

基于EMD-HMM的BIT间歇故障识别*

郭明威, 倪世宏, 朱家海

(空军工程大学工程学院 西安, 710038)

摘要 针对引起机内测试系统(BIT)虚警的间歇故障,提出了一种基于经验模态分解(EMD)和隐马尔科夫模型(HMM)的间歇故障诊断方法以抑制虚警。首先对原始信号进行EMD分解,选择能量最大的几个固有模式分量函数(IMF)进行特征提取,作为系统状态的观测值;然后将观测值输入到训练好的HMM中进行决策,求取最大似然概率值作为识别结果。结果表明,利用EMD进行特征提取并与HMM方法相结合能很好地分类出各种状态,有效地诊断出间歇故障。

关键词 机内测试;虚警;间歇故障;经验模态分解;隐马尔科夫模型

中图分类号 TP274; TH113

引言

机内测试技术已成为改善装备或系统测试性能与诊断能力的重要手段,并大量应用于军用装备和航空航天系统中^[1],但高虚警率始终阻碍着BIT充分发挥效能和更广泛地应用^[1-2]。国内、外大量研究表明,间歇故障是BIT系统暂时失效,从而导致虚警的一个主要原因^[2-3],诊断间歇故障是有效抑制BIT虚警的手段。对间歇故障的诊断多集中在基于概率的方法^[4]、基于人工智能(如神经网络虚警过滤器^[5]等)的方法上,但是概率方法需要事先知道故障与间歇故障发生的概率,条件苛刻;神经网络法从单一时刻的状态来判别,忽略了间歇故障发生前后的信息,易引起诊断决策的错误。

故障诊断的实质是一个模式识别的过程,包括特征提取和状态识别两个环节。机内测试系统的间歇故障变化是一种变化剧烈的非平稳时间序列。在非平稳时间序列信号的处理方面,Huang^[6]等提出的经验模态分解,是一种新的自适应时频分析方法。

HMM^[7]是一种动态时间序列模式识别工具,特别适合处理非平稳、重复再现性差的信号。间歇故障前后时刻的状态存在着一定的转移关系,这种状态转移关系给诊断决策提供了重要的信息。HMM不仅可以联系故障发生前后的信息,识别出故障的类型,而且可以揭示系统潜在的变化特征,对设备状态进行观测、评估,发现故障早期发展的迹象。

基于此,笔者提出一种基于EMD分解的能量特征提取和以HMM模型为诊断决策的间歇故障诊断方法,并将此法应用到动调陀螺仪的陀螺信号非平稳运行过程的间歇故障诊断中来抑制虚警,以验证其有效性。

1 基于EMD的特征提取

1.1 经验模态分解

经验模态分解后的每个固有模式函数必须满足以下两个条件^[6]:a. 整个数据长度中极值点的数量与过零点的数量必须相等或最多相差一个;b. 在任一时间点上,信号局部最大值确定的上包络线和局部最小值确定的下包络线的均值为零。EMD的分解过程可以形象地称之为“筛”的过程,步骤如下^[8]:

1) 找到信号 $x(t)$ 的局部极大值和极小值,所有的局部极大值用3次样条插值函数插值形成数据的上包络,同样,所有的局部极小值通过插值形成数据的下包络,上、下包络的平均值记作 $m_1(t)$,令 $h_1(t) = x(t) - m_1(t)$,如果 $h_1(t)$ 不满足IMF的两个必要条件,则把 $h_1(t)$ 看作新的原始信号,进行第2次“筛”。重复进行 k 次,直到 $h_{1k}(t)$ 是一个IMF

$$h_{1(k-1)}(t) - m_{1k}(t) = h_{1k}(t) \quad (1)$$

记 $c_1(t) = h_{1k}(t)$ 为信号 $x(t)$ 的第1阶IMF。

采用停止准则对筛分过程进行约束,以前后两个 $h_{1(k-1)}(t)$ 和 $h_{1k}(t)$ 的标准差SD来判断,即

* 航空科学基金资助项目(编号:20080896009)

收稿日期:2010-10-24;修改稿收到日期:2011-03-01

$$SD = \sum_{t=0}^T \left[\frac{|h_{1(k-1)}(t) - h_{1k}(t)|^2}{h_{1(k-1)}^2(t)} \right] \quad (2)$$

2) 把原始信号 $x(t)$ 减去第 1 阶固有模式函数 $c_1(t)$, 则得到残余量 $r_1(t)$

$$x(t) - c_1(t) = r_1(t) \quad (3)$$

3) 对 $r_1(t)$ 重复以上筛选过程, 从高频到低频可依次得到一系列的 IMF 分量 $c_i(t)$ 和残余项 $r_n(t)$, 原始数据 $x(t)$ 可重构为

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (4)$$

其中: 余项 $r_n(t)$ 为信号的平均趋势; 各个 IMF 分量 $c_i(t)$ 为信号固有的谐波成分。

通常, EMD 分解出来的前几个 IMF 分量往往集中了原信号中最显著、最重要的信息。

1.2 基于固有模式函数的特征提取

经 EMD 分解后的各个 IMF 包含了信号从高到低不同频率段的成分, 各频带能量的变化表征了故障发生的情况。笔者提出针对每个 IMF 单独进行分析提取能量特征的方法, 以获得更好的故障特征信息。考虑到故障信息主要集中在高频带即前几个权值比重大的 IMF 中, 因此, 选取前几个 IMF 分量的能量作为特征向量来识别工作状态与故障类型, 特征提取步骤如下:

1) 对于给定信号 $x(t)$, 设经过 EMD 分解后的 IMF 分量为 $c_i(t)$, 则 $c_i(t)$ 分频段的能量 E_i 为

$$E_i = \sum_{t=0}^N |c_i(t)|^2 \quad (5)$$

其中: N 为信号长度; i 为 IMF 的个数。

2) 选取能量最大的前 n 个包含主要故障信息的 IMF 分量, 求能量向量的第二范数

$$E = \left(\sum_{i=1}^n |E_i|^2 \right)^{\frac{1}{2}} \quad (6)$$

3) 构造特征向量 T

$$T = [E_1/E, E_2/E, \dots, E_n/E] \quad (7)$$

基于经验模态分解的特征提取方法选取了能量最大的 IMF, 可显著滤除噪声影响, 很适合于探测正常信号中夹杂的间歇瞬态现象并展示其成分。同时, 对各 IMF 单独提取特征向量, 可避免分量之间的交叠失真, 有利于故障信号的特征提取和状态识别。

2 基于 HMM 的状态识别

2.1 隐马尔科夫模型

HMM 是在 Markov 链的基础上发展而来的一种统计模型, 是一个双重随机过程^[9]。模型中真实的状态不能直接看到, 只能是通过一个观测值去感知

状态的存在及特征。HMM 具体可表示为

$$\lambda = (\pi, \mathbf{A}, \mathbf{B}) \quad (8)$$

其中: π 为初始概率分布矢量; \mathbf{A} 为状态转移概率矩阵; \mathbf{B} 为观测值概率矩阵。

π, \mathbf{A} 描述的是一个 Markov 链, 产生的输出是状态序列; \mathbf{B} 描述的是一个随机过程, 产生的输出为观察值序列。

2.2 基于 HMM 模型的选择与训练

模型采用左右型三状态转移的 Markov 链, 每个状态的观测概率由 2 个高斯概率密度函数联合决定。系统开始时总是处于正常状态, 因此取初始状态概率矢量为 $\pi = [1, 0, 0]$, \mathbf{A} 的初值均匀选取。为增加 HMM 诊断模型的稳健性, 训练时利用多个观测值序列的重估算法, 由初始模型对训练样本进行 Baum-Welch 算法

$$\bar{\pi}_i = \sum_{l=1}^L \alpha_{1 \times L}(i) \frac{\beta_{1 \times L}(i)}{P(O/\lambda)} \quad (1 \leq i \leq N) \quad (9)$$

$$\bar{\alpha}_{ij} = \frac{\sum_{l=1}^L \sum_{t=1}^{T_{l-1}} \alpha_{i \times L}(i) \alpha_{ij} b_j(O_{t+1,l}) \beta_{t+1,l}(j) / P(O_l/\lambda)}{\sum_{l=1}^L \sum_{t=1}^{T_{l-1}} \alpha_{i \times L}(i) \beta_{t,l}(j) / P(O_l/\lambda)} \quad (1 \leq i \leq N, 1 \leq j \leq N) \quad (10)$$

$$\bar{b}_{jk} = \frac{\sum_{l=1}^L \sum_{t=1}^{T_{l-1}} \alpha_{i \times L}(i) \beta_{t,l}(j) / P(O_l/\lambda)}{\sum_{l=1}^L \sum_{t=1}^{T_{l-1}} \alpha_{i \times L}(i) \beta_{t,l}(j) / P(O_l/\lambda)} \quad (1 \leq l \leq N, 1 \leq k \leq M) \quad (11)$$

其中: α 为前向变量; β 为后向变量; L 为观测值序列的数量。

由初始模型对训练样本进行匹配计算和状态标注后, 估计出一组新的模型, 再对训练样本重新进行匹配计算和状态标注, 估计出更新的模型参数 λ , 如此反复直至收敛, 得到优化模型, 使 $P(O|\lambda)$ 最大。

2.3 基于 HMM 模型的诊断方法

传统 BIT 是基于正常和故障两状态分类的, 忽略了间歇故障状态, 这样导致的结果是在间歇故障活跃时 BIT 报警有永久故障, 事后又找不到故障; 在间歇故障不活跃时 BIT 判断系统正常, 引起虚警。因此将系统划分为正常态、间歇态和故障态 3 种状态进行诊断识别以达到抑制虚警的目的^[9]。基于 HMM 模型的间歇故障诊断方法如图 1 所示。

诊断分为两个阶段: a. 分别对正常、间歇和故障 3 种状态的训练样本提取特征向量, 利用 Baum-

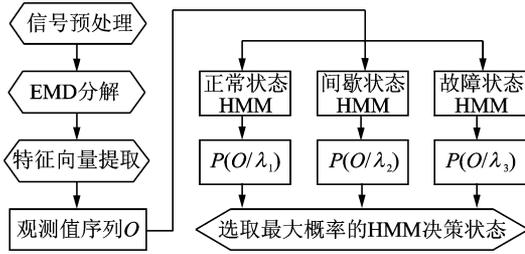


图1 基于HMM模型的诊断方法

Welch 算法进行模型训练,获得各类典型故障的HMM模型;b.在实际状态监测时,将测得的信号经EMD分解处理提取特征向量后作为观测值序列,将其送入已经训练好的HMM模型,通过前向-后向算法计算观测向量在不同模型下的概率 $P(O|\lambda)$,由概率值最大的HMM模型决定被测系统的状态。

3 试验结果与分析

动调陀螺仪是一种被广泛应用于航空航天导航与制导系统中的高精度陀螺仪,其故障常常导致飞行器无法完成预定任务,并可能导致重大恶性事故。对于动调陀螺仪而言,随着高速旋转机电部件的磨损和变形,其动态性能将出现各种细微的变化,而所有这些变化都会在振动能量的增加上反映出来^[10];因此,对陀螺振动信号的监测和分析能够获得陀螺运行异常或故障的有效信息,诊断间歇故障抑制虚警。试验对象为G01254-3型动调陀螺仪,采用CA-YD-107压电式加速度传感器拾取振动信号,采样频率为10 kHz,得到正常、间歇、故障3种状态振动数据见图2。

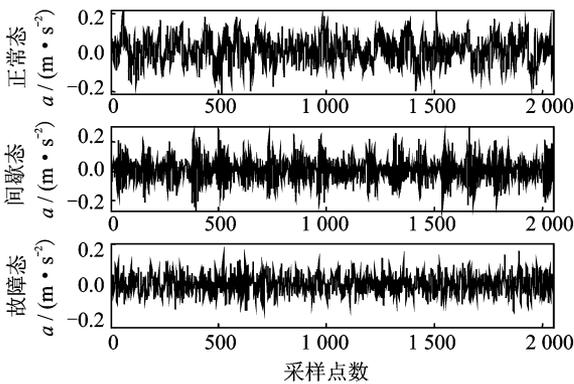


图2 3种状态的振动信号

3.1 经验模态分解的故障特征提取

首先,对不同状态的振动信号进行EMD分解。这里以正常信号为例,得到9个IMF分量,此处只给

出了前5个IMF时域波形,如图3所示。

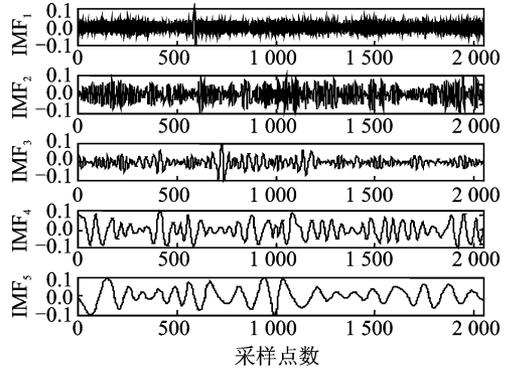


图3 信号IMF分量时域波形

分析图3可以看出,能量主要集中在前几个基本频段较高的IMF中,在每个IMF频段中的故障特征,具有比原始信号中更加集中的表现形式。

表1给出了前5个IMF分量相对于原始信号能量所占比重及重构误差,结果表明,采用包含主要故障信息的前5个IMF进行特征提取和状态识别是合理的。IMF分量按频率成分由高到低的顺序排列为 $c_1(t), c_2(t), \dots, c_5(t)$,按式(5)~式(7)求出特征向量 $T=[E_1/E, E_2/E, \dots, E_5/E]$ 。

表1 IMF分量与原始信号的能量关系

	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅
能量比重	0.265 3	0.297 2	0.078 3	0.096 6	0.157 0
重构误差	0.278 3	0.312 4	0.088 9	0.108 6	0.131 2

3.2 基于HMM模型的间歇故障识别

通过验得到正常、间歇和故障3种状态的样本序列各30组,每组序列有2 048个点,抽取10组作为训练样本,其余20组作为验证样本。对样本序列提取的特征向量经归一化处理,作为系统状态的观测值。利用10组训练样本得到正常状态HMM(λ_1)、间歇状态HMM(λ_2)和故障状态HMM(λ_3),训练时一般循环20次左右收敛。

对于正常状态的20组验证样本进行分类测试,结果如图4所示。图中每一条曲线表示样本输入到3个HMM模型时的输出概率,输出概率最大的模型代表状态识别结果。图4的测试结果表明,20组正常样本的识别结果均为正常状态,即正常HMM(λ_1)对20组样本的识别输出概率是最大的。

同样对间歇态、故障态的20组验证样本分别测试,结果如图5、图6所示,可见模型均能对样本的状态正确识别。

表2是部分测试数据组在各个模型下的输出的

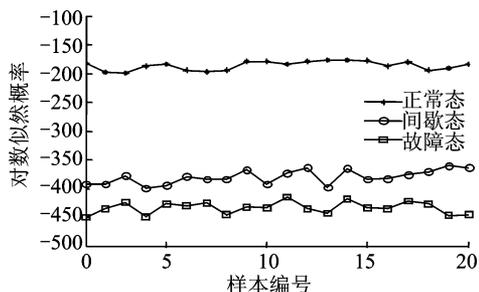


图4 HMM对正常状态的识别

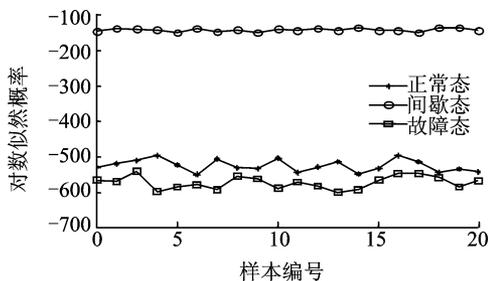


图5 HMM对间歇状态的识别

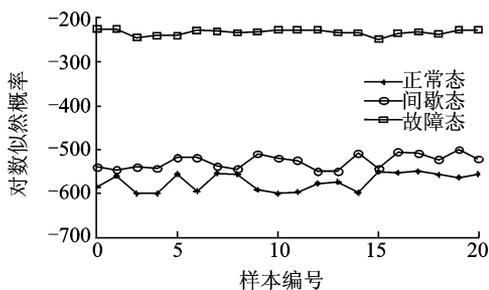


图6 HMM对故障状态的识别

对数似然概率值,并根据输出概率最大分类原则做出的判决结果。

表2 HMM模型对测试数据决策状态的判别结果

样本	正常态模型	间歇态模型	故障态模型	判别结果
λ_1-1	-196.973 8	-382.408 4	-444.519 6	正常态
λ_1-2	-188.731 2	-386.398 1	-417.249 8	正常态
λ_2-1	-533.642 7	-147.091 6	-557.007 5	间歇态
λ_2-2	-547.296 1	-136.427 8	-569.321 3	间歇态
λ_3-1	-578.381 3	-513.367 5	-233.249 9	故障态
λ_3-2	-567.089 2	-528.888 7	-244.978 1	故障态

由表2可见,所有测试数据的状态都可以正确识别,没有误判现象,具有较高的稳定性和识别率。

4 结束语

笔者针对间歇故障引起的BIT虚警,提出基于EMD-HMM的抑制虚警方法。首先,对间歇故障信号进行EMD分解,得到一系列的IMF分量,对高频

带的IMF单独提取能量特征,以此作为HMM的训练和验证样本;然后,根据系统的状态建立连续高斯密度混合隐马尔可夫模型,进行训练和诊断。将其应用在动调陀螺仪上,结果表明能有效地诊断出间歇故障,达到降低虚警的目的。

参 考 文 献

- [1] 曾天翔. 电子设备测试性及诊断技术[M]. 北京: 航空工业出版社, 1996: 1-2.
- [2] 温熙森, 徐永成, 易晓山, 等. 智能机内测试理论与应用[M]. 北京: 国防工业出版社, 2002: 29-31.
- [3] Drew R, Young N. Role of BIT in support system maintenance and availability [J]. IEEE AES Magazine, 2004, 19(8): 3-7.
- [4] Blough D M, Sullivan G F, Masson G M. Intermittent fault diagnosis in multiprocessor systems [J]. IEEE Transactions on Computers, 1992, 41(11): 1430-1441.
- [5] Aylstock F, Elerin L, Hintz J. Neural network false alarm filter [R]. USA: Raytheon Company, 1994.
- [6] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the hilbert spectrum for non-linear and non-stationary time series analysis [C] // Proceedings Royal Society. London: [s. n.], 1998: 903-995.
- [7] Lawrance R R. A tutorial on hidden Markov models and selected applications in speech recognition [J]. Proceedings of the IEEE, 1989, 77 (2): 257-286.
- [8] 胡劲松, 杨世锡. 基于能量的振动信号经验模态分解终止条件[J]. 振动、测试与诊断, 2009, 29(1): 19-22. Hu Jingsong, Yang Shixi. Energy-based stop condition of empirical mode decomposition of Vibration signal [J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(1): 19-22. (in Chinese)
- [9] 柳新民, 温熙森, 邱静, 等. 基于隐马尔可夫模型的机电系统机内测试虚警抑制[J]. 兵工学报, 2005, 26(3): 387-391. Li Xinmin, Wen Xisen, Qiu Jing, et al. False alarm filter of mechatronics built-in test based on the hidden Markov mode [J]. Acta Armamentarii, 2005, 26(3): 287-391. (in Chinese)
- [10] 徐国平. 基于支持向量机的动调陀螺仪寿命预测方法研究[D]. 上海: 上海交通大学, 2008.



第一作者简介: 郭明威, 男, 1979年8月生, 博士研究生。主要研究方向为飞行器状态监控与健康管管理、故障诊断。
E-mail: hahaj369@163.com