

# 小波神经网络在基桩动测信号处理中的应用

麦 榕<sup>1</sup>, 贺怀建<sup>1</sup>, 潘冬子<sup>2</sup>, 黄正华<sup>3</sup>

(1. 中国科学院武汉岩土力学研究所, 武汉 430071;

2. 浙江大学建工学院, 杭州 310027; 3. 江苏省电力建设第一工程公司, 南京 210072)

**摘要:** 基于小波变换的时频局部化特性及人工神经网络的非线性映射特性, 将小波变换和人工神经网络的优点结合起来, 从基桩动测信号二进小波变换的频域中提取特征, 最后将这些特征输入人工神经网络进行训练和分类, 进而实现基桩缺陷的诊断。数值模拟试验显示了该方法的合理性, 在此基础上进行了工程桩的现场试验研究, 结果表明训练成功的神经网络可以作为智能分类器对基桩常见缺陷进行识别和诊断。

**关键词:** 小波分析; 神经网络; 基桩检测; 缺陷诊断

**中图分类号:** TU473.1+6

**文献标识码:** A

**文章编号:** 1000-3665(2004)05-0091-06

## 1 前言

随着桩基工程的发展, 桩的动测技术得到了广泛的应用, 其中应力波反射法以其设备轻便、检测快速、成本低廉等优点而成为桩基完整性检测的重要手段, 取得了一定的社会效益和经济效益。但是由于基桩动测波形的判别主要依靠测试人员的经验, 故对于复杂的波形容易造成漏判和误判, 同时现场采集的数据经常含有噪声的干扰, 影响反射波突变的特征和时频定位, 严重时甚至会淹没反射波的性状, 使桩身质量检测结果存在较大的误差。

基桩反射波信号实际上是一时变非平稳信号, 时间和频率是这类信号两个极为重要的参数。小波分析是一种时频分析方法, 具有多分辨率分析的特点, 可以在时域和频域内表征信号的局部特征, 因此特别适合对非平稳信号的分析。神经网络以其并行分布式的处理、联想记忆、自组织及自学习能力和极强的非线性映射能力, 特别适合多故障、多征兆的复杂模式的识别问题<sup>[1]</sup>。若将两者结合起来, 对基桩低应变动测信号进行分析, 必将提高诊断的准确性, 因此本文提出了一种基于小波变换和神经网络的基桩缺陷诊断方法。数值模拟试验显示了该方法的合理性, 在此基础上进行了工程桩的现场试验研究, 结果表明: 小波神经网络对基桩缺陷具有较高的识别能力, 在基桩动测信号处理中

具有较好的应用前景。

## 2 基本原理

### 2.1 小波分析

小波分析的基本思想是将原始信号分解成一系列具有良好的频域定位性的基元信号, 利用基元信号的各种特征来表征原始信号的局部特征, 达到对信号进行时频局部化分析的目的。小波变换是把基本小波函数作平移后, 在不同尺度下与待分析的信号作内积<sup>[2]</sup>:

$$W_f(a, b) = \langle f, \psi_{a,b} \rangle \\ = |a|^{-1/2} \int_R f(t) \psi\left(\frac{t-b}{a}\right) dt \quad a > 0 \quad (1)$$

其中:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

变换结果  $W_f(a, b)$  反映了信号  $f(t)$  在尺度  $a$  (频率) 和位置  $b$  (时间) 的状态, 即小波变换实际上是一种时频分析。

设  $f(t)$  在  $t$  处连续,  $\psi(t) \in L^2(R)$ , 其傅立叶变换为  $\hat{\psi}(\omega)$ 。当  $\hat{\psi}(\omega)$  满足允许条件时:

$$C_\psi = \int_R \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (3)$$

则信号  $f(t)$  可由下式重构:

$$f(t) = \frac{1}{C_\psi} \int_R \int_R \frac{1}{a^2} W_f(a, b) \psi\left(\frac{t-b}{a}\right) da db \quad (4)$$

在实际应用中, 广泛使用的是二进制小波变换, 即取  $a = 2^j, j \in Z$ 。利用 Mallat 算法, 设有信号  $f(t)$  的离散采样序列  $f(n) (n = 1, 2, \dots, N)$ , 信号在尺度  $j = 0$  时的近似值记为:

收稿日期: 2003-09-03; 修订日期: 2004-04-30

作者简介: 麦榕(1975-), 男, 硕士研究生, 主要从事岩土工程测试技术方面的研究。

$$C_0(n) = C_j(n) |_{j=0} = f(n) \quad (5)$$

则离散二进小波变换由下式确定:

$$\begin{cases} C_{j+1}(n) = \sum_{k \in Z} H(k-2n) C_j(k) \\ D_{j+1}(n) = \sum_{k \in Z} G(k-2n) C_j(k) \end{cases} \quad (6)$$

式中:  $H(k-2n)$ 、 $G(k-2n)$ ——小波函数  $\phi(t)$  确定的两列共轭滤波器系数。

此时尺度函数由双尺度方程来确定:

$$\phi(t) = \sqrt{2} \sum_{k=-\infty}^{+\infty} H(k) \phi(2t-k) \quad (7)$$

相应的小波函数由双尺度方程来确定:

$$\psi(t) = \sqrt{2} \sum_{k=-\infty}^{+\infty} G(k) \phi(2t-k) \quad (8)$$

因此,信号的小波分解可以表示为:

$$\begin{aligned} A_j f(t) &= A_{j+1} f(t) + D_{j+1} f(t) \\ &= \sum_n C_j(n) \phi_n(t) + D_j(n) \psi_n(t) \end{aligned} \quad (9)$$

设  $V_j$  为由  $\phi$  张成的子空间,  $W_j$  为由  $\psi$  张成的子空间,则  $A_j f$  是  $f(t)$  在  $V_j$  上的投影,称为逼近信号,相当于一低通滤波器对  $f(t)$  滤波的结果;  $D_j f$  是  $f(t)$  在  $W_j$  上的投影,称为细节信号,相当于一组带通滤波器对  $f(t)$  滤波的结果。由此可见小波变换的实质是把原始信号中不同频段的信息抽取出来,并将其显示在时间轴上,这样既可以反映信号的时域特征也可以反映信号的频域特征。小尺度的变换包含信号的高频成分,大尺度则包含低频部分。因此我们就可以根据需要,选取不同尺度的变换来描述信号的特征。

## 2.2 基于小波变换特征提取的 BP 神经网络结构

神经网络具有学习和联想记忆功能,可以作为分类器实现模式识别。根据 Kolmogorov 定理,3 层结构的前向网络可以逼近任意连续函数,因此可以用它来解决缺陷信号的分类问题。

典型的 BP 网络有 3 层,即输入层、隐含层和输出层。每层由许多具有非线性映射能力的神经元组成,层间各神经元通过权系数相互连接,而层内各神经元之间无连接。BP 网络的学习,由“模式顺传播”和“误差逆传播”过程组成。由于 BP 神经网络是基于梯度下降的误差反向传播算法进行学习的,所以其网络训练速度通常很慢,而且很容易陷入局部极小点<sup>[3]</sup>。本文采用 Levenberg-Marguardt 优化理论实现对网络权值和阈值的调整,同时利用“提前休止”的算法来提高网络的推广能力。

基于小波变换和 BP 神经网络的桩身缺陷诊断系

统的结构如图 1 所示。

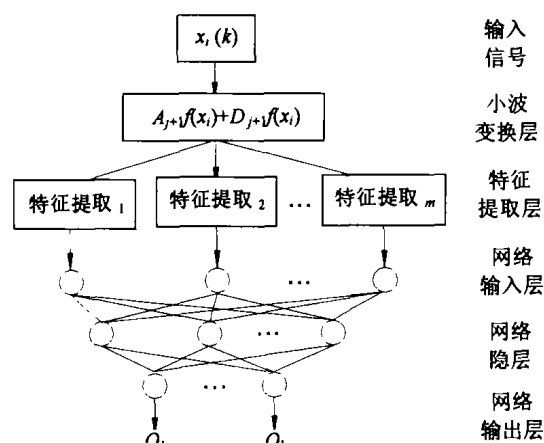


图 1 小波神经网络结构示意图

Fig.1 Sketch of wavelet and neural network structures

图 1 中  $x_i(k)$  是  $i$  个经放大、采样得到的基桩动测信号,小波变换层是对给定的信号用小波函数进行小波变换,得到不同频带上的信号分量;特征提取层提取指定频带上信号分量的特征参数;将这些特征参数作为人工神经网络的输入,当用标准样本对网络进行训练后,就可用于基桩缺陷的诊断。

## 3 应用实例

本文通过对基桩动测数值模拟信号的特征提取来构造诊断样本,将此样本作为训练数据对小波神经网络进行训练学习;网络训练完毕以后,再对某桩基工程的部分人工挖孔灌注桩进行了诊断测试。

### 3.1 数值模拟

该桩基工程的场地工程地质情况如表 1 所示。

表 1 地基各土层测试参数

Table 1 Test results of the soils in foundation

地层名称	层面埋深 (m)	层厚 (m)	压缩模量 (MPa)	侧阻 (kPa)	端阻 (kPa)
①素填土	/	0.4~2.3	/	/	/
②粉质粘土	0.4~2.3	0.0~4.0	4.5	30	/
③粉质粘土	0.4~5.5	3.7~8.2	11	45	1 400
④泥页岩强风化	7.8~9.2	0.5~1.9	20	65	3 000
⑤泥页岩中风化	8.6~11.0	本层未揭穿	30	75	3 500

设计桩长有 10m、11m、12m 3 种;桩径有 1.0m、1.1m、1.2m 3 种;桩身混凝土密度  $\rho = 2 400 \text{ kg/m}^3$ ;桩身纵波传播速度  $C = 3 500 \text{ m/s}$ ;桩顶瞬态纵向激振力采用升余弦函数式(10)来模拟,通过动力有限元的方法计算得到仿真的桩顶响应<sup>[4]</sup>。

$$p(t) = \begin{cases} \frac{1}{T} \left( 1 - \cos\left(\frac{2\pi t}{T}\right) \right) & |t| \leq \frac{T}{2} \\ 0 & |t| > \frac{T}{2} \end{cases} \quad (10)$$

式中:  $I$ 、 $T$ ——激振力的冲量和作用时间,在本文计算中  $I = 1 \text{ km} \cdot \text{m/s}$ ,  $T = 1.5 \times 10^{-3} \text{ s}$ 。

### 3.2 基于小波分析的特征提取

在小波分析的工程应用中,一个很重要的问题就是最优小波基的选取问题,这是因为运用不同的小波基解决同一个问题会产生不同的结果,另外,根据要从信号中提取的信息不同,也应恰当选择小波和构造小波函数。Daubechies 小波作为正交小波,具有有限紧支撑,其时域和频域局部化能力强,尤其是在数字信号的小波分解过程中可以提供有限长的更实际更具体的数字滤波器,因此,本文选择 Daubechies 小波系列的 db6 小波对桩顶响应信号  $S$  进行小波变换,对每一信号分解到第七层,即:

$$s = cA_7 + cD_7 + cD_6 + cD_5 + cD_4 + cD_3 + cD_2 + cD_1$$

一般而言,小波分解的级数越高,在这一级上信号的信息成分越丰富,从而可以更好地刻画信号的细节<sup>[5,6]</sup>。因此,在本文数值模拟试验中,对  $cA_7$ 、 $cD_7$ 、

$cD_6$ 、 $cD_5$  频带上的小波分量实施特征提取,提取参数为各频带范围内体现能量分布的功率谱均值和反映频率变换快慢的方差,具体步骤如下<sup>[7]</sup>:

(1)对信号的采样序列利用 db6 小波进行七层正交小波分解,得到第一层到第七层共 8 个小波分解系数序列  $\{cA_7, cD_7, cD_6, cD_5, cD_4, cD_3, cD_2, cD_1\}$ 。

(2)对小波分解系数进行重构,得到  $cA_7$ 、 $cD_7$ 、 $cD_6$ 、 $cD_5$  频带上的信号分量  $A_7$ 、 $D_7$ 、 $D_6$ 、 $D_5$ 。

(3)对信号分量  $A_7$ 、 $D_7$ 、 $D_6$ 、 $D_5$  进行功率谱分析。图 2 给出了 3 种典型缺陷的小波变换及频谱图。

(4)特征向量的构成。以 4 个信号的功率谱均值  $E_1$ 、 $E_2$ 、 $E_3$ 、 $E_4$  以及方差  $S_1^2$ 、 $S_2^2$ 、 $S_3^2$ 、 $S_4^2$  组成特征向量,即  $F = \{E_1, E_2, E_3, E_4, S_1^2, S_2^2, S_3^2, S_4^2\}$ 。显然,特征向量的维数为 8,对于各种类型的桩身缺陷具体数值如表 2 所示。

### 3.3 小波神经网络分类器的设计

表 2 各种桩身缺陷的特征向量数据(平均值)

Table 2 The eigenvector of various faults of piles (mean value)

类别	特征向量							
	$E_1$	$E_2$	$E_3$	$E_4$	$S_1^2$	$S_2^2$	$S_3^2$	$S_4^2$
完整桩	0.0654	0.0635	0.8604	0.0036	0.0165	0.0103	0.9730	0.0001
断桩	0.1191	0.0347	0.5558	0.2696	0.0575	0.0055	0.7910	0.1453
扩颈	0.0846	0.1322	0.5864	0.1720	0.0239	0.0762	0.8611	0.0382
缩颈	0.1080	0.1491	0.5357	0.1847	0.0647	0.1230	0.7312	0.0803
离析	0.1122	0.1239	0.5593	0.1792	0.0693	0.0993	0.7654	0.0694
浅部裂缝	0.3868	0.3773	0.1805	0.0367	0.6721	0.2868	0.0399	0.0008
扩底	0.0813	0.1036	0.5908	0.2012	0.0156	0.0993	0.8147	0.0696
桩尾松散	0.1082	0.0812	0.5894	0.1961	0.0612	0.0329	0.8212	0.0837

#### 3.3.1 样本数据的定义和预处理

通过数值模拟得到 8 个缺陷类别的 312 组数据,每组数据对应 8 个特征向量值。试验以特征编码作为输入,以缺陷编码作为输出。

为了提高网络的训练效率,需要对样本数据进行了适当的预处理。根据参考文献[3],当变量呈正态分布时,数据对网络的学习最有效。因此,对样本数据作归一化处理,使得归一化的输入和目标数据服从正态分布。

#### 3.3.2 对训练样本、验证样本和测试样本的划分

为了提高网络的推广能力和识别能力,训练中采用了“提前休止”的方法。在该方法中,训练样本集在训练之前被划分为训练集、验证集和测试集。训练集

用于对神经网络进行训练;验证集用于对神经网络训练的同时监控网络的训练进程,当验证误差达到一定程度时,网络训练会提前停止,这时训练函数会返回验证误差取最小时的网络对象;测试集形成的测试误差在网络训练时未被使用,但它可以用来评价网络训练结果和样本集划分的合理性。在本文计算过程中,验证样本和测试样本均是从原样本数据中均匀选取 1/4 而生成的。

#### 3.3.3 网络生成和训练

选用含有一个隐层的 BP 神经网络,其中网络输入维数为 8,输出维数为 8,隐层的节点数取为 18,传递函数采用对数 Sigmoid 函数:

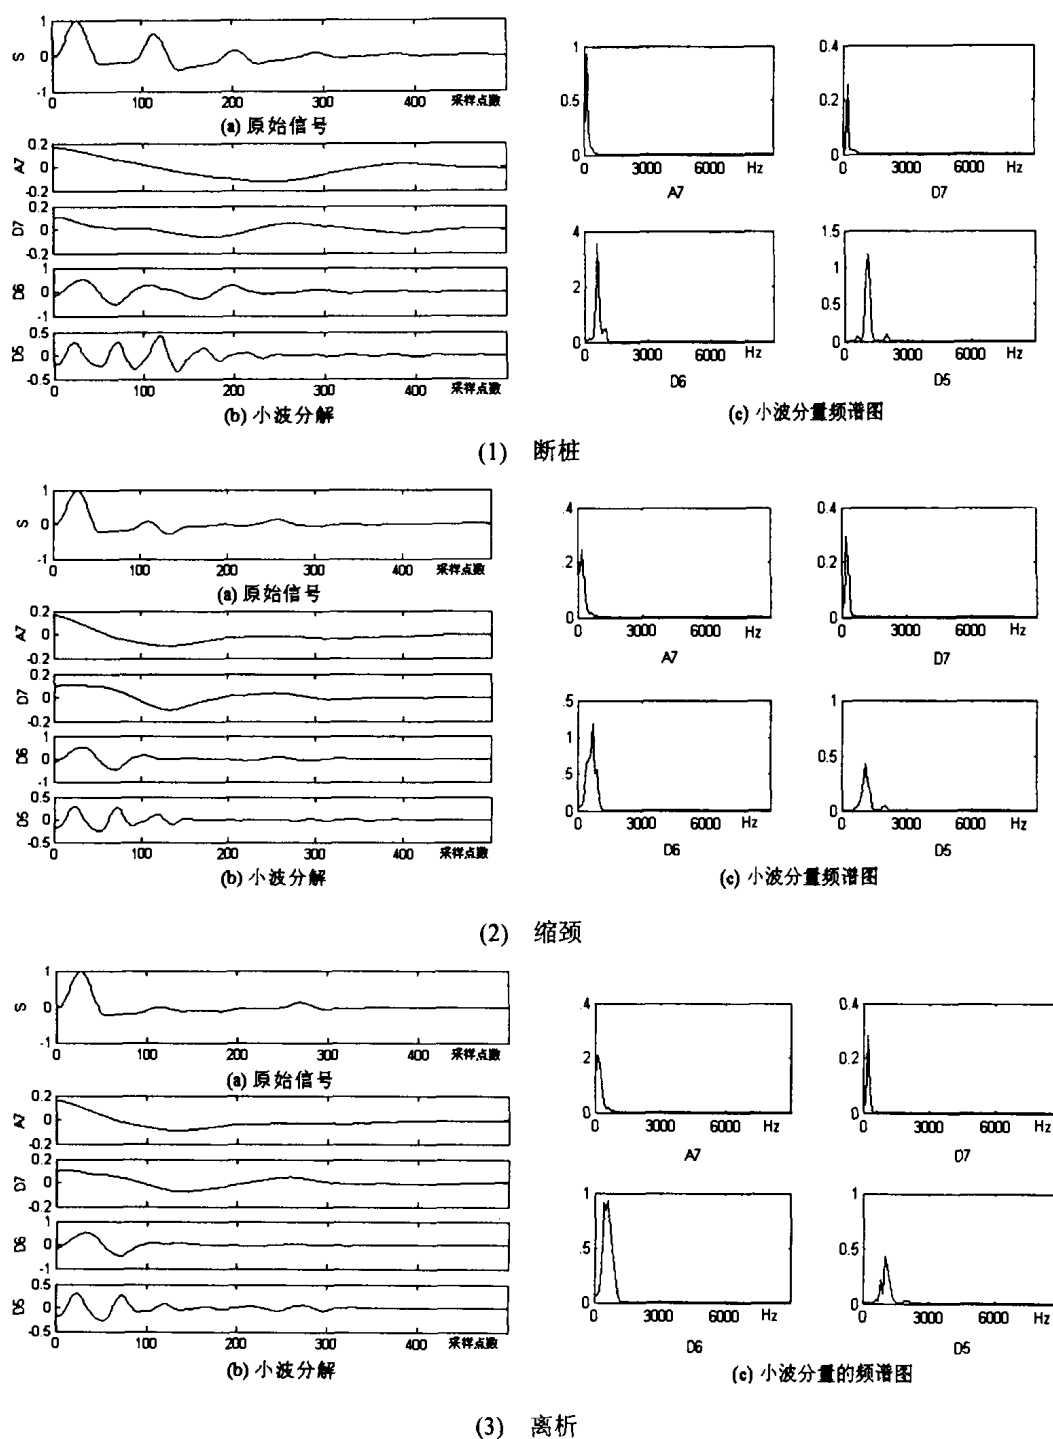


图 2 三种典型缺陷的小波变换及频谱图

Fig.2 The wavelet transforms and spectrum of three typical faults

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (11)$$

网络训练的误差变化曲线如图 3 所示,可见当网络迭代至 1280 步时提前停止,这是由于验证误差已经开始变大。从图中可知,验证误差和测试误差的变化趋势基本一致,说明样本集的划分基本合理,由训练误差的曲线可见,训练误差的结果也是比较满意的。

### 3.3.4 网络仿真

为了进一步验证训练后网络的性能,对网络仿真的输出结果和目标输出作线性回归分析,并得到两者的相关系数,从而可以作为网络训练结果优劣的判断依据。图 4 给出了网络 8 个输出的线性回归分析结果曲线,检测结果的输出是令人满意的。

### 3.3.5 网络测试




图 3 训练误差变化曲线

Fig.3 The curves of training error

为了验证所建立的神经网络的精度和可靠性,对现场实测信号进行了诊断分析。图 5 是实测桩顶响应曲线,其中 S1 和 S6 为完整桩的动测信号,S2 为浅部裂缝桩的动测信号,S3 为缩颈桩的动测信号,S4 为离析桩的动测信号,S5 为断桩的动测信号;表 3 是神经网络识别结果。

从表 3 的识别结果来看,这种基于小波分析的人工神经网络可以准确的对各种基桩缺陷进行识别。通过该桩基工程近 400 根桩的识别统计结果表明,其正确识别率可达 95% 以上,特别是对完整桩、断桩、浅部缺陷和离析桩的判别尤为准确,接近 100%。

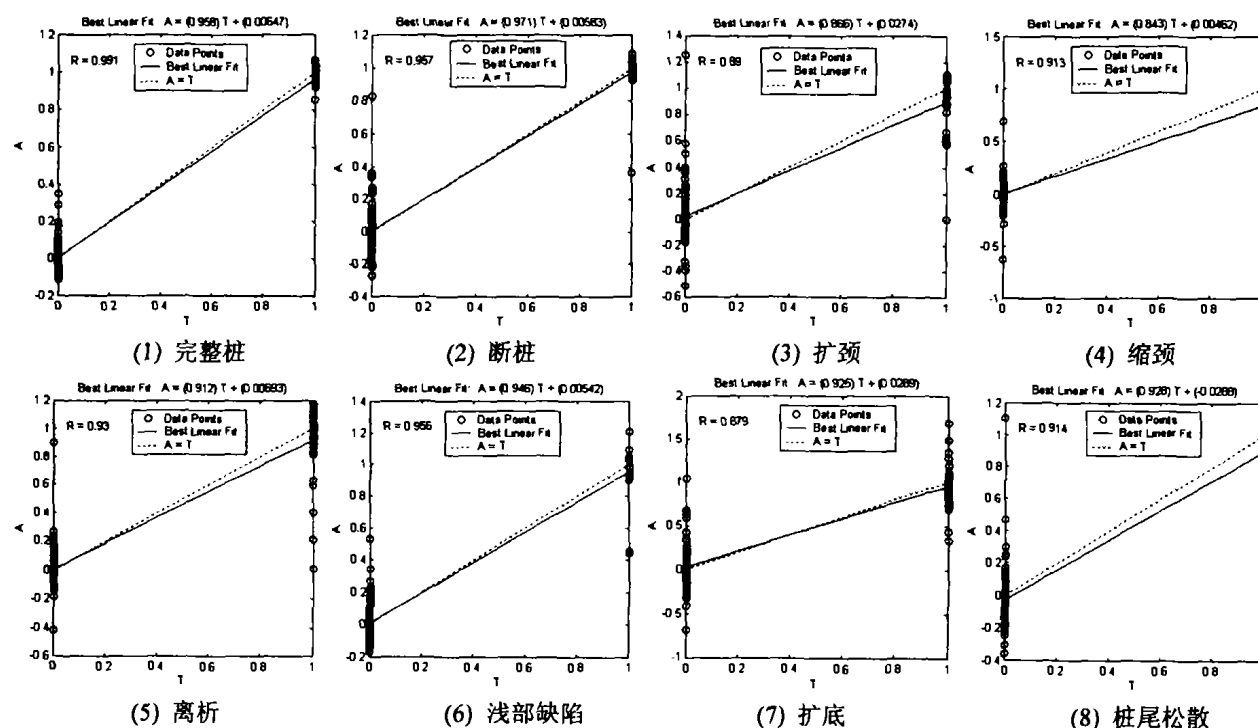


图 4 网络输出回归分析结果

Fig.4 The regression analysis results of output by the network

表 3 网络的期望输出和实际输出

Table 3 The expected and practical output of the network

		缺陷类别							
		1	2	3	4	5	6	7	8
S1	期望	1	0	0	0	0	0	0	0
	实际	0.988	0.000	0.001	0.001	0.008	0.003	0.001	0.005
S2	期望	0	0	0	0	0	1	0	0
	实际	0.000	0.000	0.001	0.002	0.002	0.993	0.00	0.001
S3	期望	0	0	0	1	0	0	0	0
	实际	0.00	0.004	0.006	0.979	0.002	0.003	0.001	0.005
S4	期望	0	0	0	0	1	0	0	0
	实际	0.004	0.002	0.001	0.001	0.982	0.003	0.002	0.000
S5	期望	0	1	0	0	0	0	0	0
	实际	0.00	0.990	0.001	0.007	0.003	0.004	0.002	0.001
S6	期望	1	0	0	0	0	0	0	0
	实际	0.964	0.005	0.007	0.002	0.008	0.001	0.003	0.004




图 5 实测波形图

Fig.5 The measured oscillogram

#### 4 结论

(1) 基桩缺陷类型不同时, 所对应的信号特征频率在不同的频带内有不同的分布。本文借助小波变换能将原始信号的频带分解到一系列不同频段内的性质, 进行了特征提取, 利用小波神经网络进行学习和识别, 结果表明该方法能成功地对各种基桩缺陷类型进行智能鉴别。

(2) 小波神经网络的应用, 为基桩完整性检测结果的评定提供了一个有效的智能化的手段, 克服了结果

分析精度依赖个人经验的缺点, 在基桩动测信号处理中具有较好的应用前景。

#### 参考文献:

- [1] 姜绍飞. 基于神经网络的结构优化与损伤检测 [M]. 北京: 科学出版社, 2002.
- [2] 胡昌华, 张军波, 等. 基于 Matlab 的系统分析与设计——小波分析 [M]. 西安: 西安电子科技大学出版社, 1999.
- [3] 许东, 吴铮. 基于 Matlab 6. x 的系统分析与设计——神经网络 [M]. 西安: 西安电子科技大学出版社, 2002.
- [4] 潘冬子, 黄正华, 等. 桩土体系相互作用的计算机仿真分析 [J]. 煤田地质与勘探, 2004, 32(4): 36 - 40.
- [5] 张良均, 王靖涛, 等. 小波变换在桩基完整性检测中的应用 [J]. 岩石力学与工程学报, 2002, 21(11): 1735 - 1738.
- [6] 吴森, 张海燕. 超声检测缺陷分类的小波分析与神经网络方法 [J]. 中南矿业大学学报, 2000, 29(3): 239 - 242.
- [7] 潘冬子. 小波分析及其在基桩完整性检测中的应用研究 [D]. 武汉: 中科院武汉岩土力学研究所硕士学位论文, 2004.

## Application of wavelet and neural network in dealing with dynamic testing signals of piles

MAI Rong<sup>1</sup>, HE Huai-jian<sup>2</sup>, PAN Dong-zi<sup>2</sup>, HUANG Zheng-hua<sup>3</sup>

(1. Institute of Rock and Soil Mechanics, Chinese Academy of Science, Wuhan 430071, China;

2. School of Civil and Architectural Engineering, Wuhan University, Wuhan 430072, China;

3. The First Power Construction Company of Jiangsu Province, Nanjing 210028, China)

**Abstract:** Based on the time-frequency localization of wavelet transform and the nonlinear mapping of neural network, a method of dynamic testing signals combining with the advantage of wavelet analysis and neural network is presented. Some features are extracted from the frequency spectrum analysis at the various resolution of the dyadic wavelet transform. These features are taken the wavelet neural network as the input patterns for training and classifying. Then, it can be used to diagnose the faults of piles. The result of insitu test is in good agreement with numerical simulation and it show that this method can successfully be applied to the identification and diagnosis of plies faults as an intelligitized classifier.

**Key words:** wavelet analysis; BP neural network; dynamic testing; signal analysis; fault diagnosis