

基于多传感器信息融合的 SVM 结构损伤诊断方法

刘义艳¹, 陈 晨², 俞竣瀚¹

(1. 长安大学电控学院, 陕西 西安 710064; 2. 汉中市建筑勘察设计研究院, 陕西 汉中 723000)

摘 要:为了能准确地诊断复杂结构损伤的发生、位置和程度,提出了一种聚类经验模式分解(EEMD)、小波包分解(WPT)、多传感器信息融合和 SVM 模式分类相结合的结构损伤诊断方法.首先对多个传感器采集的加速度振动信号进行 EEMD 分解,选择包含结构损伤信息丰富的固有模态函数(IMF);其次对其进行正交小波包分解,并计算小波包相对能量分布;最后把这些传感器信号的小波包相对能量融合,构成 SVM 分类器的输入特征向量,从而实现损伤的诊断和评价.研究表明:该方法在学习样本数较少的情况下仍然具有较好的适应性和分类能力;多传感器信息融合技术减小了损伤检测信息的不确定性,提高了损伤诊断准确率.

关键词:聚类经验模式分解;小波包频带能量;支持向量机;信息融合;损伤诊断

中图分类号:TU 973.2;TU 311.3

文献标志码:A

文章编号:1006-7930(2013)06-0803-05

大型土木工程由于不可避免的环境因素的影响,通常设计和建造一个绝对没有损伤的结构是不可能的,也是不符合实际的,这些大型复杂结构都有一个共同的特点就是使用期限很长,由于受到环境影响等多方面灾害因素的共同作用,将不可避免地使结构发生各种各样的损伤.结构一旦发生损伤其耐久性及其正常的承载能力就会受到严重影响,产生极坏的社会影响,危及正常的生产和生活秩序.因此,研究有效的结构损伤识别和预测技术具有重要的科学理论意义和工程应用价值^[1]. EEMD 方法是借助噪声剔除特性的信号分析方法^[2]. 基于统计学习理论的 SVM 在小样本条件下,对非线性和高维模式的识别具有较好的分类精度和较强的推广能力^[3-4]. Xie 把集成的遗传基因算法用到模糊最小二乘支持向量机中,对光纤结构进行智能监测^[5];刘春城将模态曲率改变率作为损伤识别特征参数,利用 SVM 进行大跨度拱桥的损伤程度识别,取得了非常接近目标值的识别效果^[6]. 然而,这些研究采用单一传感器采集的数据进行分析,具有一定的局限性^[7]. 本文首先对加速度振动信号进行 EEMD 分解,选择包含损伤信息丰富的 IMF 分量,再对其进行正交 WPT 并计算小波包相对能量分布,进行多传感器信息融合,作为 SVM 的输入特征向量来实现损伤模式分类.

1 聚类经验模式分解(EEMD)和支持向量机(SVM)

1.1 EEMD

为改善 EMD 分解中的模式混叠现象,Z. Wu 和 N. E. Huang 提出了 EEMD 方法^[8]. EEMD 方法的分解过程见参考文献^[9].

1.2 小波包能量

设加速度振动信号 $x(t)$ 的长度为 N ,则分解频带中 $x^{k,m}(i)$ 的数据长度为 $2^{-k}N$,它的能量为^[10]

$$E(x^{k,m}(i)) = \frac{1}{2^{-k}N - 1} \sum_{i=1}^{2^{-k}N} (x^{k,m}(i))^2 \quad (1)$$

式中: k 为分解次数, $m = 0, 1, 2, \dots, 2^k - 1$,表示分解频带的位置序号.第 m 频带分解信号的相对能量为

收稿日期:2013-03-26 修改稿日期:2013-11-25

基金项目:中国博士后基金资助项目(20110491637);国家青年自然科学基金资助项目(61201407,61203374);中央高校基本科研业务费的资助项目(2013G1321044)

作者简介:刘义艳(1981-),女,陕西镇安人,博士研究生,副教授,从事结构健康监测与损伤诊断研究工作.

$$E_m = \frac{E(x^{k,m}(i))}{E(x(t))} \tag{2}$$

式中: $E(x(t))$ 为总能量之和.

1.3 SVM

在结构损伤诊断中,二值分类是最基本的要求,它就是简单地判断结构有无损伤.而要对结构的损伤情况进行全面的诊断,只有二值分类显然是不够的,诊断损伤发生的位置、程度是多值分类问题.多值分类(k 分类, $k > 2$)问题是以二值分类为基础的^[6].设有 k 类训练数据,这 k 类数据两两组合,共可构建 $M = C_m^2 = m(m-1)/2$ 个训练集,分别使用 SVM 二值分类算法对这 M 个训练集进行学习,产生 M 个分类器.当决定样本 $x \in R^d$ 所属类别时,采用投票决策法,其主要思想是用所有的 $k(k-1)/2$ 个分类器对 x 进行分类,在第 m 类和第 n 类之间分类时,若该分类器判断 x 属于 m 类,则 m 类的票数加 1,否则 n 类的票数加 1.最后将 x 归为得票数最多的那一类.分类函数为

$$f(x)^{mm} = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i^{mm} y_i^{mm} K(x_i \cdot x) + b^{mm} \right\} \tag{3}$$

2 基于多传感器信息融合的 SVM 结构损伤诊断方法

多传感器信息融合是将来自某一目标的多源信息加以合成^[11].本文提出的方法如下:

- (1) 将测得的加速度振动信号进行 EEMD 分解,选择包含损伤信息丰富的分量 IMF.
- (2) 以 Battle-Lemarie^[11]小波作为基函数,进行小波包分解.
- (3) 求各频带信号的小波包能量,得到第 s 个传感器信号的小波包相对能量为

$$E_p^s = \{E_m, m = 1, \dots, M\} \tag{4}$$

式中: $s = 1, 2, \dots, S$; p 为信号采集的序号, $p = 1, 2, 3, \dots, P$.

- (4) 将 p 次传感器信号的小波包相对能量 E_p^s 组合,得到多传感器信息融合后的特征向量

$$E_p = \{E_p^1, E_p^2, \dots, E_p^s\} \tag{5}$$

- (5) 将 E_p 输入到 SVM 中,结构的损伤状态作为输出,根据训练好的 SVM,对待测样本进行分类.

3 工程实例

本文选取 ASCE 的一座 4 层的钢结构框架 12 自由度对称模型^[12],如图 1 所示.采用每层 y 方向的低水平的环境风荷载作为激励.分析信号采用检测节点为 13、22、31 和 40 处采集的加速度振动信号,采样频率为 1 000 Hz,数据长度为 16 384.

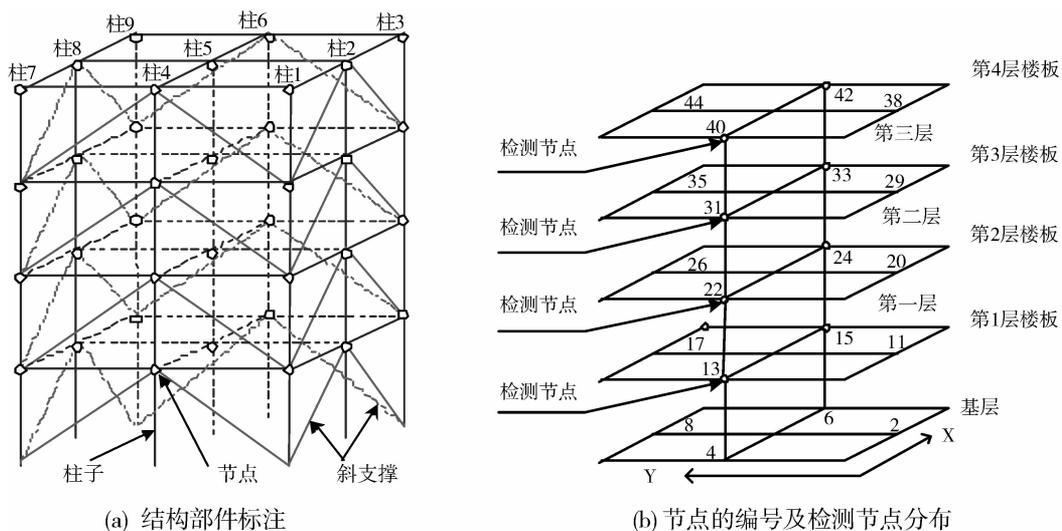


图 1 结构模型柱子的标注、节点编号及检测节点分布图解

Fig. 1 Structure mode and node number

3.1 特征提取

在进行正交小波包分解时选取第四阶模态(固有频率约为 46 Hz,对应于 EEMD 分解的第三个分量)进行分析,用 Battle-Lemarie 小波对 IMF 进行七层小波包分解,共 128 个频带,经验算 95%以上的小波包能量都集中在 100 Hz 以下的频带内,所以,分析时取小波包分解的前 5~25 个分量作为信号的主要成分,如图 2 所示.

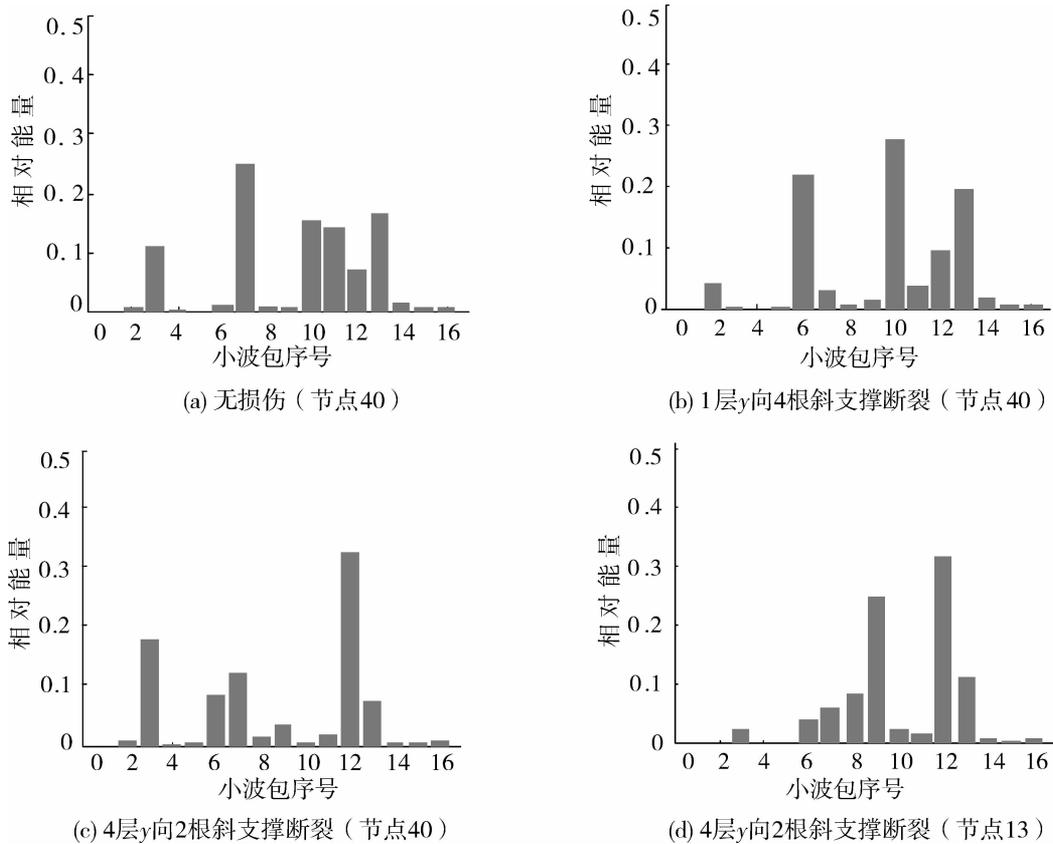


图 2 小波包相对能量分布
Fig. 2 Relative energies of wavelet package

从图 2 可以看出:IMF 的小波包能量分布有显著的差异,可对结构的损伤状态进行有效的监测.

3.2 损伤诊断

为了减少训练样本个数,缩短训练时间,先确定损伤的发生、位置,在诊断损伤的程度.

3.2.1 损伤的发生和位置诊断

实验设计了一、二、三和四层 y 向分别有 4 根、3 根、2 根、1 根斜支撑断裂的 4 种损伤,共 16 种损伤模式,加上无损伤共 17 种;在每一种状态的加速度信号中加入不同程度的白噪声(分别为 10%,20%,30%和 40%),称为 I、II、III 和 IV 类样本,共 68 组样本,其中 I 和 II 类作为训练样本,III 和 IV 类作为测试样本.检测节点分布如图 1 所示.每种工况下截取 4 段数据,每段数据长度为 1 024,共获得 136 个训练样本,136 个测试样本.将结构的损伤位置作为 SVM 的输出,取为 1、2、3、4 和 0 分别代表一层、二层、三层损伤和无损伤.这里 $k=5$,需建立 $k(k-1)/2=10$ 个二值分类器.

为了验证本文方法的有效性,本文运用 BP 神经网络和 SVM 两种模式识别方法,比较了单一传感器检测节点的诊断性能和多传感器检测节点信息融合的诊断性能.表 1 为单一传感器和多传感器信息融合的损伤发生和

表 1 损伤位置分类结果/%

Tab. 1 Classification results of damage location /%

	节点 13	节点 22	节点 31	节点 40	4 点融合
SVM 分类方法	90.44	88.97	92.65	91.91	98.53
BP 神经网络	83.82	85.29	89.71	88.97	94.12

位置诊断结果. SVM的参数 $C=10$,核函数选径向基核函数.

BP神经网络的输出分别为各层的损伤情况,0代表无损伤,1代表有损伤,输出个数为4.单一传感器诊断时输入层和隐含层数目分别为21和25,多传感器融合后输入层和隐含层数目分别为84和45.最大训练次数为5000次,训练目标误差为 1×10^{-5} ,性能函数的最小梯度为 1×10^{-20} ,学习速率为 1×10^{-3} ,隐层采用逻辑S函数,输出层采用双曲正切S函数,采用弹性反向传播算法.

从表1可以看出,无论是单一传感器还是多传感器信息融合SVM比BP神经网络分类正确率都高,分别高出7.62%,3.68%,2.69%,2.94%和4.41%.

3.2.2 损伤程度诊断

由前述1可知损伤发生在哪一层,如果损伤发生在第一层,现以第一层y方向的斜支撑损伤为例.分别为y向斜支撑4根断裂、3根断裂、2根断裂、1根断裂、1根斜支撑的横截面积减少到2/3和无损伤状态共6种,随机选取不同的种子数,共有54种损伤工况.每种工况下截取4段数据,每段数据长度为1024,共获得108个训练样本,108个测试样本. SVM的输出为0、4、3、2、1、0.7,分别对应于上述6种损伤工况.这里 $k=6$,需建立 $k(k-1)/2=15$ 个二值分类器.

同样在损伤程度的诊断中,运用BP神经网络和SVM两种模式识别方法,分别对单一传感器检测节点的诊断性能和多传感器检测节点信息融合的诊断性能作了对比.表2为单一传感器和多传感器信息融合的损伤程度诊断结果. SVM的参数 $C=10$,核函数选径向基核函数.

表2 损伤程度分类结果/%

Tab.2 Classification results of damage extent /%

	节点13	节点22	节点31	节点40	4点融合
SVM分类方法	93.38	88.89	94.12	90.44	97.06
BP神经网络	86.03	84.56	87.50	83.82	94.85

BP神经网络的输出个数为1,分别对应损伤程度.单一传感器诊断时输入层和隐含层数目分别为21和22,多传感器融合后输入层和隐含层数目分别为84和35.最大训练次数为5000次,训练目标误差为 1×10^{-4} ,性能函数的最小梯度为 1×10^{-20} ,学习速率为 1×10^{-3} ,隐层采用逻辑S函数,输出层采用双曲正切S函数,采用弹性反向传播算法.

从以上实验结果可以看出,SVM分类器的分类精度高于BP神经网络.多传感器信息融合技术减少了损伤检测信息的不确定性,提高了损伤诊断准确率.

4 结 语

本文提出了基于多传感器信息融合的SVM结构损伤诊断方法,将该方法应用于Benchmark模型结构,得出以下结论:

(1)EEMD方法利用的是白噪声的剔除特性,避免了模式混叠现象的发生.选择包含结构损伤信息丰富的IMF经正交小波包分解后,能够进行损伤信号的特征提取和状态识别.

(2)SVM分类方法在学习样本数较少的情况下仍然具有较好的适应性和分类能力,结合多传感器信息融合技术,较理想地识别了结构损伤的发生、位置和程度.

(3)多传感器信息融合损伤诊断方法提高了损伤诊断的准确性与可靠性.多传感器所采集的信息相互补充,经过信息融合处理后再利用这些信息时具有良好的容错性.

参考文献 References

- [1] GAETAN K, KEITH W, ALEXANDER F V, et al. Past, present and future of nonlinear system identification in structural dynamics [J]. Mechanical systems and signal processing, 2006(20):505-592.
- [2] LEI Ya-guo, HE Zheng-jia, ZI Yan-yang. Application of the EEMD method to rotor fault diagnosis of rotating machinery [J]. Mechanical Systems and Signal Processing, 2009, 23(4):1327-1338.
- [3] 边肇祺,张学工. 模式识别[M]. 2版. 北京:清华大学出版社,2000.
BIAN Zhao-qi, ZHANG Xue-gong. Workers Pattern Recognition [M]. 2nd ed. Beijing: Tsinghua University Press, 2000.
- [4] PARK Seunghee, INMAN Daniel J, LEE Jong-Jae, et al. Piezoelectric Sensor-Based Health Monitoring of Railroad

- Tracks Using a Two-Step Support Vector Machine Classifier[J]. *Journal of Infrastructure Systems*, 2008, 14(1): 80-88.
- [5] XIE Jian-hong. Structural damage detection based on fuzzy LS-SVM integrated quantum genetic algorithm [J]. *Information Technology for Manufacturing Systems*, 2010(20/23):1365-1371.
- [6] 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):174-244.
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):174-244.
- [7] LIU Yi-Yan, JU Yong-Feng, DUAN Chen-Dong, et al. Structure Damage Diagnosis Using Neural Network and Feature Fusion [J]. *Engineering Applications and Artificial Intelligence*, 2011, 24(1):87-92.
- [8] WU Z H, HUANG N E. Ensemble Empirical Mode Decomposition; A Noise Assisted Data Analysis Method [J]. *Advances in Adaptive Data Analysis*, 2009(1):1-41.
- [9] 刘义艳,贺栓海,巨永锋,等. 基于 EEMD 和 WPT 的结构损伤特征提取[J]. *振动、测试与诊断*, 2012, 32(2):256-260.
LIU Yi-yan, HE Shuan-hai, JU Yong-feng, et al. Structure Damage Feature Extraction Based on EEMD and WPT [J]. *Journal of Vibration, Measurement & Diagnosis*, 2012, 32(2):256-260.
- [10] ZUBAIDAH Ismail, ZHI Chao-ong. Honeycomb damage detection in a reinforced concrete beam using frequency mode shape regression [J]. *Measurement*, 2012, 45(4):950-959.
- [11] REN Wei-Xin, SUN Zeng-Shou, XIA Yong. Damage Identification of Shear Connectors with Wavelet Packet Energy: Laboratory Test Study [J]. *Journal of Structural Engineering*, 2008, 134(5):832-841.
- [12] JOHNSON E A, LAM H F, KATAFYGIOTIS L S, et al. Phase I IASC-ASCE structural health monitoring benchmark problem using simulated data [J]. *Journal of Engineering Mechanics*, 2004, 130(1): 3-15.

A structure damage diagnosis method based on multi-sensor information fusion and support vector machine

LIU Yi-yan¹, CHEN Chen², YU Jun-han¹

(1. School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China;

2. Institute of Construction Survey and Design of Hanzhong, Hanzhong 723000, China)

Abstract: In order to make a diagnosis of damage occurrence, position and degree of the complex structures accurately, a structural damage diagnosis method was presented by means of ensemble empirical mode decomposition (EEMD), wavelet packet decomposition, and multi-sensor feature fusion theory and support vector machine (SVM) pattern classification. Firstly, the response signals of the ASCE benchmark structure are processed by using EEMD, and the intrinsic mode function (IMF) which contains structural damage information are selected. Secondly, the selected IMF is decomposed by orthogonal WPT, and also wavelet package energy (WPE) on decomposition frequency bands are calculated. Thirdly, the input feature vectors of SVM classifier were built by fusing wavelet packet relative energy distribution of these sensors. Finally, with the trained classifier, damage diagnosis and assessment was realized. The result indicated that it still has good adaptability and classification capability in the case of small samples and the fused feature can reduce the uncertainty of damage detection information, with the diagnosis accuracy improved.

Key words: ensemble empirical mode decomposition (EEMD); wavelet packet frequency band energy; support vector machine (SVM); information fusion; damage diagnosis