

全矢 IMF 信息熵用于高速列车转向架故障诊断*

李亚兰, 金炜东

(西南交通大学电气工程学院 成都, 611756)

摘要 针对高速列车转向架振动信号具有非线性、非平稳的特征,以及单通道故障诊断带来的信息不完整问题,提出了一种多元经验模态分解(multivariate empirical mode decomposition,简称MEMD)和全矢本征模态函数(intrinsic mode function,简称IMF)信息熵相结合的高速列车故障特征提取方法。首先,使用MEMD方法对同源双通道的振动信号进行分解,得到一系列的2元本征模态函数;其次,分别计算前6个IMF的全矢IMF信息熵,通过特征评价方法进行特征维数约简;最后,将得到的特征向量作为支持向量机的输入来识别转向架的故障类型。实验结果表明,该方法能有效提高转向架的故障识别率,最高可达到100%,验证了全矢IMF信息熵在高速列车故障诊断中的可行性。

关键词 高速列车转向架;多元经验模态分解;本征模态函数;全矢IMF信息熵;特征评价;支持向量机

中图分类号 TH165+.3; TP206+.3

引言

高速列车转向架作为列车的核心结构,其一旦发生故障会造成车体振动加剧,严重时会引起脱轨翻车等安全事故^[1]。目前,安装在高速列车各个位置的传感器能采集到列车在运行过程中的振动信号数据,通过提取这些海量数据的特征从而达到对高速列车进行故障诊断的目的。由于高速列车转向架振动信号具有非线性、非平稳的特征,因此采用传统的信号分析方法难以准确地提取出故障特征^[2]。文献[3]提出了基于聚合经验模态分解(ensemble empirical mode decomposition,简称EEMD)和5种信息熵相结合的特征提取方法,EEMD方法能有效缓解模态混叠现象^[4-5],但在对多通道信号进行分解的时候会存在不能获得个数相同的IMF分量的问题。文献[6]提出了分割能量熵和奇异熵的故障诊断方法,都将信息熵用于转向架的故障特征提取。上述方法都存在仅采用单通道信号进行处理,不能完整反映出列车振动信号信息的问题。

韩捷等^[7]提出的全矢谱算法为单通道故障诊断带来的信息不完整问题提供了解决方法,现有的信息熵特征提取方法用于高速列车故障诊断多是基于单通道的,忽略了同源两个传感器采集到的信号之间的联系,而全矢谱算法可以融合同源双通道信号

的信息,更加完备地反映出设备的状态。文献[8]提出了基于全矢排列熵的齿轮故障特征提取方法,验证了全矢谱算法结合信息熵特征提取在故障诊断中的有效性。Rehman等^[9]提出的MEMD算法可以对多通道信号进行处理,不仅从很大程度上改善了模态混叠问题,还可以得到相同个数的IMF分量,且各IMF分量是按频率尺度对齐的。Mandic团队将MEMD应用到EEG^[10]、超声波^[11]、多普勒雷达^[12]等多通道信号的处理分析上,取得了较好的效果。文献[13]利用MEMD方法对管道阻塞声信号进行分解,与IMF分量的能量占比特征提取方法相结合,可以对管道的运行状态和阻塞程度进行识别。

针对高速列车转向架故障振动信号的特点,笔者结合全矢谱算法和MEMD算法的优点,提出了一种多元经验模态分解和全矢IMF信息熵相结合的高速列车转向架故障特征提取方法。使用MEMD方法对同源双通道的振动信号进行分解,得到一系列的2元本征模态函数,分别计算前6个IMF的全矢IMF信息熵,通过特征评价方法进行特征维数约简。将得到的特征向量作为支持向量机的输入来识别转向架的故障类型。实验结果验证了MEMD全矢IMF信息熵在高速列车故障诊断中的可行性。

* 国家自然科学基金重点资助项目(61134002)

收稿日期:2019-10-09;修回日期:2019-12-20

1 MEMD方法

考虑到高速列车振动信号数据是多元数据,而传统的经验模态分解(empirical mode decomposition,简称EMD)方法不能同时对多通道信号进行分解,且各通道分解得到的IMF分量个数也不一致,因此采用MEMD方法。MEMD方法可将多个通道信号联合在一起进行分析,保证了各通道分解出来的IMF分量在个数和频率上相匹配,且可以有效缓解模态混叠问题^[14]。下面介绍MEMD算法流程^[15]。

设一个 n 维向量组为 $s(t)=[s_1(t), s_2(t), \dots, s_n(t)]^T$,设其方向向量集中第 l 个方向向量为 $D_l=[d'_1, d'_2, \dots, d'_n]$,则MEMD算法的具体步骤如下:

1) 确定方向向量集 D ,在 D_l 上计算 s 的第 l 个投影 $p^l(t)$,其中: $l=1, 2, \dots, L$; L 为方向向量的个数;确定 $p^l(t)$ 最大值所在的时刻 t'_m ;

2) 在 $[t'_m, s'_m]$ 点上使用多元样条插值函数内插获得多维包络线 $E^l(t)$;

3) 计算包络线的均值

$$v(t) = \frac{1}{L} \sum_{l=1}^L E^l(t) \quad (1)$$

4) 计算 $d(t)=s(t)-v(t)$,当 $d(t)$ 满足多元IMF的迭代终止条件时,就将 $d(t)$ 定义为IMF,并对 $s(t)-d(t)$ 重复步骤1~4,直到分解出下一阶IMF,否则就对 $d(t)$ 重复步骤1~4,直到满足终止条件。

多通道信号经MEMD分解后各通道分解得到的IMF层数是一样的,每层IMF之间的频率由高到低,各通道间相同层的IMF是根据频率尺度来对齐的,得到了一系列的多元IMF。

2 全矢IMF信息熵算法

2.1 IMF功率谱熵

设振动信号的IMF分量为 $IMF=\{imf_1, imf_2, \dots, imf_k\}$,对 imf_k 进行FFT变换得到

$IMF(\omega)$,则其功率谱为 $S(\omega) = \frac{1}{2\pi N} |IMF(\omega)|^2$,

定义IMF功率谱熵为 $H_f = -\sum_{i=1}^N p_i \log p_i$ 。其中: p_i 为第 i 个功率谱与 imf_k 总的功率谱的比值。

2.2 IMF奇异谱熵

设振动信号的IMF分量为 $IMF=\{imf_1, imf_2, \dots, imf_k\}$,将 imf_k 构成 $m \times n$ 维矩阵,其中: n 为 imf_k 的长度。将 X 矩阵按 $X_{m \times n} = IMF_{m \times l} D_{l \times l} V_{l \times n}$ 奇异值进行分解,定义IMF奇异谱熵为 $S_i = -\sum_{i=1}^N q_i \log q_i$,其中: q_i 为第 i 个奇异值与 D 矩阵的奇异值之和的比值。

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_n \end{bmatrix}$$

2.3 全矢IMF信息熵

通过全矢谱技术对同源双通道的振动信号经MEMD分解,得到的同尺度的IMF分量做信息融合处理获得相位不变、信息更完善的全矢IMF信号,再对全矢IMF信号做信息熵特征提取得到全矢IMF信息熵。具体步骤^[16]如下:

1) 设同源双通道的振动信号经MEMD分解后得到的IMF分量为 $\{imf_x\}$ 和 $\{imf_y\}$;

2) 对 $\{imf_x\}$ 和 $\{imf_y\}$ 做快速傅里叶变换,得到 $\{IMF_x\}$ 和 $\{IMF_y\}$,其实部为 IMF_{Rx}, IMF_{Ry} 和虚部为 IMF_{Ix}, IMF_{Iy} ;

3) 分别求 $\{IMF_x\}$ 和 $\{IMF_y\}$ 的振幅和相位

$$A_{IMF_x} = \sqrt{IMF_{Rx}^2 + IMF_{Ix}^2} \quad (2)$$

$$\phi_{IMF_x} = \arctan \frac{IMF_{Ix}}{IMF_{Rx}} \quad (3)$$

$$A_{IMF_y} = \sqrt{IMF_{Ry}^2 + IMF_{Iy}^2} \quad (4)$$

$$\phi_{IMF_y} = \arctan \frac{IMF_{Iy}}{IMF_{Ry}} \quad (5)$$

4) 将 $A = \sqrt{A_{IMF_x}^2 + A_{IMF_y}^2}$ 作为幅值,分别将 ϕ_{IMF_x} 和 ϕ_{IMF_y} 作为相位,得到 IMF_{xx} 和 IMF_{yy} 。对 IMF_{xx} 和 IMF_{yy} 进行傅里叶反变换,得到新的IMF序列 imf_{xx} 和 imf_{yy} 。

$$IMF_{xx} = A(\cos\phi_{IMF_x} + j\sin\phi_{IMF_x}) \quad (6)$$

$$IMF_{yy} = A(\cos\phi_{IMF_y} + j\sin\phi_{IMF_y}) \quad (7)$$

5) 对 imf_{xx} 和 imf_{yy} 分别做信息熵特征提取得到全矢IMF信息熵。

两组新的IMF分量得到的结果是融合了2个通道信息后的结果,相比于从单一通道得到的结果来说,全矢IMF信息熵能反映出更完善的信息。

3 全矢 IMF 信息熵实验

3.1 数据来源

实验数据来源于西南交通大学牵引动力国家重点实验室,由 SIMPACK 软件搭建的某动车组车辆系统非线性动力学模型仿真所得,仿真模型如图 1 所示。仿真数据记录了从安装在转向架上的 58 个传感器反馈到的各部位的振动信号,主要包括车体、构架各个部位横向、垂向和纵向振动加速度及振动位移。转向架上共包含 8 个抗蛇行减振器和 4 个横向减振器。抗蛇行减振器故障工况包括 8 个抗蛇行减振器单个失效的 8 种故障工况。横向减振器故障工况包括 4 个横向减振器单个失效以及任意两个同时失效的共 10 种故障工况。实验数据是在不同运行速度下得到的,采样频率为 243 Hz,采样时间为 3.5 min。

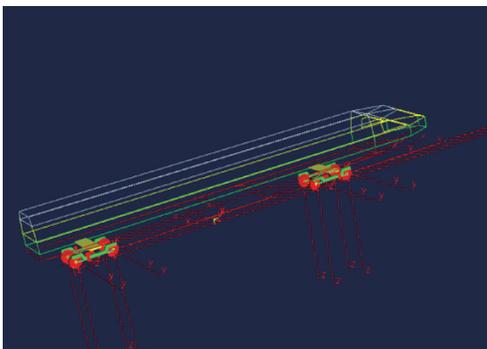


图1 仿真模型

Fig.1 Diagram of simulation model

3.2 基于全矢 IMF 信息熵的特征提取和分类

3.2.1 抗蛇行减振器故障工况

将列车在 200 km/h 速度下抗蛇行减振器 8 种故障工况数据进行 MEMD 分解,由于前 6 个 IMF 分量与原始信号的互相关系数较大,因此选取 $IMF_1 \sim IMF_6$ 这 6 个分量做后续特征提取对象。以 IMF 功率谱熵和 IMF 奇异谱熵为基础,8 种工况截取 48 600 个采样点,分为 100 组样本。分别计算所有样本的 IMF 功率谱熵、IMF 奇异谱熵、全矢 IMF 功率谱熵和全矢 IMF 奇异谱熵作为特征向量。图 2 为 8 种工况的 IMF 奇异谱熵和全矢 IMF 奇异谱熵的特征分布图。从图 2(a) 可以看出,通过 $IMF_1 \sim IMF_3$ 分量的 3 维 IMF 奇异谱熵特征值可以较好地地区分工况 1, 3, 4, 5。图 2(b) 为对应三维全矢 IMF 奇异谱熵特征值的空间分布图,图中工况 1, 3, 4, 5 是完全分开的;图 2(c), (d) 分别是 $IMF_4 \sim IMF_6$ 分

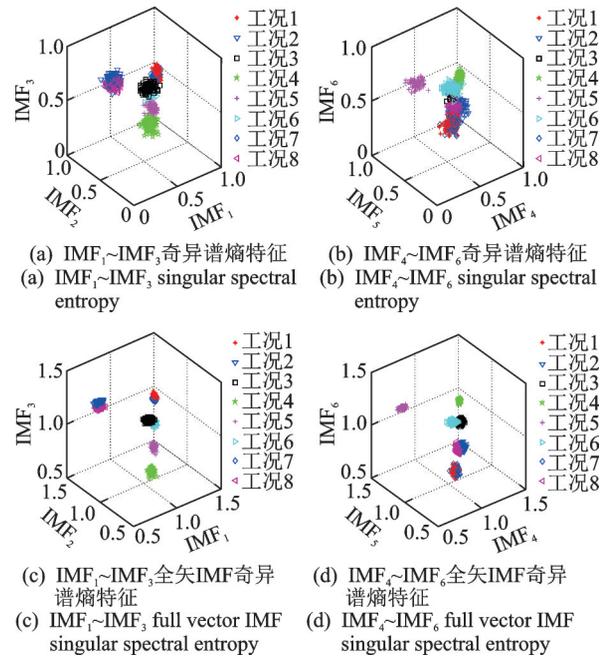


图2 两种特征的3维空间散点图

Fig.2 Scatter diagram of two features in 3-D space

量的 3 维 IMF 奇异谱熵和全矢 IMF 奇异谱熵特征值构成的特征空间分布图。从图 2(c) 中可以看出能较好地地区分工况 2, 6, 7, 8, 而图 2(d) 中的工况 2, 6, 7, 8 分开得更明显一些。因此,结合两张三维空间特征图就能很好地地区分这 8 种工况,说明 IMF 奇异谱熵特征对抗蛇行减振器故障工况的识别是有效的,同时全矢 IMF 奇异谱熵特征在三维空间中能看到更好的类内聚集性和类间分离性。

支持向量机 (support vector machine, 简称 SVM) 是 Vapnik^[17] 提出的针对有限的样本训练和分类的机器学习方法,是根据结构风险最小化的原则而提出的。实验分别提取 $IMF_1 \sim IMF_6$ 这 6 个分量的 IMF 功率谱熵、IMF 奇异谱熵、全矢 IMF 功率谱熵和全矢 IMF 奇异谱熵特征作为支持向量机的输入,每种工况有 100 组样本,其中 80% 用来训练,20% 用来测试。表 1 为抗蛇行减振器 8 种故障工况的正确识别率。

从表 1 的结果可以看出,基于 MEMD 和 IMF 功率谱熵的识别率最高可达到 86% 左右,且采用全矢 IMF 功率谱熵特征得到的结果均有所提高。基于 MEMD 和 IMF 奇异谱熵的识别率最高能达到 95% 左右,同样采用全矢 IMF 奇异谱熵特征提取后能进一步提高识别率。说明 IMF 功率谱熵和 IMF 奇异谱熵能有效识别抗蛇行减振器故障,但 IMF 奇异谱熵有更好的特征提取能力,采用本方法的识别率均有不同程度的提高。

表 1 抗蛇行减振器 8 种故障工况的正确识别率

Tab.1 Correct recognition rate of 8 kinds of fault conditions for anti-snake shock absorber

监测信号	IMF 功率谱熵	全矢 IMF 功率谱熵	IMF 奇异谱熵	全矢 IMF 奇异谱熵
车体加速度	81.250	82.500	82.500	89.375
构架 1 架加速度	86.250	88.750	95.625	98.750
构架 2 架加速度	83.125	86.250	86.875	90.625
车体位移	80.625	86.875	81.250	93.750
构架 1 架位移	81.250	81.875	81.250	91.250
构架 2 架位移	76.875	81.250	78.125	90.625

3.2.2 横向减振器故障工况

为了进一步验证本方法的有效性,实验将横向减振器 10 种故障工况下的 48 600 个采样点分为 100 组,分别提取 100 组样本的各 IMF 信息熵特征。图 3 是 10 种工况的全矢 IMF 奇异谱熵特征空间分布图,每张图中都有不同的工况特征值分得很开的情况,结合这两张三维特征空间图可以较好地地区分各工况。表 2 为 10 种工况在 200 km/h 速度下不同通道的正确识别率。

分析表 2 的结果可以得出,本方法对横向减振器故障识别同样有效,10 种工况的识别率最高可达到 97.500%,全矢 IMF 奇异熵特征提取在这里也体现出了优势,进一步说明了本方法用在高速列车转向架故障诊断中的可行性。该结果表明采用

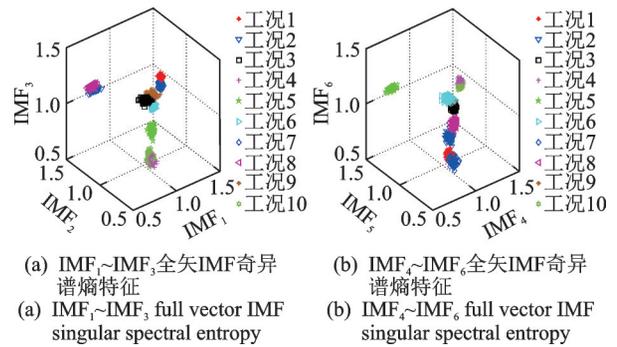


图 3 全矢 IMF 奇异谱熵特征的 3 维空间散点图

Fig.3 Scatter diagram of full vector IMF singular spectral entropy in 3-D feature space

MEMD 算法同源双通道信号进行分解,再结合全矢谱算法融合两通道的信息,能在转向架故障诊断中表现出良好的分类识别能力。

表 2 横向减振器 10 种故障工况的正确识别率

Tab.2 Correct recognition rate of 10 kinds of fault conditions for horizontal damper

监测信号	IMF 功率谱熵	全矢 IMF 功率谱熵	IMF 奇异谱熵	全矢 IMF 奇异谱熵
车体加速度	81.000	86.000	90.000	97.500
构架 1 架加速度	78.000	82.000	83.000	88.000
构架 2 架加速度	73.000	75.000	76.750	81.250
车体位移	80.000	85.500	92.500	93.000
构架 1 架位移	81.000	85.000	87.500	91.000
构架 2 架位移	80.500	89.500	91.500	95.500

3.2.3 不同速度下的全矢 IMF 信息熵特征

为了证明本方法在不同速度下的适用性,实验选择抗蛇行减振器 8 种单点故障工况,在列车运行速度为 160 km/h 时进行仿真。图 4 是 160 km/h 速度下抗蛇行减振器 8 种故障工况的奇异谱熵和全矢 IMF 奇异谱熵的前三维特征空间散点图,同上文的实验结果一样,通过前三维特征依然能对其中几种工况进行区分,且从图中可以看出采用全矢 IMF 信息熵算法在速度变化时提取到的特征仍然有更好的区分,验证了其在高速列车转向架故障诊断中的适用性。

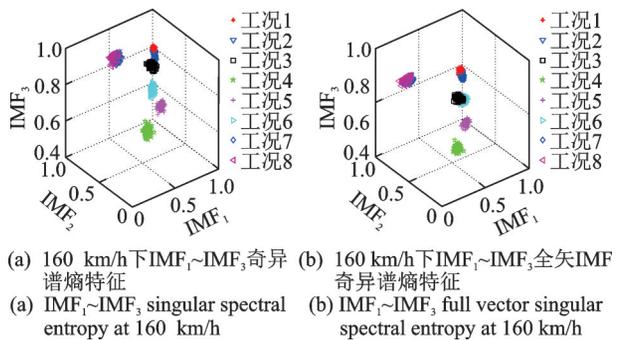


图 4 160 km/h 速度下两种特征的 3 维空间散点图

Fig.4 Scatter diagram of two features in 3-D space at 160 km/h

3.3 特征维数约简实验

为了结合 IMF 功率谱熵和 IMF 奇异谱熵的优点,现将 200 km/h 下的 24 维特征向量级联在一起作为支持向量机的输入进行分类识别。考虑到特征维数过大会冗余特征,这里采用 4 种单一特征评价准则^[18]进行特征维数约简,包括 Mahalanobis Distance (简称 MD), Fisher's ratio, Representation Entropy (简称 RE) 和 Fuzzy Entropy。表 3 和表 4 分别为抗蛇行减振器 8 种故障工况和横向减振器 10 种故障工况降维后的识别率。

分析表 3 和表 4 的结果可以得出,将所有特征进行级联构成的 24 维特征向量反而会使识别率降低,这是因为其中的冗余特征使得各工况之间的特征区分度降低。采用 4 种单一特征评价准则都能有效提高识别率,但是对比单独采用 6 维特征空间的情况,只有 MD 特征评价准则得到的识别率能高于任何一种 6 维特征空间的结果。这说明可以将 IMF 信息熵特征和全矢 IMF 信息熵特征进行级联,再结合 MD 特征评价准则进行特征维数约简,能对高速列车转向架故障进行高效率的识别。

表 3 抗蛇行减振器 8 种故障工况降维后的识别率

Tab.3 Correct recognition rate of 8 kinds of fault conditions for anti-snake shock absorber after dimension reduction %

监测信号	MD	Fisher's ratio	RE	Fuzzy Entropy	24 维特征空间
车体加速度	90.000	86.250	88.750	89.375	85.000
构架 1 架加速度	100.000	98.750	99.375	99.375	98.750
构架 2 架加速度	91.250	91.875	91.250	91.875	90.625
车体位移	95.625	91.250	92.500	93.750	92.500
构架 1 架位移	93.750	90.000	88.750	91.250	88.125
构架 2 架位移	91.875	87.500	90.000	89.375	87.500

表 4 横向减振器 10 种故障工况降维后的识别率

Tab.4 Correct recognition rate of 10 kinds of fault conditions for horizontal damper after dimension reduction %

监测信号	MD	Fisher's ratio	RE	Fuzzy Entropy	24 维特征空间
车体加速度	92.500	89.000	89.500	91.500	88.500
构架 1 架加速度	90.000	89.000	88.000	89.000	86.500
构架 2 架加速度	83.000	80.500	81.000	79.000	79.000
车体位移	95.000	94.000	93.500	94.500	92.000
构架 1 架位移	93.500	92.500	91.500	93.500	91.500
构架 2 架位移	97.000	96.000	96.000	96.000	96.000

4 结束语

笔者将 MEMD 算法和全矢 IMF 信息熵特征提取方法应用于高速列车转向架故障诊断。实验结果表明,该方法得到的全矢 IMF 信息熵特征能有效地识别出故障类型,将提取的所有特征进行级联后用 MD 方法降维,去除冗余特征,能进一步地提高故障诊断率。传统的单通道信号处理与特征提取方法存在信息不完整问题,本方法有效融合了多通道信号之间的关联性,在高速列车故障诊断上具有一定的实际意义。

参 考 文 献

- [1] 丁建明, 林建辉, 赵洁, 等. 车辆悬挂弹簧故障检测的能量传递特性比较法[J]. 交通运输工程学报, 2013, 13(4): 55-59.
DING Jianming, LIN Jianhui, ZHAO Jie, et al. Comparison method of energy transfer characteristics for fault detection of vehicle suspension spring[J]. Journal of Traffic and Transportation Engineering, 2013, 13(4): 55-59. (in Chinese)
- [2] 王小亮, 李立, 张卫华, 等. 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, et al. 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)
- [3] 秦娜,王开云,金炜东,等.高速列车转向架故障的经验模态熵特征分析[J].交通运输工程学报,2014(1): 57-64.
- QIN Na, WANG Kaiyun, JIN Weidong, et al. Fault feature analysis of high speed train bogie based on empirical mode decomposition entropy[J]. Journal of Traffic and Transportation Engineering, 2014(1): 57-64. (in Chinese)
- [4] LEI Y, HE Z, ZI Y. EEMD method and WNN for fault diagnosis of locomotive roller bearings[J]. Expert Systems with Applications, 2011, 38(6):7334-7341.
- [5] AN X, JIANG D, LI S, et al. Application of the ensemble empirical mode decomposition and Hilbert transform to pedestal looseness study of direct-drive wind turbine[J]. Energy, 2011, 36(9):5508-5520.
- [6] 朱明,吴思东,付克昌.基于熵特征的高速列车故障诊断方法[J].振动、测试与诊断,2015,35(2): 381-387.
- ZHU Ming, WU Sidong, FU Kechang. Characteristic analysis of high-speed train vibration based on entropy feature[J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(2):381-387. (in Chinese)
- [7] 韩捷,石来德.全矢谱技术及工程应用[M].北京:机械工业出版社,2008:100-136.
- [8] 郝旺身,王洪明,董辛旻,等.基于全矢排列熵的齿轮故障特征提取方法研究[J].振动与冲击,2016,35(11):224-228.
- HAO Wangshen, WANG Hongming, DONG Xinmin, et al. Gear fault extraction based on full vector permutation entropy[J]. Journal of Vibration and Shock, 2016, 35(11):224-228. (in Chinese)
- [9] REHMAN N, MANDIC D P. Multivariate empirical mode decomposition [J]. Proceedings of the Royal Society A, 2010, 466(2117):1291-1302.
- [10] PARK C, LOONEY D, UR REHMAN N, et al. Classification of Motor Imagery BCI using multivariate empirical mode decomposition[J]. IEEE Transactions on Neural Systems & Rehabilitation Engineering, 2013, 21(1):10-22.
- [11] MINSUNG K, DANILO P M, ANTHONY G C. Theory of digital filter banks realized via multivariate empirical mode decomposition [J]. Advances in Adaptive Data Analysis, 2014, 6(1): 1450001
- [12] MOSTAFANEZHAD I, YAVARI E, BORIC-LUBECKE O, et al. Cancellation of unwanted doppler radar sensor motion using multivariate empirical mode decomposition[J]. IEEE Sensors Journal, 2013, 13(5): 1897-1904.
- [13] 张浩,邹金慧,冯早.基于MEMD的管道阻塞声信号特征提取与识别方法[J].传感器与微系统,2017,36(12):57-60.
- ZHANG Hao, ZOU Jinhui, FENG Zao. Feature extraction and recognition method of pipeline blockage acoustic signal based on MEMD [J]. Transducer and Microsystem Technologies, 2017, 36(12): 57-60. (in Chinese)
- [14] 颜云华,吴志丹.基于MEMD的高速列车转向架故障的排列熵特征分析[J].电子技术应用,2016,42(5): 124-127.
- YAN Yunhua, WU Zhidan. Feature analysis of high-speed train bogie based on MEMD and permutation entropy [J]. Computer Technology and Its Applications, 2016, 42(5):124-127. (in Chinese)
- [15] ZHAO X M, PATEL T H, ZUO M J. Multivariate EMD and full spectrum based condition monitoring for rotating machinery[J]. Mechanical Systems and Signal Processing, 2012, 27: 712-728.
- [16] 王洪明,郝旺身,董辛旻,等.基于全信息样本熵的轴承故障诊断方法研究[J].煤矿机械,2015,36(6): 312-315.
- WANG Hongming, HAO Wangshen, DONG Xinmin, et al. Roller bearing fault diagnosis based on full information sample entropy [J]. Coal Mine Machinery, 2015, 36(6):312-315. (in Chinese)
- [17] VAPNIK V. The nature of statistical learning theory [M]. New York: Springer, 1995: 1-188.
- [18] 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 Jin, CAI Zhenzhen, JIANG Peng, et al. A new feature evaluation algorithm and its application in fault of high-speed railway[J]. Computer Technology and Its Applications, 2015, 41(9):153-156. (in Chinese)



第一作者简介:李亚兰,女,1995年4月生,硕士生。主要研究方向为模式识别与智能信息处理。

E-mail:liyalan_lyl@163.com