

文章编号:1001-5132 (2009) 04-0553-05

基于高频电阻抗信号与神经网络技术的 结构损伤识别研究

严 蔚, 袁丽莉

(宁波大学 建筑工程与环境学院, 浙江 宁波 315211)

摘要: 为保证结构的安全性和耐久性, 宜对结构早期的损伤情况进行健康监测. 采用电阻抗方法和人工神经网络技术对钢制薄梁进行了损伤识别的实验研究, 但将测得的电阻抗信号都作为神经网络的输入参数则显得不切实际, 所以采用主成分分析的降维方法进行实验数据的预处理, 降维后包含着最重要主成分的电阻抗信号代替原始数据将作为神经网络的输入参数. 研究表明: 采用该技术得到的仿真结果与实验观察非常吻合.

关键词: 电阻抗; 神经网络; 主成分分析; 结构健康监测

中图分类号: TU317

文献标识码: A

电阻抗法(Electro-Mechanical Impedance, EMI)作为 20 世纪 90 年代中期发展起来的一种新的结构健康监测技术已得到人们广泛的关注^[1], 它充分利用了压电材料的机电耦合效应特性, 是智能材料在土木工程领域的典型应用. 其基本原理是结构损伤引起结构的机械阻抗变化, 尽管机械阻抗难以通过直接测试得到, 但可利用压电材料的机电耦合效应, 将机械阻抗的变化通过粘贴在主体结构上的压电片电阻抗变化表现出来. 通过与结构在无缺陷时压电片的电阻抗谱比较, 诊断结构内部的损伤情况. 由于电阻抗技术的工作频率在高频范围内(一般介于 10~500 kHz), 信号的波长相当小, 所以对结构早期的局部细小损伤非常敏感^[2], 这也是该方法相比其他如基于结构振动的损伤诊断法的一个特殊优点.

Sun 等人^[3]首先把该技术应用到桁架结构的损

伤监测上. 之后, Park 等人^[4]分别针对复合材料增强混凝土墙板和空间框架结构进行了损伤识别的研究, 并验证了 EMI 技术的有效性. Bios 等人^[5]则利用 EMI 技术对层合结构层间黏结缺陷的大小和位置进行了精确的评估. 王丹生等人^[6]从电导纳(电阻抗的倒数)谱曲线中提取裂纹梁的反谐振频率, 通过比较各压电片的反谐振频率变化识别了裂纹位置. Kuang 等人^[7]采用电阻抗技术研究了含裂纹梁结构, 得到了包含裂纹深度、裂纹位置和其他系统参数信息的电导纳函数.

EMI 技术虽已被许多研究^[3-7]证明是一种能识别结构早期细小损伤的无损结构健康监测方法. 但是, 由于集成有压电驱动/传感器的智能结构系统的复杂性和结构高频振动分析的困难, 发展一种精确的电阻抗模型就显得十分困难. 另一方面, 近年来神经网络技术发展迅速, 这为基于 EMI 技

术的损伤识别反问题研究提供了可能. 但是, 在应用 EMI 技术进行结构损伤识别时, 得到的每条电阻抗(电导纳)曲线的频率点值一般达到数百个, 例如利用 HP4195A 网络分析仪进行测量, 每组可得到 401 个数值点. 如果都把它们作为输入参数, 则输入维数太高, 会出现训练速度过慢, 训练过饱和(即训练过头)等问题. 在这种情况下, 降低输入参数的维数, 将多余的变量信息剔除掉是很有必要的, 也是很重要的. 为此, 将采用主成分分析这一有效的降维方法进行测试数据的预处理.

1 实验研究

1.1 实验装置

实验试件为钢制小型构件, 长 300 mm, 宽 20 mm, 厚 2 mm. 作为驱动/传感器的压电片长、宽、高分别为 15 mm、10 mm 和 0.34 mm, 由中科院上海硅酸盐所提供, 压电片粘贴在离梁右端 10.5 mm 处. 如图 1 所示, 小型钢制构件在检测进行时搁置在普通的泡沫板上模拟自由边界条件^[8]. 压电片的 2 个电极由 2 根导线引出, 与安装在 HP4195A 网络分析仪的阻抗试验适配器相连接. 这样, 网络分析仪可以对压电片施加电激励, 并接收反馈的反映这一耦合结构系统动态特性的电阻抗信号. 为更好地说明结构损伤对于电阻抗信号的影响, 本实验采用在钢梁上钻 8 mm 圆孔的方法来模拟结构损伤^[8], 并设计了 2 种工况: (1) 1# 梁, 在离梁左

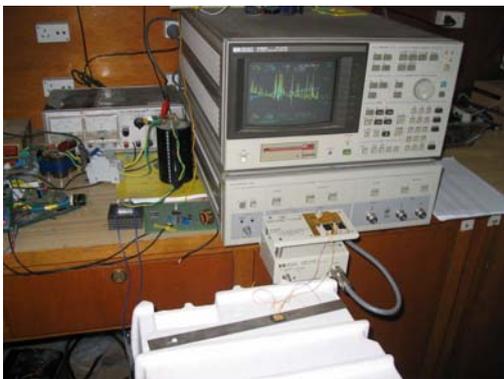


图 1 实验装置

端 30 mm 附近分别钻 1 个、2 个和 3 个圆孔(对应于损伤 1、损伤 2 和损伤 3)来模拟结构损伤的不同严重程度. (2) 2# 梁, 分别在离梁左端 30 mm、10.5 mm、16 mm 处钻圆孔(对应于损伤 1、损伤 2 和损伤 3)来模拟结构损伤的扩展.

1.2 结构损伤对电阻抗信号的影响

图 2 和图 3 展示了基于不同损伤状态的电阻抗的实部在频域内(200~300 kHz)的分布. 在高频电激励下, 电阻抗谱反映了压电片 - 主体钢构件这一耦合结构系统的振动特性. 结构的损伤造成了结构系统振动特性的变化, 从而引起电阻抗谱峰值点的偏移. 可以看到, 电阻抗信号对结构的损伤非常敏感, 即使是对初始的损伤(损伤 1), 也验证了 EMI 技术能及时反映损伤的存在, 显示了该方法的有效性. 但是, 从图 2 和图 3 中并不能定量地反映出损伤状态, 为此将引入神经网络系统进行损伤识别的反问题研究.

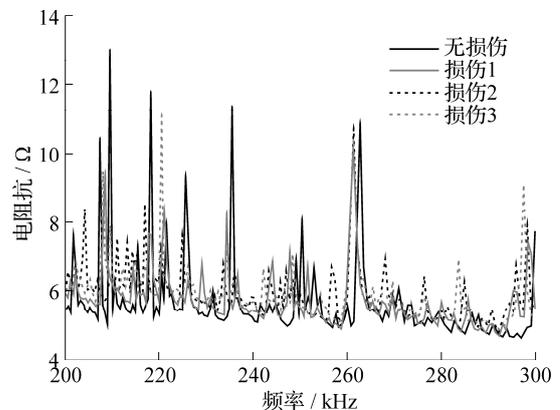


图 2 不同损伤状态的电阻抗分布(工况 1)

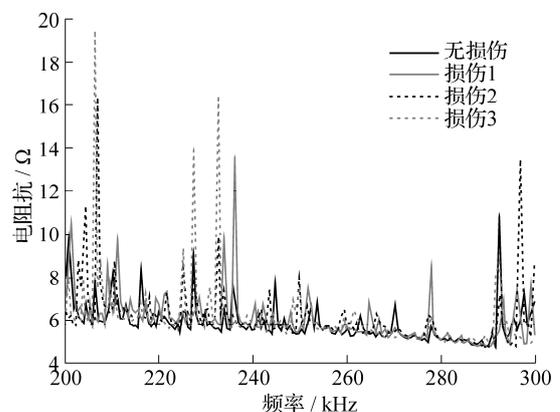


图 3 不同损伤状态的电阻抗分布(工况 2)

2 主成分分析

2.1 原理简介

主成分分析法与自相关最大特征值相对应,它是将多个相关变量简化为几个不相关变量线性组合的一种多元统计方法,也是提取信号最基本特征和进行数据压缩的基本方法.从数学的角度看,主成分的思想在于降维,即从简化方差和协方差的结构来考虑.首先,对原始数据进行归一化处理.采用所有得到的电阻抗数据,组成原始的数据矩阵 $\mathbf{X}_{M \times N}$,其中, M 表示数据的组数, N 表示在某个频段内的频率点数.矩阵中的元素用 x_{ij} 表示, i 和 j 为矩阵中对应的位置.那么第 j 列的平均值为:

$$\bar{X}_j = \frac{1}{M} \sum_{i=1}^M x_{ij}, \quad (1)$$

对应的标准偏差为:

$$S_j^2 = \frac{1}{M} \sum_{i=1}^M (x_{ij} - \bar{X}_j)^2, \quad (2)$$

那么原始数据矩阵中对应的元素将由下面新的元素代替,

$$\tilde{x}_{ij} = \frac{x_{ij} - \bar{X}_j}{S_j \sqrt{M}}, \quad (3)$$

利用(3)式产生的新元素可组成新数据矩阵 $\tilde{\mathbf{X}}_{M \times N}$.

其次,对归一化后的数据进行主成分分析,使数据集中主成分的方差贡献小的都被删除掉,同时保留变换后的输入矢量和主成分变化矩阵.定义 1 个相关矩阵:

$$\mathbf{C}_{N \times N} = \tilde{\mathbf{X}}_{N \times M}^T \tilde{\mathbf{X}}_{M \times N}. \quad (4)$$

主成分就是相关矩阵的特征值和对应的特征向量:

$$\mathbf{C}\Psi = \lambda_i \Psi, \quad (5)$$

其中, i 为主成分附标.第一阶主成分也就是最大特征值和它对应的特征向量代表原始数据的方向和最大变异性的数值;第二阶主成分与第一阶正交,代表对于原始数据有着第二重要的贡献,依次类推.因为矩阵 \mathbf{C} 是 1 个方阵,从(5)式得到的主成分

的数目为 N 个.那么归一化后得到的数据矩阵 $\tilde{\mathbf{X}}_{M \times N}$ 在主成分上的投影为:

$$\mathbf{A}_{M \times N} = \tilde{\mathbf{X}}_{M \times N} \Psi_{N \times N}. \quad (6)$$

投影矩阵 \mathbf{A} 和特征向量矩阵 Ψ 能够分成 2 部分,即包含 P 个主成分和 $N - P$ 个主成分的 2 个子矩阵:

$$\begin{aligned} \mathbf{A}_{M \times N} &= [\mathbf{A}_{1M \times P} : \mathbf{A}_{2M \times (N-P)}], \\ \Psi_{N \times N} &= [\Psi_{1N \times P} : \Psi_{2N \times (N-P)}], \end{aligned} \quad (7)$$

然后,可以重建 1 个包含 P 个主成分的数据矩阵:

$$\begin{aligned} \tilde{\mathbf{X}}_R &= \mathbf{A}\Psi^T = [\mathbf{A}_{1M \times P} : \mathbf{A}_{2M \times (N-P)}] \cdot \\ &[\Psi_{1N \times P} : \Psi_{2N \times (N-P)}]^T \approx \mathbf{A}_{1M \times P} \Psi_{1P \times N}^T. \end{aligned} \quad (8)$$

因为 $\tilde{\mathbf{X}}_R$ 中的元素 \tilde{x}_{ijR} 是从归一化后的原始数据矩阵求得的,可以应用下式构建 1 个新的电阻抗数据矩阵:

$$x_{ijR} = S_j \sqrt{M} \tilde{x}_{ijR} + \bar{X}_j. \quad (9)$$

在主成分分析中,仅考虑 P 个主成分 ($P \leq N$),由此造成的误差为:

$$Error = \left(\sum_{i=P+1}^N \lambda_i \right) / \left(\sum_{i=1}^N \lambda_i \right). \quad (10)$$

2.2 实验数据的主成分分析

应用上面理论,对实验实测得到的数据进行主成分分析以降低输入参数的维数.1#梁、2#梁材料性质、几何尺寸和压电片粘贴的位置一致.在 200~300 kHz 频段内,每根梁可以测得 4 组实验数据(即无损伤和损伤 1, 2, 3 状态),总共得到 8 组数据,即 $M = 8$,其中训练的样本数据取 6 组,检测的数据取 2 组.每组有 401 个数据,即 $N = 401$.表 1 列示了按照(5)式得到的主成分特征值,可以看到,前 5 阶特征值的累积比例已达 86% 以上,而前 7 阶几乎已达 100%.根据(8)式和(9)式可以得到新的电阻抗信号在 200~300 kHz 频域内的分布.图 4 展示了 1#梁损伤 3 状态时,测得的原始数据与主成分分析后得到的数据之间的比较,图中标注 i 表示采用的主成分数量.从图 4 中可以看到,与原始数据相比,取 2 阶主成分时有明显的误差,取 4 阶误差较小,当取 7 阶时,已很难区分与原始曲线的不

同,这与表1所表明的信息一致.

表1 主成分特征值及所占相对和累积百分比

阶数	主成分特征值	所占比例/%	累积比例/%
1	134.771 70	0.336 09	0.336 09
2	83.488 47	0.208 20	0.544 29
3	52.769 87	0.131 60	0.675 89
4	42.145 85	0.105 10	0.780 99
5	33.330 52	0.083 12	0.864 11
6	29.831 29	0.074 39	0.938 50
7	24.662 36	0.061 50	1.000 00

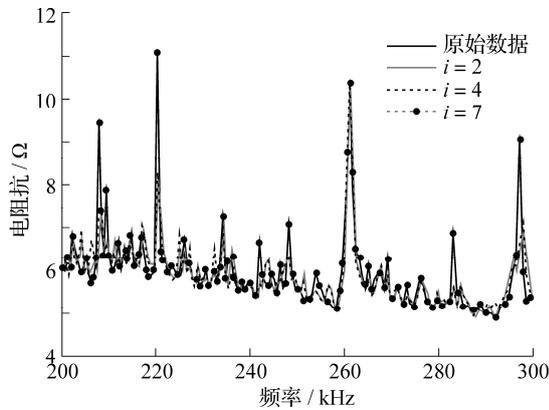


图4 原始数据与主成分分析后得到的结果对比

3 采用神经网络进行损伤识别

根据以上的分析,采用7阶主成分已足够精确,所以在下面的分析中只取前7阶主成分作为输入数据.利用(6)式的计算结果,得到8组含有7个主成分的样本数据.其中6组样本数据作为神经网络训练用途,另2组数据利用该训练好的网络进行损伤识别.训练的损伤类别分为3种,详见表2.此外,1#梁损伤2和2#梁损伤1测得的数据经过主成

表2 损伤类别及训练样本数据来源说明

损伤类别	采用的训练样本 (经过主成分分析)	输出向量
无损伤	1#、2#梁无损伤时测得的数据	(1, 0, 0)
轻度损伤	1#梁损伤1, 2#梁损伤2测得的数据	(0, 1, 0)
重度损伤	1#梁损伤3, 2#梁损伤3测得的数据	(0, 0, 1)

分分析后将作为检测的输入数据.

调用Matlab工具箱进行基于BP神经网络技术的损伤识别研究,通过仿真来检验网络的输出是否满足要求,运行结果为:

$Y =$

Columns 1 through 4

0.999 998 182 253 75 0.999 999 977 858 85

0.000 000 336 942 98 0.000 000 192 200 30

0.000 000 062 396 02 0.000 000 064 617 57

1.000 000 000 000 00 0.999 996 987 570 92

0.000 000 006 154 79 0.000 000 000 009 25

0.000 000 187 681 22 0.002 705 492 390 54

Columns 5 through 6

0.000 000 009 809 08 0.000 000 880 065 39

0.000 003 323 259 74 0.000 000 000 000 00

0.999 999 084 434 75 0.962 023 790 197 90

从运行结果可知,该网络可以有效准确地识别已经出现的结构损伤,为实际的损伤识别提供了有效的工具.然后,把另外2组数据输入该网络,运行结果为:

$Y =$

0.288 536 367 389 35 0.000 000 361 342 37

0.998 095 566 786 13 0.994 873 166 869 08

0.007 721 296 059 13 0.037 660 758 084 45

二组输出结果都对应轻度损伤状态,与设定的实际情况(1#梁损伤2, 2#梁损伤1)相符.

4 结论

从损伤识别的反问题角度出发,利用神经网络系统和EMI技术进行了针对钢制薄梁的损伤检测研究.由于采用EMI技术可以得到大量的高频频域内的电阻抗信号,所以应用神经网络系统的一个关键问题是输入参数的选取.采用主成分分析对电阻抗信号进行了预处理,从而大大降低输入参数的维数.研究表明,虽然只有少量的包含原

始数据主成分参数作为BP神经网络系统的输入参数,但是并没有影响输出结果,所有的损伤都能被成功识别.因此,结合主成分分析的数据处理方法,应用高频电阻抗信号和神经网络的组合技术,尤其对于管道系统和桁架结构,将会是一种不需要任何理论模型且具有广阔应用前景的结构损伤检测技术.

参考文献:

- [1] 孙明清,李卓球,侯作富.压电材料在土木工程结构健康检测中的应用[J].混凝土,2003,161(3):22-24.
- [2] Ritdumrongkul S, Abe M, Fujino Y et al. Quantitative Health monitoring of bolted joints using a piezoceramic actuator-sensor[J]. Smart Materials and Structures, 2004, 13:20-29.
- [3] Sun F P, Chaudhry Z, Liang C, et al. Truss structure integrity identification using PZT sensor-actuator[J]. Journal of Intelligent Material Systems and Structures, 1995, 6:134-139.
- [4] Park G, Inman D J. Structural health monitoring using piezoelectric impedance measurements[J]. Philosophical Transactions of the Royal Society, 2007, 365:373-392.
- [5] Bois C, Herzog P, Hochard C. Monitoring a delamination in a laminated composite beam using in-situ measurements and parametric identification [J]. Journal of Sound and Vibration, 2007, 299:786-805.
- [6] 王丹生,朱宏平,陈晓强,等.利用压电自传感驱动器进行裂纹钢梁损伤识别的实验研究[J],振动与冲击,2006,25(6):139-142.
- [7] Kuang Youdi, Li Guoqing, Chen Chuanyao. An admittance function of active piezoelectric elements bonded on a cracked beam[J]. Journal of Sound and Vibration, 2006, 298:393-403.
- [8] Naidu A S K, Soh C K. Damage severity and propagation characterization with admittance signatures of piezo transducers[J]. Smart Materials and Structures, 2004, 13: 393-403.

Structural Damage Detection Based on High Frequency Electro-mechanical Impedance Signatures and Artificial Neural Networks

YAN Wei, YUAN Li-li

(Faculty of Architectural, Civil Engineering and Environment, Ningbo University, Ningbo 315211, China)

Abstract: To ensure the safety and durability of the structures, a robust state monitoring technique is generally employed to detect incipient damages in the structures. Based on the experiment, an investigation into damage identification for thin steel beams is presented in this paper using electro-mechanical impedance (EMI) signatures and artificial neural networks (ANNs). The impracticality of using full-size EMI data to feed ANNs as input is noted. The principal component analysis (PCA)-based is adopted for the measured EMI data for its dimension reduction purposes. The compressed EMI data, represented by the principal components, are then used as ANN input variables instead of the raw EMI data. It is shown that the identification results from the proposed method agree fairly well with the experimental observations.

Key words: electro-mechanical impedance; artificial neural networks; principal component analysis; structural health monitoring

CLC number: TU317

Document code: A

(责任编辑 章践立)