

文章编号: 1005-0523(2019)05-0074-08

一种基于 UEE-EMD 的滚动轴承故障诊断方法

陈晓玥¹, 耿明², 陈鹏展¹

(1. 华东交通大学电气与自动化工程学院, 江西 南昌 330013; 2. 中国电子科技集团公司第二十八研究所, 江苏 南京 210007)

摘要: 滚动轴承是很多大型旋转机械的核心部件, 其故障诊断的研究对保障旋转机械运行稳定性具有重要的意义。经验模态分解方法对分析非线性不稳定的滚动轴承故障信号具有独到的优势。然而, 经验模态分解固有的端点效应问题往往会导致较大的故障特征提取误差, 影响故障诊断的准确性。针对上述问题, 本文提出基于无失真端点极值化的经验模态分解(UEE-EMD)的滚动轴承故障诊断方法, UEE-EMD 通过交叉取样策略和端点极值化策略从源头上抑制端点效应的产生, 利用本征模函数截头去尾从结果上屏蔽端点效应, 保证了滚动轴承故障特征提取的准确性。故障诊断仿真实验表明, 基于 UEE-EMD 的滚动轴承故障诊断取得了更好的诊断效果。

关键词: 故障诊断; 信号处理; 特征提取; 经验模态分解; 端点效应

中图分类号: TH133.33

文献标志码: A

经验模态分解^[1-2](empirical mode decomposition, EMD)近年来被广泛应用于故障诊断领域^[3-4], 但其固有的端点效应问题会严重影响故障分析效果^[5-6]。目前, 抑制端点效应的方法主要是数据延拓, 如局部规律延拓、数据预测和波形匹配延拓。局部规律延拓^[7-8]简单有效, 但是仅参考局部规律延拓信号, 不能反映数据的变化趋势, 延拓误差较大; 数据预测^[9-10]能有效把握信号趋势, 进而较好的控制延拓误差, 但是计算繁杂效率低; 波形匹配^[11]能实现较为理想的波形延拓, 匹配算法也相对简单。此外, 还有本征模函数选优^[12]等一些新型抑制端点效应的方法。

然而, 几乎所有的数据延拓方法都不能避免延拓误差, 只能在一定程度上减弱端点效应的影响, 不能从本质解决端点效应问题; 另外, 滚动轴承故障信号本身无法避免噪声污染, 环境噪声可能淹没故障信号本身的规律, 增加信号延拓的不准确性; 再者, 滚动轴承故障的发生发展有一个相对缓慢的过程, 信号的总体规律会有一个相对长的保存过程, 可以从样本截取上设计方案抑制端点效应。

因此, 本文深入分析端点效应产生的原因和滚动轴承故障发生发展的规律, 提出基于 UEE-EMD 的滚动轴承故障诊断方法。首先采用 UEE-EMD 提取故障特征, 保证故障信号分析的准确性, 然后结合概率神经网络实现滚动轴承的智能故障诊断。实验表明, 本文设计的方法有效提高了滚动轴承故障诊断的有效性。

1 经验模态分解及其端点效应

1.1 经验模态分解

EMD 分解原始信号获取 IMF 的过程被称作“筛选”过程^[13]; 对于目标信号 $x(t)$, 采用三次样条插值法分

收稿日期: 2019-01-18

基金项目: 国家自然科学基金青年项目(51609088); 第 63 批中国博士后科学基金面上项目(2018M632864); 江西省教育厅青年基金项目(GJJ170408)

作者简介: 陈晓玥(1988—), 女, 讲师, 博士, 研究方向为水利发电设备智能故障诊断, 大数据处理方法。

别对局部极大值和局部极小值序列进行拟合得到其上包络和下包络,并计算包络均值;目标信号减去包络均值筛选到一个震荡模式;EMD 不断重复“筛选”过程,直到得到满足本征模函数要求的震荡模式,即得到了原始信号的第一个 IMF 分量 $c_1(t)$ 。原始信号即为 $c_1(t)$ 和余量 $ru_1(t)$ 的和,继续对 $ru_1(t)$ 进行同样的分解,直到余量函数 $r_n(t)$ 是单调的或者其值已经足够小,信号 $x(t)$ 的经验模态分解结束,得到 $x(t)$ 的 IMF 集合。

1.2 经验模态分解的端点效应

在 EMD 分解中,采用三次样条插值拟合上下极值时,非极值点的端点会被当作极值点参与拟合计算,导致信号包络的失真,包络失真会随着 EMD 分解的重复“筛选”逐渐向内破坏数据,使得分解结果严重失真,这就是“端点效应”。在工程实际中,EMD 分解的样条插值端点效应无处不在,严重影响了信号分析的效果。

2 UEE-EMD 方法的基本原理

滚动轴承故障的特点:随着状态监测技术的发展,滚动轴承故障一般都在可控的状态下就已经被发现,在可控故障状态下,机械的运行状态相对稳定,故障发展和加重比较缓慢。因此,对于滚动轴承故障,传感器可以测取足够长的故障信号。样条插值端点效应产生的原因^[4]是信号端点往往不是信号极值点而被当作极值点参与样条插值计算。因此,如果以信号本身的极值点做信号的端点,就一定可以从源头上抑制样条插值的端点效应。

针对滚动轴承故障特征提取的需求,本文提出无失真端点极值化的经验模态分解方法(UEE-EMD),如图 1 所示。该方法主要包括 3 个策略:交叉取样策略、端点极值化策略和本征模函数截头去尾策略,如图 2 所示。① 交叉取样:提取样本的时候,在有效数据的两端都多取一段富余信号;② 端点极值化:对于交叉样本,选择富余信号中合适的极值点作为信号的新端点;③ 本征模函数截头去尾:当 EMD 分解完成后,依据有效数据的首尾标记,删除本征模函数中富余信号。

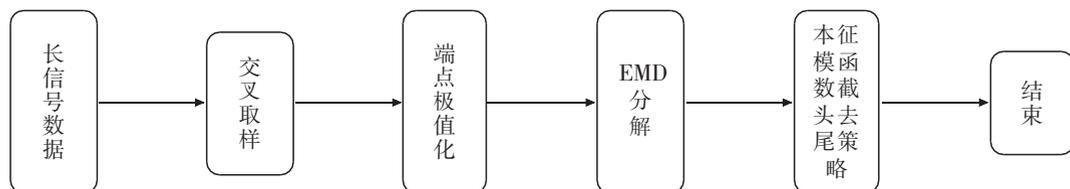


图 1 UEE-EMD 信号分解方法的流程图

Fig.1 The flow chart of UEE-EMD

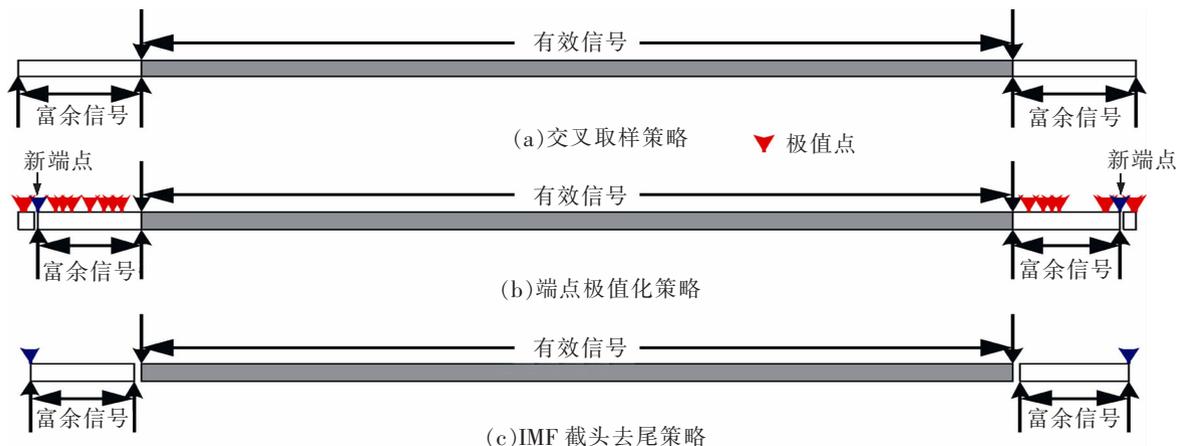


图 2 UEE-EMD 的 3 个策略

Fig.2 Three strategies of UEE-EMD

2.1 交叉取样策略

为了克服信号延拓技术的固有缺陷,本文采用交叉取样获得冗余信号,如图3所示,有效数据表示欲提取的有效样本,交叉样本是通过交叉取样获得的样本。交叉取样包括3个步骤:① 标记有效样本;② 交叉取样;③ 交叉样本归一化。

标记有效样本:记待分析信号 x 的起点为 $t_0=0$,记有效样本的长度为 ΔT ,记冗余信号长度为 Δt ,则可根据式(1)和式(2)依次求取各个有效样本的起始点 t_{isn} 和结束点 t_{ven}

$$t_{isn}=\Delta t+(n-1)\Delta T \quad (1)$$

$$t_{ven}=\Delta t+n\Delta T \quad (2)$$

交叉取样:在有效数据两端各扩充 Δt 长度的信号,便可得到交叉样本,如式(3)和式(4), t_{ssn} 和 t_{sen} 分别表示交叉样本的起始点和结束点

$$t_{ssn}=t_{isn}-\Delta t \quad (3)$$

$$t_{sen}=t_{ven}-\Delta t \quad (4)$$

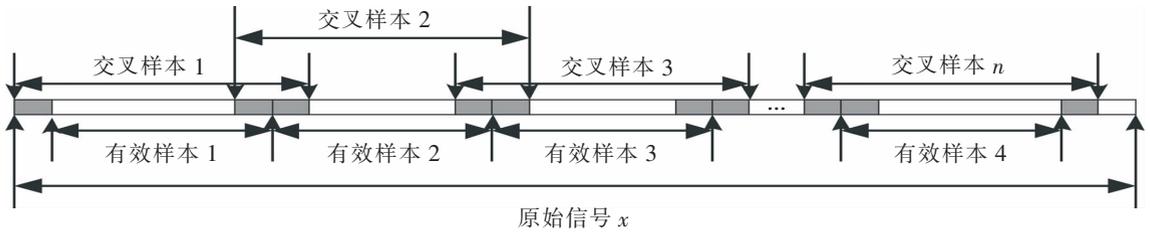


图3 交叉取样策略示意图

Fig.3 The schematic diagram of overlapped sampling

因此,只要知道 Δt 和 ΔT 就可求取交叉样本, ΔT 可根据数据分析的需要人为设定,而 Δt 是否合理直接决定端点效应对有效数据的影响程度。假设冗余信号必须包含 m 个极值点,其 Δt 的计算步骤如下:首先计算出信号 x 中任意两个相邻极值点之间的最大距离 Δt_{\max} 和最小距离 Δt_{\min} ;然后按照式(5)设置 Δt 的取值,依据待分析信号 x 的长度 Δt_x , Δt , ΔT 和式(6),式(7)就可以求出交叉样本的个数 n ;最后结合式(1)~式(4)计算交叉样本的起始点和结束点,完成交叉取样

$$\Delta t=\Delta t_d+m\Delta t_{\max} \quad (0 < \Delta t_d < \Delta t_{\min}) \quad (5)$$

$$2\Delta t+n\Delta T < \Delta t_x \leq 2\Delta t+(n+1)\Delta T \quad (6)$$

$$\frac{\Delta t_x-2\Delta t}{\Delta T}-1 \leq n < \frac{\Delta t_x-2\Delta t}{\Delta T} \quad (7)$$

交叉样本归一化:将所有交叉样本的起始点、结束点、对有效数据的起始点、结束点分别标记为 $0, \Delta t+2\Delta T, \Delta t, \Delta t+\Delta T$ 。

2.2 端点极值化策略

交叉取样不仅实现了数据延拓的功能,还保证了信号样本的零误差性。但是,交叉取样只是将端点效应的不利影响拦截在有效信号之外,不能从根本上抑制端点效应的产生。如果在零误差信号延长的基础上,保证信号样本端点的极值性,就能从根本上限制端点效应的产生。因此,本文提出向内搜索的端点极值化策略,它包括查找极值点、端点极值化和数据重标记3个步骤,如图4所示。

查找极值点:从交叉样本两端点开始,逐步向内查找信号各端的第1个极值 t_{s1} 和 t_{e1} 。

端点极值化:去掉 t_{s1} 和 t_{e1} 外侧的多余信号,得到以极值点 t_{s1} 和 t_{e1} 为端点的交叉样本。

数据重标记:按照式(8)对极值端点交叉样本的所有数据进行重新标记。

$$t_n=t_n-t_{s1} \quad (8)$$

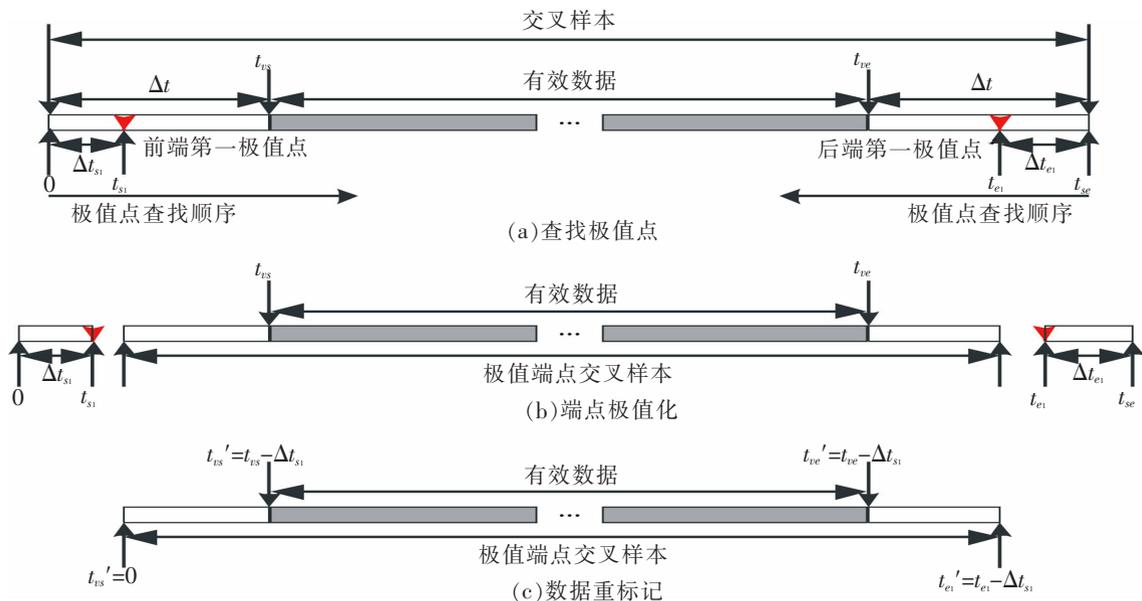


图 4 端点极值化策略示意图

Fig.4 The schematic diagram of endpoint extremum

2.3 本征模函数截头去尾策略

交叉取样和端点极值化给 EMD 分解准备了零失真极值端点的样本数据,试图从源头上制约端点效应。然而,极值端点只保证了第 1 次分解前数据的零误差性和端点极值性,分解产生的余项的端点极值性还是无法保证。因此,本文依旧保留传统端点效应抑制方法对本征模函数的截头去尾操作,即依据有效数据的首尾标记截去本征模函数两端的富余信号。

3 无失真端点极值化取样仿真实验

旋转机械的振动故障信号通常是由基频振动分量和其他倍频谐波分量组成,如式(9)。仿真实验通过 $e_1(t) \sim e_5(t)$ 的组合形成 1 组测试信号 $x_{fe}(t)$,如式(10)所示; A 为 $[0.3, 0.4]$ 范围内的随机数; B 为 $[0.28, 0.32]$ 范围内的随机数; C 为 $[0.09, 0.11]$ 范围内的随机数。

$$\begin{cases} e_1(t) = \sin(2\pi \times 60t) \\ e_2(t) = (1 + 0.1\sin(2\pi \times 15t)) \times \sin(2\pi \times 120t + 0.2\sin(2\pi \times 10t)) \\ e_3(t) = \sin(2\pi \times 240t) \\ e_4(t) = \sin(2\pi \times 360t) \\ e_5(t) = \text{noise} \end{cases} \quad (9)$$

$$x_{fe}(t) = e_1(t) + A \times e_2(t) + B \times e_3(t) + C \times e_4(t) + e_5(t) \quad (10)$$

表 1 延拓信号与原始信号在两端的误差

Tab.1 Signal-ends errors caused by signal extension

延拓方法	UEE-EMD	内积延拓	自适应三角波匹配	斜率匹配
左端	0	0.197 6	0.650 5	0.276 0
右端	0	0.991 8	0.893 9	1.026 9

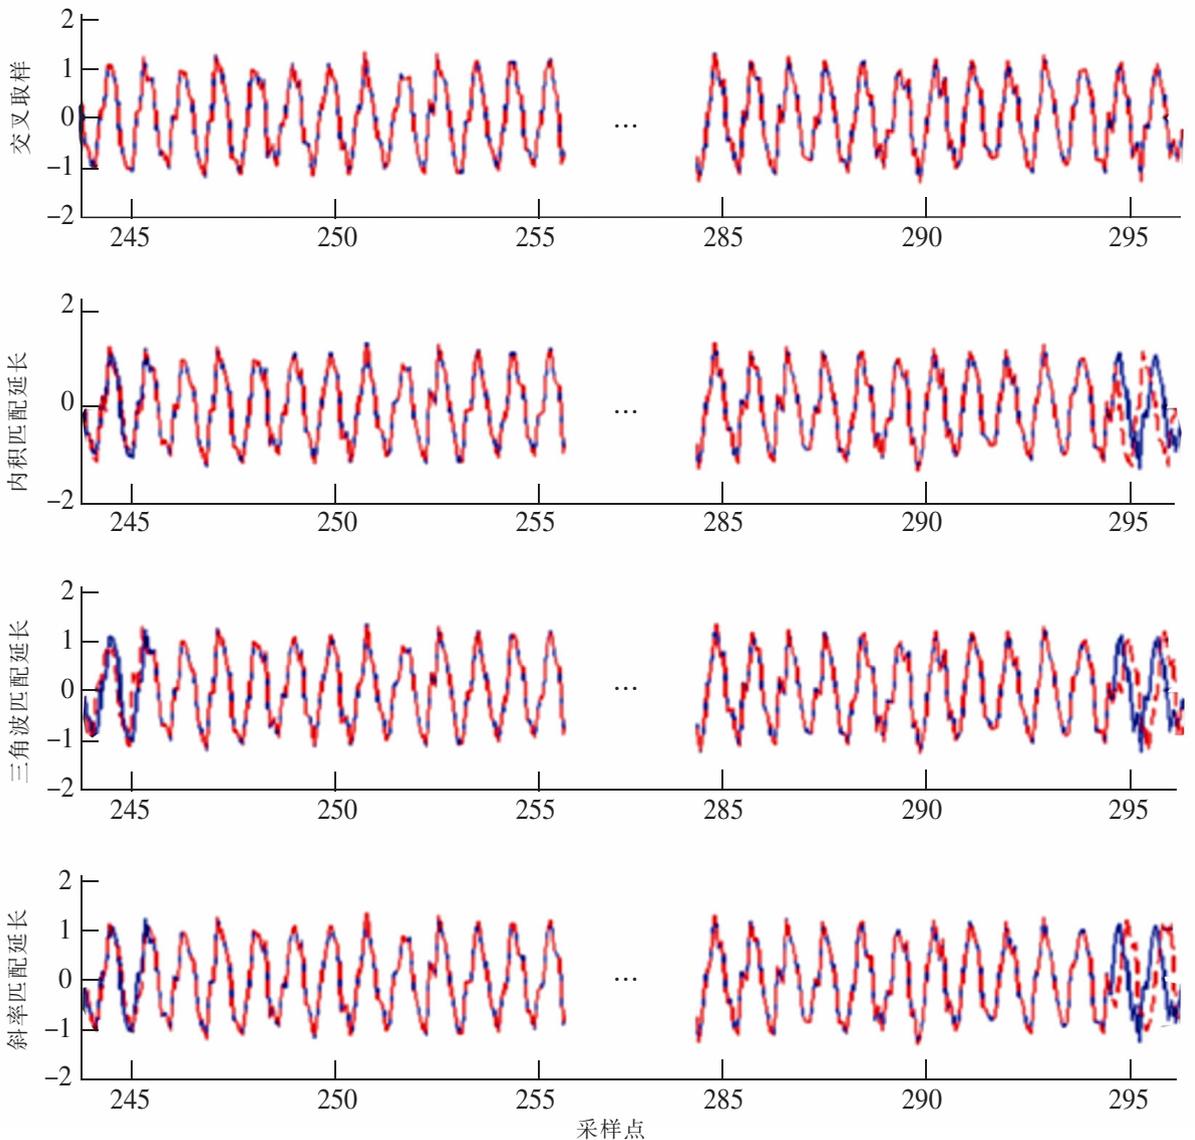


图5 交叉取样与信号延拓技术的对比

Fig.5 Comparison of overlapped sampling and signal extension

首先,对于仿真信号 $x_f(t)$,取时间轴 245.535 1 到 294.229 8 时间段的信号为有效数据。然后,分别采用交叉取样、内积匹配延长、三角波匹配延长、斜率匹配延长处理信号样本,得到延长后信号如图 5 所示,计算延拓信号与原始信号在两端的误差如表 1 所示。

从图 5 和表 1 可知,数据延拓技术都引入了明显的误差,而本文提出的交叉取样策略可以保证信号样本的零误差性。

另外,本文提出的端点极值化技术选用信号本身的极值点作为样本的端点,同时保证了信号样本的端点极值性。因此,本文设计的无失真端点极值化技术可以为后续的 EMD 分解提供一个有效的数据基础,是一种优秀的端点效应抑制方法,对于长信号的经验模态分解的预处理可以取得很好的效果。

4 滚动轴承故障诊断

近年来,经验模态分解被广泛应用于滚动轴承的故障检测与诊断^[15]。本文将 UEE-EMD 应用于滚动轴故障的特征提取,并结合概率神经网络实现滚动轴承故障智能诊断^[16]。本文采用文献[17]中提供的滚动轴承故障数据,如表 2 所示。

表 2 6 种轴承故障数据样本描述
Tab.2 Six kinds of bearing faults

类别标签	故障位置	缺陷程度	故障样本序列长度	故障样本数目/个
1	外环	0.007	500	118
2	内环	0.007	500	118
3	滚珠	0.007	500	118
4	外环	0.014	500	118
5	内环	0.014	500	118
6	滚珠	0.014	500	118

首先,应用 UEE-EMD 方法分解每类故障样本;然后,取每个样本的前 5 个本征模函数计算其如故障时域特征及故障频域特征所示的 20 项特征,用所得的 100 项特征来表征故障。

1) 故障时域特征

$$TF_1 = \frac{1}{N} \sum_{n=1}^N x(n), TF_2 = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n) - TF_1]^2}, TF_3 = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)}, TF_4 = \max |x(n)|, TF_5 = \frac{N}{(N-1)(N-2)} \sum_{n=1}^N \left(\frac{x(n) - TF_1}{TF_2}\right)^3, TF_6 = \left\{ \frac{N(N+1)}{(N-1)(N-2)(N-3)} \right\} \sum_{n=1}^N \left(\frac{x(n) - TF_1}{TF_2}\right)^4 - \frac{3(N-1)^2}{(N-2)(N-3)}, TF_7 = \frac{TF_4}{TF_3}, TF_8 = \frac{TF_4}{\left(\frac{1}{N} \sum_{n=1}^N |x(n)|\right)^2},$$

$$TF_9 = \frac{TF_3}{\frac{1}{N} \sum_{n=1}^N |x(n)|}, TF_{10} = \frac{TF_4}{\frac{1}{N} \sum_{n=1}^N |x(n)|}。式中:x(n)是 n=1,2,\dots,N 对应的信号系列;N 是信号的长度。$$

2) 故障频域特征

$$FF_1 = \frac{\sum_{k=1}^K s(k)}{K}, FF_2 = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}, FF_3 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}, FF_4 = \sqrt{\frac{\sum_{k=1}^K (f_k - FF_2)^2 s(k)}{K}}, FF_5 = \sqrt{\frac{\sum_{k=1}^K f_k^4 s(k)}{\sum_{k=1}^K f_k^2 s(k)}},$$

$$FF_6 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k^4 s(k)}}, FF_7 = \frac{FF_4}{FF_1}, FF_8 = \frac{\sum_{k=1}^K (f_k - FF_1)^3 s(k)}{K FF_1^3}, FF_9 = \frac{\sum_{k=1}^K (f_k - FF_5)^4 s(k)}{K FF_6^4}, FF_{10} = \frac{\sum_{k=1}^K (f_k - FF_5)^{12} s(k)}{K \sqrt{FF_6}}。$$

式中:s(k)是 k=1,2,\dots,K 所对应的频谱;K 是谱线的数量;f_k 是第 k 条谱线所对应的频率值。

对于每一类故障,随机抽取 50 组样本将概率神经网络训练成相应的分类器,并将剩余的样本用作检测本来检测故障诊断的准确率,重复上述实验过程 10 次,记录并统计实验结果,如表 3;将内积匹配延长、三角波匹配延长、斜率匹配延长分别应用于滚动轴承故障信号的经验模态分解,提取相同的特征集,应用相同的方法在相同的环境下进行故障诊断,其结果对比如表 4 所示。

表 3 显示,基于 UEE-EMD 的特征提取方法获得了较为理想的故障诊断准确率,这充分说明 UEE-EMD 可以有效挖掘滚动轴承故障的有效特征,是一种实用的多元故障征兆提取方法。从表 4 可以看出,UEE-

EMD 相对于传统的经验模态分解得到了更为优秀的诊断结果。因此,UEE-EMD 与时频特征提取方法相结合的策略,可以很好地提取滚动轴承故障的关键信息。

表 3 基于 UEE-EMD 的滚动轴承故障诊断结果
Tab.3 The fault diagnosis results of UEE-EMD

故障类别	诊断准确率/%	特征提取时间/ms	训练时间/ms	诊断时间/ms
F1	100	2 679	1 331	1 110
F2	97.20	2 656	1 376	1 123
F3	95.73	2 665	1 429	1 119
F4	96.02	2 657	1 375	1 108
F5	96.61	2 688	1 362	1 103
F6	97.79	2 671	1 371	1 121

表 4 UEE-EMD 与信号延拓技术的诊断结果对比
Tab.4 The comparison of the fault diagnosis results

故障特征提取方式	平均准确率/%	平均特征提取时间/ms	平均训练时间/ms	平均诊断时间/ms
UEE-EMD	97.23	2 669	1 374	1 114
内积匹配	96.32	2 632	1 369	1 107
自适应三角波匹配	95.73	2 673	1 358	1 123
斜率匹配	96.02	2 695	1 362	1 119

5 结论

本文在充分考虑滚动轴承故障本身特性的基础上,充分结合经验模态分解多元征兆的优势,有效规避经验模态分解的缺陷,提出基于 UEE-EMD 的滚动轴承故障诊断方法;借助滚动轴承故障信号相对较长的优势,设计交叉取样策略、端点极值化策略、截头去尾策略从成因和结果两方面消除端点效应对经验模态分解效果的影响,实现滚动轴承故障准确的多元特征提取;最后结合概率神经网络实现滚动轴承智能故障诊断。该方法利用了经验模态分解在信号多远特征提取中的优势,同时保证特征提取和故障表征的准确性,明显提高了故障诊断的准确性,是一种很好的滚动轴承智能故障诊断方法。

参考文献:

- [1] WANG C Q,ZHOU J Z,QIN H,et al. Fault diagnosis based on pulse coupled neural network and probability neural network[J]. Expert Systems with Applications,2011,38(11):14307-14313.
- [2] LEI Y G,HE Z J,ZI Y Y. Application of the EEMD method to rotor fault diagnosis of rotating machinery [J]. Mechanical Systems and Signal Processing,2009,23(4):1327-1338.
- [3] 马新娜,杨绍普. 滚动轴承复合故障诊断的自适应方法研究[J]. 振动与冲击,2016,35(10):145-150.
- [4] 陈俊洵,程龙生,胡绍林,等. 基于 EMD 的改进马田系统的滚动轴承故障诊断[J]. 振动与冲击,2017,36(5):151-156.
- [5] 杨小强,李沛,黄杰,等. 基于极值波延拓的端点效应处理方法[J]. 系统工程与电子技术,2016,38(9):1987-1992.
- [6] YU Y L,LI W,SHENG D R,et al. A hybrid short-term load forecasting method based on improved ensemble empirical mode decomposition and back propagation neural network[J]. Journal of Zhejiang University-Science A (Applied Physics & Engineering),2016,17(2):101-114.

- [7] 李钊,周晓军,徐云. 基于均生函数周期叠加外推法的 EMD 端点问题的研究[J]. 振动与冲击,2013,32(15):138-142.
- [8] 张桂南,刘志刚,向川,等. 多频调制下电气化铁路电压波动特性分析及频率估计[J]. 电网技术,2017,41(1):251-257.
- [9] 张梅军,陈灏,曹勤,等. 基于 SVM 信号延拓改进的 EEMD 方法[J]. 振动、测试与诊断,2013,33(1):93-98.
- [10] CHENG J S, YU D J, YANG Y. Application of support vector regression machines to the processing of end effects of Hilbert-Huang transform[J]. Mechanical Systems and Signal Processing, 2007, 21(3): 1197-1211.
- [11] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971): 903-995.
- [12] 韩建平,钱炯,董晓军. 采用镜像延拓和 RBF 神经网络处理的 EMD 中端点效应[J]. 振动、测试与诊断,2010,30(4):414-417.
- [13] 赵娜. HHT 经验模式分解的周期延拓方法[J]. 振动、测试与诊断,2008,25(12):346-350.
- [14] XIAO H, ZHONG J Z, XIAO J, et al. Fault diagnosis for rotating machinery based on multi-differential empirical mode decomposition[J]. Journal of Vibroengineering, 2014, 16(1): 487-498.
- [15] 肖汉,周建中,肖剑,等. 滑动轴承-转子系统不平衡-不对中-碰摩耦合故障动力学建模及响应信号分解[J]. 振动与冲击, 2013, 32(23): 159-165.
- [16] 刘正平,胡俊,胡俊锋,等. 基于 MED-Teager 能量算子的滚动轴承故障诊断[J]. 华东交通大学学报,2017; 34(4):97-103.
- [17] ZHANG X Y, ZHOU J Z, WANG C Q, et al. Multi-class support vector machine optimized by inter-cluster distance and self-adaptive deferential evolution[J]. Applied Mathematics and Computation, 2012, 218(9): 4973-4987.

A Failure Diagnosis Method for Rolling Bearings Based on UEE-EMD

Chen Xiaoyue¹, Geng Ming², Chen Pengzhan¹

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China;

2. The 28th Research Institute of China Electronics Technology Group Corporation, Nanjing 430074 China)

Abstract: Rolling bearing is the core component of large rotating machinery, and the fault diagnosis of rolling bearings is of great significance to guarantee the stability of rotating machinery. EMD is a very effective method for fault diagnosis because of its unique advantages in the analysis of nonlinear unstable signal. However, the intrinsic endpoint effects of EMD cause non-negligible feature extraction errors, which will affect the accuracy of fault diagnosis. To solve the above problem, this paper proposed an EMD method based on undistorted source signal whose endpoints are extreme points(UEE-EMD). EMD restrained the emergence of endpoint effects from the source through overlapping sampling and extremal endpoints, obstructed the signal distortion by cutting the ends of IMFs, and guaranteed the accuracy of the feature extraction. The simulation experiment of fault diagnosis shows that the rolling bearing fault diagnosis based on UEE-EMD achieves better diagnosis results.

Key words: fault diagnosis; signal process; feature extraction; empirical mode decomposition; end effect