

基于应变模态差和神经网络的管道损伤识别*

周邵萍, 郝占峰, 韩红飞, 张佳程, 章兰珠

(华东理工大学机械与动力工程学院 上海, 200237)

摘要 应变模态差对结构微小损伤具有很高的敏感性且对结构损伤处具有较高的定位识别率,故在工程实际中可以利用其对管道进行损伤识别。然而,应变模态差只能定性地反映结构的损伤程度,并不能直接量化损伤结构的损伤程度,故采用神经网络和应变模态差相结合的方法对损伤管道进行损伤位置和损伤程度的识别。利用有限元分析软件 ANSYS 进行模态分析提取管道的应变模态参数,并把管道损伤前后的应变模态差作为神经网络的输入参数,以损伤位置和损伤程度作为神经网络的输出参数,对损伤管道分别进行单损伤和双损伤的损伤定位和程度识别。研究表明,利用应变模态差和神经网络相结合的方法能够准确识别出管道的损伤位置以及损伤程度。

关键词 应变模态差; 损伤识别; 神经网络; 管道

中图分类号 TB123; O327

引言

应变模态差作为管道损伤检测方法之一,由于对微小损伤具有很高的敏感性,能够很好地对管道进行损伤判断和定位。结果表明^[1]:基于应变模态差的方法对管道单损伤和双损伤具有较高的定位识别率,但是并不能判断其损伤程度。神经网络诊断方法在知识获取、并行推理、适应性学习、联想推理、容错能力等方面都具有相对的优越性,因此被广泛地应用在结构分析与损伤检测中,将神经网络和模态参数相结合的方法为定量识别管道单损伤和多损伤的损伤程度提供了新的手段。

陈素文等^[2]综合论述了人工神经网络在结构损伤识别中的应用,阐述了分步识别理论和模态输入参数的选择,并描述了几种不同方法改进的 Back Propagation(BP)算法。王步宇^[3]把分形原理与神经网络相结合,对简支梁在不同损伤情况下的振动信号进行了研究,研究结果表明不同状态下的振动信号的分形维数有明显的区别,可以将分形维数作为结构损伤检测的特征量,并用神经网络将结构在不同状态模式下识别出来。于菲等^[4]提出了把振型差值曲率与神经网络相结合的结构损伤识别方法,首先利用振型差值曲率得到损伤的大致区域,其次在选定的区域内,利用 BP 神经网络确定损伤构件

的准确位置,通过对海洋平台数值模拟和实验结果验证了该方法的有效性。孙宗光等^[5]对汲水门斜拉桥桥面选取自振频率和振型分量作为网络输入向量,结合 BP 神经网络实现了对构件损伤程度的识别。范建设等^[6]利用 BP 神经网络结合模态应变能的方法对下拱形结构的损伤识别做了相关研究,证明了神经网络在损伤程度判断中的可行性。赵卓等^[7]研究了曲率模态和神经网络在矩形截面简支梁裂缝损伤识别中的应用。Dong 等^[8]提出了一种改进 BP 神经网络来识别结构损伤程度,以结构模态频率作为反向传播神经网络的输入,然后用于预测结构损伤程度,通过对复合材料悬臂梁的仿真实验结果表明了改进后的方法能够有效的识别结构损伤程度。Zhang^[9]利用模态柔度参数作为神经网络的输入参数识别结构损伤的位置,利用柔度和频率两参数作为神经网络的输入参数识别损伤程度,通过简支梁及板的例子说明该方法能够定量识别结构损伤。Diao 等^[10]提取 AR 模型的前三阶参数的变化作为损伤特征向量,并把它作为 BP 神经网络的输入参数来识别损伤的位置,通过对海上平台的数值模拟和实验结果验证了该方法的有效性。Guo 等^[11]把频率作为神经网络的输入参数识别结构的损伤情况,通过对箱形梁不同位置 and 不同程度的模拟,表明该方法具有很强的鲁棒性,能够精确识别出结构损伤情况。

然而,目前基于应变模态差和神经网络相结合

* 国家自然科学基金资助项目(51175178;51275171)
收稿日期:2014-01-02;修回日期:2014-02-27

的方法在管道损伤识别中的研究还比较少,因此,笔者提出了管道损伤的两步识别法:a. 利用应变模态差识别出管道损伤的损伤位置;b. 利用 BP 神经网络确定管道损伤程度。选取 BP 神经网络作为训练网络结构,把经过数值模拟所得到的应变模态差作为神经网络的输入量,把管道损伤的位置和程度作为输出量,对单损伤和双损伤进行定位和程度判断。

1 基本原理

1.1 应变模态差定位理论

由材料力学和弹性力学基本原理可知,当结构某处产生损伤后,则在其周围的应力分布就会急剧变化,而其他部分变化很小。由于应变是位移的一阶导数,因此对于结构的每一阶位移模态都有相对应的固有应变分布状态,称之为应变模态。和位移模态一样,应变模态也是结构的固有动力特性,不受外力载荷的影响,因此对于受损构件可以利用应变模态的变化来进行损伤定位。

对于结构的应变模态 $\{\Psi_r^e\}$,可以通过有限元分析软件 ansys 模拟得到,设管道损伤前的应变模态为 $\{\Psi_r^e\}_0$,损伤后的管道应变模态为 $\{\Psi_r^e\}_d$,则应变模态差损伤指标表达式^[12]为

$$\Delta\{\Psi_r^e\} = \{\Psi_r^e\}_d - \{\Psi_r^e\}_0$$

由于管道损伤必定会导致其损伤单元处的应变模态发生改变,因此,应变模态差曲线上有突变的单元最有可能是损伤单元。

1.2 神经网络理论基础

Back Propagation(BP)神经网络是一种通过输入连续或离散的初始信息,进行计算后按误差逆传播算法的前馈神经网络,最终实现输出和输入之间的高度的非线性映射。人工神经网络由大量处理单元互联组成,每一个神经元既是信息存储单元,又是处理单元,信息处理的能力分布在各处理单元上,其基本结构如图 1 所示,包括输入层、隐层和输出层^[13-14]。BP 神经网络能够学习和贮存大量的输入和输出模式映射关系,而无需事先解释描述这种映射的数学方程。它的学习规则是使用快速下降法,通过反向相传播来不断调整网络的权值和阈值,使网络的误差平方和最小。由于管道损伤识别的问题为高度非线性复杂系统,仅仅依靠力学和数学模型求解难以对其损伤程度进行损伤,BP 神经网络方法




图 1 神经网络结构

Fig. 1 Neural network structure

的引入为研究这一问题提供了新的手段。把应变模态差作为神经网络的输入样本数据,损伤位置和损伤程度作为输出数据,利用基于 matlab7.1 的神经网络工具箱来进行网络学习,进而对管道损伤位置及程度进行判断。

2 损伤识别数值模拟

2.1 有限元模型

文中的研究对象为一端固支一端简支的管道,其管道基本尺寸如下:长度 $L=1\text{ m}$,内径 $d=62\text{ mm}$,外径 $D=70\text{ mm}$;材料基本属性为:弹性模量 $E=200\text{ GPa}$,密度 $\rho=7\ 850\text{ kg/m}^3$,泊松比 $\mu=0.3$ 。该有限元模型采用 solid45 实体单元类型,沿轴向方向划分为 25 个单元,26 个节点。其损伤状况如图 2 所示,损伤缺口宽度为 3 mm,损伤缺口周向长度为 $1/4$ 周长,用缺口深度表示损伤程度的大小。




图 2 损伤示意图

Fig. 2 Damage schematic diagram

2.2 基于应变模态差的损伤定位

2.2.1 损伤单元设置

由理论基础可知,局部单元损伤必定会导致其损伤处的应变产生突变,相对于损伤单元处的应变模态差就会出现明显波峰,从而根据波峰的位置可识别出损伤单元。损伤工况包括单一损伤和多损

伤情况。对于单损伤在单元 11 处,其损伤深度为 0.5 mm,双损伤位置在单元 1 和单元 11 处,其损伤深度均为 1.5 mm。

2.2.2 损伤定位

通过 ansys 模拟计算,提取前四阶应变模态,并绘制应变模态差曲线如图 3 和图 4 所示。




图 3 单损伤应变模态差曲线

Fig. 3 Strain modal difference of single damage




图 4 多损伤应变模态差曲线

Fig. 4 Strain modal difference of multi-damage

从图 3 和图 4 可以看出:应变模态差能够精确地识别出管道的损伤位置,不论是单损伤还是多损伤。管道单元发生损伤时,前 4 阶应变模态差在该单元的两端节点处有较明显的突变,在其余无损伤的区域处曲线较光滑,能够很好地识别其损伤单元的位置。然而,应变模态差只能定性地反映损伤程度,并不能直接量化其损伤程度。

2.3 基于 BP 神经网络损伤的定量识别

2.3.1 BP 网络设计

笔者采用一个单隐层的三层 BP 网络来进行训练,其训练函数使用 trainlm 函数,该函数利用 Levenberg-Marquardt 算法来训练网络,其大大地加快了网络训练的速度。文中把轴向 26 个节点的第 3 阶应变模态差值作为其网络的输入向量,其形式为

$$\{\text{输入样本数据}\} = \{I_1 I_2 \cdots I_i \cdots I_{26}\}$$

其中: i 和 I_i 分别为第 i 个节点和第 i 个节点的应变模态差值,共 26 维。

把每个单元的损伤程度作为输出向量,其形式为

$$\{\text{单元损伤程度}\} = \{O_1 O_2 \cdots O_j \cdots O_{25}\}$$

其中: j 和 O_j 分别表示第 j 个单元和第 j 个单元的损伤程度,比如对于 5 单元损伤 2 mm,则输出向量就为: $\{\text{单元 5 损伤 2 mm}\} = \{0 0 0 0 2 0\}$,共 25 维。

其隐层的节点数根据以下经验公式 $2n + 1$ 得出, n 为输入层维数,即取隐层节点为 53。设置隐含层神经元的传递函数和输出层神经元传递函数都采用 S 型正切函数 tansig,其最大训练次数为 10 000 次,训练精度为 $1e-4$,学习速率为 0.01。

2.3.2 单损伤程度的定量识别

对于单损伤样本分别选取第 1,7,13,19 和 25 单元作为损伤单元,其损伤程度包括 1,2,3 和 4 mm 四种深度,共 20 组损伤工况,如表 1 所示。把以上 20 组损伤工况的第 3 阶应变模态差数据作为输入样本,把每种损伤工况对应的损伤程度作为输出样本进行网络学习。

表 1 单损伤输入样本工况

Tab. 1 The input conditions of single damage

工 伤 损 伤 程	工 伤 损 伤 程	工 伤 损 伤 程
况 单 元 度/mm	况 单 元 度/mm	况 单 元 度/mm
1 1 1	8 7 4	15 19 3
2 1 2	9 13 1	16 19 4
3 1 3	10 13 2	17 25 1
4 1 4	11 13 3	18 25 2
5 7 1	12 13 4	19 25 3
6 7 2	13 19 1	20 25 4
7 7 3	14 19 2	

选取第 1 单元损伤 3.5 mm,第 7 单元分别损伤 2.5 和 3.5 mm,第 13 单元损伤 2.5 mm,第 19 单元损伤 1.5 mm,第 25 单元损伤 2.5 mm。以上 6 种损伤工况作为测试样本,分别把 6 种损伤工况对应的应变模态差带入上述训练好的网络,得出其对应的训练结果,图 5 为单元 1 损伤 3.5 mm 时的训练结果。

由图 5 可以明显看出,损伤单元为第一单元,同




图 5 网络训练结果

Fig. 5 Network training results

时也可以得出其损伤程度,将每种测试样本对应的网络输出程度与实际程度比较,其结果如表 2 所示。

表 2 损伤程度识别结果

Tab. 2 Identification results of damage degree

损伤单元	损伤程度/mm	网络输出程度/mm	误差/%
1	3.5	3.513 5	0.44
7	2.5	2.520 4	0.82
7	3.5	3.479 6	0.58
13	2.5	2.522 8	0.91
19	1.5	1.466 7	2.22
25	2.5	2.327 7	6.89

由表 2 可知,利用神经网络学习的结果与实际损伤结果误差不超过 10%,完全可以满足工程实际的要求。因此,利用神经网络定量判断损伤程度是可行的。

2.3.3 双损伤程度的定量识别

对于双损伤的输入样本工况如表 3 所示,共 12 种损伤工况。把以上 12 种工况的应变模态差作为输入样本,每种损伤工况对应的损伤程度作为输出样本进行网络学习,比如损伤工况 11,对应输出向量(0 0 0 0 0 0 0 0 0 0 2.5 0 0 0 0 0 0 0 0 0 2.5 0 0 0 0),其神经网络层数和训练过程与单损伤情况相符。其测试样本工况设置如表 4 所示,共 9 种损伤工况,经过网络学习得到管道损伤程度,图 6 和图 7 列出损伤工况 1 和损伤工况 3 的训练结果。

表 3 双损伤输入样本工况

Tab. 3 The input conditions of double damage

工 况	损伤单元	损伤程度/mm	工 况	损伤单元	损伤程度/mm	工 况	损伤单元	损伤程度/mm
1	1,11	0.5	5	1,21	0.5	9	11,21	0.5
2	1,11	1.5	6	1,21	1.5	10	11,21	1.5
3	1,11	2.5	7	1,21	2.5	11	11,21	2.5
4	1,11	3.5	8	1,21	3.5	12	11,21	3.5

表 4 双损伤测试样本工况

Tab. 4 The testing conditions of double damage

工 况	损伤单元	损伤程度/mm	工 况	损伤单元	损伤程度/mm	工 况	损伤单元	损伤程度/mm
1	1,11	1	4	1,21	1	7	11,21	1
2	1,11	2	5	1,21	2	8	11,21	2
3	1,11	3	6	1,21	3	9	11,21	3

由图 6 和图 7 可知,可以明显看到管道损伤的单元位置,同时也可以得出其损伤程度,其网络计算值和实际损伤程度误差进行比较,如表 5 所示。由




图 6 测试工况 1 的训练结果

Fig. 6 Training results of testing conditions 1




图 7 测试工况 3 的训练结果

Fig. 7 Training results of testing conditions 3

表 5 可知,利用 BP 神经网络结构训练的结果与实际损伤结果的误差不超过 10%,也同样完全可以满足工程实际的要求,因此,BP 神经网络结构在双损伤程度识别上也具有可行性。

表 5 识别程度与实际程度比较

Tab. 5 The comparison between the identified degree and actual degree

工 况	损伤单元	损伤程度/mm	网络计算值/mm	误差/%	工 况	损伤单元	损伤程度/mm	网络计算值/mm	误差/%
1	1	1	0.964 2	3.68	6	11	3	3.211 1	7.04
	11	1	1.013 2	1.31		21	3	3.284 0	9.4
2	1	2	1.946 3	2.68	7	1	1	0.984 7	1.53
	11	2	1.978 9	1.05		21	1	1.049 7	4.97
3	1	3	2.979 2	0.69	8	1	2	1.946 6	2.67
	11	3	3.009 3	0.3		21	2	1.876 8	6.16
4	11	1	1.106 5	1.65	9	1	3	3.228 9	7.63
	21	1	1.047 6	4.76		21	3	3.277 1	9.24
5	11	2	1.917 4	4.13					
	21	2	1.865 7	6.71					

3 结 论

1) 验证了应变模态差在管道损伤识别中的应用,研究表明应变模态差对于管道的微小损伤有很高的敏感性。

2) 笔者提出用应变模态差和 BP 神经网络相结

合的方法识别管道损伤,以应变模态差作为神经网络的输入参数,损伤位置和损伤程度作为神经网络的输出参数。数值模拟的研究结果表明,该方法对于单损伤程度的定量识别误差在10%以内,识别结果有很高的可靠性。

3) 对于双损伤的定量识别,结果能够很精确地识别管道的损伤位置和损伤程度,且精度完全符合工程应用的要求,该研究为管道损伤定位和量化损伤程度提供了新的研究思路。

参 考 文 献

- [1] 蒋济同,于红理. 基于应变模态差的海洋平台构件的损伤识别研究[J]. 灾害学,2010,25(S0):67-69.
Jiang Jitong, Yu Hongli. Study on identification of offshore platform component damage based on strain modal difference [J]. Journal of Catastrophology, 2010,25(S0):67-69. (in Chinese)
- [2] 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.
Chen Suwen, Li Guoqiang. Application of artificial neural networks to damage identification of structures [J]. Journal of Vibration, Measurement & Diagnosis, 2001,21(2):116-124. (in Chinese)
- [3] 王步宇. 结构损伤的分形神经网络检测方法[J]. 振动、测试与诊断,2005,25(4):260-262.
Wang Buyu. Structural damage detection based on fractal neural network [J]. Journal of Vibration, Measurement & Diagnosis, 2005,25(4):260-262. (in Chinese)
- [4] 于菲,刁延松,佟显能,等. 基于振型差值曲率与神经网络的海洋平台结构损伤识别研究[J]. 振动与冲击,2011,30(10):190-194.
Yu Fei, Diao Yansong, Tong Xianneng, et al. Damage identification of an offshore platform based on curvature of modal shape difference and BP neural network [J]. Journal of Vibration and Shock, 2011,30(10):190-194. (in Chinese)
- [5] 孙宗光,高赞明,倪一清. 基于神经网络的损伤构件及损伤程度识别[J]. 工程力学,2006,23(2):18-22.
Sun Zongguang, Gao Zanming, Ni Yiqing. Structural damage detection based on fractal neural network [J]. Engineering Mechanics, 2006,23(2):18-22. (in Chinese)
- [6] 范建设,郑飞,许金余. 基于应变模态能与神经网络的地下拱形结构损伤诊断[J]. 噪声与振动控制,2011,31(3):120-124.
Fan Jianshe, Zheng Fei, Xu Jinyu. Damage diagnosis for underground arch structure based on modal strain energy and neural networks [J]. Noise and Vibration Control, 2011,31(3):120-124. (in Chinese)
- [7] 赵卓,王晓阳,梁军. 基于模态分析和神经网络的裂缝损伤识别[J]. 世界地震工程,2006,22(2):104-109.
Zhao Zhuo, Wang Xiaoyang, Liang Jun. The crack damage identification by the modal analysis and artificial neural networks [J]. World Earthquake Engineering, 2006,22(2):104-109. (in Chinese)
- [8] Dong Xiaoma, Wang Zhonghui. Damage severity assessment using modified BP neural network [C] // Materials Science and Engineering, 2010 International Conference on Materials Science and Engineering Science. Shenzhen, China; Trans Tech Publications, 2011:1016-1020.
- [9] Zhang Jun. Structural damage detection using parameters combined with changes in flexibility based on BP neural networks [C] // Advances in Civil Engineering and Architecture, 1st International Conference on Civil Engineering. Haikou, China; Trans Tech Publications, 2011:5475-5480.
- [10] Diao Yansong, Yu Fei, Meng Dongmei. Structural damage localization based on AR model and BP neural network [C] // Advances in Structural Engineering, 2011 International Conference on Civil Engineering and Transportation. Jinan, China; Trans Tech Publications, 2011:1211-1215.
- [11] Guo Lin, Wei Jianjun. Structural damage detection based on BP neural network technique [C] // 2010 International Conference on Intelligent Computation Technology and Automation. Changsha, China; IEEE Computer Society, 2010:398-401.
- [12] 李德葆,陆秋海. 实验模态分析及其应用[M]. 北京:科学出版社,2001:216-225.
- [13] Fu Jiyang, Liang Shuguo, Li Qiusheng. Prediction of wind-induced pressures on a large gymnasium roof using artificial neural networks [J]. Computers & Structures, 2007,85(3):179-192.
- [14] Sundareshan M K, Amoozegar F. Neural network fusion capabilities for efficient implementation of tracking algorithms [J]. Optical Engineering, 1997,36(3):682-707.



第一作者简介:周邵萍,女,1966年2月生,博士、教授。主要研究方向为结构健康监测与故障诊断。曾发表《YLII-4000J 烟气轮机振动监测与故障诊断》(《动力工程》2006年第26卷第4期)等论文。

E-mail: shpzhou@ecust.edu.cn