

文章编号:1000-8055(2011)11-2445-05

基于 SVM 和广义粗糙度特征的航空发动机 振动故障诊断方法

吴娅辉, 李新良, 洪宝林, 张大治

(中国航空工业集团公司 北京长城计量测试技术研究所
计量与校准技术重点实验室, 北京 100095)

摘 要: 通过对航空发动机振动信号进行小波分解, 依据多尺度空间局部能量分布和粗糙性提取基于子带信号能量加权广义粗糙度特征实现对振动情况的描述. 然后将上述特征送入支持向量机(support vector machine, 简称 SVM)分类器进行训练, 根据分类器的输出结果判断航空发动机的工作状态和故障类型. 通过对实测航空发动机试车时得到的振动信号的实验分析结果表明, 该算法可以有效地识别发动机的振动故障.

关 键 词: 航空发动机; 振动分析; 广义粗糙度; 支持向量机 (SVM); 小波; 故障诊断

中图分类号: V231.92; TP274

文献标志码: A

Research on aeroengine vibration fault diagnosis based on support vector machine and generalized roughness feature

WU Ya-hui, LI Xin-liang, HONG Bao-lin, ZHANG Da-zhi

(Key Laboratory of Science and Technology on Metrology and Calibration,
Changcheng Institute of Metrology and Measurement,
Aviation Industry Corporation of China, Beijing 100095, China)

Abstract: The signal was decomposed based on wavelet transform and the generalized roughness vector of the signal was formed by making use of the local energy distributions and the roughness of the sub-band signal. Then the desired parameters serve as the fault characteristic vectors to be input to the support vector machine classifier and the work conditions and fault patterns were identified by the output of the classifier. The analysis results from the aeroengine vibration signals show that the fault diagnosis method can classify working conditions and fault patterns effectively.

Key words: aeroengine; vibration analysis; generalized roughness vector;
support vector machine (SVM); wavelet; fault diagnosis

随着航空发动机结构越来越复杂, 特别是其经常在高转速、高应力、高温及高压状态下工作, 因此发动机部件发生故障的可能性大大增大, 而航空发动机状态监视与故障诊断系统能显著提高发动机运行可靠性, 保证飞行安全, 还能为实现维修策略从经验型的定期维修向更科学的视情维修

提供重要的基础^[1-2]. 从故障诊断技术的观点来看, 转轴组件是检测和诊断的主要对象, 诊断方法主要是振动分析法. 目前, 航空发动机大多为双转子结构, 在测量发动机振动时, 由于只能将传感器安装在发动机机匣外部, 因此测得的振动信号包含了高压转子、低压转子、传动系统等不同激振源

收稿日期: 2011-04-08; 修订日期: 2011-09-20

基金项目: 航空科学基金(20105644004)

作者简介: 吴娅辉(1980—), 女, 河北邯郸人, 工程师, 博士, 主要从事航空发动机振动分析和故障诊断.

所激起振动混叠,同时还包含了大量的测量噪声,为典型的非平稳信号^[3].

传统的基于频谱的信号分析算法相对成熟,但这类方法不具备时间局部化分析功能,因此只适合对平稳信号进行分析^[4]. 发动机振动信号含有丰富的低频、高频及其谐波分量,必须采用适合对瞬态信号进行分析的时频联合分析方法. 小波变换为典型的时频分析方法,它利用可伸缩和可移位特性的小波函数作为窗函数,将信号中不同的频率成分进行分解^[5],具有多分辨率分析的特点,在时频两域都具有表征信号局部特征的能力,很适合于探测在正常信号中带有瞬时反常现象的信号,应用于故障检测与诊断具有良好的效果.

在振动信号特征描述方面,国内外学者进行了大量的研究和分析^[6]. 常用的特征提取方法主要是基于信号分解子带的频谱和能量的描述方法,近年来也有研究采用尺度图和灰度矩等方法对振动信号进行描述,都取得了较好的实验结果^[7-8]. 另一方面,基于人工神经网络分类器的模式识别方法以其较强的自组织、自学习能力和非线性模式分类性能在机械故障诊断中得到了广泛应用^[9-10]. 但神经网络需要大量的典型故障数据样本或经验知识^[11],而在工程实际当中,特别是航空发动机故障分析中,一般很难获得大量典型的故障样本. 支持向量机在解决模式识别的小样本问题中表现出了独特的优势和良好的应用前景^[12],已用于模式识别和特征提取等领域^[13]. 本文提出一种基于信号小波分解子带能量加权的粗糙度特征对故障进行描述,并进一步根据支持向量机分类器的输出结果来判断航空发动机的工作状态和故障类型. 实验分析结果表明,该方法可以有效地提取振动信号的故障特征,并能成功地对发动机的工作状态和故障类型进行分类,证明了该方法对发动机振动信号描述和诊断的有效性.

1 小波分解及广义粗糙度特征提取方法

1.1 小波分解

小波变换是将信号分解为不同尺度分量的线性运算. 具体实现是通过信号与尺度变化的滤波器的卷积来完成的^[5]. 连续小波变换定义为

$$W_f(b, a) = a^{-1/2} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{b-x}{a}\right) dx \quad (1)$$

其中 a 是尺度参数, b 是位置参数, 母小波 $\psi(x) \in$

$L^2(R)$ 并满足 $\int_{-\infty}^{+\infty} \psi(x) dx = 0$.

对连续小波变换进行二进制离散化, 即 $a = 2^j, b = 2^j k, j, k \in Z$, 得到尺度-时间都离散化的小波变换, 即多分辨率分析. 若 $\psi(x)$ 为正交小波, 则该小波经伸缩、平移可得正交基

$$\{\psi_{j,k}(x)\} = \{2^{-j/2} \psi(2^{-j}x - k)\} \quad (2)$$

由于其正交性, $f(x)$ 的小波变换系数 $c_{j,k}$ 可通过 $c_{j,k} = \langle f, \psi_{j,k} \rangle$ 计算.

1.2 广义粗糙度特征提取方法

粗糙性是信号陡变的结果, 可用于对信号变化情况描述. 研究发现该变化与两个因素有关: 变化频率(transition frequency, 简称 TF) 和变化长度(transition length, 简称 TL)^[14]. TF 的大小决定了信号变化出现的频繁程度. 由于一个信号通常可看作是不同成分信号的叠加, 因此首先需要使用滤波器对信号进行滤波得到不同分解尺度下的结果. 换句话说, 考虑特定尺度下的分解信号可以更好地识别信号变化情况. 本文利用离散小波分解将信号分解成不同频率子带进行分析.

信号被分解到不同的 TF 上后, 使用 TL 描述该尺度上信号的变化情况. 为了说明信号峰点带宽与信号变化情况之间的关系, 使用极值算子 $\max_{\tau \in (t-\epsilon, t+\epsilon)} |c_i(\tau)|$ 对信号进行运算. 该算子表示在信号间隔 $(t-\epsilon, t+\epsilon)$ 内计算子带 c_i 的最大值.

$\max_{\tau \in (t-\epsilon, t+\epsilon)} (\cdot)$ 算子的作用是扩展分量 c_i 的峰值范围, 随着参数 ϵ 的增大, 新信号的峰点带将会变宽.

对信号进行上述极值运算后得出结论: 如果原信号的峰点带已经比较宽, 那么当 ϵ 增大时该信号对应的峰点带变宽的程度并不明显, 反之如果原信号的峰点范围比较窄, 那么随着 ϵ 的增大峰点带变宽的程度就比较明显. 为了描述峰点带宽度变化与参数 ϵ 变化间的比例关系, 引入类似于分形概念中的比例表示方法将该关系表示为

$$\langle \max_{\tau \in (t-\epsilon, t+\epsilon)} |c_i(\tau)| \rangle \sim e^{R_s} \quad (3)$$

其中 R_s 称为信号在尺度 s 上的广义粗糙度.

R_s 衡量了 $\langle \max_{\tau \in (t-\epsilon, t+\epsilon)} |c_i(\tau)| \rangle$ 随参数 ϵ 的变化率, 它是信号变化长度的平均测度. 如果分解的信号中包含了较窄的峰点范围, 则该值随参数 ϵ 的增加而显著增加, 故 R_s 较大; 如果信号包含了较宽的峰点范围, 则随着参数 ϵ 的增加其变化并不明显, 因此 R_s 就比较小.

由于粗糙性的视觉效果在很大程度上依赖于信号在不同子带上的相对能量大小, 同时能量值

也可以体现该子带信号对后续分析的有效性,因此本文使用子带能量百分比对子带上的广义粗糙度特征进行加权来模拟人眼的视觉效果.则基于能量分布的加权广义粗糙度特征定义为

$$W_i = R_i * E_i \quad (4)$$

其中 R_i 为第 i 个子带的广义粗糙度特征, E_i 为第 i 个子带所占的能量百分比.实验分析的双转子航空发动机振动信号经上述特征提取后,可将不同转子分量和对应故障特征分解到不同的子带中进行描述.

2 支持向量机(SVM)原理

考虑训练样本 $\{(x_i, y_i)\}_{i=1}^n$, 其中 x_i 是输入模式的第 i 个例子, y_i 是对应的期望响应输出.假定由子集 $y_i = +1$ 和 $y_i = -1$ 代表的模式线性可分.对于非线性分类,则首先使用非线性映射 ϕ 把数据样本从原空间映射到高维特征空间,再利用核函数进行分析.分类面应满足约束

$$y_i(\mathbf{w} \cdot \phi(x_i) + b) \geq 1 - \xi_i \quad (5)$$

其中 $i = 1, 2, \dots, n$, $\mathbf{w}$ 是分类面的权系数向量, b 为分类阈值, $\xi_i \geq 0$ 为松弛变量.

对于一个给定的权值向量 $\mathbf{w}$ 和偏置 b , 由方程定义的超平面和最近的数据点之间的间隔称为分离边缘.支持向量机的目标是找到一个特殊的超平面,对于这个超平面分离边缘最大.在这个条件下,决策曲面称为最优分类面.如图 1 所示, H 为最优分类面; H_1, H_2 分别为过各类中离分类面最近的样本且平行于分类面的面; H_1, H_2 上的训练样本点就称作支持向量.




图 1 最优分类面

Fig. 1 Optimal separating plane

构造最优分类面的问题可以转化为在式(5)

的约束下,求函数 $\frac{1}{2} \|\mathbf{w}\|^2 + C(\sum_{i=1}^n \xi_i)$ 的最小值,即在确定最优分类面时折中考虑最小错分样本和最大分类间隔.常数 $C > 0$ 控制对错分样本

的惩罚程度.利用 Lagrange 函数在约束条件

$$\sum_{i=1}^n \alpha_i y_i = 0 \text{ 和 } C \geq \alpha_i \geq 0 \text{ 下求解函数最大值}$$

$$Q(\alpha) =$$

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (6)$$

根据 Kuhn-Tucker 条件,优化系数 α_i 满足 $\alpha_i[y_i(\mathbf{w} \cdot \phi(x_i) + b) - 1 + \xi_i] = 0$, $K(x_i, x_j)$ 为对应核函数.按式(6)求出优化系数 α_i 后,对于给定的测试样本 x ,SVM 对应分类函数的一般形式表示为^[15]

$$f(x) = \text{sgn}\left\{\sum \alpha_i y_i K(x_i, x) + b\right\} \quad (7)$$

式中 $\text{sgn}\{\}$ 为符号函数,由 $f(x)$ 的正负即可判定 x 所属的类别.

3 实验分析

实验主要研究双转子航空发动机整机振动信号特性,采用某型航空发动机试车时产生的碰摩和不平衡以及正常工况三种情况下的振动数据进行分析,由于采集的信号中噪声分量较大,首先采用小波软阈值法对信号进行降噪处理,然后对降噪信号进行小波分解,提取信号各子带分量,并计算各分量下的能量加权广义粗糙度特征向量.

3.1 网络训练

SVM 本身是针对二元分类问题设计的分类器,不能直接用来解决多元分类问题.近年来,基于 SVM 多分类方法的研究主要是将多分类问题逐步转化为两分类问题,即用多个两分类 SVM 组成一个多分类器.主要方法包括“一对多”方法,“一对一”方法和基于决策树方法等.考虑到“一对多”和“一对一”方法需要的分类器数目较多,且组合后对于累积误差的计算具有不确定性,因此本实验选择基于决策树的方法构建多分类器.

实验中,根据发动机实际测试情况,选取正常信号总特征数为 260,不平衡信号总特征数为 102,碰摩信号总特征数为 164.训练时随机从上述集合中选取 70% 的特征数据用于 SVM 网络训练,剩余数据用于网络测试.因此,训练中碰摩信号特征数为 116,正常工况特征数为 182,不平衡信号特征数为 71.对应测试集中,碰摩信号特征数为 48,正常工况特征数为 78,不平衡信号特征数为 31.

3.2 基于广义粗糙度特征下的分类性能

选择 db4 小波进行特征提取,小波分解级数

为9级,故特征向量维数为10维.经过参数优化后,该特征下对应SVM网络参数为:核函数选择径向基函数,C设为1024,训练后得到的支持向量个数为65.网络输入节点数为10,输出节点数为1.

表1给出了该特征下训练集中不平衡信号、碰摩信号和正常工况的分类正确率.

表1 广义粗糙度特征下训练集分类正确率

Table 1 Classification accurate on the train set based on the generalized roughness feature

	不平衡	碰摩	正常工况
特征总数	71	116	182
分类正确数	70	112	181
分类正确率/%	98.59	96.55	99.45

表2给出了测试集中不平衡信号、碰摩信号和正常工况的分类正确率.

表2 广义粗糙度特征下测试集分类正确率

Table 2 Classification accurate on the test set based on the generalized roughness feature

	不平衡	碰摩	正常工况
特征总数	31	48	78
分类正确数	31	42	77
分类正确率/%	100	87.5	98.72

从上面两表的分析可以看出,采用能量加权的广义粗糙度特征进行基于SVM的分类实验中,在训练集上,对不平衡和正常工况的分类均出现1个错分,碰摩情况下出现4个错分;在测试集上,不平衡故障全部分类正确,碰摩故障出现6个错分,正常工况出现1个错分.因此,整体上对碰摩故障的分类正确率稍低,其他两种工况相对较高.分析其对应原因主要为:对航空发动机振动分析而言,正常工况下的测试数据最容易得到,因此对应的训练集最充分,且正常工况下的信号特征比较明确,不容易与其他两类造成混淆.而对于碰摩和不平衡故障而言,航空发动机中经常出现由于不平衡故障导致转子和静子间的间隙变小,进而引发碰摩故障的情况,因此碰摩故障一般属于由于不平衡等故障引起的二次故障情况,其特征也最容易与其他工况下的情况混淆.因此在分类中,碰摩故障的分类性能要较其他两种情况稍差.

3.3 基于小波子带能量特征下的分类性能

为了与基于广义粗糙度特征下的分类结果进行比较,本节对实验中常用的基于小波分解子带能量特征下SVM网络的分类性能进行了分析.测试集与训练集的选取与前面实验相同,对应特征向量维数仍为10.经过参数优化后,该网络参数选择为:核函数为径向基函数,C设为8,训练后得到的支持向量个数为156.网络的输入节点数为10,输出节点数为1.

表3给出了该特征下训练集中不平衡信号、碰摩信号和正常工况下的分类正确率.

表3 小波能量特征下训练集分类正确率

Table 3 Classification accurate on the train set based on the wavelet energy feature

	不平衡	碰摩	正常工况
特征总数	71	116	182
分类正确数	69	105	182
分类正确率/%	97.18	90.52	100

表4给出了该特征下测试集中不平衡信号、碰摩信号和正常工况下的分类正确率.

表4 小波能量特征下测试集分类正确率

Table 4 Classification accurate on the test set based on the wavelet energy feature

	不平衡	碰摩	正常工况
特征总数	31	48	78
分类正确数	30	39	76
分类正确率/%	96.77	81.25	97.44

从上面的分析可以看出,采用子带能量特征进行基于SVM的分类实验中,在训练集上,不平衡故障出现2个错分,碰摩故障出现11个错分,正常工况分类正确;在测试集上,不平衡故障出现1个错分,碰摩故障出现9个错分,正常工况出现2个错分.与基于能量加权的广义粗糙度特征下的分类结果进行对比可知,在训练集上,虽然该特征在正常工况下的分类性能稍好,但其他两种情况,特别是碰摩故障下其性能下降比较明显;在实验更关心的测试集分类上,不论何种工况,该特征对应的分类性能都有所下降.这说明基于能量加权的广义粗糙度特征的分类性能要优于基于小波分解子带能量特征下的分类性能.

4 结 论

本文采用小波变换的方法对航空发动机振动信号进行分解,并在子带上提取能量加权的广义粗糙度特征对航空发动机不同振动故障特性进行描述.然后使用支持向量机分类器对特征进行故障分类,实现对航空发动机的故障诊断.通过对实际航空发动机试车时采集的不同工况下的振动信号的实验分析结果表明,采用基于能量加权的广义粗糙度特征和支持向量机的故障诊断方法可以有效识别发动机的工作状态和故障类型.

参考文献:

- [1] 张津. 民用航空发动机状态监视和故障诊断系统研究[J]. 航空动力学报, 1994, 9(4): 339-343.
ZHANG Jin. A condition monitoring and fault diagnosis system for civil aeroengines[J]. Journal of Aerospace Power, 1994, 9(4): 339-343. (in Chinese)
- [2] 郝英, 孙健国, 白杰. 航空燃气涡轮发动机气路故障诊断现状与展望[J]. 航空动力学报, 2003, 18(6): 753-760.
HAO Ying, ZHANG Jianguo, BAI Jie. State of the art and prospect of aircraft engine fault diagnosis using gas path parameters[J]. Journal of Aerospace Power, 2003, 18(6): 753-760. (in Chinese)
- [3] 高斌. 基于希尔伯特-黄变换的航空发动机整机振动故障诊断[D]. 南京: 南京航空航天大学, 2009.
GAO Bin. Aero-engine vibration fault diagnosis based on Hilbert-Huang transform[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2009. (in Chinese)
- [4] Goldman P E S. Vibration spectrum analysis[M]. New York: Industrial Press, 1999.
- [5] Daubechies I. The wavelet transform, time-frequency localization and signal analysis[J]. IEEE Transactions on Information Theory, 1990, 36(5): 961-1006.
- [6] Tommy W S C, Shi H. Induction machine fault diagnostic analysis with wavelet technique[J]. IEEE Transactions on Industrial Electronics, 2004, 51(3): 558-565.
- [7] Zhang Y P, Huang S H, Hou J H, et al. Continuous wavelet grey moment approach for vibration analysis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2006, 20(5): 1202-1220.
- [8] Hou J H, Huang S H, Shen T, et al. Wavelet-based quantitative analysis of vibration signal of rotating machinery[J]. Chinese Journal of Mechanical Engineering, 2004, 40(1): 131-135.
- [9] Paya B A, Esat I I, Badi M N M. Artificial neural network based fault diagnosis of rotating machinery using wavelet transforms as processor[J]. Mechanical Systems and Signal Processing, 1997, 11(5): 751-765.
- [10] Dellomo M R. Helicopter gearbox fault detection: a neural network based approach[J]. Journal of Vibration and Acoustics, 1999, 121(3): 265-272.
- [11] Qu L S, Zhang H J. Some basic problems in machinery diagnostics[J]. China Mechanical Engineering, 2000, 10(1-2): 211-216.
- [12] Fan J S, Tao Q, Fang T J. Genetic algorithm of optimizing perception based on statistical learning theory[J]. Pattern Recognition and Artificial Intelligence, 2001, 14(2): 211-215.
- [13] Zhang X G. Introduction to statistical learning theory and support vector machines[J]. Acta Automatica Sinica, 2000, 26(1): 32-42.
- [14] Charalampidis D, Kasparis T. Wavelet-based rotational invariant roughness features for texture classification and segmentation[J]. IEEE Transactions on Image Processing, 2002, 11(8): 825-837.
- [15] Vapnik V N. The nature of statistical learning theory [M]. New York: Springer Verlag, 1999.