

基于 EMD 和 BP 网络的轴承故障诊断方法

张永建¹, 孔祥振¹, 张永超¹, 路艳春¹, 邢龙超¹, 张小刚²
 (1. 山东科技大学 机械电子工程学院, 山东 青岛 266590;
 2. 滨化集团股份有限公司, 山东 滨州 256619)

摘要: 故障轴承的振动信号是非平稳信号, 传统的非平稳信号分析手段存在许多不足; BP 网络能够出色地解决传统识别模式难以解决的复杂问题。提出了经验模态分解(EMD)与 BP 神经网络相结合的滚动轴承故障诊断方法。采用 EMD 方法对振动信号进行分解, 得到组成信号的多个内禀模态分量(IMF), 提取重要的 IMF 分量的能量作为信号的特征量; 采用 BP 网络作为模式分类器, 对轴承的故障类型进行分类。经试验数据分析证明, 该方法能够准确地对轴承故障进行诊断。

关键词: 经验模态分解(EMD); BP 网络; IMF 能量; 故障诊断

中图分类号: TH17

文献标识码: A

文章编号: 1674-7720(2014)04-0077-04

Method of bearing fault diagnosis based on EMD and BP neural network

Zhang Yongjian¹, Kong Xiangzhen¹, Zhang Yongchao¹, Lu Yanchun¹, Xing Longchao¹, Zhang Xiaogang²
 (1. College of Mechanical and Electronic Engineering, Shandong University of Science and Technology, Qingdao 266590, China;
 2. Befar Group Co., Ltd, Binzhou 256619, China)

Abstract: The vibration signal of fault rolling bearing is nonstationary, traditional methods of analyzing the nonstationary signal have some deficiencies; BP neural network can well solve complex problems that are difficult to be solved through traditional recognition mode. The method of rolling bearing fault diagnosis presented in this article combines with the empirical mode decomposition (EMD) and BP neural network. The EMD method is used to decompose the bearing vibration signal, multiple intrinsic mode function(IMF) components composed the signal are acquired, IMF energy is used to be the characteristic quantity of signal; BP network is adapted to be the fault mode classifier and classify the bearing fault type. The analysis of experiment data shows that the method can diagnose the bearing fault accurately.

Key words: empirical mode decomposition(EMD); BP neural network; IMF energy; fault diagnosis

滚动轴承的振动分为与轴承弹性有关的振动和与滚动表面状况有关的振动^[1]。轴承故障的振动信号属于后者, 其为非平稳信号。对于非平稳信号, 时频分析是有效的分析手段^[2]。加窗傅里叶变换可以对非平稳信号进行时频分析, 但其只适用于缓变信号; 双线性变换实际上不是线性变换, 因此对多分量信号进行分析时会产生严重的交叉干扰分量; 小波变换需要预先选取基函数, 不具备自适应的信号分解特性。具有自适应性与正交性的经验模态分解方法(EMD), 在分析非平稳信号方面具有强大的优势。

本文采用经验模态分解方法(EMD)对轴承振动信号进行分解, 获得组成信号的多个内禀模态(IMF)分量, 并提取 IMF 分量的能量作为特征量; 以 BP 神经网络作为

模式识别器, 对特征量进行识别和分类, 从而实现轴承故障的诊断。

1 信号的 EMD 分解方法

“筛分”是 EMD 分解方法的实质, “筛分”的目的是消除模态波形的叠加并使波形轮廓对称。为了有效找出信号的所有模态, EMD 方法采用基于极值点的特征时间尺度参数^[3], 把非平稳信号按特征时间尺度从小到大的顺序分解成多个内禀模态(IMF)分量。IMF 分量反应了信号内部固有的波动特性, 在它的每一个周期上仅包含一个波动特性, 不存在多个波动模态混叠的现象^[3]。一个 IMF 分量具有相同的极值点与过零点, 且其上下包络线关于时间轴对称。复杂的非平稳信号能够通过 EMD 方法进行分解的基本假设是: 任何复杂信号均可以由多

技术与方法 Technique and Method

个不同的且相互独立的 IMF 分量组成;一个复杂信号可以包含多个 IMF 分量,IMF 分量相互叠加可以形成原复杂信号。

采用 EMD 方法对非平稳信号 $x(t)$ 进行分解的步骤为^[4]:

(1)采用三次样条曲线拟合出信号的上、下包络线。

(2)信号上下包络线的均值记为 m_1 ,并计算 $h_1=x(t)-m_1$ 。满足 IMF 函数要求的 h_1 即为组成原信号的第一个 IMF 分量,记 $c_1=h_1$ 。

(3)若 h_1 不满足 IMF 的要求,把 h_1 作为初始信号,重复步骤(1)和(2),直至 h_1 满足 IMF 的要求,并记 $c_1=h_1$,则 c_1 即是 $x(t)$ 的第一个 IMF 分量。

(4)采用式 $r_1=x(t)-c_1$ 将分量 c_1 从原信号中提取出来, r_1 为原信号的残余信号。将 r_1 作为初始信号并重复步骤(1)~步骤(3)对信号进行分解,可以得到原信号的多个 IMF 分量: c_2, c_3, \dots, c_n 。它们满足下列等式:

$$\begin{cases} r_2=r_1-c_2 \\ \vdots \\ r_n=r_{n-1}-c_n \end{cases} \quad (1)$$

当 r_n 成为一个单调函数并不能再进行分解时,分解过程结束。原信号 $x(t)$ 可以用各 IMF 分量表达为:

$$x(t)=\sum_{i=1}^n c_i+r_n \quad (2)$$

式中, c_1, c_2, \dots, c_n 为包含了原信号从高到低不同频率成分的 IMF 分量; r_n 称为残余函数,表示了原信号的中心趋势。

2 BP 神经网络分类器

对于轴承故障诊断,模式识别是其核心技术之一。BP 网络具有自学习、分类和识别等诸多优势,能够出色地解决传统识别方法难以解决的复杂问题^[5]。由于 BP 网络具有识别原因和故障分类的能力,所以 BP 网络是解决故障诊断模式识别问题的有效方法。

BP 网络具有良好的非线性映射能力、容错性和泛化能力,其结构简单,可塑性强,识别率高,抗干扰能力好,因此 BP 网络作为分类器广泛应用于故障诊断中。故障诊断的实质就是对不同的模式进行分类,本文将 BP 网络作为模式识别器对轴承故障进行分类。

1989 年,Robert Hecht-Nielsen 证明了任何闭区间的连续函数都可以用单隐层的 BP 网络来逼近^[6]。因此,具有单隐层和相应数量节点,且激励函数为 Sigmoid 型的 BP 网络可以完成任意 n 维到 m 维的映射。BP 网络是一个“模式顺传播”与“误差逆传递”反复进行的过程,网络通过训练逐渐得到最优的权值,进而使网络的实际输出逼近期望的输出值。在 BP 网络的训练中,常采用批训练的方式,因为在样本数量较多时,批训练的收敛速度快^[7]。批训练的过程如图 1 所示。

在进行网络训练前首先应根据轴承工作过程的理论分析和实际运行经验,确定轴承出现故障的部位或原

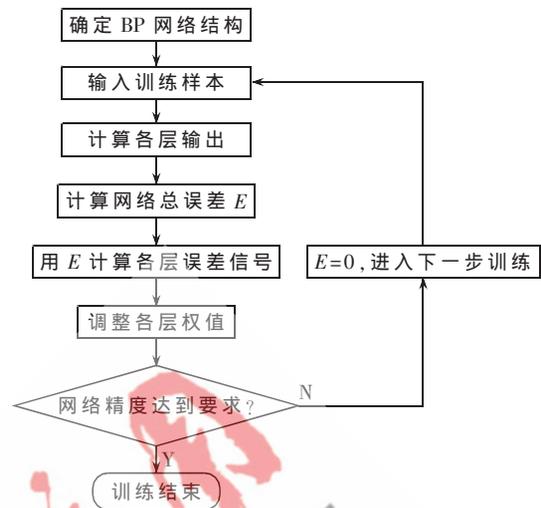


图 1 BP 网络批训练流程图

因,作为故障变量即网络的输出变量;同时确定用于区别各种故障的特征量作为网络的输入变量^[9]。

3 提取特征量

选择对工况状态最敏感的特征量是对工况进行有效识别的基础,并在很大程度上决定了状态识别的正确性^[8]。不同故障类型的滚动轴承振动信号的 IMF 分量的能量具有明显区别,本文将选取其值作为信号的特征量。其步骤为:

(1)采用 EMD 方法对采集到的振动信号进行分解,获取其各个 IMF 分量 c_i ,其中 $i=1, \dots, n$ 。图 2 为滚动轴承内圈有故障时的振动信号,图 3 为 EMD 分解图,图中给出了其前 9 个 IMF 分量。

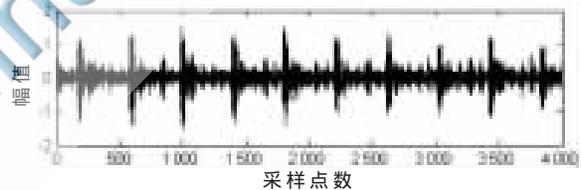


图 2 滚动轴承内圈故障时的振动信号

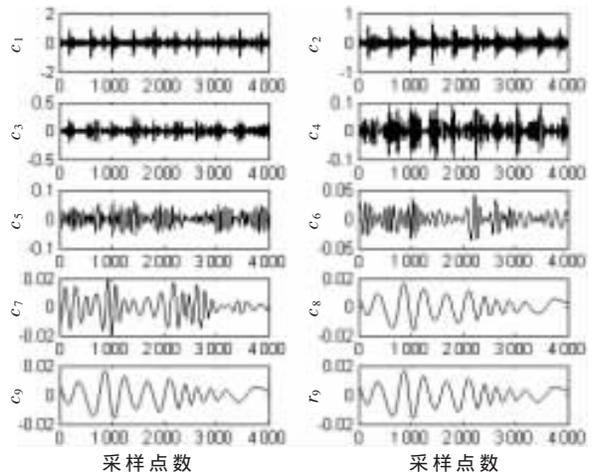


图 3 滚动轴承内圈故障时的振动信号的 IMF 分量

(2)信号能量的定义如式(3)所示,但在实际的处理过程中,若信号为离散量,一般采用式(4)进行 IMF 能量

技术与方法

Technique and Method

的计算。

$$E_i = \int_{-\infty}^{\infty} c_i^2(t) dt \quad (3)$$

$$E_i = \sum_{k=1}^n (k\Delta t) c_i^2(k\Delta t) \quad (4)$$

式中, n 为总采样点数; k 为采样点; Δt 为采样时间间隔。

(3) 构建振动信号的特征量 P , 并对其进行归一化, 得:

$$P = [E_1, E_2, E_3, \dots, E_n] / \sum_{i=1}^n E_i \quad (5)$$

特征量 P 综合地反映了各个 IMF 分量能量的分布情况, 包含了原始振动信号的故障信息, 可以作为故障诊断系统的输入特征量。

4 实验数据分析

试验中采集的是某型号电机轴承的多种振动信号数据, 采样频率为 12 kHz, 电机功率为 1.5 kW。

实验中采集了正常轴承以及内圈、外圈和滚动体存在故障的轴承振动信号。通过分析轴承振动信号, 对轴承故障类型进行识别和诊断的过程如图 4 所示。

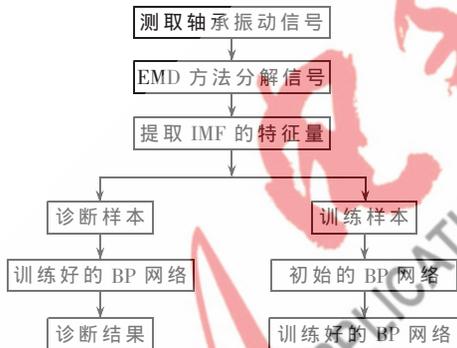


图 4 轴承故障识别过程

采用 EMD 方法对原始振动信号进行分解, 并从得到的分解信号中选取包含原信号主要特征信息的前 8 个 IMF 分量, 按分解后的顺序依次命名为 $c_1 \sim c_8$ 。利用式 (4) 和式 (5) 构建振动信号的特征量 P , 把 P 作为 BP 神经网络的输入参数。将特征量 P 分成两部分: 训练样本和诊断样本, 分别对设计好的 BP 网络进行训练和诊

断。部分训练样本如表 1 所示。

模式分类器选取单隐层的 BP 神经网络。由前述可知, 输入层节点的个数为 8。实验中采集了 4 种轴承振动信号, 采用“ n 中取 1”表示法为输出层编码: 正常轴承为 [1, 0, 0, 0], 内圈、外圈和滚动体故障的轴承为 [0, 1, 0, 0]、[0, 0, 1, 0] 和 [0, 0, 0, 1], 因此输出层的节点数为 4 个。根据输入层和输出层的节点数确定隐层的节点个数: $m = (4+8)^{1/2} + 7 \approx 10$ 。将诊断样本输入训练好的 BP 网络, 对不同类型的滚动轴承故障进行诊断和分类, 部分诊断结果如表 2 所示。

表 2 部分 BP 网络的诊断结果

诊断样本	分类器类型	实际输出数据				标准输出	故障类型
样本 1	BP 网络	0.999 7	0.000 3	0.000 0	0.000 0	1 0 0 0	正常
		0.998 1	0.001 9	0.000 0	0.000 0		
样本 2	BP 网络	0.000 2	0.999 8	0.000 0	0.000 2	0 1 0 0	内圈故障
		0.000 1	1.000 4	0.000 5	0.000 8		
样本 3	BP 网络	0.000 0	0.000 0	0.982 6	0.017 4	0 0 1 0	外圈故障
		0.000 0	0.000 0	1.000 6	0.006 6		
样本 4	BP 网络	0.003 9	0.003 4	0.004 8	0.994 8	0 0 0 1	滚动体故障
		0.001 8	0.002 1	0.004 4	0.995 9		

实验分析结果表明, EMD 分解方法结合 BP 神经网络能够准确地对滚动轴承故障类型进行识别和分类。

本文综合论述了 EMD 方法与 BP 神经网络相结合的滚动轴承故障诊断方法。该方法整体上包括 4 部分: 信号采集、信号分解、特征量提取和模式分类。通过理论和实验分析可得出以下结论:

- (1) EMD 方法能够将非平稳的振动信号分解成多个平稳的 IMF 分量信号;
- (2) IMF 分量能量能够充分表征原始振动信号所包含的轴承故障信息;
- (3) EMD 分解方法与 BP 神经网络相结合能够准确地对轴承故障类型进行模式识别和诊断。

参考文献

- [1] 刘园, 张永建, 李元宝. 改进小波能量分析法在轴承故障诊断中的应用[J]. 煤矿机械, 2012, 33(5): 254-255.
- [2] 岳建海, 裴正定. 信号处理技术在滚动轴承故障诊断中的应用与发展[J]. 信号处理, 2005, 21(2): 185-190.
- [3] 于德介, 程军圣, 杨宇. 机械故障诊断的 Hilbert-Huang 变换方法[M]. 北京: 科学出版社, 2006.

表 1 部分 BP 网络训练样本

训练样本类型	E_1	E_2	E_3	E_4	E_5	E_6	E_7	E_8	标准输出
正常轴承	0.319 0	0.288 6	0.137 9	0.103 2	0.075 0	0.050 9	0.018 2	0.004 5	1 0 0 0
	0.317 8	0.303 2	0.104 0	0.094 3	0.088 1	0.083 2	0.005 3	0.002 3	
内圈故障轴承	0.688 1	0.248 2	0.042 0	0.008 9	0.006 0	0.003 9	0.001 6	0.000 5	0 1 0 0
	0.690 2	0.226 9	0.058 5	0.010 5	0.005 0	0.004 1	0.003 1	0.000 8	
外圈故障轴承	0.860 8	0.071 2	0.055 3	0.006 9	0.003 0	0.001 1	0.000 7	0.000 3	0 0 1 0
	0.880 5	0.062 3	0.045 5	0.005 7	0.003 4	0.001 7	0.000 4	0.000 2	
滚动体故障轴承	0.784 5	0.058 2	0.054 4	0.048 5	0.032 6	0.011 6	0.008 2	0.001 3	0 0 0 1
	0.858 9	0.059 0	0.036 2	0.022 0	0.015 4	0.005 5	0.002 1	0.000 6	

技术与方法 Technique and Method

- [4] HUANG N E, SHEN Zheng, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proc. R. Soc. Lond. A, 1998(454): 903-995.
- [5] 钟秉林, 黄仁. 机械故障诊断学[M]. 北京: 机械工业出版社, 2002.
- [6] 傅荟璇, 赵红. MATLAB 神经网络应用设计[M]. 北京: 机械工业出版社, 2010.
- [7] 韩力群. 神经网络教程[M]. 北京: 北京邮电大学出版社, 2006.
- [8] 于婷婷. 基于 BP 网络的滚动轴承故障诊断方法[D]. 大连: 大连理工大学, 2008.

(收稿日期: 2013-09-19)

作者简介:

张永建, 男, 1954 年生, 教授, 研究生导师, 主要研究方向: 流体机械, 通风机安全、节能、降噪、喘振及运行监控等。

电子技术应用
APPLICATION OF ELECTRONIC TECHNIQUE
www.ChinaAET.com