

小波包能量谱和 BP 神经网络在波纹管压浆 超声检测中的应用

梁 凯, 韩庆邦

(河海大学物联网工程学院, 江苏常州 213022)

摘要: 针对小波分析在信号处理的局限性, 将小波包分析和反向传播(Back Propagation, BP)神经网络相结合, 提出一种基于小波包能量谱和 BP 神经网络的波纹管压浆超声检测方法。采用超声检测方法接收波纹管模型的回波信号, 以小波包分解后各子频带的能量作为检测特征, 当波纹管内部出现脱落时, 检测特征会发生变化, 最后将特征输入 BP 神经网络中进行分类识别。试验结果表明, 该方法能够理想地实现波纹管内部缺陷的诊断, 可为波纹管超声检测提供一定的技术支持。

关键字: 超声检测; 小波包; 能量谱; BP 神经网络

中图分类号: TB551

文献标识码: A

文章编号: 1000-3630(2020)-02-0151-06

DOI 编码: 10.16300/j.cnki.1000-3630.2020.02.005

Application of wavelet packet energy spectrum and BP neural network to ultrasonic detection of slurry in bellows

LIANG Kai, HAN Qingbang

(College of Internet of Things Engineering of Hohai University, Changzhou 213022, Jiangsu, China)

Abstract: Considered the limitation of wavelet analysis in signal processing, a wavelet analysis method based on wavelet packet energy spectrum and Back Propagation (BP) neural network is proposed to detect the slurry quality in bellows. Ultrasonic detection method is adopted to receive the echo signal of the bellows model, and the energy in every sub-frequency band after the wavelet packet decomposition is taken as the detection feature. When the concrete slurry inside the bellows falls off, the detection features change. Finally, the features are input into the BP neural network for classification and identification. The experimental results show that this method can be used to diagnose the internal defects of bellows and provides a technical support for the non-destructive testing of bellows.

Key words: ultrasonic detection; wavelet packet; energy spectrum; Back Propagation (BP) neural network

0 引 言

预应力混凝土梁是一种高强度的承重结构, 在桥梁建设过程中被广泛使用, 在施工过程中, 波纹管中混凝土的压浆质量备受重视。如果由于灌浆过程中施工操作不当, 以及受环境的影响, 波纹管内部附着在钢绞线上的混凝土存在不密实和脱落情况, 那么会对桥梁的安全使用带来很大的隐患。因此, 对于波纹管压浆质量的检测就显得至关重要。

无损检测在不损坏建筑结构的前提下, 还具有无害、设备携带方便、检测快捷等优点。目前常采

用的无损检测技术主要有射线法、冲击回波法(Impact-Echo, IE)、探地雷达法(Ground Penetrating Radar, GPR)、超声波成像法(Ultrasonic Test, UT)、表面频谱成像法(Spectral Analysis of Surface Wave, SASW)等^[1-2]。对于这些方法, 结合检测成本、准确度、原理和安全性等评价因素, 超声应用到无损检测技术方面一直受到国内外学者的高度关注。对于波纹管压浆质量的检测, 成锦等^[3]利用小波熵技术取得了很好的效果; 陈媛、郑豪等将递归奇异熵和多尺度排列熵应用到其中, 也取得不错的效果^[4-5]; 郑豪等^[5]也将总体平均经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)和支持向量机(Support Vector Machine, SVM)结合起来, 有效地实现了波纹管缺陷情况的自动分类检测。

小波包分析是对小波的推广, 在不同尺度下观察可以得到其特征变化, 对信号频带能够多层次划分, 对信号的分辨能力也得以大大提高。由缺陷隐

收稿日期: 2019-01-26; 修回日期: 2019-03-19

基金项目: 国家自然科学基金(11574072, 11274091)、江苏省重点研发项目(BE2016056, BE2017013)资助课题

作者简介: 梁凯(1991—), 男, 河南商丘人, 硕士研究生, 研究方向为通信与信息系统。

通讯作者: 韩庆邦, E-mail: hqb0092@163.com

藏在波纹管的回波信号中, 很难直观地看出缺陷的位置等具体信息, 因此本文从波纹管回波信号入手, 对信号进行小波包分解, 小波包分解后具有丰富的信息和数据, 可求取分解信号的能量谱; 以小波包能量谱作为信号特征, 输入到反向传播(Back Propagation, BP)神经网络中进行训练、识别, 进而检测波纹管压浆的密实性。

1 小波包能量谱理论

1.1 小波包理论

小波包分解^[6]是一种优于小波、分解更细腻的信号处理方式, 它可对低频和高频同时处理, 对信号划分多个频段, 使缺陷特征更加细致。图 1 为小波包三层分解的过程。




图 1 三层小波包分解示意图

Fig.1 Schematic diagram of three-layer wavelet packet decomposition

从图 1 中可以看出, 小波包每次分解都会得到低频、高频两个子频带; 对于 n 层分解的小波包信号, 可以得到 2^n 个子频带。小波包分解可以精确地对信号进行局部分析。

3 层小波包分解关系式为

$$(0,0)=(3,0)+(3,1)+(3,2)+(3,3)+(3,4)+(3,5)+(3,6)+(3,7) \quad (1)$$

使 $u_n(t)$ 满足二维尺度方程:

$$u_{2n}(t)=\sqrt{2}\sum_{w\in\mathbb{Z}}h_wu_n(2t-w) \quad (2a)$$

$$u_{2n+1}(t)=\sqrt{2}\sum_{w\in\mathbb{Z}}g_wu_n(2t-w) \quad (2b)$$

式(2)中, h_w 、 g_w 为多分辨率分析中高通滤波器和低通滤波器的系数, 满足 $g_w=(-1)^w h_{-w}$, 因此为正交镜像滤波器组, w 决定平移幅度, t 为自变量。当 $n=0$ 时, $u_0(t)=\phi(t)$, 为正交尺度函数, 当 $n=1$ 时, $u_1(t)=\psi(t)$, 为小波基函数, 因此, 函数系 $\{u_n(t)\}$ 称为由基函数 $u_0(t)=\phi(t)$ 确定的正交小波包。

1.2 小波包能量谱分析

每次小波包分解可以得到两个相互独立的子频带, 而原信号的信息也会分解到其子频带中。当波纹管内部出现不同的脱落缺陷时, 就会对回波信

号在各频带的能量分布产生影响, 然后根据不同的分布情况, 可以区别波纹管内部有无缺陷以及缺陷情况。因此, 小波包分解后各频带能量的分布特征可以作为判断波纹管内部情况的重要依据。

假设一个离散信号 $x^{k,m}(i)$, 其数据长度为 N , 该信号的能量表达式为

$$E_n[x^{k,m}(i)]=\frac{1}{N}\sum_{i=1}^N[x^{k,m}(i)]^2 \quad (3)$$

式子中, k 为分解次数; m 为分界频带的位置序号 ($m=0,1,\dots,2^k-1$)。

由能量守恒可以得到关系式:

$$E_n[x(t)]=\sum_{m=0}^{2^k-1}E_n(U_{j-k}^{2^k+m})=\sum_{m=0}^{2^k-1}E_n[x^{k,m}(i)] \quad (4)$$

第 m 频带分解信号占总能量的比例, 即归一化的小波包分解的频带能量为

$$E_n(m)=\frac{E_n[x^{k,m}(i)]}{E_n[x(t)]} \quad (5)$$

全部频带能量比例总和应该等于 1, 即:

$$\sum_{m=0}^{2^k-1}E_n(m)=1 \quad (6)$$

2 BP 神经网络

人工神经网络(Artificial Neural Networks, ANNs)是一种类生物的数学模型, 原理就是模拟大脑神经进行数据处理, 常被称之为类神经网络或者神经网络。反向传播 BP(Back Propagation)神经网络^[7-8]是 Rumelhart 等^[8]于 1986 年提出的基于误差反向传播训练算法的神经网络计算模型, BP 神经网络的优势在于, 如果存在足够多的隐含层和节点的话, 就可以逼近任意的非线性映射关系, 具有较好的泛化能力^[9]。对于典型的 BP 神经网络模型, 包括输入层(input layer)、隐含层(hidden layer)、输出层(output layer)三层结构, 其结构如图 2 所示; 每层内有若干个神经元, 神经元模型如图 3 所示。




图 2 BP 神经网络拓扑结构图

Fig.2 Topology structure diagram of BP neural network




图 3 BP 神经元模型
Fig.3 BP neuron model

3 仿真分析

3.1 仿真模型建立

波纹管压浆结构模型如图 4 所示，该波纹管结构最外层是包裹的混凝土材料，其内部中心由钢绞线提供支撑，而钢绞线和波纹管中间的空隙部分，则用水泥浆填充，在钢绞线附近可能出现水泥浆不同程度的脱落情况，这就是本文研究的部分。超声波在传播过程中，当遇到不同介质之间的界面时，会发生不同程度的反射、透射以及散射。混凝土和空气是声阻抗差异比较大的两种物质，所以，超声波由混凝土传播到空腔的过程中，会在固-气(水泥浆-空气)界面发生强烈的反射，这些反射信号就包含着波纹管内部缺陷的信息，通过对反射信号的有效处理，可以实现对缺陷的检测。




图 4 波纹管压浆结构模型
Fig.4 Structure model of slurry in bellows

首先，对不同程度脱落的波纹管进行仿真分析，利用 COMSOL Multiphysics^[10]仿真软件设计如图 5 所示的仿真模型，该模型的尺寸为 150 cm×30 cm，波纹管内径为 8.4 cm，壁厚为 3 mm，中心钢绞线直径为 1 cm。从图 5 的模型可以看出，模型根据波纹管缺陷程度分为 6 部分，Q1~Q6 代表现实中不同脱落程度的波纹管结构，其中 Q1 代表完整无缺陷的波纹管模型，其余模型均为脱落模型，Q6 为全脱落模型；在超声检测过程中把模型分为以下三类：

A 类：波纹管内部压浆密实模型，即内部没有缺陷或者缺陷很小；




图 5 波纹管仿真模型
Fig.5 The simulation model of bellows

B 类：波纹管内部压浆一般密实模型，即内部存在水泥浆脱落但还没有完全脱落的情况；

C 类：波纹管内部压浆全部脱落模型，即内部完全脱浆。

波纹管模型脱落尺寸如表 1 所示。

表 1 波纹管模型尺寸(cm)						
模型段	Q1	Q2	Q3	Q4	Q5	Q6
纵向缺陷	\	1	2	3.8	6	8.4
横向缺陷	\	8	8	8	8	8

本文采用二维仿真，在二维图中激励源长度设置为 2 cm，回波信号通过自发自收的方式获取。激励源的发射信号是汉宁窗调制的脉冲信号，表达式如式(7)：

$$S(t)=\frac{1}{2}\left(1-\cos\frac{2\pi t}{t_0}\right)\cos\left[2\pi f\left(t-\frac{t_0}{2}\right)\right],\quad t<t_0\quad (7)$$

其中，f=200 kHz 为信号的中心频率，t₀=10 μs。

3.2 仿真结果分析

分别以接收的无缺陷 Q1 模型和全脱落 Q6 模型的超声回波信号为例进行分析，回波信号如图 6、7 所示。Q6 模型波纹管内部结构比较复杂，一次接收的回波信号也比较复杂，包含大量内部信息，这些信息很难直接从波形中看出，因此，对信号的有效处理可以直观地反映出波纹管的内部信息。




图 6 无缺陷模型 Q1 的回波信号
Fig.6 The echo signal in defect-free model Q1




图 7 有缺陷模型 $Q6$ 的回波信号
Fig.7 The echo signal in defective model $Q6$

对典型的无缺陷回波信号进行小波包分解, 选择使用 db3 小波进行 3 层分解, 共得到 8 组分解信号, 图 8 为 $Q1$ 信号分解后的波形; 计算分解后频带的能量谱信息, 得到能量谱, 如图 9(a)所示。根据图 9 可知, $Q1$ 无缺陷模型的能量主要集中在分量 2 和分量 4, 随着缺陷的改变, 分量 2 和分量 4 的能量比例会发生变化, 其余分量上的能量比例也会发生微弱变化, 但是回波信号的能量主要集中在低频处, 且存在一定的不规则性。

缺陷判别过程如下: (1) 以求得的回波信号分解的能量谱作为 BP 神经网络的输入样本, 同时对 3.1 节中的不同模型进行编码, 作为相应的期望输出, 分别为 A 类波纹管内部压浆密实模型(1,0,0)、B 类波纹管内部压浆一般密实模型(0,1,0)、C 类波纹管内部压浆全部脱落模型(0,0,1); (2) 对 BP 神经







图 8 $Q1$ 回波信号的分解
Fig.8 Decomposition of $Q1$ echo signal



(a) $Q1$ 模型能量谱分布



(b) $Q3$ 模型能量谱分布



(c) $Q6$ 模型能量谱分布

图 9 不同模型状态下的小波包能量谱分布
Fig.9 Distribution of wavelet packet energy spectrum in different model states

网络结构进行确定, 中间层神经元选择 S 型正切函数为激活函数, 输出层的激活函数为 S 型对数函数; (3) 利用已经建立好的 BP 神经网络结构和输入样本进行样本训练。分别以 $Q1$ 、 $Q3$ 、 $Q6$ 这 3 个仿真模型对应 A 类、B 类、C 类作为训练输入; 以此结构对上述模型进行判别, 输出分别为 $Q1(1,0,0)$ 、 $Q2(1,0,0)$ 、 $Q3(0,1,0)$ 、 $Q4(0,1,1,0)$ 、 $Q5(0,0,1,0,9)$ 、 $Q6(0,0,1)$ 。

从 BP 神经网络的分类判别来看, $Q2$ 模型比较接近 $Q1$ 模型, 判别为 A 类压浆密实模型; $Q4$ 模型较为接近 $Q3$ 模型, 判别为 B 类波纹管内部压浆一

般密实模型;对于Q5模型,其判别输出更为接近Q6,波纹管内部压浆全部脱落模型。仿真结果表明,此方法较适用于模型缺陷有无的检测,对于缺陷差距较小的模型的判别可能存在一定误差。

4 实验分析

根据仿真需求,对实际波纹管缺陷位置进行设计以及浇筑,构造如图10所示的波纹管混凝土结构。浇筑试块的尺寸是 $10\text{ m}\times 0.5\text{ m}\times 1\text{ m}$,其中,波纹管内径是 69 mm ,波纹管壁厚是 3 mm ,内部设有不同程度的空气泡缺陷,预设模型如图11所示,缺陷的宽度统一设置为 20 mm ,长度分别为 $0、5、30、45、60、69\text{ mm}$ 。以内部缺陷尺寸 $20\text{ mm}\times 45\text{ mm}$ 代表B类缺陷。本次实验以功率为 200 kW 、频率为 200 kHz 的单脉冲为激励源,采用一发一收的方式,采样频率为 1 MHz 。获取的回波信号如图12、13所示。




图10 实验模型
Fig.10 Experimental model




图11 实验模型结构图
Fig.11 The structure diagram of experimental model




图12 实测典型无缺陷回波信号
Fig.12 The typical measured echo signal in the experimental defect-free model






图13 实测典型缺陷回波信号
Fig.13 The typical measured echo signals in experimental defective model

对比图12、13可知,模型内部的缺陷情况隐含在波纹管回波反射信号中,由于不同缺陷的存在,回波信号的缺陷反射时刻以及幅值都有所差异,且受到各种因素的影响,很难从回波信号清晰直观地判别出波纹管内部的缺陷情况。所以,采用仿真的方法,利用小波包分解后的能量谱(如图14所示)作为判别指标输入到BP神经网络进行自动判别。本次实验采集试件中对应A类、B类、C类的信号各20组,将这20组信号的特征向量作为输入,期望输出如3.2节预设相同。建立判别器后,采集



(a) 无缺陷



(b) 有缺陷

图14 实测典型回波信号的小波包能量谱分布
Fig.14 Wavelet packet energy spectrum distribution of typical measured echo signals

实际测量模型信号, 计算实测信号的特征向量, 输入 BP 神经网络系统, 检测结果如下: I (1,0,0)、II (1,0,0)、III (0.1,1,0)、IV (0,1,0)、V (0,0.3,0.8)、VI (0,0,1)。从输出的数据来看, II 段模型和 I 段模型(A 类压浆密实模型)相吻合; III 段模型比较接近 IV 段模型(B 类波纹管内部压浆一般密实模型); V 段模型接近 VI 段模型(C 类波纹管内部压浆全部脱落模型)。为了验证该判别器的稳定性, 测试采集 A 类、B 类、C 类模型的回波信号各 20 组、共 60 组信号作为判别样本, 神经网络的判别结果如表 2 所示。从表 2 中的判别结果可以看出, BP 神经网络对于这三类不同的波纹管类型的判别准确率分别为 90%、80%、85%, 其中对 A 类压浆密实的波纹管类型判别正确率最高。可见通过超声脉冲回波信号获取波纹管的内部信息, 经过小波包能量谱处理以及 BP 神经网络的判别, 可以初步判断波纹管内部的压浆情况。

表 2 BP 神经网络判别结果
Table 2 The discriminant results of BP neural network

波纹管类型	判别样本数	判别错误数	正确率/%
A 类	20	2	90
B 类	20	4	80
C 类	20	3	85

5 结 论

小波包能量谱作为一种时频分析方法, 将波纹管超声回波信号进行小波分解并进行能量分布分析, 其结果作为反映波纹管内部水泥浆脱落程度的特征, 结合 BP 神经网络, 可以有效地对波纹管内部是否存在严重的空腔缺陷进行判别。但是, 本文设置的缺陷模型较为单一, 对于复杂模型的精确判别还需作进一步研究。

参 考 文 献

- [1] SAKA M, SALAM AKANDA M A. Ultrasonic measurement of the crack depth and the crack opening stress intensity factor under a no load condition[J]. Journal of Nondestructive Evaluation, 2004, 23(2): 49-63.
- [2] 罗斯 J L 著. 固体中的超声波[M]. 何存富, 吴斌, 王秀彦, 译. 科学出版社, 2004
- [3] 成锦, 韩庆邦, 范洪辉, 等. 基于小波熵技术的波纹管压浆质量无损检测[J]. 压电与声光, 2014, 36(6): 1026-1029.
CHENG Jin, HAN Qingbang, FAN Honghui, et al. Nondestructive test of corrugated pipe grouting based on wavelet entropy technology[J]. Piezoelectrics & Acoustooptics, 2014, 36(6): 1026-1029.
- [4] 陈媛, 韩庆邦, 姜学平, 等. 基于递归奇异熵方法的波纹管压浆超声检测[J]. 声学技术, 2016, 35(1): 44-48.
CHEN Yuan, HAN Qingbang, JIANG Xueming, et al. Nondestructive test method based on singular entropy of recurrence matrix[J]. Technical Acoustics, 2016, 35(1): 44-48.
- [5] 郑豪, 韩庆邦, 王鹏. 基于 EEMD-SVM 的波纹管压超声检测[J]. 无损检测, 2018, 40(6): 38-42.
ZHENG Hao, HAN Qingbang, WANG Peng, et al. Ultrasonic testing of corrugated pipe based on the ensemble empirical mode decomposition and support vector machine[J]. Nondestructive Testing, 2018, 40(6): 38-42.
- [6] 徐晶, 刘德坤, 刘彦慧, 等. 基于小波包能量谱及 SVM 算法的轴承故障检测[J]. 黑龙江科技大学学报, 2015, 25(1): 110-114.
XU Jing, LIU Dekun, LIU Yanhui, et al. Bearing fault detection method based on wavelet packet energy spectrum and SVM algorithm[J]. Journal of Heilongjiang University of Science & Technology, 2015, 25(1): 110-114.
- [7] HANSEN L K, SALAMON P. Neural network ensembles[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(10): 993-1001.
- [8] RUMELHART D E, MCCLELLAND J L, the Pap Research Group. Parallel distributed processing: explorations in the microstructures of cognition Volume1: Foundations[M]. Cambridge: Bradford Books/MIT Press, 1986.
- [9] 焦敬品, 李勇强, 吴斌, 等. 基于 BP 神经网络的管道泄漏声信号识别方法研究[J]. 仪器仪表学报, 2016, 37(11): 2588-2596.
JIAO Jingpin, LI Yongqiang, WU Bin, et al. Research on acoustic signal recognition method for pipeline leakage with BP neural network[J]. Chinese Journal of Scientific Instrument, 2016, 37(11): 2588-2596.
- [10] HAN Q B, CHENG J, FAN H H, et al. Ultrasonic nondestructive testing of cement grouting quality in corrugated pipes based on impact-echo[J]. Journal of Advanced Concrete Technology, 2014, 12(11): 503-509.