

基于小波降噪的振动传感器数据分析

张阳峰¹ 韦仕鸿¹ 邓娜娜² 王文瑞³

(中国水利水电第七工程局有限公司 成都 610000)¹ (上海云统信息科技有限公司 上海 201210)²
(中国科学院上海高等研究院 上海 201210)³

摘要 针对矿山机械设备的振动数据在信号滤波和故障信号数据保存及提取方面存在的问题,提出了神经网络优化阈值的小波变换方法。采用 MEMS 三轴加速度传感器采集数字量,对其运算处理后转换成位移,再进行小波分解,对分解出的高频系数部分进行神经网络阈值优化调节,重构数据以达到降噪的效果,最终对滤波后的信号进行傅里叶变换,并根据幅频能量计算高频系数的占比。实验表明,基于神经网络调节阈值的小波变换方法能够在自适应学习后自动调节阈值,对振动传感器信号具有理想的滤波效果。优化重构后的信号比传统方法多滤除了 15% 以上的高频噪声能量,并能保留突变故障信息,为后期的故障诊断提供重要依据。

关键词 振动传感器,小波变换,阈值优化,神经网络,数据处理

中图分类号 TM937 文献标识码 A

Vibration Sensor Data Analysis Based on Wavelet Denoising

ZHANG Yang-feng¹ WEI Shi-hong¹ DENG Na-na² WANG Wen-rui³

(Sinohydro Bureau 7 Co., Ltd., Chengdu 610000, China)¹

(Shanghai Unitoon Information Technology Co., Ltd., Shanghai 201210, China)²

(Shanghai Advanced Research Institute, Chinese Academy of Sciences, Shanghai 201210, China)³

Abstract Aiming at the problems of signal filtering and fault signal data preservation and extraction in vibration data of mining machinery and equipment, this paper proposed a wavelet transform method based on neural network optimization threshold. The MEMS triaxial accelerometer is used to sample the digital data, then converted into displacement by the processing, and then the wavelet decomposition is performed. The high-frequency coefficients are optimized and adjusted by neural network threshold, and the data are reconstructed to achieve the effect of noise reduction. Finally, Fourier transform of filtered signals is carried out, and the ratio of high-frequency coefficients is calculated according to amplitude frequency energy. Experimental results show that the wavelet transform method based on neural network adjusting threshold can automatically adjust the threshold after adaptive learning, and has ideal filtering effect on vibration sensor signal. The high frequency noise energy can be filtered more than 15% than the traditional threshold, and can retain abrupt fault information, which provides an important basis for later fault diagnosis.

Keywords Vibration sensor, Wavelet transform, Threshold optimization, Neural network, Data processing

1 引言

矿山建设从传统迈入智能,古德生院士指出:“矿山智能化主要指导智能采矿,即采矿决策过程高度可靠、准确”^[1],其中机械设备的各种运行数据的智能化是重要条件之一。其中振动信号显得尤为重要,通过这些数据不仅可以观察设备的运行状态,还能对设备进行故障诊断,甚至预测设备可能出现的状况。然而采集到的信号总是夹杂着各种各样的噪声,如何去掉这些噪声对后期的信号分析有着重要的意义。目前,对振动信号进行分析的方法有时域分析和频域分析,傅里叶变换是最常用的频域分析方法,主要用于分析在时域不稳定、但在频域有更简洁信息的信号。而局限性主要发现在两个方面:一是傅里叶分析不能表现时域里信号的局部特征;二是傅里叶分析对突变和非平稳信号的效果不好。由此,现代研究

人员利用小波分析,一个同时拥有时域和频域信号的分析方法,通过基波函数的尺度变换和平移使信号在高频处时间细分,低频处频率细分,从而得到信号的任意细节,被称为“数学显微镜”^[2]。

噪声是掺杂在有效信号里的无用信息,若要精密地对设备进行故障诊断,需要在信号损失量最低的条件下去除噪声。无论是时域还是频域小波变换都能提供信息,更重要的是可以有效处理非平稳信号。小波变换(Wavelet Transform, WT)已成功应用于多个研究领域,包括信号和图像的去噪和压缩、特征提取、故障诊断等^[3-7]。小波阈值去噪是一种简单有效且强大的方法,因此问题从一组数据中去除噪声转化为在数据系中找到最佳阈值,在过去的 20 年中,研究者们针对小波变换提出了很多的阈值方法,这些阈值方法分为线性与自适应,各自应用于不同的领域中^[8-12]。

本文受上海市经信委专项基金(201601060),国家自然科学基金(51507175)资助。

张阳峰(1983—),男,工程师,主要研究方向为工程项目管理;韦仕鸿(1977—),男,工程师,主要研究方向为水电工程技术管理;邓娜娜(1983—),女,硕士生,高级工程师,主要研究方向为物联网、智能检测与控制等,E-mail:dnn1023@126.com(通信作者);王文瑞(1988—),男,工程师,主要研究方向为智能检测与控制技术、物联网等。

本文对大型机械设备的振动传感器信号进行小波变换处理,在进行阈值确定时,引入了神经网络进行软阈值学习判断,进而对信号进行去噪,通过滤波后的重构,对比结果误差,高频噪声能量比传统阈值多滤除了15%以上,达到了系统要求的最佳性能。

2 小波变换

在噪声滤除和故障诊断方面,小波变换得到了广泛的研究与应用,通常在进行诊断时需要同时从时域和频域进行分析,小波变换正好满足这些要求,并且它能够适用于非平稳信号,本文所提方法是基于离散小波变换的多分辨率分解的去噪方法。




图2 离散小波变换分析

离散小波变换(Discrete Wavelet Transform, DWT)的分析过程如图2所示,实现步骤如下:

- 1) 根据合适的信号和噪声特征选择合适的小波基;
- 2) 确定分层数,将原始信号进行该层次分解,得到近似(低频)信号和细节(高频)信号;
- 3) 针对每一层的高频信号,选取不同阈值,设置方法有软阈值和硬阈值;
- 4) 对阈值后的低频信号和低频信号进行重构,得到去噪后的数据。

2.1 常用阈值设置

经过10多年的发展,出现了很多求阈值的公式,我们选择Donoho等人提出的量化阈值 λ ,小于 λ 的认为都是由噪声引起,置0;大于 λ 的都是由信号引起,按某固定量向零收缩,这里选择应用最广泛的一种来说明:

这是一个软阈值,算法如下:

$$\hat{w}_{j,k} = \begin{cases} \text{sgn}(w_{j,k})(w_{j,k} - \lambda), & |w_{j,k}| \geq \lambda \\ 0, & |w_{j,k}| < \lambda \end{cases} \quad (1)$$

其中,

$$\lambda = \sigma \sqrt{2 \log(n)} \quad (2)$$

$$\text{sgn}(x) = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0 \end{cases} \quad (3)$$

其中, n 是噪声信号采样长度, σ 是噪声方差, $w_{j,k}$ 是各尺度下的小波系数, σ 的计算公式如下:

$$\sigma = \left\lfloor \frac{\text{median}|\Delta_{i,j}|}{0.6475} \right\rfloor \quad (4)$$

其中, $\Delta_{i,j}$ 是含有噪声的原始信号经过小波变换的第一层高频系数; $\text{median}|\Delta_{i,j}|$ 表示找出这些系数的中位数。

2.2 经验阈值算法

DWT分别表现了低频系数和高频系数,在高频里数据有两种特征:小振幅的高频振动和大振幅的低频振动。两者分别包含了高峰和噪声信号。因此选择式(5)来求取正负阈值:

$$\lambda_i = \begin{cases} \lambda_+ = \alpha * \max(d_i) \\ \lambda_- = \alpha * \min(d_i) \end{cases} \quad (5)$$

其中, d_i 表示第 n 层的高频细节系数, α 是经验参数($0 < \alpha < 1$),我们选择 $\alpha = 0.85$,即在这些系数中找出最大值和最小值,并将其与 α 相乘,得到该层的阈值,再根据软阈值算法进行去噪。

3 基于神经网络的阈值算法分析

3.1 神经网络输入输出数据

神经网络是指由多个具有自适应的单元组成的广泛并行的互连网络,包括输入层、一个或多个隐藏层以及输出层。输入数据为小波分解后每一层的高频系数 cD_n ($n=1,2,3,4$),输出数据选择为前文计算得到的阈值 λ_n 。

3.2 阈值算法的分析过程

设输入和输出的神经元相同为 d ,隐含神经元为 q ;设输出层第 j 个神经元的阈值为 λ_j ;设隐含层第 h 个神经元的阈值为 Δ_h ;设第 i 个输入层与第 h 个隐含层神经元的连接权重为 V_{ih} ;设第 j 个输出层与第 h 个隐含层神经元的连接权重为 w_{hj} ;设第 h 个隐含层神经元接收到输入层的是 α_h :

$$\alpha_h = \sum_{i=1}^d V_{ih} cD_n \quad (6)$$

设第 j 个输出层接收到隐含层的输入为 β_j :

$$\beta_j = \sum_{h=1}^q W_{hj} b_h \quad (7)$$

其中, b_h 为第 h 个隐含层的输出。

激活函数选择sigmoid函数:

$$f(x) = \frac{1}{a + e^{-x}} \quad (8)$$

神经网络的输出表达式为 (CD_k, Δ_k) ,其中,

$$\Delta_k = f(\beta_j - \lambda_j) \quad (9)$$

则 (CD_k, Δ_k) 的均方误差为:

$$E_k = \frac{1}{2} \sum_{j=1}^d (\Delta_j^k - \lambda_j^k)^2 \quad (10)$$

为求导时计算方便,系数乘以1/2以抵消掉参数;在第 h 个隐含层,输入层需传送 d 个权重,且有 d 个权重传到输出层,并且其自身还有一个阈值,即一个隐含层有 $(2d+1)$ 个阈值,另输出层有 d 个阈值,因此总共有 $(2d+1) * q + d$ 个待定参数。这些参数一开始是随机给定的,通过算法迭代逐渐收敛至合适的值,这时训练完成。

权重更新的公式为:

$$w \leftarrow w + \Delta w \quad (11)$$

以隐含层至输出层的权重 W_{hj} 求解过程为例:

首先依据前文公式求出均方误差 E_k ,期望其为可接受的误差范围,这里取5%。基于梯度下降法求解,调整参数需以目标的负梯度为方向,通过迭代,逐渐得到最优解。根据已知(自己确定)步长,即学习率 η ,得到权重变化率:

$$\Delta w = -\eta \frac{\partial E_k}{\partial w_{hj}} = \eta \Delta_j^k (1 - \Delta_j^k) (\lambda_j^k - \Delta_j^k) b_h \quad (12)$$

其中, η 为梯度下降补偿,即学习率, Δ_j^k 为第 j 个输出层的输出值; λ_j^k 为训练后给出的输出系数; b_h 为第 h 个隐含层的输出。

同理:

$$\begin{cases} \Delta \lambda_j = -\eta g_j \\ \Delta V_{ih} = \eta e_h CD_i \\ \Delta \gamma_h = -\eta e_h \end{cases} \quad (13)$$

其中,

$$e_h = -\frac{\partial E_k}{\partial B_h} \frac{\partial B_h}{\partial \alpha_h} = -\sum_{j=1}^d \frac{\partial E_k}{\partial B_j} \frac{\partial B_j}{\partial \alpha_h} f'(\alpha_h - \gamma_h) \quad (14)$$

4 数据实验分析

对于小波去噪,小波基的选择尤其重要,需要选择与采集到的原始信号相接近的小波基,另外,小波的分解层数同样不可忽视。本文根据振动传感器采集真实矿山机械设备得到的数据进行绘图,当含有噪声的信号源为正弦波时,以 Daubechies(db4)小波族为母小波。首先利用经验软阈值对信号进行四层分解,再分别将含有噪声和阈值处理后的信号进行傅里叶变换,比较去噪前后的频率分布。小波分解系数图像如图 3 所示。滤波后的信号如图 4 所示。经过傅里叶变换后的结果如图 5 所示。




图 3 正弦信号的 CA4 和 CD1 图像




图 4 正弦信号的原始信号和去噪信号的对比

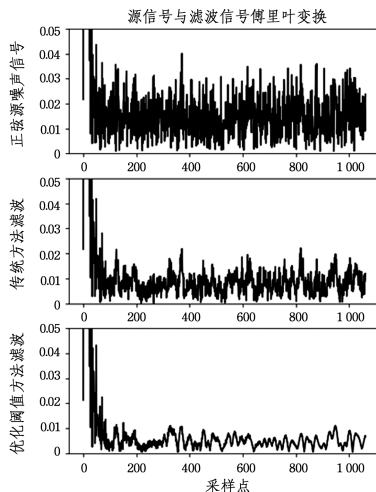


图 5 源信号和去噪信号的傅里叶变换对比

本文所有仿真信号图像的横坐标为时间(s),纵坐标为振幅(μm)。对振动信号进行处理会涉及到两个方面:1)滤波;2)保存状态改变时的振动信息,对该状态信息进行识别,可为故障诊断做准备。图 3 是神经网络优化阈值后的小波分解图像,横坐标是采样点,纵坐标是系数值,CA4 是尺度 4 的低频系数,CD1 是尺度 1 的高频系数,可以明显看到频率变化时的高频噪声,即需要保留的信号。图 4 分别是源信号、传统方式重构与神经网络阈值优化重构后的信号。图 5 是这 3 种信号的傅里叶变换。从图 5 的图像信号中可以得到:与传统小波滤波方式相比,经过 FFT 运算得出,所提出的优化方法的高频噪声能量减少了 70%,比传统方式多滤除了 22% 的高频噪声能量,且保存了频率变化时的特征信息。

另一组数据信号源为方波时,选择 Haar 为小波基进行分析。由于方波本身即是高频信号,因此不做傅里叶变换分析仿真,其他与正弦波类似处理,可得到如图 6 和图 7 所示的仿真图像。




图 6 方波的 CA4 和 CD1 图像

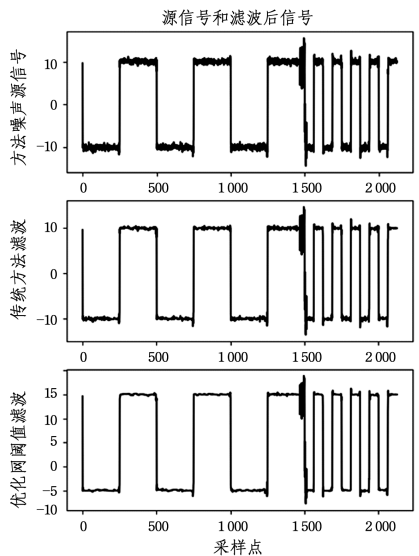


图 7 方波的原始信号和去噪信号对比

图 6 是神经网络优化阈值后的小波分解图像,同理,CA4 是尺度 4 的低频系数,CD1 是尺度 1 的高频系数,且可以看出:在幅值变化大或噪声增大时,信号保留下来,并能找出对应的采样点。图 7 中方波噪声源信号是含有噪声的方波信号源,同样在频率变化时噪声变大,信号稳定后,噪声减小且稳