

VMD 多尺度熵用于高速列车横向减振器故障诊断^{*}

苟先太, 李昌喜, 金炜东

(西南交通大学电气工程学院 成都, 610031)

摘要 针对高速列车横向减振器故障振动信号具有非线性和非平稳特征、特征信号提取相对困难问题, 提出了变分模态分解和多尺度熵结合的特征提取方法。原始信号经变分模态分解方法处理后, 被分解为若干本征模态, 利用互信息指标筛选有效模态, 求多尺度熵组成特征向量, 通过特征评价方法去除冗余特征, 最终将最优特征子集输入支持向量机识别横向减振器的故障类型。实验结果表明, 该方法能有效提取振动信号的特征, 实现横向减振器故障的有效判别, 验证了该方法在高速列车横向减振器故障诊断的可行性。

关键词 变分模态分解; 多尺度熵; 高速列车横向减振器; 故障诊断

中图分类号 TP206⁺.3; TH707

引 言

高速列车横向减振器属于典型的非线性复杂系统, 列车运行时产生的振动信号具有明显的非线性、非平稳特征, 故障诊断时采用传统的信号处理方法很难提取到故障的有效特征^[1]。针对该问题, 不少学者进行了研究。文献[2]提出了基于聚合经验模态分解(ensemble empirical mode decomposition, 简称 EEMD)排列熵的特征分析方法, 能有效解决模态混叠和端点效应。文献[3]提出了一种基于 Copula 函数的特征提取方法, 将信号进行 EEMD 分解, 对本征模态函数(intrinsic mode functions, 简称 IMFs)使用 Gaussian Copula 函数构建它们的联合概率密度函数, 提取边缘分布的 Kullback - Leibler Distance 值, 联合概率密度函数的均值和方差作为特征。EEMD 是在经验模态分解(empirical mode decomposition, 简称 EMD)基础上的改进算法, 能有效抑制模态混叠现象, 但算法效率低。文献[4]提出的变分模态分解(variational mode decomposition, 简称 VMD)可以自适应地将振动信号分解成一系列有限带宽的模态函数集合, 实现了各信号分量频率的分离, 克服了 EMD 存在的模态混叠和数学理论缺乏等问题, 并且算法效率高。

熵是一种度量时间序列复杂性的方法。从近似熵(approximate entropy, 简称 ApEn)^[5]到样本熵(sample entropy, 简称 SpEn)^[6]都是度量序列复杂度的方法。ApEn 是将数据与其本身进行比较, 由于熵测度的是新信息产生率, 所以与其自身比较毫无意义。SpEn 是改进的复杂性测度方法, 具有较好鲁棒性, 由于其测度信号单一尺度的复杂度, 所以不能充分表征信号在不同尺度上的复杂程度^[7]。文献[8]提出了多尺度熵(multiscale entropy, 简称 MSE)分析方法, 即在多尺度上挖掘信号的 SpEn, 既可以从总体上量化序列的复杂度, 又可以从多个尺度上提取有效特征, 从不同角度准确识别信号。以 MSE 作为特征的提取方法常被应用到故障诊断及医学信号识别等领域。文献[9]提出了结合局部均值分解和 MSE 的特征提取方法, 首先对原始振动信号进行改进的局部均值分解, 然后利用 MSE 对分解结果进行量化, 构成特征向量进行识别。文献[10]提出一种基于 EMD 的 MSE 的脑电信号瞬态特征提取方法, 分类效果良好。

针对高速列车横向减振器故障振动信号的特点, 笔者结合 VMD 和 MSE 的优点, 用于高速列车横向减振器故障振动信号的特征提取, 即 VMD-MSE。实验结果表明, 该方法可有效提取故障特征信息, 实现故障类型的准确判断。

^{*} 国家自然科学基金重点资助项目(61134022); 国家自然科学基金资助项目(61075104); 四川省科技计划项目-四川省重点研发项目(2017GZ0159); 四川省科技计划资助项目; 四川省重大科技专项资助项目(18ZDZX0132)
收稿日期: 2017-04-30; 修回日期: 2017-06-20

1 变分模态分解

VMD 可以非递归地将振动信号分解成一系列有限带宽的固有模态函数,从而能够自适应地实现信号频域的有效分离。

1.1 变分问题的构造

VMD 将一个原始信号 f 分解成 k 个模态函数 $u_k(t)$, 每一个模态函数具有中心频率 ω_k 。VMD 可以表述为求解 k 个模态函数,使所有模态函数的带宽总和最小,约束条件是所有模态函数和等于原始信号 f

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\}^2 \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (1)$$

具体步骤如下:

- 1) 通过对原始信号 f 的每个模态函数 $e^{-j\omega_k t}$ 进行 Hilbert 变换,得到其单边频谱;
- 2) 对各模态函数 $e^{-j\omega_k t}$ 混合预估中心频率 $e^{-j\omega_k t}$, 并将每个模态函数的频谱调制到相应的基带;
- 3) 求解解调信号梯度的平方 L^2 范数,估计出每个模态函数的带宽。

1.2 变分问题的求解

通过引入拉格朗日乘子 $\lambda(t)$ 和二次惩罚因子 α , 将约束变分问题变为非约束变分问题。其中 α 保证信号在高斯噪声存在情况下的重构精度, $\lambda(t)$ 使得变分问题的求解保持严格的约束性。延伸后的拉格朗日表达式如下

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) := & \alpha \sum_k \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} + \\ & f(t) - \sum_k u_k(t) \end{aligned} \quad (2)$$

采用乘法算子交替方向求解式(2),通过交替更新 u_k^{n+1} , ω_k^{n+1} 和 λ_k^{n+1} 寻求延伸拉格朗日的“鞍点”。 u_k^{n+1} , ω_k^{n+1} 和 λ_k^{n+1} 更新为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (5)$$

其中: $\hat{u}_k^{n+1}(\omega)$ 相当于当前剩余量 $\hat{f}(\omega) - \sum \hat{u}_i(\omega)$ 的维纳滤波; ω_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,其实部则为 $\{u_k(t)\}$ 。

具体流程如图 1 所示。VMD 算法的求解过程中,各模态分量不断更新其中心频率及带宽,最终可根据原始信号的频域特性完成频带的剖析,实现信号的自适应分解。

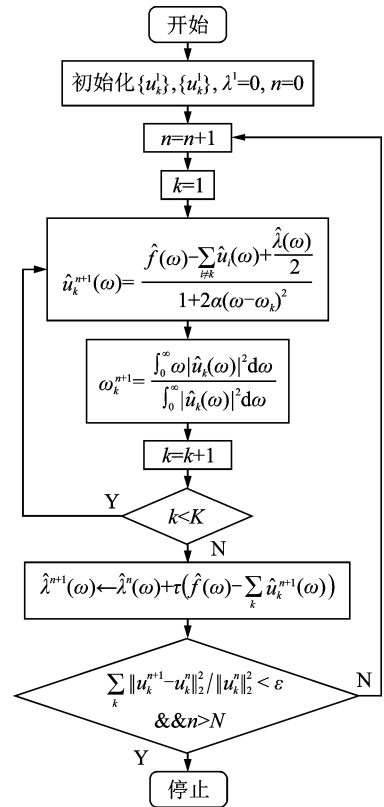


图 1 VMD 流程图

Fig.1 Flowchart of VMD

2 故障诊断流程

高速列车横向减振器故障振动信号是典型的非线性、非平稳信号,故障特征主要体现在低频部分^[11]。首先,采用小波包方法对原始振动信号处理;其次,用 VMD 方法分解得到具有特定物理含义的 IMFs,以 MSE 方法对得到的 IMFs 进行定量描述,形成特征向量;最后利用一种基于 Murphy 改进的 D-S 方法作为融合规则的多准则特征评价方法对特征向量进行综合评价,去除冗余特征^[12],利用分类器实现高速列车横向减振器故障类型的识别。图 2 为高速列车横向减振器故障诊断具体实现步骤。




图 2 故障诊断步骤图

Fig. 2 Graphic of the steps of fault diagnosis

3 高速列车横向减振器故障诊断

3.1 实验数据

实验数据是由西南交通大学牵引动力国家重点实验室提出的基于多体动力学软件 Simpack 建立的某动车组车辆系统非线性动力学模型仿真得到。模型结构如图 3 所示。其中:①表示构架 1 右侧上抗蛇行减振器;②表示构架 1 右侧下抗蛇行减振器;③表示构架 1 右侧横向减振器;④表示构架 1 空气弹簧;⑤表示构架 2 左侧横向减振器;⑥表示构架 2 左侧上抗蛇行减振器;⑦表示构架 2 左侧下抗蛇行减振器。横向减振器 7 种故障工况如表 1 所示。实验数据是在 220 km/h 下运行约 3.5 min 得到,采样频率为 243 Hz。仿真实验的振动信号主要包括车体、一系、二系、构架、轮对各部位横向、纵向和垂向的振动位移和车体、构架、轴箱上各个部位三个方向的振动加速度,共 58 个通道数据。




图 3 模型结构图

Fig. 3 Structure diagram of the model

图 4 为构架 1 架 1 位横向加速度振动信号 7 种工况部分数据时域和频谱图。由图 4 可以看出,故障状态振动信号时域图和频谱与原车有明显的区

表 1 7 种工况编号

Tab. 1 Number of seven working condition

编号	工况类型
1	原车
2	构架 1 左横向减振器失效
3	构架 1 右横向减振器失效
4	构架 2 左横向减振器失效
5	构架 2 右横向减振器失效
6	构架 1 左、2 右横向减振器同时失效
7	构架 1 横向减振器全部失效

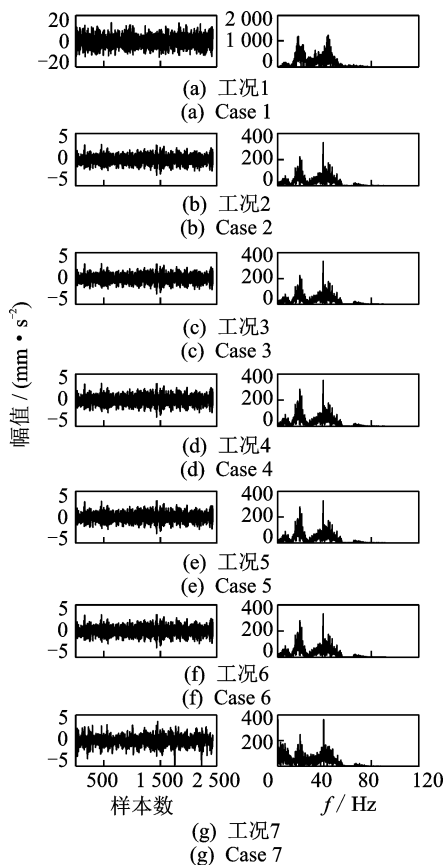


图 4 7 种工况的时域信号和频谱图

Fig. 4 Time-domain signal and spectrum graphics of seven working condition

别,但不同故障状态的振动信号时域图和频谱相似,无法识别。

3.2 振动信号的变分模态分解

对信号进行 VMD 分解,首先要确定分解层数 K 。 K 取值过小时, VMD 分解会出现模态混叠或者模态丢失的现象;反之分解结果出现残余分量。文中采用观察模态频谱图的方法确定 K 。选用构架 2 架 8 位横向加速度信号进行 VMD 分解,信号采样频率 243 Hz,选取 486 个数据点作为 1 个样本。图 5(a~c)为振动信号在不同 K 值下 VMD 的分解结

其中平衡约束参数 $\alpha = 30$, $\tau = 0$ 以保证实际信号的保真度。

从图 5(a~c)中可以看出, $K = 8$ 时 IMF_8 的频谱中存在不同尺度信息, 模态分解不充分; $K = 10$ 时 IMF_7 和 IMF_8 两个模态的频谱几乎重合, 存在多余的模态分量。因此, 选取 $K = 9$ 。为了验证本方法的优势, 利用 EMD 和 EEMD 方法对上述仿真信号进行处理, 以作对比。分解结果如图 6 所示。从图 6(a)中可以看出, EMD 处理后信号存在严重的模态混叠, 而图 6(b)中 EEMD 处理后的 IMF_{3-7} 分解充分, 而包含相对高频段信息的 IMF_1 和 IMF_2 存在模态混叠。

为了说明本方法的计算效率, 采用不同方法对同一工况的同一通道数据所有样本进行分解, 需要的时间如表 2 所示。EMD 方法效率最高, VMD 次之, EEMD 方法的效率最低。理论上, 每个 IMF 都

是一个平稳信号, 代表原信号中的特征成分之一。由于受参数选取等因素影响, 分解结果中不可避免地存在虚假成分。文献[13]提出了基于互信息的 HHT 虚假分量识别方法, 研究结果表明, 与相关系数法相比, 互信息法能更好的识别虚假分量。同时通过各方法分解出的 IMF 数来确定有效 IMF 数, 因此文中采用互信息法选取 VMD 和 EEMD 方法的前 4 个有效 IMF, EMD 方法的前 3 个有效 IMF。

表 2 不同方法的分解效率

Tab. 2 Decomposition efficiency of different methods			
方法	EMD	EEMD	VMD
t/s	7.708 8	2 597.7	1 148.5

3.3 多尺度熵特征提取

在 MSE 的计算中, 参数的选择会影响计算结

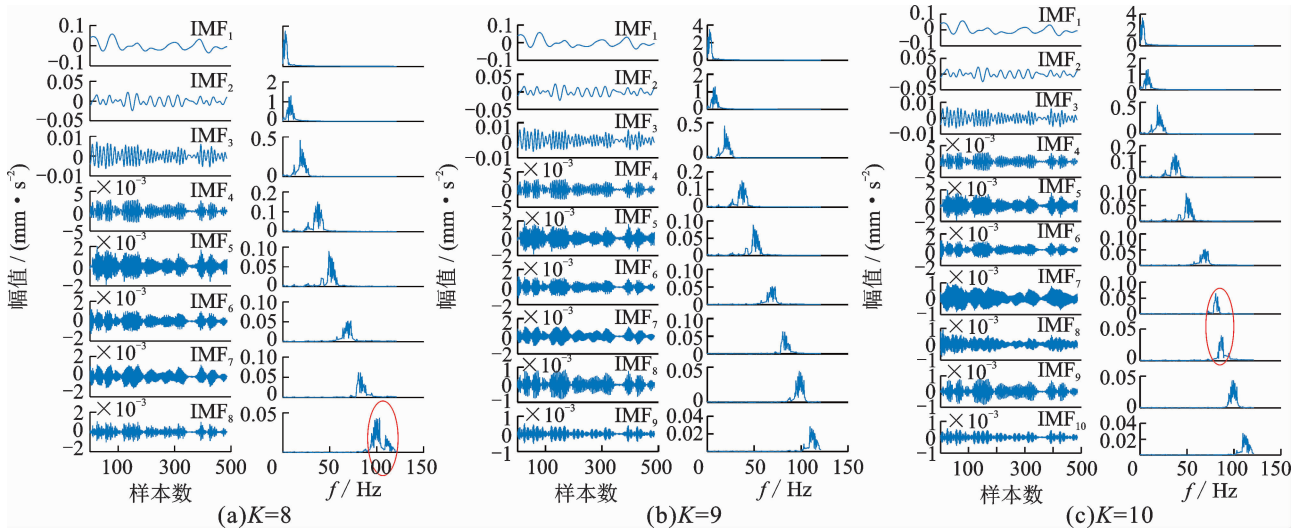


图 5 不同 K 值 VMD 处理结果

Fig. 5 Processing results by VMD under different K




图 6 基于 EMD 和 EEMD 的振动信号处理结果

Fig. 6 Processing results of vibration signal by EMD and EEMD

果。其相似容限 r 取值一般与原始序列的标准差相关(一般取 $r = 0.1 - 0.25SD$, SD 为原始序列标准差),因此反映的是原始序列在不同尺度上的复杂度。此外对于嵌入维数 m ,研究表明当 $m = 2$ 时,计算结果的准确性与序列的长度 N 依赖性最小。尺度因子 $\tau = \tau_{max}$ 。

实验中每种工况数据是在 200 km/h 运行 210 s 得到,采样频率为 243 Hz。截取 486 个采样点作为 1 个样本,除去异常点,每种工况 90 个样本。由于列车运动状态需要多个自由度表示且多通道数据具有较强的相关性,所以在特征提取时对 7~18 通道采用串联的方式进行数据融合,则有

$$F(x_i) = [f_1(c_7), f_2(c_7), \dots, f_n(c_7), f_1(c_j), f_2(c_j), \dots, f_n(c_j), \dots, f_1(c_{18}), f_2(c_{18}), \dots, f_n(c_{18})] \quad (1 \leq i \leq 90, 7 \leq j \leq 18) \quad (6)$$

其中: x_i 为第 i 样本; c_j 为第 j 通道; n 为有效模态数; $f_n(c_j) = \text{MSE}_{\text{IMF}_n}$ 为通道 j 数据模态分解后第 n 个有效模态的多尺度熵; $F(x_i)$ 为 x_i 的多尺度熵。

可知,VMD 和 EEMD 方法得到的特征为 $90 * (12 * 4)$ 的矩阵,EMD 方法得到的特征为 $90 * (12 * 3)$ 矩阵。

3.4 特征约简和支持向量机故障识别

通过 VMD-MSE 方法得到特征向量,采用文献 [12] 的特征评价方法进行特征评价,最后得到一个特征排序列表。根据每一维特征量的重要性对该表依次去掉冗余特征,得到若干个嵌套的特征子集 $F_1 \subset F_2 \subset \dots \subset F$ 来训练 SVM,并以 SVM 的预测准确率评估特征子集的优劣,从而获得最优特征子集。7 种工况各 90 个样本集经归一化后,随机选取 50 个作为训练样本,40 个样本作为测试样本。支持向量机故障识别时,输入的特征维数大于等于 3,图 7 为不同方法的不同特征子集的分类精度。

从图 7 中可以看出,基于 VMD-MSE 方法得到的特征向量的故障识别率高于基于 EMD-MSE 和 EEMD-MSE 方法得到的特征向量的识别率,并且在特征子集维数达到 6 后趋于稳定。EMD-MSE 和 EEMD-MSE 方法的特征向量的准确率都有巨大波动,验证了 VMD-MSE 方法在特征提取时的优越性。另外,EMD 方法的最优特征子集维数是 28, EEMD 方法的最优特征子集维数是 32, VMD 方法的最优特征子集维数是 36。

表 3~5 为各方法最优特征子集准确率的混淆矩阵。由表 3~5 可知,在针对高速列车横向减振器故障信号的特征提取中,VMD-MSE 方法比 EMD-

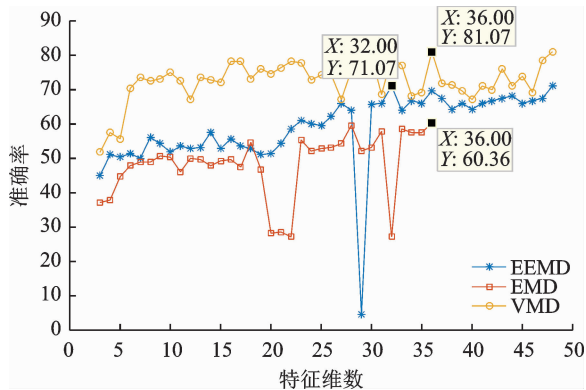


图 7 不同特征子集故障识别率

Fig. 7 Fault recognition rate of different feature subsets

MSE 方法具有更好的识别效果。EEMD 和 VMD 对原车状态和多个横向减振器失效工况的识别率最高可达 100%,对于多个横向减振器失效工况的故障检测具有很高的可行性,但对单个横向减振器失效的故障识别率较低。这是因为同一架构上的两个横向减振器安装位置比较接近,任何一个失效对于列车振动的影响差异不大,导致难以区分同一架构上的横向减振器失效的具体位置。如果将同一架构上的两个横向减振器归为一类,则故障识别率大大提高。这也间接说明多个横向减振器失效对车体的

表 3 EMD-MSE 特征提取方法识别结果

Tab. 3 Identification of feature extraction Method by EMD-MSE

类型	预 测 工 况							
	工况	1	2	3	4	5	6	7
实际 工况	1	39	1	0	0	0	0	0
	2	0	21	8	2	4	4	1
	3	0	20	8	2	6	3	1
	4	1	4	0	12	19	3	1
	5	0	4	0	3	28	4	1
	6	0	9	0	1	7	23	0
	7	0	0	0	0	2	0	38

表 4 EEMD-MSE 特征提取方法的识别结果

Tab. 4 Identification of feature extraction Method by EEMD-MSE

类型	预 测 工 况							
	工况	1	2	3	4	5	6	7
实际 工况	1	40	0	0	0	0	0	0
	2	0	28	9	0	2	1	0
	3	0	21	16	1	0	2	0
	4	0	0	0	20	20	0	0
	5	0	1	1	16	22	0	0
	6	0	1	2	2	2	33	0
	7	0	0	0	0	0	0	40

表 5 VMD-MSE 特征提取方法的识别结果

Tab. 5 Identification of feature extraction Method by VMD-MSE

类型	预 测 工 况							
	工况	1	2	3	4	5	6	7
实际 工况	1	40	0	0	0	0	0	0
	2	0	29	8	1	2	0	0
	3	0	6	33	0	1	0	0
	4	0	1	1	28	7	3	0
	5	0	1	0	17	20	2	0
	6	0	0	0	2	1	37	0
	7	0	0	0	0	0	0	40

影响大于单个横向减振器失效对车体的影响。

4 结束语

笔者把 VMD 和 MSE 相结合的特征提取方法应用于高速列车横向减振器的故障诊断,实验结果表明,该方法得到的特征向量可以有效识别故障类型。基于 VMD-MSE 的特征提取方法得到的特征向量相比其他两种方法有较好的分类结果,而且相对稳定。同时该方法的计算效率高。基于离线数据的高速列车横向减振器故障诊断是对高速列车安全状态实时监测的预演,对后期实时在线分析与评估具有重要意义。

参 考 文 献

[1] 王小亮,李立,张卫华. 高速列车垂向振动的模拟器再现方法研究[J]. 振动、测试与诊断, 2009, 29(1): 101-104.
Wang Xiaoliang, Li Li, Zhang Weihua. Fuzzy self-tuning based washout algorithm for simulator of high-speed locomotive vertical vibration [J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(1): 101-104. (in Chinese)

[2] 秦娜,蒋鹏,孙永奎,等. 基于 EEMD 排列熵的高速列车转向架故障特征分析[J]. 振动、测试与诊断, 2015, 35(5):885-891.
Qin Na, Jiang Peng, Sun Yongkui, et al. Fault diagnosis of high speed train bogie based on EEMD and permutation entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(5):885-891. (in Chinese)

[3] 金炜东,吕乾勇,孙永奎. 基于 Copula 函数的高速列车转向架故障特征提取[J]. 西南交通大学学报, 2015, 50(4):676-682.
Jin Weidong, Lu Qiangyong, Sun Yongkui. Extracting fault features of high speed train bogies using copula function [J]. Journal of Southwest Jiao Tong University, 2015, 50(4):676-682. (in Chinese)

[4] Dragomiretskity K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.

[5] Pincus S M. Approximate entropy as a measure of system complexity [J]. Proceedings of the National Academy of Sciences of the United States of America, 1991, 88(6):2297-2301.

[6] Richman J S, Moorman J R. Physiological time-series analysis using approximate entropy and sample entropy [J]. American Journal of Physiology Heart & Circulatory Physiology, 2000, 278(6):H2039-H2049.

[7] 郑近德,程军圣,胡思宇. 多尺度熵在转子故障诊断中的应用[J]. 振动、测试与诊断, 2013, 33(2):294-297.
Zheng Jinde, Cheng Junsheng, Hu Siyu. Rotor fault diagnosis based on m-ultiscale entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(2): 294-297. (in Chinese)

[8] Costa M, Goldberger A L, Peng C K. Multiscale entropy to distinguish physiologic and synthetic RR time series [J]. Computers in Cardiology, 2002, 29:137-140.

[9] 杨松山,周灏,赵海洋,等. 基于 LMD 多尺度熵与 SVM 的往复压缩机轴承故障诊断方法[J]. 机械传动, 2015, 39(2):119-123.
Yang Songshan, Zhou Hao, Zhao Haiyang, et al. Fault diagnosis method for the bearing of reciprocating compressor based on LMD multiscale entropy and SVM [J]. Journal of Mechanical, 2015, 39(2):119-123. (in Chinese)

[10] 谢平,陈晓玲,苏玉萍,等. 基于 EMD 多尺度熵和 ELM 的运动想象脑电特征提取和模式识别[J]. 中国生物医学工程学报, 2013, 32(6): 641-648.
Xie Ping, Chen Xiaoling, Su Yuping, et al. Feature extraction and recognition of motor imagery EEG based on EMD multiscale entropy and extreme learning machine [J]. Chinese Journal of Biomedical Engineering, 2013, 32(6):641-648. (in Chinese)

[11] 李智敏,苟先太,秦娜,等. 高速列车振动监测信号的频率特征[J]. 仪表技术与传感器, 2015(5):99-103.
Li Zhimin, Gou Xiantai, Qin Na, et al. Vibration monitoring signals frequency feature of high-speed train [J]. Journal of Instrument Technique and Sensor, 2015 (5):99-103. (in Chinese)

[12] 杜静,蔡震震,蒋鹏,等. 一种新的特征评价方法及在高铁故障中的应用[J]. 电子技术应用, 2015, 41(9):153-156.
Du Jing, Cai Zhenzhen, Jiang Peng, et al. A new feature evaluation algorithm and its application in fault of high-speed railway [J]. Journal of Computer Technology and Its Applications, 2015, 41(9):153-156. (in Chinese)

[13] 胡爱军. Hilbert-Huang 变换在旋转机械振动信号分析中的应用研究[D]. 保定:华北电力大学, 2008.



第一作者简介:苟先太,男,1971 年 5 月生,博士、副教授。主要研究方向为信号处理、智能信息处理及网络通信。曾发表《Adaptive picking of microseismic event arrival using a power spectrum envelope》(《Elsevier》2011, Vol. 37, No. 6)等论文。
E-mail:gouxiantai@sohu.com