

doi:10.3969/j.issn.1673-9833.2012.03.013

基于EMD模态能量分析的滚动轴承故障特征提取

魏巍, 彭涛

(湖南工业大学 电气与信息工程学院, 湖南 株洲 412007)

摘要: 针对滚动轴承振动信号具有非平稳性的特点, 提出一种提取相同工况条件下正常信号与故障信号各固有模态函数能量比构建特征向量的特征提取方法。由于EMD分解后各模态分量存在模态混叠现象, 导致分解结果具有不确定性, 因此传统的能量特征提取方法在滚动轴承故障诊断中的故障识别率较低。通过引入相同工况条件下的正常信号, 将各模态分量的能量特点转化为相对于正常信号的能量特征。仿真实验表明, 本文所提方法能够有效地提取滚动轴承的故障特征, 进而实现其故障诊断。

关键词: 特征提取; 经验模态分解; 滚动轴承; 故障诊断

中图分类号: TP206⁺.3

文献标志码: A

文章编号: 1673-9833(2012)03-0058-05

Fault Feature Extraction of Roller Bearing Based on EMD Modal Energy Analysis

Wei Wei, Peng Tao

(School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan, 412007, China)

Abstract: According to the non-stationary signal of rolling bearing, a feature extraction method of extracting energy ratio of intrinsic mode function(IMF) of normal signal and fault signal to construct characteristic vectors is proposed. Because of the modal aliasing by EMD, the decomposition results are uncertain, and the fault recognition rate of traditional energy feature extraction is low. By introducing normal signal under the same working conditions, the energy characteristics of various mode vectors are changed into energy features relative to normal signal. The experimental results show that the proposed method can effectively extract the fault feature of roller bearing and achieve its fault diagnosis.

Keywords: feature extract; Empirical mode decomposition; rolling bearing; fault diagnosis

0 引言

滚动轴承是旋转机械的核心部件, 同时也是极易发生故障的零部件之一, 据不完全统计, 约有30%的旋转机械故障是由滚动轴承故障引起的。由于滚动轴承工作环境极其复杂, 其振动信号是由不同零部件振动耦合而成。因此, 如何对滚动轴承信号进行有效的特征提取, 成为对其进行有效故障诊断的难点和关键点。

经验模态分解(empirical mode decomposition, EMD)是一种典型的现代信号处理方法, 能够根据信号自身特点自适应地将信号分解为一系列具有不同频率范围和能量分布的固有模态函数(intrinsic mode function, IMF)。因此基于EMD分解的能量特征提取方法在故障诊断领域得到了广泛的研究^[1-13]。文献[1]针对天然气发动机故障信号的非平稳性、非线性等特点, 提出一种基于EMD提取能量特征参数的故障诊断方法; 文献[2]采用线性预测方法对信号

收稿日期: 2012-03-27

基金项目: 国家自然科学基金资助项目(61170101, 60774069)

作者简介: 魏巍(1985-), 男, 河南省荥阳市人, 湖南工业大学硕士生, 研究方向为信号处理与模式识别,

E-mail: yushang20260@163.com

进行边界延拓,改进EMD方法,应用EMD对战场声信号进行分解,选择每一个IMF的能量相对于原始信号总能量的能量比作为特征向量,并将其归一化。最后,设计神经网络分类器对不同类战场声目标进行分类与识别;文献[3-5]通过提取若干个IMF分量与原始信号的能量比构建特征向量;文献[6]对各IMF分量分别设定阈值,剔除幅值较小的数据点增强信号故障特征,然后再提取消减后IMF分量与原始信号的能量比构建特征向量;文献[7]则对各IMF分量进行小波包分解,提取不同频带信号与IMF分量的能量比构建特征向量。然而,正常信号作为故障信号的基础成份,其对信号能量的贡献却很少受到人们的关注。因此,本文引入正常信号,提取正常信号各模态分量与故障信号各模态分量的能量比构建特征向量,用于滚动轴承的故障诊断。

2 能量特征提取

2.1 EMD原理

EMD是一种自适应的时频分析方法,不需要任何先验知识,被应用于非线性、非平稳信号的分析处理中。Huang N E^[4]等人认为,任何复杂信号都是由多个固有模态函数组成,因此,EMD分解的目的就是为了获得固有模态函数。IMF分量必须满足以下两个条件:1)在整个数据序列中,极大值与极小值点个数之和与过零点个数相等,且相差不超过1个;2)在任意时间点上,由局部极大值与局部极小值点构成的包络均值为零或近似为零。

EMD分解可以被描述为以下过程。

Step1 设原始信号为 $x(t)$,采用三次样条插值拟合上下包络线。定义上下包络线的均值为 $m(t)$,定义包络线均值与原始信号之差为 $h(t)$,即:

$$h(t) = x(t) - m(t) \quad (1)$$

如果 $h(t)$ 满足上述IMF分量条件,那么 $h(t)$ 即为信号的第一个IMF分量;如果不满足条件,则需要对 $h(t)$ 继续进行以上过程的筛选,直到得到符合要求的IMF分量。

Step2 得到信号的第1个IMF分量,以及该分量分离后的余项

$$\begin{cases} c(t) = h(t), \\ r(t) = x(t) - c(t). \end{cases} \quad (2)$$

Step3 将 $r(t)$ 作为新的处理信号,重复上述“筛选”过程,得到一系列的IMF分量 $c_i(t)(i=1,2,\dots,n)$ 和最终的余项 $r_n(t)$ 。原始信号可以重构为

$$x(t) = \sum_{i=1}^n c_i + r_n, \quad (3)$$

式中: n 为IMF分量个数; r_n 为残差函数,是一个单调函数。

2.2 基于EMD模态能量的特征提取

能量冲击是滚动轴承发生故障时最显著的特征,因此本文从能量的角度出发,提取原始信号的能量特征构建特征向量。EMD能够将信号分解为若干个具有不同频段范围的IMF分量,而当故障发生时,不同故障类型会导致不同频率范围的信号发生变化,从而引起相应频段内的能量发生变化。因此,本文提取正常信号各模态能量与故障信号对应模态分量的能量比构建滚动轴承振动信号的能量特征。

能量是信号的特征常量,本文定义信号能量为

$$E = \sum_{k=1}^n |x(t)|^2 \quad (4)$$

式中, $x(t)$ 为离散信号。

正常信号与待检测样本信号的模态分量的能量比为

$$\vartheta_j = \frac{e_j}{E_j}, (j=1,2,\dots) \quad (5)$$

式中: e_j 表示故障信号第 j 个IMF分量的能量大小; E_j 表示正常信号第 j 个IMF分量能量大小, ϑ_j 表示待检测样本信号的第 j 个能量特征。

因此,本文首先分别对待检测信号和相同工况条件下正常信号进行EMD分解;然后,提取正常信号各模态分量与故障信号各模态分量的能量比,构建特征向量;最后,将构建的特征向量用于SVM的分类识别。

3 滚动轴承故障诊断流程

通过引入正常信号,将信号的能量特征转化故障信号相对于正常信号的能量变化,并通过支持向量机分类器实现对滚动轴承运行状态的智能识别,故障诊断流程如下:

Step1 对来自传感器的含有大量噪声的原始信号进行低通滤波等预处理,得到待分析信号 $x(t)$;

Step2 对待分析信号在同一工况条件下的正常信号进行相关性分析、移位,求得正常信号的平均波形^[9];

Step3 分别对待分析信号 $x(t)$ 和正常信号进行EMD分解;

Step4 按照式(5)分别求得正常信号前5个模态分量与待分析信号前5个模态分量的能量比,构建信号的能量特征;

Step5 用提取出的前20个样本特征训练SVM分

类器, 将其余的样本特征送入分类器进行状态识别。

4 仿真实验

仿真实验采用的数据来自美国 Case Western Reserve 大学的滚动轴承数据中心^[15]。实验测试系统由三相交流电机、转矩传感器、测力计和电子控制装置组成。电机轴由测试轴承支撑, 通过放电加工技术在测试轴承中植入单一局部故障缺陷, 故障直径分别为0.177 8 mm、0.355 6 mm和0.533 4 mm, 深度为0.279 4 mm, 测试轴承为6025-2RS JEM SKF型深沟轴承。振动信号通过加速度传感器采集, 采样频率为48 kHz。




图1 测试台

Fig. 1 The test stand

在电机不同转速工况下, 记录4种不同故障类型(正常状态、滚动体故障、内环故障、外环故障)的振动加速度信号数据, 共40个样本集, 其中正常信号只按负载大小采集, 共4个样本集; 其余按负载大小和故障类型采集, 共36组样本集。将40个样本集分成12组数据集, 每组数据集由相同电机负载条件下的4种故障类型组成, 数据集描述如表1所示, 表中, N表示正常状态, I表示内环故障, B表示滚动体故障, O表示外环故障(下同)。

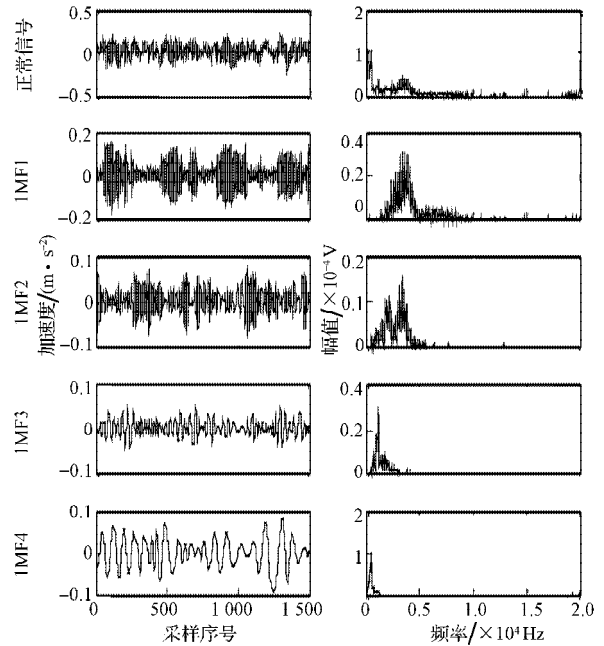
表1 数据集描述

Table 1 The description of sample sets


| 数据集 | 转速 / ($r \cdot \min^{-1}$) | 故障直径 / mm | 样本个数 | | | |
|--------|---------------------------------|--------------|------|-----|-----|-----|
| | | | N | I | B | O |
| D007_0 | 179.7 | 0.177 8 | 238 | 238 | 239 | 237 |
| D007_1 | 177.2 | 0.177 8 | 472 | 474 | 475 | 475 |
| D007_2 | 175.0 | 0.177 8 | 473 | 474 | 475 | 475 |
| D007_3 | 173.0 | 0.177 8 | 474 | 474 | 477 | 476 |
| D014_0 | 179.7 | 0.355 6 | 238 | 62 | 243 | 239 |
| D014_1 | 177.2 | 0.355 6 | 472 | 372 | 474 | 473 |
| D014_2 | 175.0 | 0.355 6 | 473 | 476 | 475 | 475 |
| D014_3 | 173.0 | 0.355 6 | 474 | 473 | 475 | 477 |
| D021_0 | 179.7 | 0.533 4 | 238 | 238 | 238 | 240 |
| D021_1 | 177.2 | 0.533 4 | 472 | 473 | 475 | 477 |
| D021_2 | 175.0 | 0.533 4 | 473 | 479 | 475 | 476 |
| D021_3 | 173.0 | 0.533 4 | 474 | 477 | 475 | 477 |

图3中, a~d分别表示正常、内环故障、滚动体故障和外环故障融合信号的EMD分解过程和各模态分量的频率、能量分布情况。从图3中可以看出, EMD将信号分解为具有不同频段范围的IMF分量, 相邻分量一般有频率交叠现象, 但不同故障类型的IMF分量所具有的能量分布却各有特点。

随机挑选两组样本信号, 并对各样本信号进行EMD分解。提取故障信号与相同工况条件下正常信号的模态分量的能量比构建特征向量, 如表2所示。



a) 正常信号 EMD 分解过程及其各 IMF 的边际谱



b) 内环故障信号 EMD 分解过程及其各 IMF 的边际谱




图3 EMD分解过程及其各IMF分量的边际谱

Fig. 3 The results of EMD

表2 部分样本的特征向量

Table 2 The feature vectors of some samples

| 样本 | \mathcal{G}_1 | \mathcal{G}_2 | \mathcal{G}_3 | \mathcal{G}_4 | \mathcal{G}_5 |
|---------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 正常(样1) | 1.084 2 | 0.436 5 | 0.414 4 | 0.590 4 | 0.336 3 |
| 正常(样2) | 0.761 1 | 0.660 1 | 0.360 5 | 0.587 8 | 1.136 5 |
| 内环(样1) | 43.827 2 | 52.406 1 | 47.206 6 | 8.670 2 | 7.749 2 |
| 内环(样2) | 86.264 3 | 59.106 7 | 22.747 9 | 5.123 1 | 3.458 0 |
| 滚动体(样1) | 4.723 7 | 0.665 2 | 1.113 4 | 0.066 5 | 0.770 6 |
| 滚动体(样2) | 6.936 1 | 0.941 2 | 0.504 7 | 0.029 1 | 0.604 1 |
| 外环(样1) | 496.050 6 | 4.491 3 | 2.046 7 | 0.761 1 | 1.272 4 |
| 外环(样2) | 392.696 2 | 5.588 1 | 1.686 6 | 0.662 8 | 0.645 4 |

为了验证本文所提能量特征提取方法对滚动轴

承进行故障诊断的有效性,设计以下3个实验方案对参考文献所提特征提取方法和本文所提方法进行比较,仿真结果如表3所示。

方案一 按文献[1-5]仅提取各IMF分量与信号的能量比构建特征向量,并进行支持向量分类器的故障识别;

方案二 按文献[7]所提方法提取各IMF分量的小波包能量特征进行支持向量机分类器的滚动轴承故障诊断;

方案三 按照本文2.2节所述方法,提取各IMF分量的能量贡献率和信号信噪比共同构建特征向量,进行支持向量机分类器的滚动轴承故障诊断。

从表2中不难发现不同故障类型之间的特征具有较为明显的区别,进而说明了该特征能够表征滚动轴承的工作状态。

表3 仿真结果

Table 3 The simulation results

| 数据集 | 测试样本识别率/% | | | | 整体识别率/% | | |
|--------|-----------|-------|-------|-------|---------|------|-------|
| | N | I | B | O | 方案一 | 方案二 | 本文 |
| D007_0 | 100.0 | 100.0 | 100.0 | 100.0 | 97.0 | 93.6 | 100.0 |
| D007_1 | 100.0 | 100.0 | 100.0 | 100.0 | 99.9 | 95.8 | 100.0 |
| D007_2 | 100.0 | 100.0 | 100.0 | 100.0 | 98.4 | 95.4 | 100.0 |
| D007_3 | 100.0 | 100.0 | 100.0 | 100.0 | 96.5 | 97.6 | 100.0 |
| D014_0 | 99.1 | 78.6 | 65.9 | 96.8 | 77.2 | 73.2 | 86.6 |
| D014_1 | 100.0 | 61.3 | 88.6 | 97.6 | 77.3 | 85.5 | 88.4 |
| D014_2 | 100.0 | 63.8 | 75.4 | 91.2 | 69.8 | 77.1 | 82.6 |
| D014_3 | 100.0 | 66.4 | 78.3 | 85.2 | 75.8 | 80.4 | 83.7 |
| D021_0 | 100.0 | 79.8 | 96.8 | 68.2 | 82.6 | 81.7 | 86.2 |
| D021_1 | 100.0 | 84.3 | 89.0 | 78.6 | 86.2 | 87.9 | 88.0 |
| D021_2 | 100.0 | 99.4 | 88.8 | 84.2 | 85.6 | 88.4 | 93.1 |
| D021_3 | 100.0 | 99.8 | 79.6 | 97.2 | 91.2 | 92.3 | 94.1 |

从表3的仿真结果可以看出,虽然本方法对个别样本信号的识别率并不高,但是与方案一相比,通过引入正常信号的能量值能够丰富信号的能量特征,提高了对滚动轴承的故障识别率;与方案二相比,除了个别样本集识别率略低外,本文所述方法的故障识别率整体上优于文献[7]所述方法。仿真实验表明本文所提特征提取方法具有一定的有效性。

5 结语

针对滚动轴承振动信号具有非平稳性的特点,本文提出一种提取故障信号与相同工况条件下正常信号的模态分量能量比构建特征向量的特征提取方法,实现了滚动轴承故障识别率的有效提高。然而个别样本的故障识别率依然较低,因此,如何降低模态混叠现象对各模态分量的影响是下一步的工作重心。

参考文献:

- [1] 段礼祥, 张来斌, 李刚, 等. 基于EMD的天然气发动机供气系统故障诊断方法[J]. 车用发动机, 2010(1): 72-75.
Duan Lixiang, Zhang Laibin, Li Gang, et al. Fault Diagnosis of Gas Supply System for Natural Gas Engine Based on EMD[J]. Vehicle Engine, 2010(1): 72-75.
- [2] 吕艳新, 孙书学, 顾晓辉. 基于EMD和能量比的战场声目标分类与识别[J]. 振动与冲击, 2008, 27(11): 51-55.
Lv Yanxin, Sun Shuxue, Gu Xiaohui. Battlefield Acoustic Target Classification and Recognition Based on EMD and Power Ratio[J]. Journal of Vibration and Shock, 2008, 27(11): 51-55.
- [3] 张超, 陈建军, 郭迅. 基于EMD能量熵和支持向量机的齿轮故障诊断方法[J]. 振动与冲击, 2010, 29(10): 216-220.
Zhang Chao, Cheng Jianjun, Guo Xun. A Gear Fault Diagnosis Method Based on EMD Energy Entropy and SVM[J]. Journal of Vibration and Shock, 2010, 29(10): 216-220.
- [4] 周将坤, 陆森林. 基于EMD平均能量法的滚动轴承故障诊断[J]. 轻工机械, 2010, 28(2): 36-40.
Zhou Jiangkun, Lu Senlin. Fault Diagnosis of Rolling Bearing Based on EMD Average Energy Method[J]. Light Industry Machinery, 2010, 28(2): 36-40.
- [5] 张小蓊, 张歆, 孙进才. 基于IMF能量熵的目标特征提取与分类方法[J]. 计算机工程与应用, 2008, 44(4): 68-69.
Zhang Xiaojie, Zhang Xin, Sun Jincai. Feature Extraction and Classification Experiment Based on Energy Entropy of IMF's. Computer Engineering and Applications, 2008, 44(4): 68-69.
- [6] 冯志刚, 王祁, 信太克规. 基于EMD和SVM的传感器故障诊断方法[J]. 哈尔滨工业大学学报, 2009, 41(5): 59-63.
Feng Zhigang, Wang Qi, Shida Kataunori. Sensor Fault Diagnosis Based on Empirical Mode Decomposition and Support Vector Machines[J]. Journal of Harbin Institute of Technology, 2009, 41(5): 59-63.
- [7] 沈志熙, 黄席樾, 马笑潇. 基于EMD多模态特征融合支持向量机的故障诊断[J]. 控制与决策, 2009, 24(6): 890-893.
Shen Zhixi, Huang Xiyue, Ma Xiaoxiao. Fault Diagnosis Method Based on Empirical Mode Decomposition and Support Vector Machine[J]. Control and Decision, 2009, 24(6): 890-893.
- [8] 刘敏华, 肖德云. 基于相似度的多传感器数据融合. 控制与决策, 2004, 19(5): 534-537.
Liu Minhua, Xiao Deyun. Multi-Sensor Data Fusion Based on Similitude Degree[J]. Control and Decision, 2004, 19(5): 534-537.
- [9] 唐炬, 陈娇, 张晓星, 等. 用于局部放电信号定位的多样本能量相关搜索提取时间差算法[J]. 中国电机工程学报, 2009, 29(19): 125-130.
Tang Ju, Chen Jiao, Zhang Xiaoxing, et al. Time Difference Algorithm Based on Energy Relevant Search of Multi-Sample Applied in PD Location[J]. Proceedings of the CSEE, 2009, 29(19): 125-129.
- [10] 李健宝, 彭涛. 改进的EMD方法及其在滚动轴承故障诊断中的应用[J]. 湖南工业大学学报, 2009, 23(6): 28-32.
Li Jianbao, Peng Tao. Improved EMD and Its Application in Rolling Bearing Fault Diagnosis[J]. Journal of Hunan University of Technology, 2009, 23(6): 28-32.
- [11] 李琳, 张永祥, 明廷涛. EMD降噪的关联维数在齿轮故障诊断中的应用研究[J]. 振动与冲击, 2009, 28(4): 145-148.
Li Lin, Zhang Yongxiang, Ming Tingtao. Gear Fault Diagnosis Based on Correlation Dimension Pre-Processed with EMD[J]. Journal of Vibration and Shock, 2009, 28(4): 145-148.
- [12] 苏文胜, 王奉涛, 张志新, 等. EMD降噪和谱峭度法在滚动轴承早期故障诊断中的应用[J]. 振动与冲击, 2010, 29(3): 18-21.
Su Wensheng, Wang Fengtao, Zhang Zhixin, et al. Application of EMD Denoising and Spectral Kurtosis in Early Fault Diagnosis of Rolling Element Bearings[J]. Journal of Vibration and Shock, 2010, 29(3): 18-21.
- [13] 杨正友, 彭涛. 基于振动信号分析和支持向量机的滚动轴承故障诊断[J]. 湖南工业大学学报, 2009, 23(1): 96-99.
Yang Zhengyou, Peng Tao. Fault Diagnosis of Rolling Element Bearing Based on Vibration Signal Analysis and Support Vector Machine[J]. Journal of Hunan University of Technology, 2009, 23(1): 96-99.
- [14] Huang N E, Shen Z, Long S R. The Empirical Mode Decomposition and the Hilbert Spectrum for Non-Linear and Non-Stationary Time Series Analysis[C]//Proceedings of the Royal Society. London: [s.n.], 1998: 903-995.
- [15] Case Western Reserve University Bearing Data Center. Seeded Fault Test Data[DB/OL]. [2012-02-13]. http://www.eecs.cwru.edu/laboratory/bearing/welcome_overview.htm.

(责任编辑: 申剑)