



## 基于人工神经网络的扬声器故障检测方法

王思俊, 许增朴, 于德敏, 王永强  
(天津科技大学机械工程学院, 天津 300222)

**摘要:** 提出了一种基于神经网络的扬声器故障检测方法. 通过扫频仪激励扬声器, 采集扬声器的响应信号, 利用小波包分解的方法时频分析响应信号, 得到各频段的能量; 对分解后各频段信号的特征能量进行提取, 规一化特征能量; 把规一化后的特征能量作为人工神经网络的输入, 通过 BP 神经网络对扬声器故障进行分类识别. 实验对 165 个扬声器进行识别, 识别率为 95.8%. 实验结果表明, 该方法简便有效, 具有实用价值.

**关键词:** 扬声器; 小波包变换; 特征提取; 神经网络; 故障诊断

中图分类号: TB52 文献标识码: A 文章编号: 1672-6510 (2008) 01-0046-03

### Method of Testing Loudspeaker Fault Base on Artificial Neural Networks

WANG Si-jun, XU Zeng-pu, YU De-min, WANG Yong-qiang

(College of Mechanical Engineering, Tianjin University of Science & Technology, Tianjin 300222, China)

**Abstract:** A fault diagnosis method based on artificial neural networks was presented. After the loudspeaker was incentivised by the sweeping LAU, the response signal of loudspeaker can be acquired. The response signal was decomposed by means of wavelet packet decomposition of time-frequency analysis method, each band decomposition characteristics energy was extracted, the feature energy was normalized put as the artificial neural network input, then the loudspeakers faults were classified by BP Neural networks. Experiments on 165 loudspeakers were designed. The identification rate was 95.8%. Results show that this method is effective and feasible.

**Keywords:** loudspeakers; WPT; feature extraction; neural networks; fault diagnosis

在扬声器的生产过程中, 对扬声器故障检测通常采用通过人耳监听的检测方法<sup>[1,2]</sup>. 近年来, 随着自动化水平的提高, 对扬声器自动检测方法也有研究<sup>[3,4]</sup>. 这种方法通过短时傅里叶变换进行时频处理, 并用距离的方法进行模式识别, 对环境的要求过高, 要求建立每一类扬声器的标准矩阵, 容易受到现场外界因素的干扰. 因此, 本文研究了利用小波包变换提取采集信号各频段能量, 用神经网络的方法, 只需求得信号在激励后的能量百分比, 不用建立扬声器标准, 容易实现扬声器故障的在线检测.

### 1 扬声器的自动故障诊断的方法及原理

利用扫频信号源产生信号, 对扬声器进行激励,

同时采集扬声器的响应信号, 用计算机对其进行小波包分析, 得到不同时频区域的能量, 用神经网络进行训练学习, 得到神经网络的权值和阈值, 使之用于对扬声器的客观评价.

#### 1.1 扬声器响应信号的小波包分析

##### 1.1.1 小波包分解

短时傅里叶变换运算量大、信息量少、时频分辨率低、且窗口大小固定<sup>[5]</sup>. 小波变换克服了短时傅里叶变换在时频域固定分辨率的缺陷, 但小波变换不能对高频分量进一步分解. 小波包变换是在小波变换的基础上对高频分量进行进一步的分解. 能较好地得到信号的时频域信息.

小波包变换是一种建立在小波变换基础上的时频分析方法, 从工程技术上看, 小波包变换可以看成

收稿日期: 2007-11-06; 修回日期: 2007-11-23

基金项目: 天津市科技发展计划资助项目 (06YFGPGX08900)

作者简介: 王思俊 (1981—), 男, 湖北人, 硕士研究生.

是函数空间逐级正交剖分的扩展,能够为信号提供一种更加精细的分析方法,它将频带进行多层次划分,对多分辨率分析没有细分的高频部分进一步分解,从而提高了时频分辨率.小波包函数 $W_{j,k}^n(t)$ 是一个多变量的函数,整数 $j$ 和 $k$ 分别对应小波变换的尺度和平移操作, $n$ 称为振荡系数.小波包函数与小波函数的关系为<sup>[6]</sup>

$$W_{j,k}^n(t) = 2^{j/2} W^n(2^j t - k) \quad (1)$$

小波包函数的前两个函数是一般的尺度函数和母小波函数

$$W_{0,0}^0(t) = \phi(t) \quad (2)$$

$$W_{0,0}^1(t) = \varphi(t) \quad (3)$$

对于 $n=2,3,\dots$ 时的小波包函数,可通过如下递归过程计算得到:

$$W_{0,0}^{2n}(t) = \sqrt{2} \sum_k h(k) W_{j,k}^n(2t-k) \quad (4)$$

$$W_{0,0}^{2n}(t) = \sqrt{2} \sum_k g(k) W_{j,k}^n(2t-k) \quad (5)$$

其中, $h(k)$ 和 $g(k)$ 是定义的对尺度函数和母小波函数的镜像滤波器.为分析信号 $z(t)$ 中对应小波包基 $W_{j,k}^n$ 的时频信息,取 $z(t)$ 和小波包基 $W_{j,k}^n$ 的内积.则 $z(t)$ 对应的小波包系数可由式(6)计算得到.

$$\omega_{j,n,k} = \langle z, W_{j,k}^n \rangle = \int z(t) W_{j,k}^n dt \quad (6)$$

当小波包函数的三个参数进行相应的变化时,就得到了信号 $z(t)$ 对应的小波包分解.其分解过程如图1所示.




图1 小波包变换树

Fig. 1 Wavelet packet tree

结合扬声器的本身固有频率,工厂提供的扬声器的固有频率一般在 $(148 \pm 22)$ Hz,实际上,将采集得到的原始信号进行6层小波包分解,在图1中, $(i,j)$ 表示第 $i$ 层的第 $j$ 个节点,其中 $i=0,1,2,3,4,5,6$ ;  $j=0,1,\dots,63$ ;  $(0,0)$ 代表原始信号 $S$ ,即前面所讲的 $z(t)$ .  $(1,0)$ 代表小波包分解的第一层的低频信息 $S_{10}$ ,故原始信号经6层小波包分解以后, $S$ 可表示为

$$S = S_{600} + S_{601} + \dots + S_{663} \quad (7)$$

### 1.1.2 小波包能量提取

求取各频段信号的总能量:设 $S_{6j}$  ( $j=0,1,\dots,63$ ),则有各频率段对应的能量为

$$E_{6j} = \int |S_{6j}(t)|^2 dt = \sum_1^n |X_{jk}|^2 \quad (8)$$

其中, $X_{jk}$  ( $j=0,1,\dots,63; k=1,2,\dots,n$ )表示重构信号 $S_{6j}$ 的离散点的幅值.

构造特征向量:定义信号的全部能量为

$$E_{\text{Total}} = \sum_0^{63} E_{6j} \quad (9)$$

规一化为

$$P_{6j} = E_{6j} / E_{\text{Total}} \quad (10)$$

定义相对小波包能量特征向量为

$$P = (P_{600}, P_{601}, \dots, P_{663}) \quad (11)$$

## 1.2 基于BP神经网络的扬声器故障分类方法

### 1.2.1 神经网络基本原理

基于神经网络的故障诊断技术,即通过对故障实例和诊断经验的训练学习,用分布在网络内部的连接权值来表达所学习的故障诊断知识.它具有对故障模式的联想记忆、模式匹配和相似归纳能力,从而实现扬声器故障的自动识别.

BP算法即反向传播算法,其主要思想是从后向前逐层传播输出层的误差,以间接算出隐层误差.解决了前馈算法中隐层不与外界直接连接,无法直接算出其误差的缺陷.

采用三层BP网络,结构如图2所示. BP网络的学习过程由两部分组成:正向传播和反向传播.正向传播时,输入信息从输入层经隐含层单元层处理后传向输出层,每一层神经元的状态只影响下一层的神经元状态.如果在输出层得不到希望的输出,则转入反向传播,将误差信号沿原来的神经元连接通路返回.返回过程中,逐一修改各层神经元的连接权值.这种过程不断迭代,最后使得信号误差达到允许的范围之内.




图2 BP网络的拓扑结构

Fig. 2 BP network topology

BP 网络中,采用了有一定阈值特性的连续可微的 Sigmoid 函数作为神经元的激发函数. 这里采用的 S 型函数为

$$f(x) = \frac{1}{1 + e^{-x}}$$

### 1.2.2 BP 神经网络学习过程

BP 神经网络的学习过程包括正向传播和反向传播 2 个过程. 其算法过程如下<sup>[7]</sup>:

(1) 置各权值  $\omega_{ji}$  和阈值  $\theta_j$  的初始值:  $\omega_{ji}(0)$  和  $\theta_j(0)$  为小的随机数值;

(2) 提供训练样本: 输入矢量  $X_k, k=1,2,\dots,P$ ; 期望输出值  $d_k, k=1,2,\dots,P$ ; 对每个输入样本进行

(3) 到 (5) 的迭代;

(3) 计算网络的实际输出  $O_{kj}$  及隐含单元的状态:  $O_{kj} = f_i(\sum_i \omega_{ji} O_{ki} + \theta_j)$ ;

(4) 计算训练误差  $\delta_{kj}$ :

$$\text{输出层 } \delta_{kj} = O_{kj}(1 - O_{kj})(t_{kj} - O_{kj})$$

$$\text{隐含层 } \delta_{kj} = O_{kj}(1 - O_{kj}) \sum_m \delta_{km} \omega_{mj}$$

修正权值  $\omega_{ji}$  和阈值  $\theta_j$ :

$$\omega_{ji}(t+1) = \omega_{ji}(t) + \eta \delta_j O_{ki} + \alpha[\omega_{ji}(t) - \omega_{ji}(t-1)]$$

$$\theta_j(t+1) = \theta_j(t) + \eta \delta_j + \alpha[\theta_j(t) - \theta_j(t-1)]$$

(5) 当  $k$  每经历 1 至  $P$  后,判断指标是否满足精度要求;

(6) 结束.

## 2 实验

系统流程图见图 3.




图 3 系统流程图

Fig. 3 System flow chart


检测实验步骤:

(1) 信号采集. 通过扫频仪激励扬声器,用采集系统采集扬声器的响应信号.


(2) 信号处理. 对采集的整周期信号进行小波包分解,将信号分解到不同频率段进行分析.

(3) 特征提取. 计算各频段的信号能量,发现扬声器的能量值 99.9%集中在 10 个相同的节点上,其他节点的能量明显小于这 10 个节点的能量,为了减少网络的输入维数,将特征数目选为 10,将这 10 个能量进行规一化作为神经网络的输入.


(4) 建立人工神经网络模型. 将各类故障样本统称为故障,其他称为好的扬声器,所以输出的维数为 1. 通过对不同隐含层网络的训练发现,选择 5 或 7 个隐含层数没有 6 个隐含层单元的训练效果好,如图 4 所示. 结合文献[8],本文采用 10-6-1 的网络结构. 经过调试,有较好的泛化能力.



(a) 神经元数为 5



(b) 神经元数为 6



(c) 神经元数为 7

图 4 训练实验结果

Fig. 4 Experiment results of training

(5) 分析识别结果. 用训练好的网络来识别扬声器的故障,对采集的扬声器的响应信号进行特征提取,将提取的参数输入到神经网络,最终得到网络的识别结果.

实验数据来自扬声器厂家采集的原始数据,由于采集样本的困难性,很难在同一环境中取得大量的样本,抽取 282 个(其中好扬声器 200 个,故障扬声器

(下转第 62 页)