

# 基于形态变分模态分解和 JRD 的 航天器异常状态识别

姜海旭<sup>1,2</sup>, 张科<sup>1,2</sup>, 王靖宇<sup>1,2</sup>, 吕梅柏<sup>1,2</sup>

(1.西北工业大学 航天学院, 陕西 西安 710072;  
2.西北工业大学 航天飞行动力学国家级重点实验室, 陕西 西安 710072)

**摘要:**针对在轨航天器微弱异常难以识别问题,提出了一种基于形态变分模态分解和 JRD 距离的异常状态识别方法。首先利用形态变分模态分解将航天器遥测数据分解为不同频率的多尺度模态分量,然后提取各模态分量的 Rényi 熵,将得到的 Rényi 熵向量作为遥测数据的特征,最后通过计算样本数据与实测数据特征之间的 JRD 距离,实现对航天器异常状态的识别。以某卫星反作用轮转微弱异常转速实测数据对该方法进行仿真验证,仿真结果表明,提出的识别方法能够有效识别航天器异常状态,且在识别速度上具有明显优势。

**关键词:**形态变分模态分解;Rényi 熵;JRD 距离;异常识别

**中图分类号:**V448      **文献标志码:**A      **文章编号:**1000-2758(2018)01-0020-08

遥测数据是反映在轨航天器状态的主要依据,通过对遥测数据的准确分析不但可以掌握航天器当前的工作状态,更可以及时发现航天器存在的异常,降低航天器运行风险。目前,对航天器的异常检测以阈值法为主<sup>[1]</sup>,阈值法检测过程简单,但对异常处理存在明显的滞后性。若能够在航天器出现异常初期,通过提取遥测数据相关特征及时检测和识别出系统异常,则可以降低航天器维护成本,确保航天器运行安全。

现有研究中,对遥测数据的异常检测和识别以时域分析法为主,文献[2-4]利用历史遥测数据建立数据的时间序列模型,将模型输出数据与遥测数据进行比较,实现对遥测数据的异常检测。该方法在遥测数据结构和类型发生变时,需要对先前所建模型进行修正甚至重建,因此在实际应用中存在较大局限性。近年来,研究人员提出时频域分析法对遥测数据进行分析,利用时频分解得到的各频段分量,以获取数据更多细节信息实现异常检测。变分模态分解(variational mode decomposition, VMD)是一种新型自适应准正交模态时频分解方法,可将数

据分解为多个具有确定中心频率的有限带宽固有模态<sup>[5]</sup>。相较于传统的经验模态分解方法, VMD 能够更为准确地分离出数据中所包含的各频带模态分量,文献[6-8]分别利用 VMD 对轴承滚动数据进行分解,实现对轴承不同类型故障的诊断。但 VMD 分解的有效性依赖于分解参数的合理选择。现有研究对 VMD 分解参数的选择仍未有确定方法,多由经验确定,因此 VMD 参数在设定策略上仍存在不足。

初期异常引起遥测数据的频率和能量等典型特征变化并不显著,难以利用 VMD 分解得到的模态分量直接识别,因此需要进一步提取各模态分量的其他数学特征,以提高异常显著性。Rényi 熵是信息熵的扩展形式,可以更准确地表征数据不确定性程度,被广泛用于模式识别、图像分割和时间序列分析等领域<sup>[9-10]</sup>。文献[11]在提取轴承数据各模态分量 Rényi 熵基础上,利用 Jensen-Rényi Divergence (JRD)距离测定参考数据与实测数据的 Rényi 熵特征距离,实现对轴承微弱异常状态的识别和评估。

由上述分析可知,从时频角度分析遥测数据仍

处于初步阶段,而将VMD用于航天器遥测数据异常状态识别尚未有公开文献报道。针对在轨航天器异常识别问题,本文提出了一种基于形态变分模态分解(morphological variational mode decomposition, M-VMD)和JRD距离的在轨航天器异常状态识别方法。首先利用M-VMD方法对遥测数据进行分解,然后提取各模态分量的Rényi熵特征,通过计算遥测数据与样本数据对应各模态分量的JRD距离,实现在轨航天器异常状态的识别,最后以反作用轮实测数据验证方法的有效性。

## 1 变分模态分解(VMD)

VMD分解是基于维纳滤波、希尔伯特变化和混频的变分问题求解过程,主要包括变分问题建立和求解2个过程。建立变分问题为:在约束条件为 $k$ 个模态和等于输入数据情况下,寻找 $k$ 个模态函数,令各模态估计带宽和最小。问题构造时,首先利用Hilbert变换计算各模态分量 $u_k(t)$ 的单边谱:

$$\left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \quad (1)$$

式中, $\delta(t)$ 为单位脉冲函数,\*为卷积运算。

然后,将预估中心频率指数信号 $e^{-j\omega_k t}$ 加入到各模态分量,将各模态频谱调制到“假设基带上”:

$$\left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \quad (2)$$

估计各模态带宽,构造出变分问题为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (3)$$

s.t.  $\sum_k u_k = f$

式中, $u_k = \{u_1, u_2, \dots, u_K\}$ 为 $K$ 个模态分量(IMF), $\omega_k = \{\omega_1, \omega_2, \dots, \omega_K\}$ 为各模态分量对应中心频率。

引入二次惩罚因子 $\alpha$ 和拉格朗日乘法算子 $\lambda(t)$ , $\alpha$ 决定带宽, $\lambda(t)$ 确保了约束条件的严格性,得到增广拉格朗日函数:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (4)$$

采用乘法算子交替方向法,通过更新 $u_k^{n+1}$ 、 $\omega_k^{n+1}$ 和 $\lambda^{n+1}$ 求解上述问题中拉格朗日函数的鞍点,利用Parseval/Plancherel傅里叶等距变换,将问题转化到频域得到更新方法为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (6)$$

式中, $\omega_k^{n+1}$ 为当前模态函数功率谱的重心,对 $\{\hat{u}_k(\omega)\}$ 进行傅里叶逆变换,则其实部为模态分量 $\{u_k(t)\}$ 。当满足迭代停止条件时,结束迭代得到 $K$ 个IMF。

## 2 形态学变分模态分解(M-VMD)

VMD分解参数的合理性直接影响VMD分解质量。分解参数设置不合理会引起模态过分解或模态混叠,导致数据中有效信息的缺失。因此本文提出一种基于形态学的VMD分解方法,实现对VMD分解参数初值的确定和自适应修正。

首先提取数据频谱包络,然后统计包络中有效的局域极值点数量,并以该数量作为VMD分解数量参数的初值。提取数据频谱包络等同于对包络低通滤波,而形态滤波是一种快速全局性非线性滤波方法,通过在数据全局滑动结构元素改变数据局部形态,实现对高频噪声的抑制。其基本运算包括膨胀“ $\oplus$ ”和腐蚀“ $\ominus$ ”,计算公式分别为:

$$(x \oplus b)(n) = \max[x(n-m) + b(m)] \quad (7)$$

$$(x \ominus b)(n) = \min[x(n+m) - b(m)] \quad (8)$$

式中,输入数据 $x(n)$ 为定义在 $F = (0, 1, \dots, N-1)$ 上的离散函数,结构元素 $b(n)$ 为在 $G = (0, 1, \dots, M-1)$ 上的离散函数,且 $N \geq M$ 。其中,膨胀运算具有平滑正脉冲,抑制负脉冲的作用,符合提取数据频谱包络的目标,但仅采用膨胀运算会造成正脉冲方向数据形态变形过大,引起数据信息丢失。为避免此情况,采用先膨胀再腐蚀的复合形态闭运算对提取包络进行修正,形态闭运算“ $\cdot$ ”公式为:

$$(x \cdot b)(n) = (x \oplus b \ominus b)(n) \quad (9)$$

由形态滤波原理可知,形态滤波效果取决于形态结构元素 $b$ 及其参数。通常情况下,结构元素 $b$

应选取与输入数据形态相似的结构元素<sup>[12]</sup>,参考航天器遥测数据频谱形状,本文采用半圆或椭圆形结构元素。结构元素  $b$  参数主要包括:幅度  $h_m$  和宽度  $w_m$ 。幅度  $h_m$  与滤波结果平滑度成反比,宽度  $w_m$  与滤波结果平滑度成正比。

利用形态滤波提取频谱包络的原则为:在有效保留原数据频谱信息基础上,提取数据频谱中具有显著特征的局部极值,因此给出形态结构元素参数设定参考值:

$$\begin{cases} h_m = \zeta_h * 0.1 * \bar{A} \\ w_m = \zeta_w * f_{dmin} \end{cases} \quad (10)$$

式中,  $\bar{A}$  为输入数据幅度均值数据,  $f_{dmin}$  为最小分辨率频宽。  $\zeta_h$  和  $\zeta_w$  为修正系数,通常情况下设定其值为 1,在处理特定问题时,可根据设定滤波结果与输入数据目标的均方差进行修正。

由上述分析可知,参数合理的形态滤波可有效提取数据频谱包络,但一次形态滤波所提取包络中可能仍存在局域极值点密度过大问题。因此,在一次滤波结果基础上,采用二次形态滤波进一步去除一次滤波结果中过多频率相近的极值点。二次形态滤波选择结构元素不变,对结构元素幅度和宽度进行适度增大,参数值可根据一次滤波结果  $f_{xm1}$  与二次滤波  $f_{xm2}$  结果的标准差进行修正,满足如下关系:

$$[w, h] = \underset{w_i, h_i, i \in \mathbf{R}}{\operatorname{argmax}} \{ (f_{xm1}(w_1, h_1) - f_{xm2}(w_2, h_2))_{\text{std}} \} \quad (11)$$

通过二次形态滤波,可以提取含有有效局部极值的数据频谱包络,对局部极值数量进行统计并将数量作为 VMD 分解数量初值。设模态分解数量初值为  $K$ ,给出惩罚因子  $\alpha$  初值的计算方法<sup>[8]</sup>为:

$$\alpha = \frac{B_M}{K} \quad (12)$$

式中,  $B_M$  为原数据频谱带宽。

由此可得到 VMD 分解参数初值  $[K, \alpha]$ 。利用 VMD 对数据进行初次分解,将数据分解为  $K$  个模态分量。计算  $K$  个模态分量的重构数据,公式为:

$$x' = \sum_{i=1}^K U_i \quad (13)$$

式中,  $U_i$  为分解得到的模态分量。

计算重构数据  $x'$  与原始数据  $x$  的相关系数  $\rho(x', x)$ ,公式为:

$$\rho(x', x) = \frac{\sum_{i=1}^n (x'_i - \bar{x}') (x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (x'_i - \bar{x}')^2} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (14)$$

将相关系数  $\rho(x', x)$  与预设阈值  $\rho_{th}$  进行比较,当  $\rho(x', x) < \rho_{th}$  时,对原始数据进行  $K+1$  层分解,利用(13)式和(14)式重新计算重构数据与原始数据的相关系数并判断分解层数合理性,直到  $\rho(x', x) \geq \rho_{th}$  时,确定此时分解参数为最终理想 VMD 分解参数。设理想模态分解数量为  $K_s$ ,则分解参数判断关系为:

$$\begin{cases} K_s = K & \rho(x', x) \geq \rho_{th} \\ K_s = K + 1 & \rho(x', x) < \rho_{th} \end{cases} \quad (15)$$

通常设定相关系数阈值  $\rho_{th}$  为 0.9。将分解得到的  $K_s$  个模态分量作为 M-VMD 方法得到的理想多尺度模态分量。

### 3 基于 M-VMD 与 JRD 距离的状态识别

#### 3.1 数据特征提取

对遥测数据进行状态识别时,首先应选择合适的数据测度,将数据测度的度量值作为数据的特征。信息熵是一种测量数据不确定性的度量,在已知数据概率分布情况下,信息熵能够定量的表征数据中特定信息出现概率,因此信息熵可作为一种全局性测度表征数据特征。对于离散随机变量  $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ ,其信息熵  $H(\mathbf{X})$  计算公式为:

$$H(\mathbf{X}) = - \sum_{i=1}^N p_i(x_i) \ln(p_i(x_i)) \quad (16)$$

式中,  $\mathbf{P} = \{p_1, p_2, \dots, p_N\}$  为各随机变量对应概率。由(16)式可知,  $\mathbf{P}$  集确定时,数据信息熵值确定,当数据中出现新息数据时,信息熵对新息数据的敏感性有限,影响对数据特征的准确表达,因此采用对数据不确定性具有更强描述能力的 Rényi 熵<sup>[13]</sup>作为数据特征。Rényi 熵  $H_\alpha(\mathbf{X})$  计算方法为:

$$H_\alpha(\mathbf{X}) = \begin{cases} \frac{1}{1-\alpha} \ln \sum_{i=1}^N p_i^\alpha(x_i) & \alpha \geq 0, \alpha \neq 1 \\ H(\mathbf{X}) & \alpha = 1 \end{cases} \quad (17)$$

当  $\alpha = 1$  时, Rényi 熵退化为信息熵,文献[13]对 Rényi 熵  $\alpha$  值选取进行了分析,得出当  $\alpha = 0.5$  时,其度量结果较为稳定。

### 3.2 数据特征识别

对数据的特征识别可转化为对实测数据与样本数据特征之间相似度的度量。结合航天器对遥测数据处理速度的要求,本文使用基于距离的相似度度量方法。JRD 距离是一种基于 KL(kullback-leibler divergence)距离<sup>[14]</sup>的相似度度量方法,能够定量反映 2 个概率分布间的相似度。对于归一化后的 2 个概率分布  $\mathbf{P} = \{p_1, p_2, \dots, p_N\}$  和  $\mathbf{Q} = \{q_1, q_2, \dots, q_N\}$ , JRD 距离<sup>[14]</sup>计算公式为:

$$D_{\text{JRD}}(\mathbf{P} \parallel \mathbf{Q}) = \frac{1}{2}D_{\text{KL}}(\mathbf{P} \parallel \mathbf{M}) + \frac{1}{2}D_{\text{KL}}(\mathbf{Q} \parallel \mathbf{M}) = H_{\alpha}(\mathbf{M}) - \frac{1}{2}H_{\alpha}(\mathbf{P}) - \frac{1}{2}H_{\alpha}(\mathbf{Q}) \quad (18)$$

式中,  $\mathbf{M}$  为  $\mathbf{P}$  和  $\mathbf{Q}$  的平均概率,  $H_{\alpha}$  为 Rényi 熵,  $D_{\text{KL}}$  为 KL 距离,其定义为:

$$D_{\text{KL}}(\mathbf{P} \parallel \mathbf{Q}) = \sum_{i=1}^N p_i \log \frac{p_i}{q_i} \quad (19)$$

由(18)式、(19)式可知, JRD 距离有效避免了 KL 距离不对称问题,更符合距离测度的典型定义。JRD 距离取值范围为  $[0, +\infty)$ , 而相似度取值范围通常为  $[0, 1]$ , 因此将 JRD 距离转化为 JRD 距离相似度,计算公式为:

$$\rho(\mathbf{P}, \mathbf{Q}) = \exp \left[ - \sum_{i=1}^N D_{\text{JRD}}(\mathbf{P}, \mathbf{Q}) \right] \quad (20)$$

当  $\mathbf{P} = \mathbf{Q}$  时,即两组数据的概率分布相同时,数据的相似度为 1, JRD 距离为 0。因此通过计算实测数据与样本数据的 JRD 距离,可以实现对实测数据状态的识别。

### 3.3 基于 M-VMD 与 JRD 距离的异常状态识别

地面站获取的航天器遥测数据具有典型的非线性、非平稳特点,为实现对异常数据的检测和识别,本文提出一种基于 M-VMD 与 JRD 距离的航天器异常状态识别方法。

首先,利用 M-VMD 方法将遥测数据分解为  $K_s$  个模态分量,然后对各模态分量进行检测,若存在显著异常模态分量,则判断数据存在异常,通过与异常样本数据库进行对比,识别实测数据的异常状态。若不存在显著异常模态分量,则计算各模态分量的 Rényi 熵,并对 Rényi 熵进行分析,提取其中具有显著特征的  $l$  个模态分量的 Rényi 熵,组成实测数据状态特征向量  $\mathbf{V} = [H_{a1}, H_{a2}, \dots, H_{al}]$ 。

最后,利用 JRD 距离计算样本数据与遥测数据各模态分量的 Rényi 熵特征距离,将 JRD 距离值转

为 JRD 距离相似度值,将相似度最大值对应样本数据状态作为实测数据识别状态。方法流程如图 1 所示。

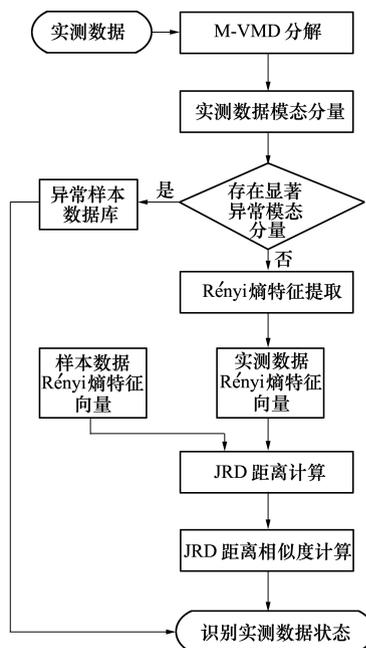


图 1 基于 M-VMD 与 JRD 距离的航天器状态识别流程图

## 4 仿真实验及分析

### 4.1 M-VMD 分解仿真分析

为验证 M-VMD 方法有效性,采用具有明显背景噪声的 A 时段动量轮转速数据进行测试,转速数据时域图如图 2 所示。

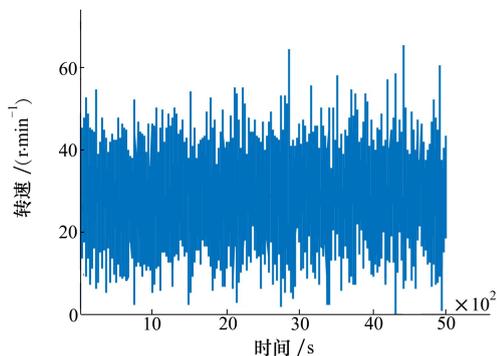


图 2 A 时段动量轮转速时域图

根据 M-VMD 分解方法,首先提取 A 时段转速数据频谱包络,得到频谱并提取频谱包络如图 3 所示。

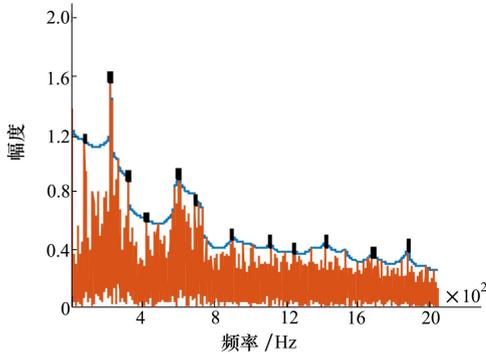


图3 A时段动量轮转速频域图及提取包络

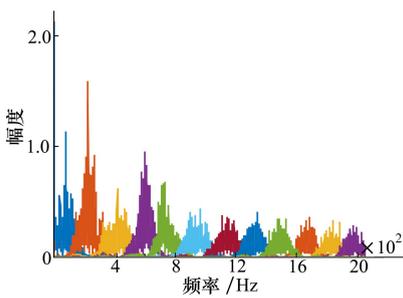


图4 A时段动量轮转速各模态频谱图

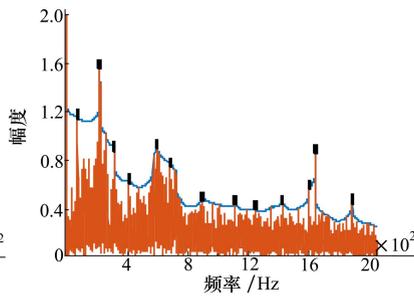


图5 B时段动量轮转速频域图及提取包络

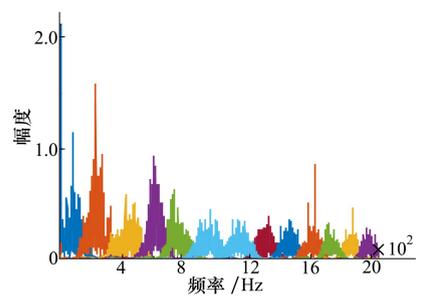


图6 B时段动量轮转速各模态频谱图

对比图4与图6中各模态分量的频谱图,可以发现M-VMD方法能够有效提取B时段数据中1650 Hz处的模态分量。若以A时段数据为正常,B时段数据异常,则通过对比2组数据M-VMD模态分解结果可以直接发现此异常。因此M-VMD方法可以从时频分解角度发现数据中存在显著异常,通过参考典型异常样本库可以确定此异常类型。

以B时段数据为例,分别采用文献[7-8]中遍历寻优和粒子滤波VMD分解方法进行对比,参数设定参考相关内容。对比结果如表1所示:

表1 不同VMD分解参数确定方法效率对比

采用方法	运行时间/s	迭代次数
遍历寻优	223.9	12
粒子滤波	183.1	8
M-VMD	44.3	1

由表1可知,M-VMD分解方法在运行时间和迭代次数上均有明显优势,具有更快的处理速度。

#### 4.2 基于M-VMD与JRD距离的异常状态识别仿真分析

为验证基于M-VMD与JRD距离的异常识别方法有效性,以某卫星反作用轮由正常至轻微异变到

图中对局部极值点进行了标记,经统计数量为12,因此设定分解数量初值为12,对应惩罚因子为170。利用M-VMD进行分解,得到最终分解模态为12个,各分解模态频谱如图4所示。

选取相同背景噪声的B时段转速数据进行对比测试,B时段数据较A时段数据在1650 Hz附近含有更多的频率分量,得到频谱并提取频谱包络如图5所示。图中对局部极值点进行了标记,经统计数量为13,因此设定分解数量初值为13,对应惩罚因子150。利用M-VMD进行分解,得到最终分解模态为13,各分解模态频谱如图6所示。

严重异常的演化过程的转速遥测数据为例,如图7a)~7d)所示。此处将异常程度分别定义为I、II、III型。

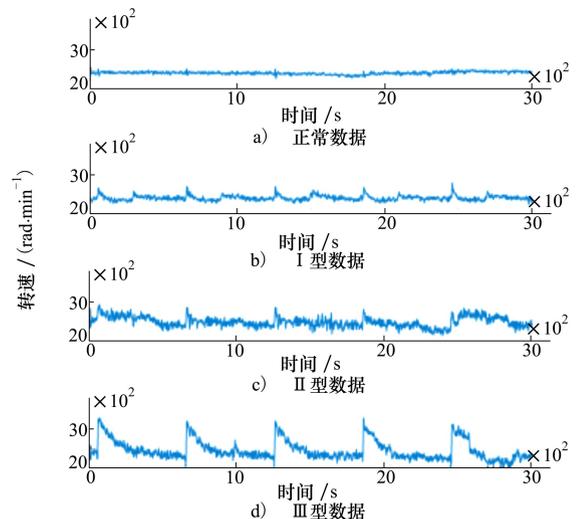


图7 反作用轮各状态数据

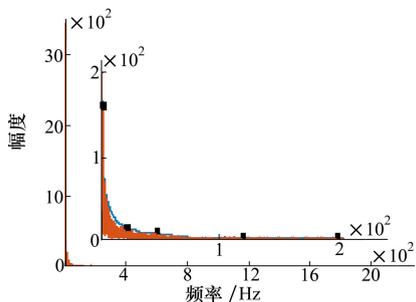


图 8 正常数据频谱、局部放大频谱及提取包络

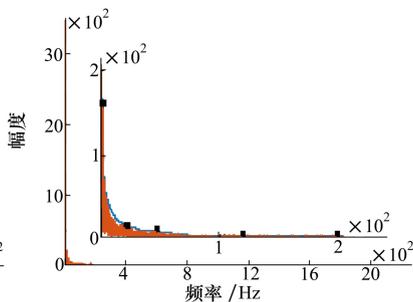


图 9 I 型数据频谱、局部放大频谱及提取包络

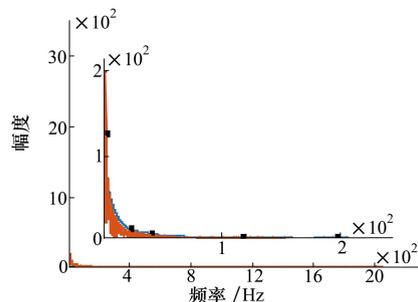


图 10 II 型数据频谱、局部放大频谱及提取包络

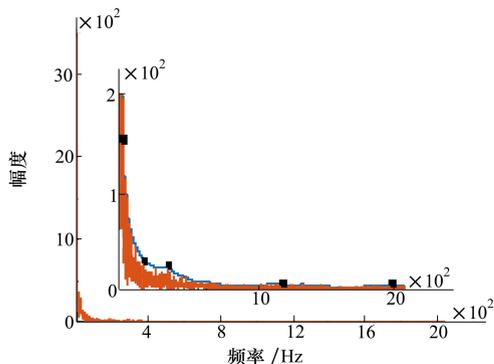


图 11 III 型数据频谱、局部放大频谱及提取包络

根据基于 M-VMD 与 JRD 距离的数据异常状态识别流程,首先对各遥测数据进行 M-VMD 分解,各数据频谱、局部放大频谱和提取包络如图 8~图 11 所示,对各数据包络局部极值进行统计,确定分解参数初值均为 5、惩罚因子为 400,得到各数据最终分解模态分量为 5。通过各数据频谱局部放大图可知数据频谱特征区分不明显,难以通过对比各数据的模态分量差异直接检测出系统异常,因此进一步提取各数据模态分量的 Rényi 熵特征,得到各数据 Rényi 熵,如图 12 所示。由图 12a) 可知正常状态下,反作用轮转速遥测数据在稳定值附近波动,数据分布随机性强,因此得到各模态分量的 Rényi 熵值相对较大。随着异常情况加重,异常变化逐渐提升了数据中的周期性成分,引起各模态分量 Rényi 熵值下降,图 12b)~12d) 所示各数据 Rényi 熵柱状图数值变化规律符合上述分析结论。

最后,分别计算正常状态数据与 I、II、III 型数据各模态分量的 JRD 距离,结果如表 2 所示:

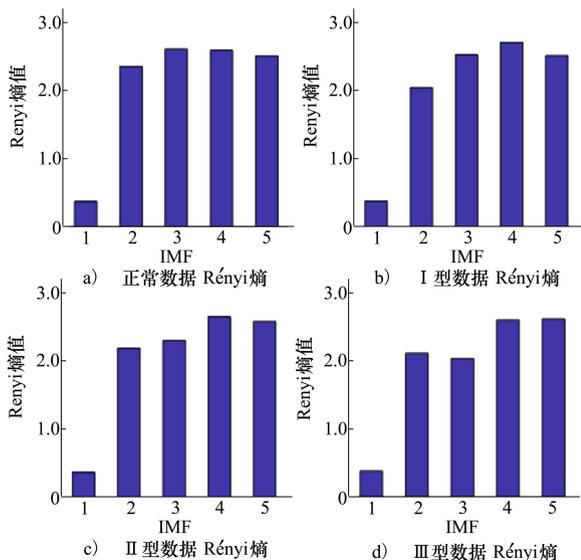


图 12 各状态数据 Rényi 熵柱状图

表 2 I、II、III 型数据与正常数据 JRD 距离

模态分量	I 型数据	II 型数据	III 型数据
IMF1	0.005	0.046	0.048
IMF2	0.099	0.105	0.128
IMF3	0.035	0.060	0.020
IMF4	0.032	0.046	0.047
IMF5	0.038	0.044	0.033

由表 2 可知,随着异常情况加剧, I、II、III 型数据与正常数据各模态分量的 JRD 距离逐渐增大,其主要区别体现在 IMF 的前 3 分层,因此在此例中可以将数据的前 3 层 IMF 作为主要数据特征。同时, I、II、III 型数据与正常数据各模态分量之间的 JRD 距离在数值上具有相对独立特征,因此通过 JRD 距离可以识别出系统异常状态的类型。

将上述4组数据作为反作用轮异常演化过程的样本数据,采用演化过程中其他8个时段数据作为测试数据,正常时段截取数据为 $D_{n1}$ 和 $D_{n2}$ ;近I型数据时段截取数据为 $D_{\alpha1}$ 和 $D_{\alpha2}$ ;近II型数据时段截取数据为 $D_{\beta1}$ 和 $D_{\beta2}$ ;近III型数据时段截取数据为 $D_{\gamma1}$ 和 $D_{\gamma2}$ ,分别计算测试数据与样本数据特征之间的JRD距离,利用(20)式转化为JRD距离相似度,计算结果如表3所示。

表3 测试数据与样本数据JRD距离相似度结果

样本数据	JRD距离相似度				识别结果
	正常数据	I型数据	II型数据	III型数据	
$D_{n1}$	0.981	0.927	0.870	0.806	正常
$D_{n2}$	0.953	0.892	0.850	0.796	正常
$D_{\alpha1}$	0.850	0.922	0.827	0.783	I型
$D_{\alpha2}$	0.805	0.908	0.792	0.715	I型
$D_{\beta1}$	0.756	0.830	0.917	0.816	II型
$D_{\beta2}$	0.784	0.852	0.936	0.838	II型
$D_{\gamma1}$	0.671	0.756	0.806	0.886	III型
$D_{\gamma2}$	0.695	0.776	0.830	0.908	III型

由表3可知,由于微弱异常引起遥测数据变化较小,因此各测试数据与样本数据所得JRD距离相似度的计算结果在数值上较为接近,但各测试数据与相近时段样本数据特征的JRD距离相似度仍然高于与其他时段样本数据特征的JRD距离相似度。因此可以通过比较相似度计算结果确定测试数据对应状态,表3对各测试数据的状态识别结果均正确。

## 5 结论

本文针对在轨航天器微弱异常识别的问题,提出了一种基于M-VMD和JRD距离的异常状态识别方法,研究结果表明:

1) 本文所提出的M-VMD方法能够快速、准确的获取VMD分解参数初值,减少VMD获取理想模态分量的运算次数。

2) 本文所提出的基于M-VMD和JRD距离的异常状态识别方法,以M-VMD分解得到各模态分量的Rényi熵为数据特征,通过计算实测数据与样本数据各模态分量之间数据特征的JRD距离可以实现对航天器异常状态的准确识别。

## 参考文献:

- [1] 彭喜元, 庞景月, 彭宇, 等. 航天器遥测数据异常检测综述[J]. 仪器仪表学报, 2016, 37(9):1929-1945  
Peng Xiyuan, Pang Jingyue, Peng Yu, et al. Review on Anomaly Detection of Spacecraft Telemetry Data[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1929-1945 (in Chinese)
- [2] 张栋, 胡绍林, 于宁莉, 等. 航天器下行数据异变检测算法研究[J]. 飞行器测控学报, 2013, 32(2):123-126  
Zhang Dong, Hu Shaolin, Yu Ningli, et al. Anomaly Data Detection Algorithm for Telemetry of Spacecraft[J]. Journal of Spacecraft TT & C Technology, 2013, 32(2):123-126 (in Chinese)
- [3] 李维铮, 孟桥. 基于遥测数据动态特征的卫星异常检测方法[J]. 空间科学学报, 2014, 34(2):201-207  
Li Weizheng, Meng Qiao. Fault Detection for In-Orbit Satellites Using an Adaptive Prediction Model[J]. Chinese Journal of Space Science, 2014, 34(2):201-207 (in Chinese)
- [4] Fekih A. Fault Diagnosis and Fault Tolerant Control Design for Aerospace Systems: a Bibliographical Review[C] // American Control Conference, 2014: 1286-1291
- [5] Dragomiretskiy K, Zosso D. Variational Mode Decomposition[J]. IEEE Trans on Signal Processing, 2014, 62(3):531-544
- [6] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊C均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13):3358-3365  
Liu Changliang, Wu Yingjie, Zhen Chenggang. Rolling Bearing Fault Diagnosis Based on Variational Mode Decomposition and Fuzzy C Means Clustering[J]. Proceedings of the CSEE, 2015, 35(13): 3358-3365 (in Chinese)
- [7] 马增强, 李亚超, 刘政, 等. 基于变分模态分解和Teager能量算子的滚动轴承故障特征提取[J]. 振动与冲击, 2016, 35(13):134-139  
Ma Zengqiang, Li Yachao, Liu Zheng, et al. Rolling Bearings' fault Feature Extraction Based on Variational Mode Decomposition and Teager Energy Operator[J]. 2016, 35(13):134-139 (in Chinese)

- [8] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5):73-81  
Tang Guiji, Wang Xiaolong. Parameter Optimized Variational Mode Decomposition Method with Application to Incipient Fault Diagnosis of Rolling Bearing[J], Journal of Xi'an Jiaotong University, 2015, 49(5):73-81 (in Chinese)
- [9] Lerga J, Saulig N, Mozetič V. Algorithm Based on the Short-Term Rényi Entropy and IF Estimation for Noisy EEG Signals Analysis[J]. Computers in Biology & Medicine, 2017, 80:1-13
- [10] Boškoski P, Gašperin M, Petelin D, et al. Bearing Fault Prognostics Using Rényi Entropy Based Features and Gaussian Process Models[J]. Mechanical Systems & Signal Processing, 2015: 327-337
- [11] Singh J, Darpe A K, Singh S P. Bearing Damage Assessment Using Jensen-Rényi Divergence Based on EEMD[J]. Mechanical Systems & Signal Processing, 2017, 87:307-339
- [12] 刘妹. 数学形态学在信号处理方面的应用研究[D]. 大连:大连理工大学, 2006  
Liu Shu. Applying the Mathematical Morphology in Signal Processing[D]. Dalian, Dalian University of Technology, 2006
- [13] Sunoj S M, Linu M N. Dynamic Cumulative Residual Renyi's Entropy[J]. Statistics, 2012, 46(1):41-56
- [14] Lee Y K, Park B U. Estimation of Kullback-Leibler Divergence by Local Likelihood[J]. Annals of the Institute of Statistical Mathematics, 2006, 58(2):327-340

## Spacecraft Anomaly Recognition Based on Morphological Variational Mode Decomposition and JRD

Jiang Haixu<sup>1,2</sup>, Zhang Ke<sup>1,2</sup>, Wang Jingyu<sup>1,2</sup>, Lü Meibo<sup>1,2</sup>

(1.School of Astronautics, Northwestern Polytechnical University, Xi'an 710072, China;  
2.National Key Laboratory of Aerospace Flight Dynamics, Northwestern Polytechnical University, Xi'an 710072, China)

**Abstract:** Considering the difficulty in identifying the in-orbital spacecraft weak anomaly, a spacecraft anomaly state recognition method based on Morphological variational mode decomposition and JRD distance is proposed. First of all, the telemetry data of the spacecraft is decomposed into multi-scale modal functions with different frequencies via morphological variational modal decomposition. Then the Rényi entropy of each modal function is extracted, which is regarded as the feature of telemetry data. Finally, the recognition of spacecraft anomaly state is realized by comparing the JRD distance between the sample data and the measured data. The proposed method is verified by means of the telemetry data of the weak anomaly speed of a satellite reaction wheel. The simulation results demonstrate that the proposed method can effectively identify the anomaly of the spacecraft and has obvious advantage in recognition speed.

**Keywords:** M-VMD; Rényi entropy; Jensen-Rényi divergence; anomaly recognition