

FDM 和 RCMDE 结合的特征提取与故障诊断*

左红艳^{1,2}, 刘晓波^{1,2}, 洪连环^{1,2}

(1.南昌航空大学航空制造工程学院 南昌,330063)

(2.南京航空航天大学机电学院 南京,210016)

摘要 为提取有效特征向量以实现航空发动机转子的故障诊断,针对航空发动机转子振动信号的非线性、非平稳的特性,首先,应用傅里叶分解方法(Fourier decomposition method,简称FDM)提取航空发动机转子信号的边际谱重心及最大能量层的谱重心;其次,计算振动信号的精细复合多尺度散布熵;最后,应用双阶自适应小波聚类方法对特征空间实现故障分类与识别。应用航空发动机转子试验器采集的样本验证表明,上述方法提取的特征值准确且波动小,同种故障类型的特征值集中,不同故障类型之间差异大,有利于提高多种故障类型混合的诊断精度。

关键词 傅里叶分解;精细复合多尺度散布熵;双阶自适应小波聚类;故障诊断

中图分类号 TH165+.3

引言

航空发动机是一个高速旋转、大功率的复杂机械设备系统,工作条件为高温、高压、高应力,并受到交变载荷作用,易发生机械故障。航空发动机在运行过程中,转子、轴承和机匣系统相互耦合和相互影响,往往表现为复合故障。因此,为了实现航空发动机转子复合故障的分类与识别,有效特征向量的提取是故障诊断的基础。

对于非线性、非平稳机械振动信号的时频分析与特征提取,Zhang等^[1]应用经验模态分解(empirical mode decomposition,简称EMD)将振动信号分解为一组固有模态函数,计算主要模态函数的排列熵,再应用支持向量机实现电机轴承故障的分类。李瑞彤等^[2]应用离散小波变换和约束独立成分分析相结合,提取复合故障信号的故障特征。Wang等^[3]提出基于变分模态分解(variational mode decomposition,简称VMD)的摩擦信号故障诊断方法,该方法能较好地同时提取多种特征。万书亭等^[4]应用VMD分解方法对高压断路器振动信号进行分解,计算固有模态函数分量的样本熵,然后应用支持向量机对断路器的运行状态进行分类识别。上述故障特征的提取方法,在某些场合下都取得了较好的应用效果,但也存在分解缺陷和应用的局限性,如小波基函数的选择问题、EMD分解的模态混叠、端点效应问题及VMD分解需预先确定中心频率个数等。

熵在故障分类与识别中,成为评价时间序列不均匀性和不确定性的一个重要指标。杨大为等^[5]将VMD分解和样本熵结合,提取行星变速箱的故障特征。郑近德等^[6]通过分解振动信号,提取分量的排列熵,用于滚动轴承的故障诊断。张淑清等^[7]应用局部均值分解方法,提取分量的近似熵,然后应用模糊C均值聚类,实现机械故障诊断方法。虽然样本熵、排列熵及近似熵被广泛地应用,但也存在着不足:排列熵没有考虑振幅平均值与振幅值之间的差异;近似熵对于复杂度低的信号区分不明显;样本熵对于长信号,其速度不够快,且受突变信号影响大。Rostaghi等^[8]提出了一种新的不规则指标——散布熵(dispersion entropy,简称DE),克服了上述排列熵和样本熵的局限性,其受突变信号影响较小,且考虑了幅值之间的大小关系,稳定性更好,计算速度更快。在散布熵的基础上,文献[9]又提出了精细复合多尺度散布熵(refined composite multiscale dispersion entropy,简称RCMDE),应用于生物信号的特征提取。

傅里叶分解(Fourier decomposition method,简称FDM)算法是一种无先验基础的通用自适应分解方法^[10],用FDM可将非线性和非平稳信号生成一系列傅里叶固有频带函数(Fourier intrinsic band functions,简称FIBFs)。笔者采用FDM方法提取航空发动机转子振动信号的频率特征,并与RCMDE特征值组合使用,应用双阶自适应小波聚类的方法实现航空发动机转子的多种故障的分类与识别。

* 国家自然科学基金资助项目(51365040);博士启动基金资助项目(EA202003380)

收稿日期:2019-04-01;修回日期:2019-07-25

1 FDM分解原理

FDM是在满足狄利克雷条件下,将信号分解成一系列FIBFs函数。FDM分解的主要思想如下:首先,定义FIBFs函数,作为被分解信号的单分量成分;其次,利用零相位滤波器组(zero phase filtering banks,简称ZPFB),采用从高频到低频或从低频到高频的搜索方法,分解出满足解析傅里叶固有频带函数(analytic Fourier intrinsic band functions,简称AFIBFs)定义条件的各个分量。将非平稳非线性信号分解为一系列瞬时频率具有物理意义的FIBFs分量。

设长度为 n 的离散信号 $x[n]$,利用FDM的分解方法可表示为

$$x[n] = \sum_{i=1}^M y_i[n] + r[n] \quad (1)$$

其中: $r[n]$ 为信号的残余分量; $y_i[n]$ 为 M 个FIBFs函数的第 i 个分量。

单分量 $y_i[n]$ 的FIBFs满足:

1) FIBFs是一个零均值函数,即 $\sum_{n=1}^N y_i[n] = 0$;

2) FIBFs的各个分量之间满足相互正交,即

$$\sum_{n=1}^N y_i[n] y_j[n] = 0 \quad (i \neq j)$$

3) 分量FIBFs相应的AFIBFs函数的幅值大于等于零,且相位函数为单调递增函数,令 $y_i[n] + jy_i[n] = a_i[n] \exp(j\phi_i[n])$,则对于 $\forall n$,满足 $a_i[n] \geq 0, \omega_i = \phi_i[n+1] - \phi_i[n] \geq 0$ 。

通过离散傅里叶变换,离散信号 $x[n]$ 表示为

$$x[n] = X[k] \exp\left(\frac{j2\pi kn}{N}\right) = \quad (2)$$

$$X[0] + 2\operatorname{Re}\{z_1[n]\} + X\left[\frac{N}{2}\right](-1)^n$$

其中: $X[k] = \frac{1}{N} \sum_{n=1}^N x[n] \exp\left(-\frac{j2\pi kn}{N}\right)$ 为离散信号 $x[n]$ 的离散傅里叶变换; $\operatorname{Re}\{z_1[n]\}$ 为解析信号 $z_1[n]$ 的实部。

解析信号 $z_1[n]$ 表达式为

$$\sum_{k=1}^{\frac{N}{2}-1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) = \sum_{i=1}^M a_i[n] \exp(j\phi_i[n]) \quad (3)$$

通过由低频到高频(或高频到低频)方式,搜索每个符合FIBFs条件的 M 个AFIBFs分量,其中 $y_i[n]$ 为AFIBFs解析函数的实部。由式(1)、式(2)和式(3),可将每个 $y_i[n]$ 表达为式(4),即低频到高频的搜索方法为

$$\begin{cases} y_1[n] + \hat{y}_1[n] = a_1[n] \exp(j\phi_1[n]) = \\ \sum_{k=1}^{N_1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \\ y_2[n] + \hat{y}_2[n] = a_2[n] \exp(j\phi_2[n]) = \\ \sum_{k=N_1+1}^{N_2} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \\ \vdots \\ y_M[n] + \hat{y}_M[n] = a_M[n] \exp(j\phi_M[n]) = \\ \sum_{k=N_{M-1}+1}^{N_M} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \end{cases} \quad (4)$$

其中: $N_0 = 0; N_M = \frac{N}{2} - 1$ 。

基于傅里叶变换的FDM时频分析方法,其数学理论充分,并且能够自适应分解非线性非平稳信号,并且分解的一系列FIBFs分量具有完备性、正交性和局部性,因此FDM时频分析方法具有广泛的应用领域与前景。

2 散布熵原理

散布熵是衡量时间序列不规则复杂程度的一种算法,对于给定长度为 N 的时间序列 $x = \{x_1, x_2, \dots, x_N\}$,DE算法主要步骤如下。

1) 利用正态分布函数

$$y_i = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{x_j} e^{-\frac{(t-u)^2}{2\sigma^2}} dt$$

将时间 x 映射到 $y = \{y_1, y_2, \dots, y_N\}, y_i \in (0, 1)$,其中: u 和 σ^2 分别为期望值与方差。

2) y_i 通过式(5)的线性变换对应到 $[1, 2, \dots, c]$ 的范围内, R 为取整函数, c 为类别个数

$$z_i^c = R(cy_i + 0.5) \quad (5)$$

3) 利用式(6)计算嵌入向量 $z_i^{m,c}$

$$z_i^{m,c} = \{z_i^c, z_{i+d}^c, \dots, z_{i+(m-1)d}^c\} \quad (6)$$

其中: $i = 1, 2, \dots, N - (m-1)d; m$ 为嵌入维数; d 为时延。

4) 计算散布模式 $\rho_{v_0 v_1 \dots v_{m-1}} (v = 1, 2, \dots, c)$ 。若 $z_i^c = v_0, z_{i+d}^c = v_1, v_2, \dots, z_{i+(m-1)d}^c = v_{m-1}$,则 $z_i^{m,c}$ 对应的散布模为 $\rho_{v_0 v_1 \dots v_{m-1}}$ 。由于 $\rho_{v_0 v_1 \dots v_{m-1}}$ 由 m 个数字组成,每个数字有 c 个取值,因此对应的散布模式共有 c^m 个。

5) 计算每种散布模式 $\rho_{v_0 v_1 \dots v_{m-1}}$ 的概率 $p(\rho_{v_0 v_1 \dots v_{m-1}})$

$$p(\rho_{v_0 v_1 \dots v_{m-1}}) = \frac{N(\rho_{v_0 v_1 \dots v_{m-1}})}{N - (m-1)d} \quad (7)$$

其中: $N(\rho_{v_0 v_1 \dots v_{m-1}})$ 为 $z_i^{m,c}$ 映射到 $\rho_{v_0 v_1 \dots v_{m-1}}$ 的个数。

6) 根据香农熵的定义,原始信号 x 的散布熵定义为

$$D_{DE}(x, m, c, d) = - \sum_{\pi=1}^c p(\rho_{v_0 v_1 \dots v_{m-1}}) \ln(p(\rho_{v_0 v_1 \dots v_{m-1}})) \quad (8)$$

式(8)参数的选择参考文献[8], m 取值通常为2或3, c 为4~8之间的整数,时延 d 通常取1,样本长度要求大于2000。

3 精细复合多尺度散布熵

在RCMDE中,对应不同的尺度因子 τ ,具有 τ 个不同起点的粗粒化时间序列,RCMDE值为不同起点的粗粒化时间序列的散布模式概率的平均值的香农熵值。RCMDE计算步骤如下。

1) RCMDE首先将原始信号从第1至 τ 个点依次为初始点,连续分割成长度为 τ 的小段,并求每个小段的平均值,再将这些平均值按顺序排列得到一个粗粒化序列。

对于时间序列 $x = \{x_1, x_2, \dots, x_N\}$,尺度因子 τ 的第 k 个粗粒化序列为 $x_k^{(\tau)} = \{x_{k,1}^{(\tau)}, x_{k,2}^{(\tau)}, \dots, x_{k,j}^{(\tau)}, \dots\}$,其中: $x_{k,j}^{(\tau)} = \frac{1}{\tau} \sum_{b=k+\tau(j-1)}^{k+\tau j-1} x_b$; $1 \leq j \leq \frac{N}{\tau}$; $1 \leq k \leq \tau$ 。

2) 根据上述的DE算法,计算尺度因子 τ 的 τ 个粗粒化时间序列的散布模式 ρ 的概率,再求这些散布模式概率的平均值,最后根据式(9)计算RCMDE

$$R_{RCMDE}(x, m, c, d) = - \sum_{\pi=1}^c \bar{p}(\rho_{v_0 v_1 \dots v_{m-1}}) \ln(\bar{p}(\rho_{v_0 v_1 \dots v_{m-1}})) \quad (9)$$

其中: $\bar{p}(\rho_{v_0 v_1 \dots v_{m-1}}) = \frac{1}{\tau} p_k^{(\tau)}$ 为粗粒化序列 $x_k^{(\tau)}$ 的散布模式 ρ 概率的平均值。

这种对信号精细化处理的方式能够有效地减少粗粒化过程中部分统计信息的丢失以及初始点位置对计算结果的影响,减小计算偏差。RCMDE的计算需要设置如下参数:嵌入维数 m 、类别 c 、时延 d 和最大尺度因子 τ_{max} 。参数 m, c, d 与前述的DE参数选择保持一致, τ_{max} 选择所需要分析的尺度即可。

4 双阶自适应小波聚类方法

小波聚类算法^[11]是基于网格聚类的典型算法,其原理是将对象空间量化为有限数目的网格单元,形成一个网格结构,所有的聚类操作都在这个网格结构上进行。其处理速度很快,能够得到任意形状的聚类;但其聚类精度非常依赖于网格量化值及密度阈值的选择,给出最优量化值及阈值,是得到高精度聚类结果的关键。对于密度分布不均匀的数据类型,很难取到一个合理的量化值和相似度阈值,实现正确的故障识别与分类。为了能够快速准确并且无监督地实现航空发动机转子的故障诊断,笔者应用了双阶自适应小波聚类分析方法^[12],此方法在保持了小波聚类方法的诊断速度快、效率高的基础上,可自适应选取二次细分的量化值,消除网格量化值及密度阈值的参数设置对聚类精度的影响。

双阶自适应小波聚类方法主要分为4个阶段:

- 1) 原始数据空间的粗网格划分,实现数据的预选聚类,由粗网格划分得到的各个聚类,称为子聚类;
- 2) 统计各子聚类信息与计算子聚类自适应细分的量化值;
- 3) 子聚类数据空间的自适应细分与小波聚类;
- 4) 输出信息存储表,比对数据,判断聚类标识分别属于哪类故障,并标识故障类型。

5 双阶自适应小波聚类的故障诊断

5.1 数据采集

在某航空发动机转子试验器^[13]上采集故障样本,航空发动机转子试验器的真实图片如图1所示,剖面图如图2所示。通过该试验器模拟了航空发动

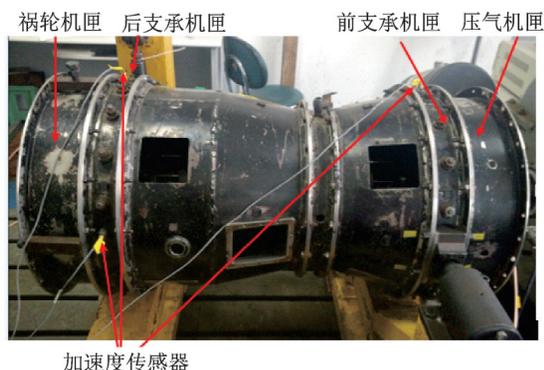


图1 航空发动机转子试验器

Fig.1 Aero-engine rotor test rig

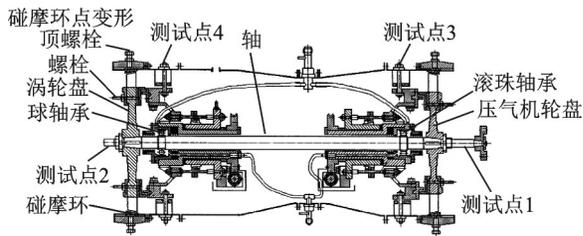


图2 航空发动机转子试验器剖面图

Fig.2 Sectional view of aero-engine rotor test rig

机转子不平衡、不对中、动静件碰摩、支承松动及复合故障的状态。不平衡故障的设置是在图2所示的螺栓位置增加螺母的数量,造成涡轮盘的质量分布不平衡,产生转子不平衡故障。不对中故障设置是调整安装台架上的支承件,使发动机位置发生变化,导致发动机的输入轴与电机的输出轴不对中,从而造成联轴器不对中故障。碰摩故障设置是将发动机旋转到一定转速后,用扳手拧碰摩螺栓,使碰摩环产生形变,从而与旋转的涡轮叶片产生碰摩。轴承松动的设置是使与滚珠轴承外圈配合的支承孔增大,使配合为间隙配合,从而造成轴承松动故障。在涡轮机匣的水平及垂直位置布置加速度传感器采集机匣振动信号,采样频率为10 240 Hz,样本长度为

4 196,每一种故障稳定在1.8,2.1,2.5和2.7 kr/min速度状态下采集。笔者所用故障类型为9种,每种样本数为100,共900组。

5.2 基于FDM的样本分析与特征提取

首先,用自相关降噪方法对航空发动机试验器上采集的信号进行降噪处理及功率谱计算;其次,对降噪信号进行FDM分解,得到一系列FIBFs分量,提取相关性系数大于阈值的FIBFs分量,进行Hilbert变换,计算其边际谱与边际谱重心;最后,提取能量最大的FIBFs分量,计算其功率谱重心。

图3~11分别为无故障、不平衡、不对中、碰摩、碰摩-不平衡、碰摩-不对中、松动、松动-碰摩、松动-不平衡及松动-不对中的振动加速度信号、傅里叶变换的功率谱、FDM分解的边际谱及最大能量层的功率谱。由图3、图4可看出,信号在正常状态与不平衡状态下,在频域内频谱特征相同,不能识别与判断,但时域内的时间序列的复杂度不同。图5为不对中故障信号,多倍频为主要振动频率。图6为航空发动机转子在碰摩状态下的振动信号,信号的振动幅值成倍数增加,并且具有明显的周期冲击特征,在频谱上出现了叶片通过频率及其倍频,叶片通过

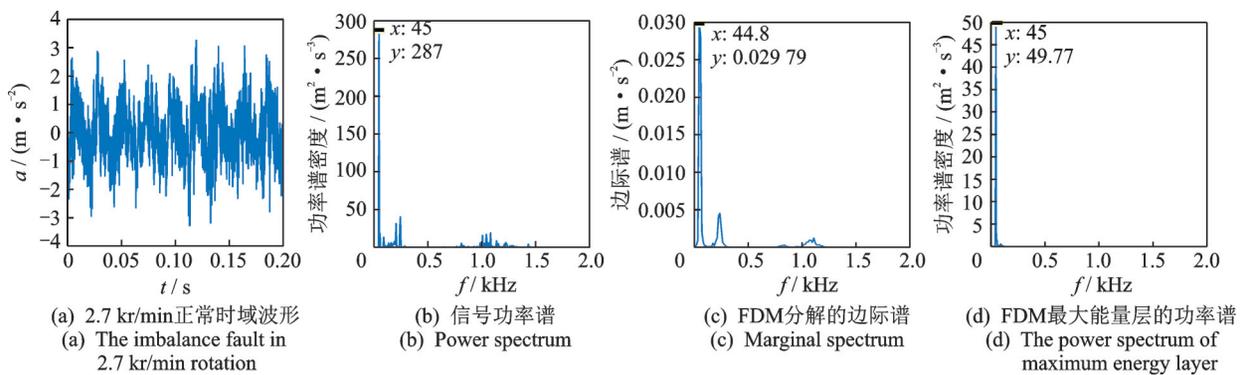


图3 正常信号的样本分析

Fig.3 The normal signal sample analysis

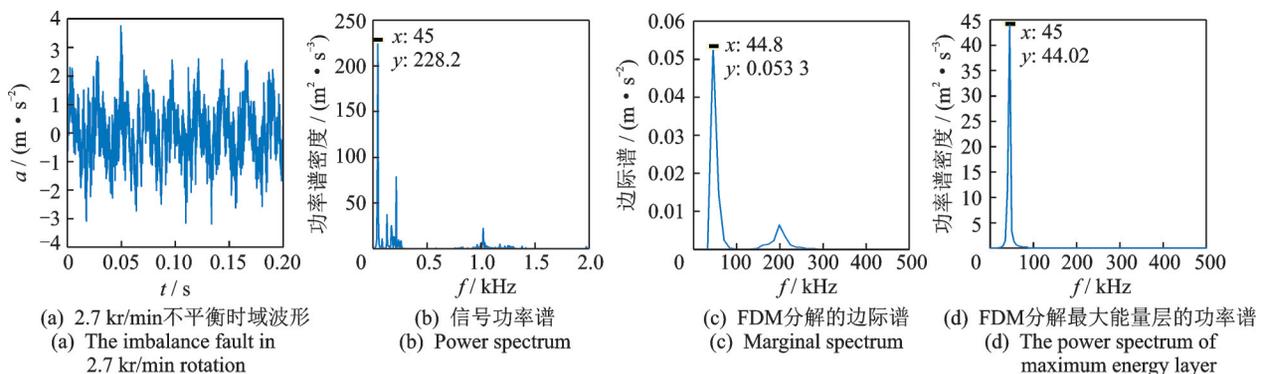


图4 不平衡故障信号的样本分析

Fig.4 Imbalance fault sample analysis

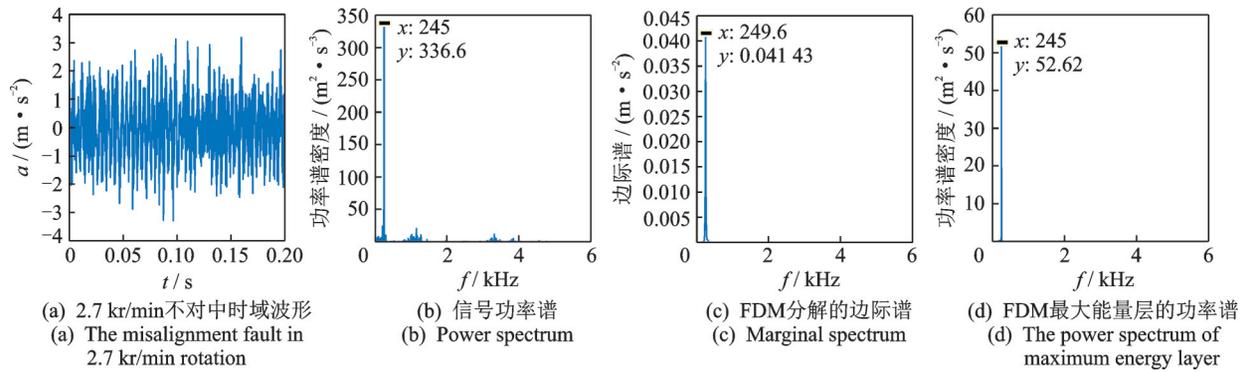


图 5 不对中故障信号的样本分析

Fig.5 Misalignment fault sample analysis

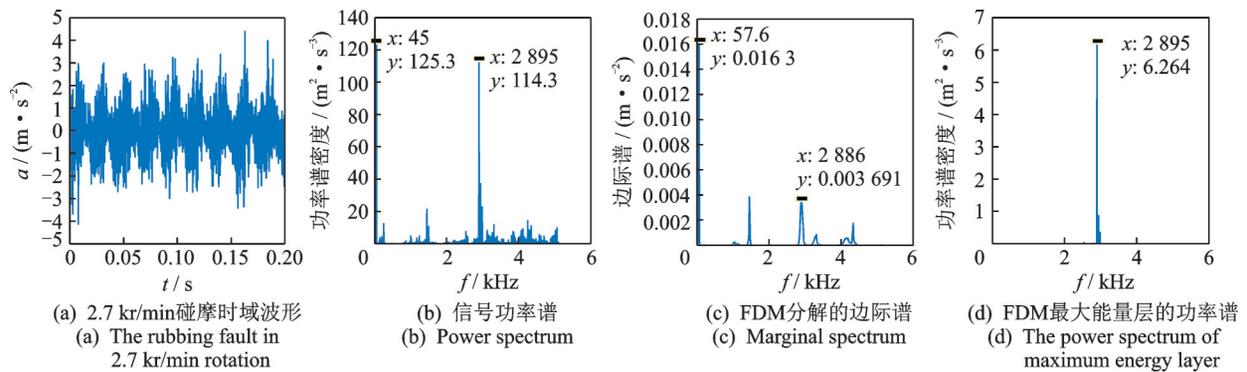


图 6 碰摩故障信号的样本分析

Fig.6 Rubbing fault sample analysis

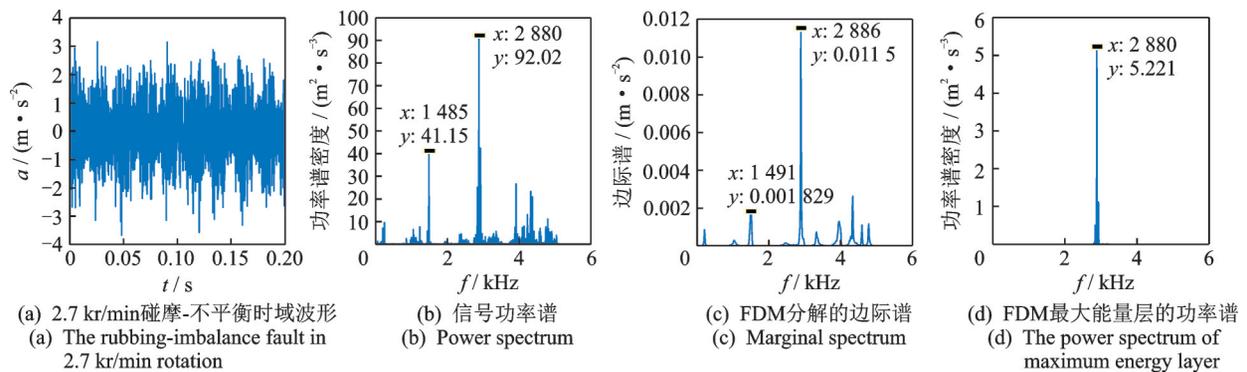


图 7 碰摩-不平衡故障信号的样本分析

Fig.7 Sample analysis of rubbing - imbalance fault

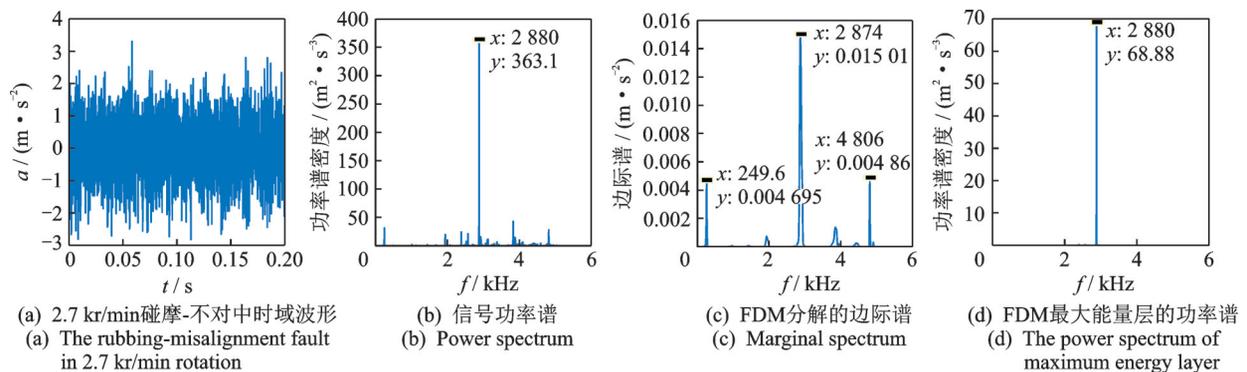


图 8 碰摩-不对中故障信号的样本分析

Fig.8 Sample analysis of rubbing - misalignment fault

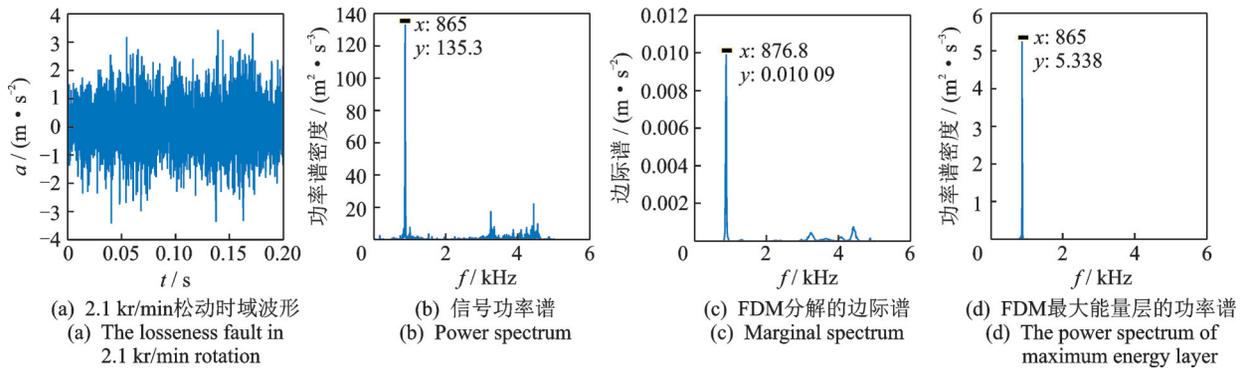


图 9 松动故障信号的样本分析

Fig.9 Sample analysis of looseness fault

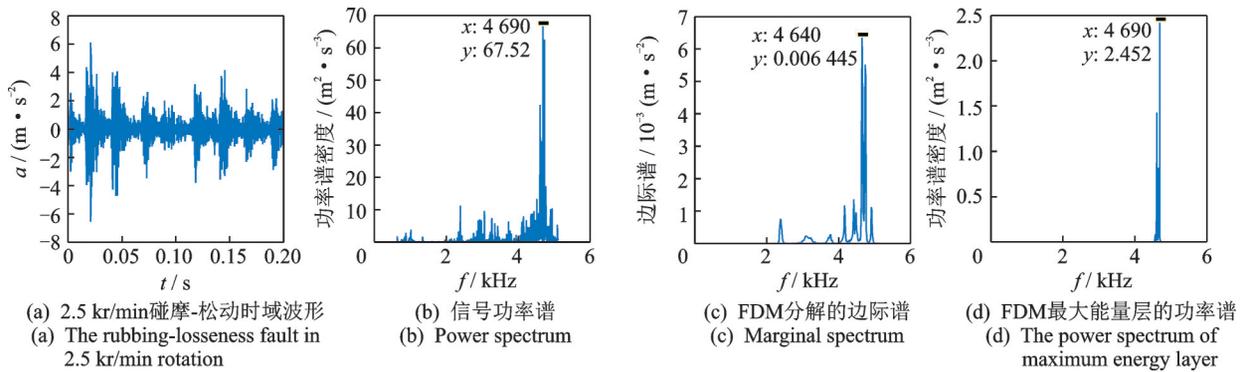


图 10 松动-碰摩故障信号的样本分析

Fig.10 Sample analysis of looseness- rubbing fault

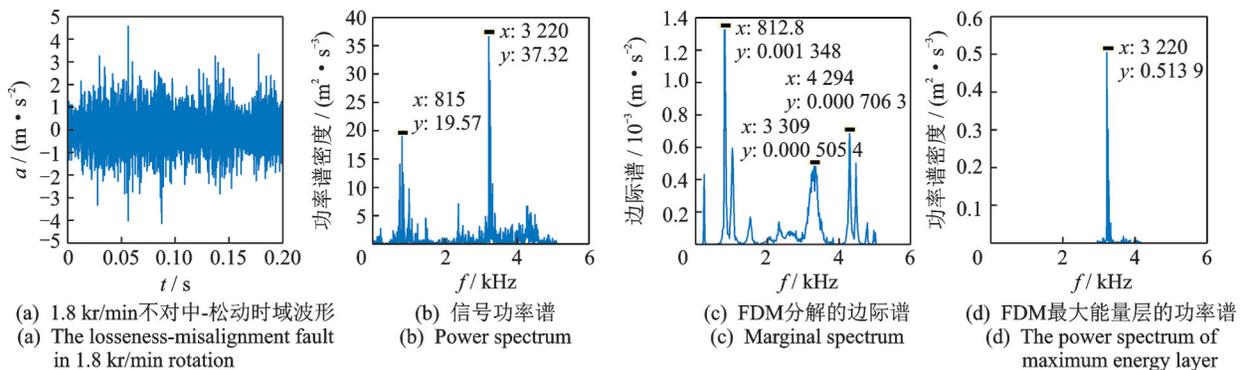


图 11 松动-不对中故障信号的样本分析

Fig.11 Sample analysis of looseness - misalignment fault

频率的 2 倍频能量最大。图 7、图 8 所示为碰摩-不平衡、碰摩-不对中的复合故障,从边际谱可以看出,叶片通过频率的 2 倍的频谱成分更加凸出,碰摩能量加大。图 9 为轴承松动状态时的振动信号的特征时、频域分析图,其振动幅值锐减,整个频率段内,伴随高频低幅振动,轴承松动的主要特征是以 855 Hz 为主频率的谐振波,是激起的轴承部件固有频率。图 10 为松动-碰摩故障状态,信号特征以碰摩为主,叶片通过频率的 4 倍频成为主要振动频率。图 11 为

松动-不对中故障状态的振动信号,松动故障频率的 4 倍频成为主要振动频率。

通过分析各种故障状态下的振动信号,确定提取 FDM 的边际谱重心和最大能量层的功率谱重心作为特征量对故障进行分类。图 12 为不同故障的 RCMDE 分布图,尺度因子大于 14 后,其熵值趋于稳定,且熵值的区分度较好,故选择了尺度因子为 18 时的熵值作为特征值用于故障分类。图 13 为 900 个样本的 FDM 分解边际谱重心、最大能量层谱重心、RC-

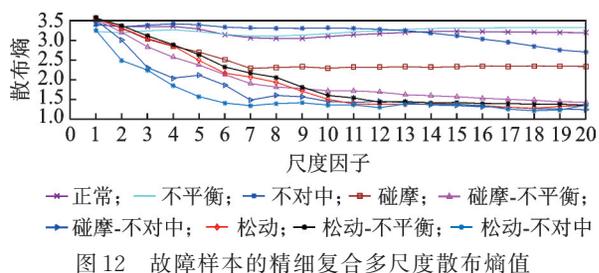


Fig.12 Refined composite multiscale dispersion entropy of the failure sample

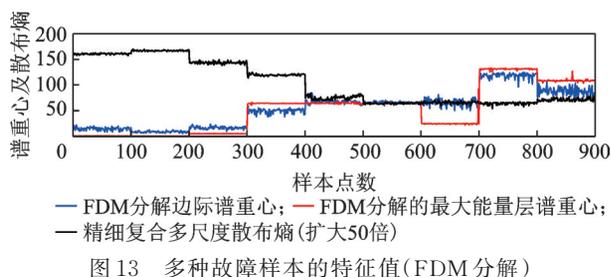


图 13 多种故障样本的特征值(FDM 分解)
Fig.13 Characteristic vector values of multiple fault samples (FDM)

MDE 熵值(放大了 50 倍)的分布图,共 9 种故障类型,每种故障的样本个数为 100。图 14 为应用 EMD 分解提取的边际谱重心、小波分解提取的最大能量层谱重心及有效值。通过图 13 与图 14 比较发现:FDM 分解的边际谱重心、最大能量层谱重心凸显了信号的主要特征频率;同一故障类型的特征值波动小,特征值集中;不同类型特征值之间的差异值较大,有利于实现故障的分类。图 13 中的正常与不平衡(样本点为 100~200)、碰摩-不对中与碰摩-不平衡(样本点为 400~600)的频率特征基本相同,不利于故障分类,但正常与不平衡、碰摩-不平衡与碰磨-不对中的 RCMDE 熵值不同,因此联合 RCMDE 熵值,共同作为特征向量,用于故障分类。图 14 中的 EMD 分解的边际谱重心、小波分解最大能量层谱重心,同一故障类型的特征值波动大,导致不同故障类型的数据相近,不利于分类。有效值作为时域内的特征值,受转速影响较大,同一故障,不同速度下的有效值有差异,因此不同速度下的相同故障状态可能被

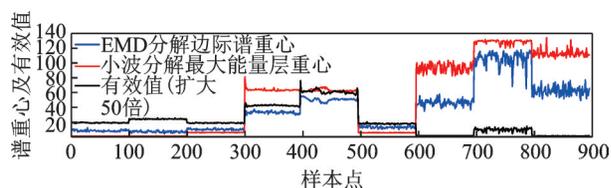


图 14 多种故障样本的特征值(EMD 分解)
Fig.14 Characteristic vector values of multiple fault samples (EMD)

分为多类。RDMDE 熵值是一个无量纲值,基本不受速度影响,用于故障分类优于有效值。因此,选取 FDM 分解的边际谱重心、最大能量层的谱重心及 RCMDE 熵值为特征量用于故障分类,3 个特征量为无量纲单位的特征值。图 15 为 3 个特征量的空间分布图,同一故障类型数据分布集中,而不同故障数据之间的边界清晰。图 16 为应用双阶自适应小波聚类的诊断结果,9 种类型数据,每种样本数量为 100,提取信息表中被正确分类的样本数,与 100 相除,得到每类的诊断正确率,计算平均值即为总体样本诊断正确率,此样本的诊断正确率为 97.67%。

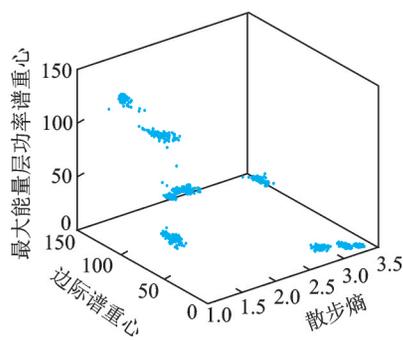


图 15 特征向量分布图

Fig.15 Distribution of feature vectors

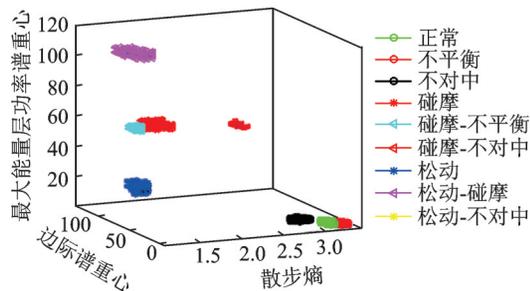


图 16 双阶自适应小波聚类结果

Fig.16 The result of two-stage adaptive WaveCluster

6 结 论

1) 应用 FDM 分解方法,得到若干固有频带函数,根据其与原信号的相关系数,提取主要固有频带函数,重构生成边际谱,并且提取了最大能量层的固有频带函数,其边际谱与最大能量层凸显了信号的主要特征频率。应用 FDM 分解方法提取的特征值准确且波动小,同一类的故障信号的特征值集中,不同的类型特征值差异值较大,有利于实现多类混合故障的分类与识别。

2) 在复合故障诊断中,虽然复合故障不同,但其频率特征可能相近,只应用频率特征不能将多种故障区分开来。将精细复合多尺度散布熵与频率特

征联合应用,提取信号的精细多尺度散布熵、FDM分解的边际谱重心及最大能量层的谱重心作为特征向量,应用双阶自适应小波聚类方法对航空发动机转子故障进行分类,其诊断正确率可达到97.67%。

参 考 文 献

- [1] ZHANG X Y, LIANG Y T, ZHOU J H, et al. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM[J]. Measurement, 2015, 69:164-179.
- [2] 李瑞彤,王华庆,屈红伟,等.基于约束独立成分分析的轴承复合故障特征提取方法[J].噪声与振动控制, 2015, 35(3):173-176.
LI Ruitong, WANG Huaqing, QU Hongwei, et al. Application of CICA in compound fault feature extracting of rolling bearings[J]. Noise & Vibration Control, 2015, 35(3):173-176. (in Chinese)
- [3] WANG Y X, MARKERT R, XIANG J W, et al. Research on variational mode decomposition and its application in detecting rub-impact fault of the rotor system[J]. Mechanical Systems & Signal Processing, 2015, 60/61:243-251.
- [4] 万书亭,豆龙江,李聪,等.基于VMD和样本熵的高压断路器故障特征提取及分类[J].振动与冲击, 2018, 37(20):32-38.
WAN Shuting, DOU Longjiang, LI Cong, et al. Fault feature extraction and classification of high voltage circuit breakers based on VMD and sample entropy[J]. Journal of Vibration & Shock, 2018, 37(20):32-38. (in Chinese)
- [5] 杨大为,冯辅周,赵永东,等.VMD样本熵特征提取方法及其在行星变速箱故障诊断中的应用[J].振动与冲击, 2018, 37(16):198-205.
YANG Dawei, FENG Fuzhou, ZHAO Yongdong, et al. A VMD sample entropy feature extraction method and its application in planetary gearbox fault diagnosis [J]. Journal of Vibration & Shock, 2018, 37(16):198-205. (in Chinese)
- [6] 郑近德,程军圣,杨宇.多尺度排列熵及其在滚动轴承故障诊断中的应用[J].中国机械工程, 2013, 24(19):2641-2646.
ZHENG Jinde, CHENG Junsheng, YANG Yu. Multi-scale permutation entropy and its applications to rolling bearing fault diagnosis[J]. China Mechanical Engineering, 2013, 24(19):2641-2646. (in Chinese)
- [7] 张淑清,孙国秀,李亮,等.基于LMD近似熵和FCM聚类的机械故障诊断研究[J].仪器仪表学报, 2013, 34(3):714-720.
ZHANG Shuqing, SUN Guoxiu, LI Liang, et al. Study on mechanical fault diagnosis method based on LMD approximate entropy and fuzzy C-means clustering [J]. Chinese Journal of Scientific Instrument, 2013, 34(3):714-720. (in Chinese)
- [8] ROSTAGHI M, AZAMI H. Dispersion entropy: a measure for time series analysis [J]. IEEE Signal Processing Letters, 2016, 23(5):610-614.
- [9] AZAMI H, ROSTAGHI M, ABASOLO D, et al. Refined composite multiscale dispersion entropy and its application to biomedical signals. [J]. IEEE Transactions on Biomedical Engineering, 2017, 64(12):2872-2879.
- [10] SINGH P, JOSHI S D, PATNEY R K, et al. The Fourier decomposition method for nonlinear and nonstationary time series analysis [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2017, 473(2199):871-885.
- [11] SHEIKHOLESLAMI G, CHATTERJEE S, ZHANG A. WaveCluster: a wavelet-based clustering approach for spatial data in very large databases [J]. VLDB Journal, 2000, 8(3/4):289-304.
- [12] 左红艳,刘晓波,洪连环.双阶自适应小波聚类的航空发动机故障分类与识别[J].振动工程学报, 2018, 31(1):165-175.
ZUO Hongyan, LI Xiaobo, HONG Lanhuan. Aero-engines fault classification and recognition based on two-stage adaptive WaveCluster [J]. Journal of Vibration Engineering, 2018, 31(1):165-175. (in Chinese).
- [13] 陈果.南京航空航天大学智能诊断与专家系统[EB/OL].(2016-09-16)[2019-03-24].<http://ides.nuaa.edu.cn/main.htm>



第一作者简介:左红艳,女,1976年8月生,博士、讲师。主要研究方向为设备故障诊断。曾发表《双阶自适应小波聚类的航空发动机故障分类与识别》(《振动工程学报》2018年第31卷第1期)等论文。

E-mail:373334570@qq.com

通信作者简介:刘晓波,男,1963年7月生,博士、教授、博士生导师。主要研究方向为动力学与设备故障诊断。

E-mail:xbliu0791@126.com