}$$

$$d_k^m = \sum_L d_L^{2m} h_{k-2L} + \sum_L d_L^{2m+1} g_{k-2L}. \tag{8}$$

这样, 对信号的高、低频分量都实施了相同的分解, 对数字信号而言, 可以直接定义  $d_1 = \{d_k^1\}$  为待分解信号, 分解和重构方式达到了完全离散化.

对信号进行  $N$  层小波包分解时, 得到从低频到高频  $2^N$  个频带成分的特征信号  $D_{N_j}, j = 1, 2, 3, \dots, 2^N$ . 对小波包分解系数进行重构, 提取各频带范围的信号, 计算各频带信号的能量. 各频带信号的能量为

$$E_{N_j} = \int |D_{N_j}(t)|^2 dt = \sum_{k=1}^n |d_{jk}|^2, \tag{9}$$

式中  $d_{jk}$  为重构信号  $D_{N_j}$  的第  $k$  个离散点的幅值,  $n$  表示重构信号  $D_{N_j}$  的离散点的个数  $j = 0, 1, \dots, 2^N - 1, k = 1, 2, \dots, n$ .

### 3 SVM

考虑训练样本集  $s = \{ \langle x_i, y_i \rangle \}, i = 1, 2, \dots, n$ ,

其中  $x_i \in R^n$  为第  $i$  个样本的特征向量,  $y_i$  为  $x_i$  的类标. 对于二分类问题有  $y_i \in \{-1, 1\}$ , 而多分类问题中  $y_i \in \{1, 2, \dots, k\}$ , 其中  $k$  为类别数.

SVM 是从线性可分情况下的最优分类超平面发展而来的, 所谓最优分类超平面就是以最大间隔将两类正确分开的超平面. SVM 的线性决策规则为  $f(x) = \text{sgn}\{w \cdot x + b\}$ , 其中  $w$  为权值向量,  $b$  为偏置值. SVM 的主要思想就是找出最优分类超平面.

标准的 SVM 模型为

$$\begin{aligned} \min_{w,b,\xi} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i, \\ \text{s. t.} \quad & y_i (w^T \cdot x_i + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, i = 1, 2, \dots, l. \end{aligned} \tag{10}$$

其中  $\xi_i$  是松弛变量, 参数  $C > 0$  是一个常数, 它控制对错分样本惩罚的程度. 该模型的对偶形式为

$$\begin{aligned} \max \quad & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j), \\ \text{s. t.} \quad & \sum_{i=1}^l y_i \alpha_i = 0, \\ & 0 \leq \alpha_i \leq C, i = 1, 2, \dots, l. \end{aligned} \tag{11}$$

上述的 SVM 可以解决线性可分问题, 为了解决线性不可分问题, 将优化问题中目标函数的内积  $(x_i \cdot x_j)$  用核函数  $k(x_i, x_j)$  代替, 从而将低维特征空间中线性不可分问题映射到高维特征空间中转换成线性可分问题来解决.

SVM 本质上是二分类问题提出的, 如何将其扩展到多分类问题是一个研究的重点. 一对多方法 (one-versus-rest, 1-v-r) 和一对一方法 (one-versus-one, 1-v-1) 是 2 种基本的将二分类问题扩展到多分类问题的方法. 对于  $k$  分类问题这 2 种方法分别需要构造  $k$  和  $k(k-1)/2$  个子分类器. 由于类别较多, 本文选取一对多的方法. 该方法对  $k$  个类别的样本集构造  $k$  个 SVM 子分类器, 在构造第  $i$  个分类器  $f_i$  时, 将训练样本中属于第  $i$  类的样本标示为“+1”, 不属于第  $i$  类的其余  $k-1$  类样本全部标记为“-1”, 这样, 依据不同的样本划分进行训练, 就可以构造出  $k$  个不同的 SVM 子分类器. 例如, 第  $j$  类 SVM 解决如下问题:

$$\begin{aligned} \min_{w^j, b^j, \xi^j} \quad & \frac{1}{2} \|w^j\|^2 + C \left[ \sum_{i=1}^l \xi_i^j \right], \\ \text{s. t.} \quad & (w^j \cdot x_i) + b^j - 1 + \xi_i^j \geq 0, \quad y_i = j, \\ & (w^j \cdot x_i) + b^j - 1 + \xi_i^j < 0, \quad y_i \neq j, \\ & \xi_i^j \geq 0, i = 1, 2, \dots, l. \end{aligned} \tag{12}$$

用这种方法进行多分类时我们解其对偶问题, 最终得到  $k$  个决策函数  $f_j(x)$ , 对于未知类别属性的样

本  $x$  进行测试时,有的采用多数投票法,大部分还是采取 MaxWin 策略,即对测试样本分别计算  $k$  个子分类器的判别函数值,并选取最大的判别函数值所对应的类别作为测试数据的类别:

$$x_{\text{label}} \equiv \arg \max_{j=1,2,\dots,m} f_j(x), \quad (13)$$

其中  $\arg$  表示  $f_j(x)$  取最大值时的下标  $j$  的值。

## 4 结构的损伤诊断

### 4.1 Benchmark 模型<sup>[13]</sup>

Benchmark 模型(简图见图 1)由 Ventura 等在 UBC(University of British Columbia)建造,该模型为 1/3 缩尺的 4 层 2×2 跨钢框架结构,每层平面尺寸为 2.5 m×2.5 m,层高 0.9 m,每层各有 8 根斜撑,根据各层楼板处放置的钢板位置及质量,结构体系可分为对称和非对称两类。图 1 显示了数据输出时每层柱的编号和传感器的位置,例如传感器 1,5,9,13 安放在 2 号柱上。本文采用 Benchmark 模型第 II 阶段的研究,损伤情况如表 1 所示。

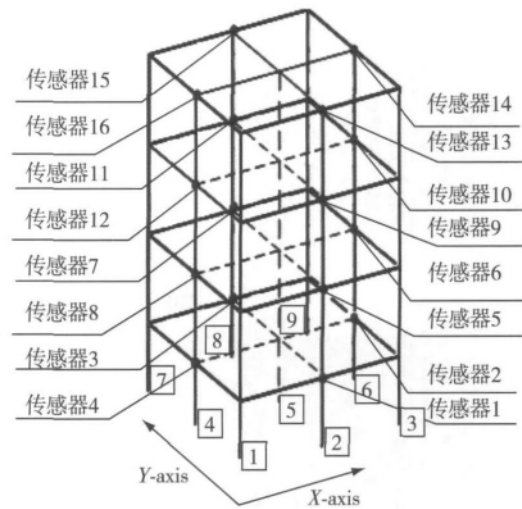


图 1 柱编号及传感器位置

Fig. 1 Number of column and location of sensor

表 1 各种损伤模式位置及程度

Tab.1 Types of damage model position and degree

损伤模式	具体情况
RB	完全斜撑框架、无损伤
DP1B	完全斜撑框架、第 1 层框架在 $x$ 方向上的两道斜撑各缺失一根斜撑杆,该层 $x$ 方向斜撑提供的侧向刚度损失 50%
DP2B	损伤位置与 DP1B 相同,但仅其中一道斜撑缺失一根斜撑杆,该层 $x$ 方向斜撑提供的侧向刚度损失 25%
DP3B	同 DP1B,另外第 3 层中 $x$ 方向上的其中一道斜撑缺失一根斜撑杆,该层 $x$ 方向斜撑提供的侧向刚度损失 25%
RU	完全无斜撑框架、无损伤
DP1U	$x$ 方向上的两榀框架中第 1 层的 3 个梁柱节点和第 2 层的 2 个梁柱节点发生转动刚度减小的损伤
DP2U	$x$ 方向上的两榀框架中第 1 层的 2 个梁柱节点发生转动刚度减小的损伤

### 4.2 损伤特征提取

损伤特征提取的步骤为:

1) 利用互相关函数计算同一柱上两相邻传感器所得到的加速度响应信号的幅值。例如传感器 1 和传感器 5 为同一柱上相邻的 2 个传感器,传感器 2 和传感器 6 为同一柱上相邻的 2 个传感器等等。由此方法

可将 16 个原始信号转换为 12 个新的互相关信号。依次编号 1(1,5),2(2,6),3(3,7),4(4,8),5(5,9),6(6,10),7(7,11),8(8,12),9(9,13),10(10,14),11(11,15),12(12,16),其中 1(1,5)指的是传感器 1 和传感器 5 进行互相关后得到的信号。

2) 利用正交小波作为小波基函数,将第一步得到的互相关信号进行 4 阶小波包分解,分别得到从低频到高频 16 个频率成分的信号特征。

3) 根据公式(9)计算各频带的能量,利用各频带的能量为元素构造一个特征向量  $S$ :

$$S = [E_{4,0}, E_{4,1}, \dots, E_{4,j}, \dots, E_{4,15}],$$

分别对每一个互相关信号数据得到的特征向量进行归一化处理,作为训练和测试分类器性能的损伤样本。

由传感器 1 和传感器 5 得到的互相关信号的 7 种损伤状况的小波包能量分布如图 2 所示。

从图 2 中可以看出在不同的损伤状况下,同一个互相关信号经过小波包分解后,各频带的能量大小和分布不同,而且差异较明显。由此说明互相关信号经过小波包分解得到的特征向量对损伤信号敏感,有利于分类器对损伤情况的识别。

### 4.3 损伤识别

每一个互相关信号的能量特征向量有 63 个样本,包含 7 种损伤情况,每种损伤有 9 个样本。实验时,对每一个互相关数据,每次随机选取每种损伤情况的 6 个样本作为训练 SVM 的数据,剩下的 3 个作为测试数据。在 SVM 中,核函数采用高斯径向基核函数, $C$  和  $\gamma$  通过 10 折交叉验证获得。对 12 个互相关信号全部做训练和测试,测试准确率取 10 次平均。图 3

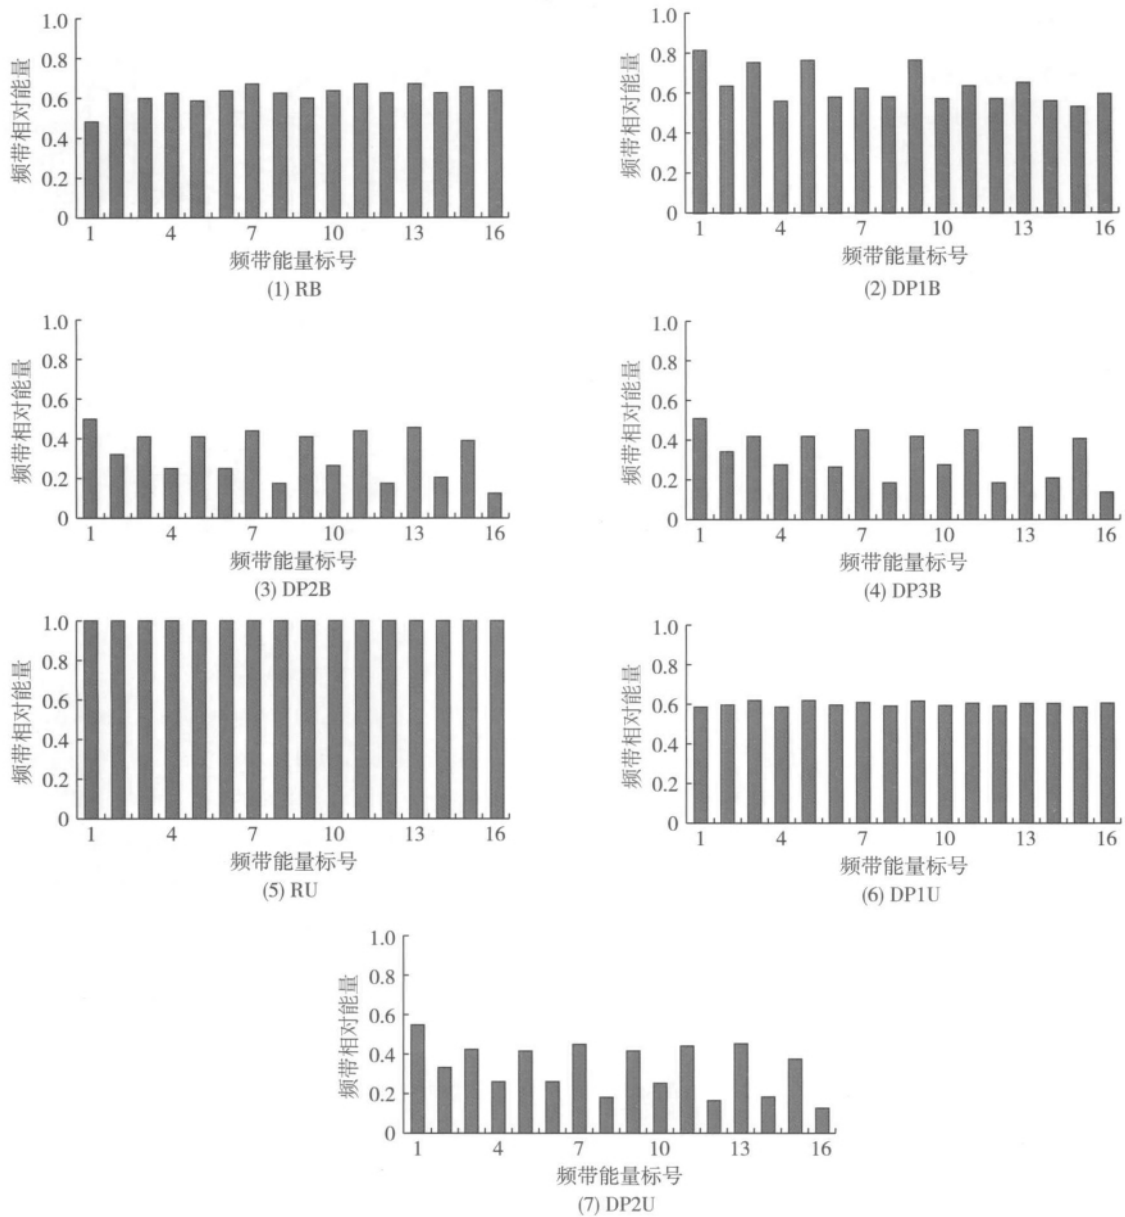


图 2 7 种损伤情况下小波包相对能量分布

Fig. 2 Wavelet packet relative energy distribution of seven damages

显示了 7 类损伤平均准确率.

由上述结果可以看出,1(1,5),3(3,7),5(5,9),7(7,11),9(9,13),11(11,15)6 个信号上的准确率比 2(2,6),4(4,8),6(6,10),8(8,12),10(10,14),12(12,16)6 个信号上的准确率高出很多.这是由于所有的损伤类别都发生在  $x$  轴方向上,并且传感器 1,3,5,7,9,11,13,15 是安置在  $x$  轴方向的柱上,因此它们对损伤更加敏感,这些传感器得到的加速度响应在不同类别的损伤之间有着更大的差异,这样就更容易进行识别分类.综上所述,对于这个模型仅需要选择  $x$  轴方向的信号来进行损伤识别,识别准确率如表 2 所示.




图 3 平均准确率

Fig. 3 Average accuracy

表 2  $x$  轴方向的识别准确率  
Tab. 2 Detection accuracy on 6  $x$ -axis direction signals

损伤类别	测试集上的准确率/%						平均准确率/ %
	1(1,5)	3(3,7)	5(5,9)	7(7,11)	9(9,13)	11(11,15)	
RB	100.0	100.0	100.0	100.0	100.0	100.0	100.0
DP1B	95.0	95.0	100.0	100.0	100.0	95.0	97.5
DP2B	96.7	96.7	96.7	100.0	100.0	96.7	97.8
DP3B	97.5	97.5	95	100.0	100.0	97.5	97.9
RU	96.7	98.0	92.0	97.3	94.7	95.3	95.7
DP1U	97.2	98.3	93.3	96.1	95.6	96.1	96.1
DP2U	94.3	95.2	92.9	96.7	96.2	96.7	95.3

此外,本文将提出的方法和其他常用的基于 SVM 的损伤识别方法进行了比较,结果如图 4 所示,其中 PCA+SVM 表示使用主成分分析从原始的加速度响应里提取特征向量作为 SVM 的输入向量;WPD+SVM 表示仅适用小波包分解从原始的加速度响应里提取特征向量作为 SVM 的输入向量;CCF+WPD+SVM 表示用本文提到的方法来进行识别,其中 CCF 指的是互相关函数.图 5 显示了 3 种识别方法在每类损伤上的标准差.实验结果表明结合了互相关函数、小波包分解和支持向量机的结构损伤识别方法可以有效地识别多类损伤问题,并且比其他 2 种方法获得更好的识别准确率和稳定性.




图 4 3 种识别方法的比较

Fig. 4 Performance compare of three SVM-base methods

## 5 结 论

将相邻 2 个传感器得到的加速度响应信号进行互相关后得到的信号可以消除测量过程中的一些特定的噪声,并且比单个传感器得到的加速度响应信号有更强的损伤表达能力.小波包分解将信号频带进行多层次划分,对多分辨分析没有细分的高频部分进一步分




图 5 3 种识别方法的标准差

Fig. 5 Standard deviations of three SVM-base methods

解,这些分解频带信号都具有一定的能量,不同损伤的频带能量分布不同,所以用能量的相对变换可以反映损伤类型.SVM 作为一种有效的分类算法,可以很好地解决小样本问题.通过与其他两种基于 SVM 的识别方法的比较,表明结合互相关函数、小波包分解和 SVM 的结构损伤识别方法在 Benchmark 模型上取得很高的识别精度,证明了本文提出的方法具有很好的结构损伤识别效果.

## 参考文献:

- [1] Sohn H S, Farrar C R, Hemez F M, et al. A review of structural health monitoring literature: 1996—2001 [R]. California; Los Alamos National Laboratory, 2004.
- [2] 韩大建, 王文东. 基于振动的结构损伤识别方法的近期研究进展[J]. 华南理工大学学报: 自然科学版, 2003, 31(1): 91-96.
- [3] 陈素文, 李国强. 人工神经网络在结构损伤识别中的应用[J]. 振动、测试与诊断, 2001, 21(2): 116-124.
- [4] 刘龙, 孟光. 支持向量回归算法在梁结构损伤诊断中的应用研究[J]. 振动与冲击, 2006, 25(3): 99-100, 126.
- [5] 赵学风, 段晨东, 刘义艳, 等. 基于小波包变换的支持向量

- 机损伤诊断方法[J]. 振动、测试与诊断, 2008, 28(2): 104-107.
- [6] Bellino A, Fasana A, Garibaldi L, et al. PCA-based detection of damage in time-varying systems[J]. Mechanical Systems and Signal Processing, 2010, 24(7): 2250-2260.
- [7] Song H Z, Luo Z, Bo H. Structural damage detection by integrating independent component analysis and support vector machine[J]. International Journal of Systems Science, 2006, 13(37): 961-967.
- [8] Worden K, Lane A J. Damage identification using support vector machines [J]. Smart Materials and Structures, 2001, 10(3): 540-547.
- [9] 周绮凤, 洪文财, 邵桂芳. 基于 SVM 的不同特征空间多分类方法研究[J]. 厦门大学学报: 自然科学版, 2010, 49(1): 30-33.
- [10] 何正嘉, 孟庆丰, 赵纪元. 机械设备非平稳信号的故障诊断原理及应用[M]. 北京: 科学出版社, 2001: 2-105.
- [11] Vapnik V. The nature of statistical learning theory[M]. New York: Springer, 1995.
- [12] 雷家艳, 姚谦峰, 雷鹰, 等. 基于随机振动响应互相关函数的结构损伤识别试验分析[J]. 振动与冲击, 2011, 30(8): 221-224, 236.
- [13] The City University of Hong Kong. ASCE structural health monitoring benchmark problem phase II & IIe [EB/OL]. [2011-10-08]. <http://www.ca.cityu.edu.hk/asce.shm/>.

## Structural Damage Detection Based on Support Vector Machine

ZHOU Qi-feng<sup>1\*</sup>, NING Yong-peng<sup>1</sup>, ZHOU Qing-qing<sup>1</sup>, YANG Fan<sup>1</sup>, LEI Jia-yan<sup>2</sup>

(1. School of Information Science and Technology, Xiamen University, Xiamen 361005, China;

2. School of Architecture and Civil Engineering, Xiamen University, Xiamen 361005, China)

**Abstract:** A structural damage detection method by integrating cross-correlation function, wavelet packet decomposition (WPD) and support vector machine (SVM) was proposed. Cross-correlation functions amplitude were calculated on two acceleration responses which are obtained from two adjacent sensors. Then the processed signals were translate into energy features by WPD, the energy sequences at different bands of frequency were inputted to classifier as feature vectors. Finally, SVM as an effective classifier for small sample set problems was used to detect the multiclass damage. The experiment results on a Benchmark model show that the proposed method obtained significantly higher identify accuracy than several other commonly used SVM-based methods.

**Key words:** damage detection; cross-correlation function; wavelet packet decomposition; support vector machine