

文章编号: 1001-0920(2009)06-0889-05

基于 EMD 多模态特征融合支持向量机的故障诊断

沈志熙¹, 黄席樾¹, 马笑潇²

(1. 重庆大学 自动化学院, 重庆 400030; 2. 新西兰况得实仪器有限公司 北京代表处, 北京 100016)

摘要: 针对非平稳时间序列信号, 提出一种基于经验模态分解(EMD)的特征提取和多模态特征融合支持向量机的故障诊断方法. 首先对原始信号进行 EMD 分解, 选择能量最大的几个基本模式分量(IMF)并提取其小波包特征, 获得对每个 IMF 独立的特征子集; 然后在每个 IMF 特征子集中训练 SVM 弱分类器, 并根据各特征子集对应的 IMF 能量权重进行加权融合, 获得故障状态的强分类器. 将该方法应用于 6135 型柴油机振动信号故障诊断中, 实验结果表明了其可行性和有效性.

关键词: 故障诊断; 非平稳时间序列; 经验模态分解; 基本模式分量; 支持向量机

中图分类号: TP206.3 **文献标识码:** A

Fault diagnosis method based on empirical mode decomposition and support vector machine

SHEN Zhi-xi¹, HUANG Xi-yue¹, MA Xiaoxiao²

(1. College of Automation, Chongqing University, Chongqing 400030, China; 2. Beijing Representative Office, New Zealand Commtest Instruments Ltd, Beijing 100016, China. Correspondent: SHEN Zhi-xi, E-mail: shenzxcq@yahoo.com.cn)

Abstract: For non-stationary time series signal, a fault diagnosis method based on empirical mode decomposition (EMD) and multi-features fusion support vector machine (SVM) is proposed. Firstly, EMD is employed to decompose the original signal, the several energy-dominating intrinsic mode functions (IMFs) are chosen and the wavelet packet features of each of IMFs are extracted respectively to form several independent feature sub-spaces. Then, a series of SVM-based weak classifiers are trained in each of feature sub-spaces respectively. And a weighted fusion strategy based on the energy proportion of each of IMFs is employed to obtain stronger classifier of fault pattern. The experimental result in fault diagnosis of 6135 diesel engine shows the feasibility and effectiveness of the proposed method.

Key words: Fault diagnosis; Non-stationary time series; Empirical mode decomposition; Intrinsic mode function; Support vector machine

1 引言

故障诊断实质是一个模式识别问题, 包括特征提取和状态识别两个关键环节. 对于非平稳时间序列信号, 一般的时域分析法或频域分析法都难以全面反映信号的特点. 具有时频两域多尺度解析能力的小波变换^[1,2]和小波包变换^[3-5]在非平稳信号分析中得到了更为广泛的应用. 但通常的用法都是针对整个信号直接进行分解^[1-5], 其结果是按尺度分频后的固定频段信号, 每一分频段只与信号的采样频率有关, 而与信号本身无关, 这样很容易受到信号中相

邻谐波成分的重叠影响. 近年来, Huang 等^[6]提出的 Hilbert-Huang 变换 (HHT) 中采用了经验模态分解 (EMD), 经 EMD 分解获得的基本模式分量 (IMF) 所包含的频率成分随信号本身而变化, 提高了信噪比, 非常适合于非平稳时变信号的处理^[7,8].

在状态识别方面, 目前常用的方法主要有: 分形维^[9]、神经网络^[4]以及支持向量机 (SVM)^[3,5,9]等. 在实际工作中, 故障状态信号一般不易获得. 基于统计学习理论的 SVM^[10]在小样本条件下, 对非线性和高维模式的识别具有更好的分类精度和更强的分类推广能力. 为此, 本文提出一种基于 EMD 多模态

收稿日期: 2008-06-11; 修回日期: 2008-08-27.

基金项目: 国家自然科学基金项目 (60443006).

作者简介: 沈志熙 (1976—), 男, 重庆人, 博士生, 从事人工智能、模式识别等研究; 黄席樾 (1943—), 男, 重庆奉节人, 教授, 博士生导师, 从事人工智能、故障诊断等研究.

特征融合支持向量机的故障诊断方法. 采用 EMD 分解获取信号的若干 IMF; 选取能量最大的几个 IMF 并提取其小波包特征, 每个 IMF 单独映射为一个特征子空间; 分别在各 IMF 特征子空间中训练出相应的二叉树支持向量机 (BT-SVM) 弱分类器; 根据每个 IMF 占据原始信号的能量比, 将相应的弱分类器加权融合, 得到故障模式的多类强分类器. 图 1 为本文算法的总体框图.

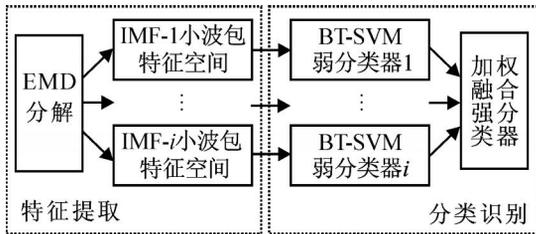


图 1 本文算法总体框图

2 故障信号特征提取

2.1 经验模态分解

经验模态分解可用于非线性和非平稳信号的处理. EMD 分解后的每个基本模式分量须满足以下两个条件^[6]: 1) 极值点的数量与过零点的数量必须相等或最多相差不多于一个; 2) 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. 本文通过以下 EMD“筛选”过程来获得各个 IMF 分量^[6].

Step1: 设原始信号为 $x(t)$, 通过 3 次样条函数取其上下包络的局部均值 $m(t)$. 令 $h(t) = x(t) - m(t)$, 如果 $h(t)$ 不满足 IMF 条件, 则将其视为新的待处理信号. 重复 k 步后, 得到

$$h_k(t) = h_{(k-1)}(t) - m_k(t). \quad (1)$$

在现实条件下不可能严格按照 IMF 定义分解, 可采用前后两个 $h(t)$ 的标准差 sd 来判断, 即

$$sd = \sqrt{\int_{t=0}^T \left[\frac{h_{(k-1)}(t) - h_k(t)}{h_{(k-1)}(t)} \right]^2 dt}. \quad (2)$$

Step2: 得到信号的第 1 个 IMF 分量, 以及该分量分离后的余项

$$\begin{cases} c_1(t) = h_{1k}(t), \\ r_1(t) = x(t) - c_1(t). \end{cases} \quad (3)$$

Step3: 将 $r_1(t)$ 作为新的处理信号, 重复上述“筛选”过程, 得到一系列 IMF 分量 $c_i(t)$ ($i = 1, 2, \dots, n$) 和最终余项 $r_n(t)$. 原始信号可重构为

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

其中: 余项 $r_n(t)$ 代表信号的平均趋势, 各个 IMF 分量 $c_i(t)$ 则表征了信号固有的谐波成分.

2.2 基于多模态分量的小波包特征提取

传统的小波变换^[1,2]只对低通滤波器输出递归

分解, 这导致对信号的低频段分辨率高而高频段则分辨率较差. 小波包变换^[3-5]因其在各层中平分低通和高通滤波带宽, 故具有对高频段更好的分辨能力. 但小波包分解通常是针对整个信号直接进行, 得到的是基于采样频率的固定频段信号, 在每一频段内, 很容易受信号自身邻近谐波成分的交叠影响, 从而导致特征提取的困难甚至失真. 考虑到 EMD 分解所得 IMF 的物理意义, 本文提出针对每个 IMF 单独进行分析的方法, 以获得更好的故障特征信息.

信号的小波包分解递推公式为

$$\begin{cases} d_{s+1}^j(n) = d_s^j(n) * h(-2n), \\ d_{s+1}^{j+1}(n) = d_s^j(n) * g(-2n). \end{cases} \quad (5)$$

其中: s 为分解层数, $0 < j < 2^s - 1$ 为频段带数, h 和 g 为共轭滤波器系数, d 为小波包子频带分解系数.

信号经小波包分解后, 可直观了解故障的特征频带, 但若直接进行识别, 将导致大的计算量和复杂分类面. 因此, 本文进一步计算出每个频段的相对幅值谱值并组成特征向量. 对于给定信号 $x(t)$, 设经 EMD 分解后的 IMF 分量为 $c_i(t)$, 则 $c_i(t)$ 各频段的小波包幅值谱值 E_i^j 和相对幅值谱值 \bar{E}_i^j 分别为

$$\begin{cases} E_i^j = \sqrt{\sum_{k=1}^T [d_{ik}^j]^2}, \\ \bar{E}_i^j = E_i^j / \sum_{s=1}^j E_i^s. \end{cases} \quad (6)$$

其中: T 为信号长度; i 为 IMF 个数; j 为 s 层小波包分解后的频段个数, 与式 (5) 定义相同.

$c_i(t)$ 的特征向量由其归一化幅值谱值 \bar{E}_i^j 组成, 即 $F_i = [\bar{E}_i^1, \dots, \bar{E}_i^j]$. 根据 IMF 的信号能量, 选择前 p 个能量最大的 IMF 分量, 最终形成与之对应的 p 个独立的特征向量子集 $\{\tilde{F}_1, \dots, \tilde{F}_p\}$.

本文提出的特征提取方法主要优点是: 1) 选取能量最大的前 p 个 IMF, 可显著滤除噪声影响, 使得分析更加集中于故障特征所在的频段; 2) 对各 IMF 单独提取其小波包特征, 可尽量避免分量之间的交叠失真, 使得小波包特征更加集中, 有利于故障信号的特征提取和状态识别.

3 故障状态分类识别

3.1 支持向量机及其分类原理

支持向量机^[10]通过用核函数 $K(x_i, x)$ 代替非线性变换特征空间中的点积, 将输入样本 x 映射到一个高维特征空间, 并在该空间中求广义最优分类面. 对于给定样本集 (x_i, y_i) , $x \in R^d$, $y \in \{-1, +1\}$, SVM 通过解一个不等式约束下的二次函数极值问题, 得到如下最优分类函数:

$$f(x) = \text{sign} \left\{ \sum_i a_i^* y_i K(x_i, x) + b^* \right\}. \quad (7)$$

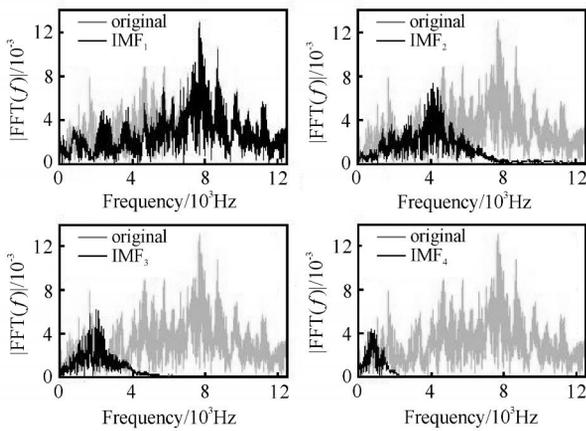


图 4 振动信号及其 IMF 分量频域波形

IMF 频段中的故障特征,具有比在原始信号中更加集中的表现形式.可见,在每个单独的 IMF 中更有利于信号特征提取和状态识别.

表 1 给出了前 4 个 IMF 分量相对于原始信号能量所占权重及重构误差.结果表明,完全可用前几个 IMF 来近似重构原始振动信号.本文取 $p = 4$,即采用前 4 个 IMF 进行特征提取和状态识别是合理的.

表 1 IMF 分量与原始信号的能量对应关系

	IMF ₁	IMF ₁ ~ IMF ₂	IMF ₁ ~ IMF ₃	IMF ₁ ~ IMF ₄
能量权重	0.695492	0.181061	0.0728858	0.0330861
重构误差	0.625620	0.244193	0.0945646	0.0356225

分别提取前 4 个能量最大的 IMF 分量的小波包特征.本文采用 db3 小波,进行 3 层小波包分解.为简化特征空间,求出每个 IMF 经小波包分解后子频带的归一化能量组成特征向量,最终得到对应于每个 IMF 的共 4 个独立特征子集.

4.2 多模态特征融合的 SVM 故障识别

6135 型柴油机的气门故障主要有 4 种,按发生优先级排序分别为^[3]:排气门间隙过小 M_1 ,排气门间隙过大 M_2 ,新气阀轻微漏气 M_3 和气阀严重漏气 M_4 .再加上正常工作状态 M_0 ,共 5 种待识别的状态类型.从缸盖上测取不同气门间隙状态下的振动信号样本共 300 个,其中 4 类故障 $M_1 \sim M_4$ 样本各 50 个,其余为正常样本.

考虑到分类器训练可以离线完成,本文主要针对分类器的分类速度和分类精度进行对比验证.用于对比的分类器分别包括最常用的 3 层 BP 神经网络,测试精度表现较好的 1a1-SVM,测试效率表现较好的 B-T-SVM 以及本文提出的融合 B-T-SVM.为了充分证明本文算法的有效性,对于前 3 种分类器,采用传统的整体特征提取方法;而对于本文的多模态特征融合 B-T-SVM,则采用本文提出的基于各 IMF 分量单独提取状态特征的方法.实验中,二值 SVM 算法在 LIBSVM 工具包^[11]基础上修改实现,B-T-SVM 采用文献[3]中提出的与本文有相同树型结构的分类算法,核函数选用 RBF 函数,KKT 停止条件的容许误差为 0.001.为避免取值范围大的属性比取值范围小的属性更占优势,本文对样本数据各属性进行归一化预处理,线性调整到 $[-1, 1]$.将每种类型的样本均分为 10 组,任取其中的 8 组作为训练样本,其余 2 组为测试样本.做 10 次 Cross-Validation,测试结果由多次测试平均得到,表 2 给出了采用不同方法的测试结果.

由表 2 可见:1) 就分类精度而言,传统的 BP 网络由于对样本数量和质量过于依赖,易陷入局部极

表 2 几种分类方法的测试结果对比

模式类别	BP		1a1-SVM		文献[3] B-T-SVM		本文 B-T-SVM	
	精度 / %	速度 / s	精度 / %	速度 / s	精度 / %	速度 / s	精度 / %	速度 / s
M_1	92.91	0.089	99.05	0.023	98.12	0.017	98.72	0.022
M_2	91.17	0.088	98.83	0.027	97.74	0.018	98.10	0.025
M_3	88.30	0.092	96.25	0.031	93.67	0.021	96.33	0.031
M_4	89.74	0.093	96.17	0.029	93.44	0.020	95.67	0.031
M_0	92.52	0.086	97.92	0.025	95.83	0.015	97.02	0.022

表 3 几种分类方法的误检率和漏检率对比

模式类别	BP		1a1-SVM		文献[3] B-T-SVM		本文 B-T-SVM	
	误检率	漏检率	误检率	漏检率	误检率	漏检率	误检率	漏检率
M_1	4.65	2.44	0.41	0.54	0.90	0.98	0.66	0.62
M_2	6.16	2.67	0.50	0.67	1.14	1.12	1.16	0.74
M_3	7.52	4.18	1.90	1.85	3.69	2.64	2.15	1.52
M_4	6.34	3.92	1.87	1.96	3.54	3.02	2.14	2.19
M_0	7.48	—	2.08	—	4.17	—	2.98	—

小点,具有比 SVM 差的分类精度;本文的 SVM 由于采用了弱分类器融合策略,有效地改进了节点分类器,特别是上层节点分类器的精度,具有比一般 BT-SVM 更高且与 1a1-SVM 接近的分类精度. 2) 就测试时间而言, SVM 具有比 BP 网络更高的分类效率;在各种 SVM 分类方法中, BT-SVM 具有最高的分类效率;本文方法中由于需要完成对各自弱分类器的加权组合,其分类效率低于传统 BT-SVM;与 1a1-SVM 相比,本文采用树型结构的 SVM 并不需要遍历所有子分类器,考虑到实际运行情况,设备绝大多数时候处于正常工作状态 M_0 , 或故障状态 M_1 和 M_2 , 因此本文方法应比 1a1-SVM 具有更高的分类效率.

实验中,分类精度主要由误检率和漏检率两部分组成. 本文进一步对各种方法的误检率和漏检率进行统计,如表 3 所示. 其中:误检率定义为某一状态被识别为其他故障状态的误检比率,漏检率定义为某一故障状态被识别为正常状态的误检比率.

分析表 3 的统计结果可以看出: 1) 4 种方法的平均误检率分别为 6.43%, 1.35%, 2.69% 和 1.82%; 平均漏检率分别为 3.30%, 1.26%, 1.94% 和 1.27%. 2) 就系统误检率和漏检率而言,本文算法由于采用对时序信号各个基本模态单独提取特征、以及各模态特征加权融合的判决机制,具有远优于 BP 神经网络,优于传统 BT-SVM,近似于 1a1-SVM 的检测精度. 3) 考虑到在 1a1-SVM 基础上采用本文思路进行改进,虽然可望进一步提高系统检测精度,但必将导致系统实时性恶化;而本文算法在 BT-SVM 基础上进行改进,既有效提高了系统检测精度,又能满足实际系统实时在线故障诊断的要求.

5 结 论

本文提出了一种针对 EMD 分解后的每个 IMF 分量单独进行分析,然后加权融合的改进算法. 该方法不仅减少了特征提取中各种谐波频段的交叠影响,而且通过多源融合的思想提升了状态识别的精度. 以柴油机缸盖振动信号的特征提取和状态识别为应用实例,分析并验证了本文算法在非平稳时间序列信号故障诊断中的可行性和有效性,具有较强的推广价值.

参考文献(References)

- [1] Wang W J. Wavelet for detecting mechanical faults with high sensitivity [J]. Mechanical System and Signal Processing, 2001, 15(4): 685-696.
- [2] 陈果. 基于小波分析的转子故障信号自适应降噪技术研究[J]. 航空动力学报, 2008, 23(1): 9-16.
(Chen G. Research on self-adaptive de-noising technique for rotor faults signal based on wavelet analysis[J]. J of Aerospace Power, 2008, 23(1): 9-16.)
- [3] 马笑潇, 黄席樾, 柴毅. 基于 SVM 的二叉树多类分类算法及其在故障诊断中的应用[J]. 控制与决策, 2003, 18(3): 272-276.
(Ma X X, Huang X Y, Chai Y. 2PTMC classification algorithm based on support vector machines and its application to fault diagnosis[J]. Control and Decision, 2003, 18(3): 272-276.)
- [4] 梁平, 白蕾, 龙新峰, 等. 基于小波包分析及神经网络的汽轮机转子振动故障诊断[J]. 控制理论与应用, 2007, 24(6): 981-985.
(Liang P, Bai L, Long X F, et al. Turbine rotor vibration faults diagnosis based on wavelet packet analysis and neural network[J]. Control Theory and Applications, 2007, 24(6): 981-985.)
- [5] 何学文, 孙林, 付静. 基于小波分析和支持向量机的旋转机械故障诊断方法[J]. 中国工程机械学报, 2007, 5(1): 86-90.
(He X W, Sun L, Fu J. Fault diagnosis of rotary machinery based on wavelet analysis and support vector machine [J]. Chinese J of Construction Machinery, 2007, 5(1): 86-90.)
- [6] 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 [C]. Proc of the Royal Society. London, 1998, 454: 903-995.
- [7] 李建伟, 许宝杰, 韩秋实. 非平稳振动信号分析中 Hilbert-Huang 变换的对比研究[J]. 机械强度, 2006, 28(2): 165-169.
(Li J W, Xu B J, Han Q S. Study on Hilbert-Huang transform in the analysis of non-stationary vibration signal[J]. J of Mechanical Strength, 2006, 28(2): 165-169.)
- [8] Qi Keyu, He Zhengjia, Zi Yanyang. Cosine window-based boundary processing method for EMD and its application in rubbing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2007, 21(7): 2750-2760.
- [9] Yang Junyan, Zhang Youyun, Zhu Yongsheng. Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension [J]. Mechanical Systems and Signal Processing, 2007, 21(5): 2012-2024.
- [10] Vapnik V. Statistical learning theory [M]. New York: John Wiley and Sons, 1998.
- [11] Chang C C, Lin C J. LIBSVM: A library for support vector machines [EB/OL]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2004-4-1.