

# 部分集成局部特征尺度分解:一种新的基于 噪声辅助数据分析方法

郑近德,程军圣,杨 宇

(湖南大学汽车车身先进设计制造国家重点实验室,湖南长沙,410082)

**摘 要:** 局部特征尺度分解(Local Characteristic-Scale Decomposition, LCD)是最近提出的一种类似于经验模态分解(Empirical Mode Decomposition, EMD)的非平稳信号分析方法.为解决 LCD 方法的模态混淆问题,论文首先提出了基于噪声辅助分析的集成局部特征尺度分解方法(Ensemble LCD, ELCD).然而,ELCD 有类似于总体平均经验模态分解(Ensemble EMD, EEMD)和互补总体平均经验模态分解(Complementary, CEEMD)的固有缺陷,在此基础上,同时结合最近提出的随机性检测方法——排列熵(Permutation Entropy, PE),论文提出了部分集成局部特征尺度分解(Partly Ensemble LCD, PELCD)方法.仿真数据分析表明,论文提出的 PELCD 方法不仅能够有效地抑制 LCD 分解的模态混淆,而且在抑制伪分量的产生以及分量精确性等方面要优于 CEEMD 和 ELCD 方法.

**关键词:** 局部特征尺度分解;模态混淆;排列熵;部分集成局部特征尺度分解;总体平均经验模态分解

**中图分类号:** TN911.23      **文献标识码:** A      **文章编号:** 0372-2112 (2013)05-1030-06

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2013.05.033

## Partly Ensemble Local Characteristic-Scale Decomposition: A New Noise Assisted Data Analysis Method

ZHENG Jin-de CHENG Jun-sheng YANG Yu

(State key Laboratory of Advanced Design and Manufacture for Vehicle Body, Hunan University, Changsha, Hunan 410082, China)

**Abstract:** Local characteristic-scale decomposition (LCD) was a new non-stationary data analysis method, which was proposed recently and similar to empirical mode decomposition (EMD). In order to solve its mode mixing problem, firstly a noise-assisted data analysis method named ensemble local characteristic-scale decomposition (ELCD) is presented. However, since ELCD inherited the shortcomings of ensemble empirical mode decomposition (EEMD) and complementary ensemble empirical mode decomposition (CEEMD), in the same time, based on the new randomness detecting method-permutation entropy (PE), another method for restraining mode mixing called partly ensemble local characteristic-scale decomposition (PELCD) had been proposed in this paper. Lastly, the novel method was compared with the existing method (CEEMD) by analyzing simulation data and real data and the results indicate that the proposed method can restrain the phenomenon of mode mixing effectively and is superior to ELCD and other traditional noise-assisted method in aspects of inhibiting false components and improving the accuracy of components.

**Key words:** local characteristic-scale decomposition; mode mixing; permutation entropy; partly ensemble local characteristic-scale decomposition; ensemble empirical mode decomposition (EEMD)

## 1 引言

经验模态分解(EMD)是 HUANG N E 等提出的一种自适应的非平稳信号处理方法<sup>[1,2,3]</sup>, EMD 方法不需要事先选择基函数,而是依据数据本身进行自适应的分解. EMD 方法自提出后在很多领域得到了广泛的应用<sup>[3,4]</sup>. 然而, EMD 方法存在包络过冲和欠包络、端点效

应以及模态混淆等问题. 作为对 EMD 方法的改进, 作者在文献[5]中提出了另一种自适应时频分析方法—局部特征尺度分解(LCD), LCD 采用新的方法定义均值曲线, 不但减小了拟合误差, 提高了计算速度, 而且对模式混淆也有一定的抑制, 但是 LCD 仍存在模态混淆.

为了解决 LCD 的模态混淆问题, 借鉴 WU 和 HUANG 提出的集成经验模态分解(Ensemble Empirical

Mode Decomposition, EEMD)<sup>[7]</sup>, 和 YEH 提出的互补集成经验模态分解 (Complementary EEMD, CEEMD)<sup>[8]</sup> 等的思路, 即: 通过向待分析信号添加白噪声, 再利用白噪声的统计特征通过集成平均消除白噪声的误差影响, 从而达到抑制模态混淆的目的, 论文提出了集成局部特征尺度分解 (Ensemble Local Characteristic-Scale Decomposition, ELCD) 方法, 以期能够抑制 LCD 分解过程中的模态混淆. ELCD 借鉴 CEEMD 思路, 在添加一个正的白噪声的同时也添加一个负的白噪声, 减小了白噪声残留, 提高了分解的完备性.

然而研究发现, 机械地照搬 CEEMD 思路提出的 ELCD 效果并不理想, 因为 LCD 对噪声比 EMD 方法更敏感, 有更高的频率分辨能力, 这使得添加幅值相近的白噪声, LCD 分解结果却有较大差异, 集成时会出现偏差, 分解会出现较多伪分量, 也无法保证得到的分量满足内禀尺度分量 (Intrinsic Scale Component, ISC) 定义<sup>[5]</sup>.

由于添加白噪声是为了均匀化原始信号极值点分布, 而间歇和噪声等引起模态混淆的信号一般会被最先分解出, 之后极值点分布较为均匀, 仍进行集成平均分解是没有必要的. 基于此, 论文提出了部分集成局部特征尺度分解方法 (Partly Ensemble LCD, PELCD). (1) 向目标信号中成对地添加符号相反的白噪声信号, 对加噪信号依据频率高低逐层进行集成平均分解; (2) 检测高频间歇和噪声信号; 及时检测出异常信号是分解的关键, 如果未完全检测出异常信号, 则达不到抑制模态混淆的目的; C Bandt 等提出的时间序列的随机性检测方法<sup>[9, 10]</sup>——排列熵 (Permutation Entropy, PE) 能够检测时间序列随机性和动力学突变行为. PE 值越大, 时间序列越随机; PE 值越小, 时间序列越规则; 由于先分解出的高频信号和噪声随机性较大, 因此 PE 较大, 而当分解出的分量为平稳信号时, 序列较为规则, PE 值较小; 且 PE 取值 [0, 1] 区间, 便于控制; 因此, 通过设置合理的 PE 阈值可以实现信号随机性的检测; (3) 将检测出的间歇和噪声信号从原始信号中分离出来, 再对得到的剩余信号进行完整 LCD 分解.

PELCD 方法不但能够在一定程度上抑制模态混淆, 而且克服了集成平均的方法的计算量大、分量未必满足 ISC 定义条件等缺陷, 具有一定的优越性. 通过仿真信号对 ELCD 和 PELCD 方法进行了验证, 结果表明, ELCD 和 PELCD 都能够在一定程度上抑制模态混淆, PELCD 方法在抑制伪分量, 提高分量精确性等方面有更好的效果.

## 2 LCD 与 EMD 比较

局部特征尺度分解 (LCD) 方法能自适应地将一个复杂信号分解为若干个瞬时频率具有物理意义的相互

独立的内禀尺度分量 (ISC) 和一个残余趋势项之和. 文献<sup>[5]</sup>给出了 LCD 分解详细步骤, 而且详细比较了 LCD 和 EMD 方法的优势与不足, 限于篇幅, 本文不再赘述. 仅以下述信号 (1) 为例, 说明 LCD 在频率分辨能力和抑制模态混淆方面要优于 EMD 方法.

考察仿真信号 (1)

$$x_1(t) = (1 + 0.5\sin(8\pi t))\sin(180\pi t), x_2(t) = \sin(100\pi t)$$

$$x(t) = x_1(t) + x_2(t); t = 0: \frac{1}{1024}: 1 \quad (1)$$

$x(t)$  与其两个分量的时域波形如图 1 所示. 分别采用 EMD 和 LCD 方法对其进行分解, 结果分别如图 2 和图 3 所示.




图1 仿真信号(1)及其分量的时域波形




图2 仿真信号(1)的EMD分解结果




图3 仿真信号(1)的LCD分解结果

由图 2 和图 3 可以看出, 由于待分解信号的两个分量的频率分别为 50Hz 和 90Hz, 较为接近, EMD 无法完全分辨出, 分解出现了模态混淆. 而 LCD 则能够分辨出两个分量成分, 得到合理的分解结果. 这说明 LCD 方法在分解能力和抑制模态混淆方面有一定的优越性. 然而, LCD 方法也有一定程度的模态混淆. 对此论文提出了如下的解决方法.

### 3 集成局部特征尺度分解(ELCD)

由于成对添加符号相反的白噪声到目标信号再进行集成平均分解,不但能够得到与 EEMD 相同结果,且能大大减小分解过程中由白噪声引起的重构误差,提高分解的完备性<sup>[8]</sup>,基于此,论文提出了 ELCD 方法。

(1)假设原始信号为  $S(t)$ ,分别添加白噪声信号  $n_i(t)$  和  $-n_i(t)$  到原始信号,即

$$S_i^+(t) = S(t) + a_i n_i(t) \quad (2a)$$

$$S_i^-(t) = S(t) - a_i n_i(t) \quad (2b)$$

其中,  $n_i(t)$  表示添加的白噪声信号,  $a_i$  表示添加噪声信号的幅值,  $i = 1, 2, \dots, Ne$ ,  $Ne$  表示添加白噪声对数。

(2)分别对  $S_i^+(t)$  和  $S_i^-(t)$  进行 LCD 分解,得到不同的 ISC 分量  $I_{ij}^+(t)$ ,  $I_{ij}^-(t)$  和剩余项  $r_{ij}^+(t)$ ,  $r_{ij}^-(t)$ ;  $j = 1, 2, \dots, P$ ,  $P$  为分量个数。

(3)执行上述步骤(2)直至  $i = Ne$ 。

(4)将上述对应 ISC 分量进行集成平均,消除添加白噪声的影响,得到

$$I_j(t) = \frac{1}{2Ne} \sum_{i=1}^{Ne} [I_{ij}^+(t) + I_{ij}^-(t)] \quad (3)$$

$$\text{于是} \quad S(t) = \sum_{j=1}^P I_j(t) + r_j(t) \quad (4)$$

对不同的信号添加白噪声的幅值  $a_i$  和集成次数  $Ne$  还没有一致的标准。所加白噪声的幅值一般为原始信号标准偏差(Standard Deviation, SD)的 0.1 ~ 0.5 倍<sup>[7]</sup>。 $N$  数量级一般取百以内。

## 4 PELCD

### 4.1 PELCD 算法

由于添加白噪声是均匀化信号极值点分布,在提取出间歇和噪声等干扰信号之后信号极值点分布渐近均匀,基于此,论文提出了部分集成局部特征尺度分解(PELCD)方法,步骤如下。

(1)同 ELCD 方法(1),并令分解阶数  $j = 1$ 。

(2)分别对  $S_i^+(t)$  和  $S_i^-(t)$  进行  $j$  阶 LCD 分解,得到一系列  $\{I_{ij}^+(t)\}$  和  $\{I_{ij}^-(t)\}$  ( $i = 1, 2, \dots, Ne$ ,  $Ne$  是添加白噪声对数),集成平均得到:

$$I_j(t) = \frac{1}{2Ne} \sum_{i=1}^{Ne} [I_{ij}^+(t) + I_{ij}^-(t)] \quad (5)$$

(3)检测  $I_j(t)$  是否是高频间歇或噪声信号;如果是  $j = j + 1$ ,继续执行步骤(2),直至  $I_p(t)$  不是异常信号;如果排列熵(PE)值大于阈值  $\theta_0$  则认为该分量为异常信号(间歇或者噪声等引起模式混淆的高频信号),若 PE 值小于  $\theta_0$  则该分量不是异常信号。

(4)将已分解的前  $p - 1$  个分量从原始信号  $S(t)$  中

分离出来,即

$$r(t) = S(t) - \sum_{j=1}^{p-1} I_j(t) \quad (6)$$

(5)再对剩余信号  $r(t)$  进行完整 LCD 分解。

### 4.2 基于排列熵的随机性检测

上述步骤(3)中采用了基于排列熵的随机性检测。排列熵(Permutation Entropy, PE)是最近由 C Bandt 和 B Pompe<sup>[9,10]</sup>提出的一种检测时间序列随机性和动力学突变的方法,PE 具有概念简单,计算速度快,抗干扰能力强等优点,而且特别适用于非线性数据,其详细计算方法参见文献[9,10],简要步骤如下。

对时间序列  $\{x(i), i = 1, 2, \dots, N\}$  进行相空间重构得到:

$$\begin{cases} X(1) = \{x(1), x(1+\lambda), \dots, x(1+(m-1)\lambda)\} \\ \vdots \\ X(k) = \{x(i), x(i+\lambda), \dots, x(i+(m-1)\lambda)\} \\ \vdots \\ X(N-(m-1)\lambda) = \{x(N-(m-1)\lambda), \\ x(N-(m-2)\lambda), \dots, x(N)\} \end{cases} \quad (7)$$

其中,  $m$  是嵌入维数,  $\lambda$  是时间延迟。

将  $X(i)$  的  $m$  个向量按照升序重新排列,即

$$X(i) = \{x(i+(j_1-1)\lambda) \leq x(i+(j_2-1)\lambda) \leq \dots \leq x(i+(j_m-1)\lambda)\} \quad (8)$$

若存在  $x(i+(j_{i1}-1)\lambda) = x(i+(j_{i2}-1)\lambda)$  则按  $j$  的的大小来进行排序,即当  $j_{i1} < j_{i2}$  时,有:  $x(i+(j_{i1}-1)\lambda) \leq x(i+(j_{i2}-1)\lambda)$ ; 因此,任意一个向量  $X(i)$  都可以得到一组符号序列

$$S(g) = [j_1, j_2, \dots, j_m] \quad (9)$$

其中,  $g = 1, 2, \dots, k, k \leq m!$ 。  $m$  个不同的符号  $[j_1, j_2, \dots, j_m]$  共有  $m!$  种不同的排列,对应地,共有  $m!$  种不同的符号序列。计算每一种符号序列出现的概率,  $P_1, P_2, \dots, P_k, \sum_{g=1}^k P_g = 1$ 。  $\{x(i), i = 1, 2, \dots, N\}$  的排列熵可按照 Shannon 熵的形式定义为

$$H_p(m) = - \sum_{g=1}^k P_g \ln P_g \quad (10)$$

当  $P_g = \frac{1}{m!}$  时,  $H_p(m)$  达到最大值  $\ln(m!)$ , 因此,可将排列熵  $H_p(m)$  进行标准化处理:

$$H_p = H_p(m) / \ln(m!) \quad (11)$$

$H_p$  的取值范围是  $0 \leq H_p \leq 1$ ,  $H_p$  值的大小表示时间序列的随机性程度。  $H_p$  越大,说明时间序列越随机,反之,则说明时间序列越规则。 PE 参数  $m$  和  $\lambda$  的选择详见文献[9,10]。论文选取  $m = 6$ 。一般地,嵌入维数较小时,计算所需数据长度则越小。若  $m$  选定等于 6,数据长度大于 1024 即可获得稳定的 PE 值<sup>[10]</sup>。  $\lambda$  对时间序列

的计算影响较小<sup>[10]</sup>,论文选择  $\lambda = 1$ . 实验发现,阈值  $\theta_0$  取 0.55~0.6 较为合适,论文取为 0.6.

PELCD 由于成对地添加白噪声,减小了噪声残留,保证了分解的完备性;同时通过检测异常信号,避免了不必要的集成平均,不但能够抑制模态混淆,而且减小了计算量,使得更多分量满足 ISC 判据条件. 为了说明 ELCD 和 PELCD 方法的有效性和合理性,论文通过仿真信号进行验证.

## 5 仿真与实测信号分析

为了验证论文所提方法的有效性,考虑仿真信号(12)

$x_1(t) = (t^2 + 1) \cos(2\pi 40t)$ ,  $x_2(t) = e^{-\frac{t}{2}} \cos(2\pi 15t)$ ;  $x_3(t)$  为幅值为 0.4 频率 200Hz 和幅值为 0.2 频率为 150Hz 的两段正弦信号组成的高频间歇信号.

$$x(t) = x_1 + x_2 + x_3(t), t = 0:1/1000:1. \quad (12)$$

分别采用 ELCD, CEEMD 和 PELCD 对仿真信号(12)进行分解,结果分别如图 4,图 5 和图 6 所示.




图4 仿真信号(12)的ELCD分解结果. 其中,添加噪声幅值 $a$ 和集成次数 $N_e$ 分别为0.4和120




图5 仿真信号(12)的CEEMD分解结果; $a$ 和 $N_e$ 分别为0.2和120

分解过程的模态混淆,但出现了较多的伪分量,仍存在模态混淆;CEEMD 虽然也实现了高频间歇信号和低频分量的区分,抑制了分解的模态混淆,然而 CEEMD 分解的分量  $I_2(t)$  包含了  $I_3(t)$  成分,使得分量  $I_3(t)$  与真实值  $x_1(t)$  吻合较差;PELCD 方法则完美地实现了高频间歇信号和低频分量的分解,前两个分量为间歇信号,  $I_3(t)$  与  $I_4(t)$  分别对应为仿真信号的  $x_1(t)$  和  $x_2(t)$ . 经计算,CEEMD 两个分量与真实值的相关性系数分别为 0.9897 和 0.9932,而 PELCD 的分量与真实值的相关性为 0.9995 和 0.9979. 因此,综上,PELCD 在抑制模态混淆和伪分量,提高分量的精确性方面要优于 ELCD 和 CEEMD 方法.




图6 仿真信号(12)的PELCD分解结果; $a$ 和 $N_e$ 分别为0.4和120

上述仿真信号中干扰信号分为间歇高频信号. 再考虑仿真信号(13)

$$x(t) = x_1(t) + x_2(t) + x_3(t), t \in [0, 1] \quad (13)$$

$x_1(t) = \cos(80\pi t)$ ,  $x_2(t) = \cos(30\pi t)$ ,  $x_3(t)$  为幅值 0.1 的白噪声.

分别采用 CEEMD 和 PELCD 对  $x(t)$  进行分解,分解结果如图 7 和图 8 所示. 其中添加白噪声幅值为 0.1,添加白噪声对数为 60(即集成次数为 120).




图7 仿真信号(13)的CEEMD分解结果

由图 7 和图 8 可以看出,CEEMD 虽然分解出了噪声信号和两个低频分量,但  $I_2(t)$  包含了噪声和  $I_3(t)$  成

由图 4,图 5 和图 6 可以发现,ELCD 虽然能够抑制

分,得到的  $I_3(t)$  和  $I_4(t)$  与真实值也有明显的误差. 计算发现,二者与真实值的相关性分别为 0.9763 和 0.9910. PELCD 分解的结果与真实值较为接近,误差较小,得到的分量与对应真实值的相关性分别为 0.9971 和 0.9977. 为比较分解分量的瞬时特征,论文给出了二者第三个分量  $I_3(t)$  的瞬时幅值和瞬时频率,如图 9 所示. 由图可以看出,CEEMD 和 PELCD 方法得到的分量瞬时频率与真实频率(40Hz)的差别都很小,但 CEEMD 分量的端点效应较为严重;CEEMD 第三个分量的瞬时幅值波动较大,而 PELCD 第三个分量的瞬时幅值误差较小,更接近理论值 1.




图9 (a)与(b)分别为CEEMD得到的第三个分量的瞬时频率和瞬时幅值;(c)与(d)为PELCD得到的第三个分量的瞬时频率和瞬时幅值

上述仿真信号表明,与 CEEMD 相比,PELCD 能够更好地抑制模态混淆,得到的分量精确性更高,是一种有效的信号分解方法. 为了说明 PELCD 对实测信号分解的模态混淆也具有抑制作用,考虑将 PELCD 方法应用于 WU 和 HUANG 在原 EEMD 文献中的天长 (Length-of-Day, LOD) 数据<sup>[7,11]</sup>的部分数据(1980 年 01 月 01 日 ~ 1990 年 01 月 01 日),数据幅值单位:10 000. 分别采用 CEEMD 和 PELCD 对其进行分解,添加噪声幅值为 0.2,集成次数为 200. 分解结果分别如图 10 和图 11 所示,为节约篇幅只画出了前五个分量及其剩余项.




图10 LOD数据的CEEMD分解结果

观察图 10 和图 11 易发现,二者的分解结果是相对应的. 各分量的物理意义是,  $I_1(t)$  平均幅值远小于其它分量,是具有拟正则的周期近似为 7 天峰值与随机高频波动的叠加.  $I_2(t)$  平均周期为 14 天,  $I_3(t)$  平均周期为 28 天<sup>[7]</sup>,等. 虽然从二者分解的结果都能得到如上周期规律,但从波形图可以看出,CEEMD 分解得到的分量并




图8 仿真信号(13)的PELCD分解结果

不是关于横轴对称的(如图中虚线所圈部分),不是严格意义上的 IMF. 如分量  $I_2(t)$ ,  $I_4(t)$  和  $I_5(t)$ ;而 PELCD 分解得到的分量光滑性更好,关于横轴对称,满足 ISC 分量的定义,而且计算发现,PELCD 各分量的上述周期特征更为明显和精确.




图11 LOD数据的PELCD分解结果

## 6 结论

提出了两种抑制 LCD 分解模态混淆的方法,ELCD 和 PELCD. ELCD 虽然能够在一定程度上抑制模态混淆,但分解会产生很多伪分量. PELCD 则对模态混淆有更好的抑制作用. PELCD 至少在三个方面要优越于 ELCD 和 CEEMD 方法:

(1)在计算时间和速度方面;PELCD 只有前几个分量采用集成平均,而剩余分量则是 LCD 分解. 因此,理论上 PELCD 计算时间要少于 ELCD 方法.

(2)在抑制模态混淆和伪分量方面;ELCD 和 CEEMD 虽然能在一定程度上抑制模态混淆,但依赖于添加白噪声的幅值和集成次数,如果参数选择不合适,分解会产生较多的伪分量,而 PELCD 分解则相对产生伪分量较少。

(3)在分解得到的分量的精确性方面;CEEMD 和 ELCD 方法并不能保证得到的分量满足 IMF 和 ISC 分量的定义,需要后续处理。PELCD 得到的分量满足 ISC 分量定义条件,提高了分量的精确性。

综上,理论和仿真分析结果都表明了 PELCD 对 LCD 分解中的模态混淆有很好的抑制作用,是一种有效的数据分析方法。下一步主要工作是研究如何自适应地选择添加白噪声的幅值和数目及比排列熵更有效的其它随机性或者平稳性的检测方法。

#### 参考文献

- [1] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proc Roy Soc London, A, 1998, 454(1971):903 - 995.
- [2] Rilling G, Flandrin P, Goncalves P. On empirical mode decomposition and its algorithms [A]. Proceedings in IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing NSIP - 03 (2003) [C]. Grado, Italy, <http://perso.ens-lyon.fr/paulo.goncalves/pub/emd-urasip03.pdf>. 2003.
- [3] Huang N E, Wu Z. A review on Hilbert Huang transform: Method and its applications to geophysical studies[J]. Reviews of geophysics, 2008, 47(2):1 - 23.
- [4] 徐晓刚,徐冠雷,王孝通,等.经验模式分解(EMD)及其应用[J].电子学报,2009,37(3):581 - 585.  
Xu Xiaogang, Xu Guanlei, Wang Xiaotong, et al. Empirical mode decomposition and its application[J]. Acta Electronica Sinica, 2009, 37(3):581 - 585. (in Chinese)
- [5] 程军圣,郑近德,杨宇.一种新的非平稳信号分析方法——局部特征尺度分解法[J].振动工程学报,2012, 25(2):215 - 220.  
Cheng Junsheng, Zheng Jinde, Yang Yu. A new nonstationary signal analysis approach—the local characteristic-scale decomposition method [J]. Journal of Vibration Engineering, 2012, 25(2):215 - 220. (in Chinese)

- [6] Deering R, Kaiser J F. The use of masking signal to improve empirical mode decomposition[A]. Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing [C]. Philadelphia, USA, 2005, 485 - 488.
- [7] Wu Z, Huang N E. Ensemble empirical mode decomposition: a noise assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1):1 - 41.
- [8] Yeh J R, Shieh J S. Complementary ensemble empirical mode decomposition: A noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(2):135 - 156.
- [9] Bandt C, Pompe B. Permutation entropy: a natural complexity measure for time series[J]. Physical Review Letters, 2002, 88(17):174102 - 1—174102 - 4.
- [10] Yan R Q, Liu Y B, Gao R X. Permutation entropy: A nonlinear statistical measure for status characterization of rotary machines[J]. Mech Syst Signal Process 2012 (29):474 - 484.
- [11] N E Huang, M C Wu, S R Long, et al. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis [J]. Proc R Soc Lond A, 2003, 459 (2037):2317 - 2345.

#### 作者简介



郑近德(通讯作者) 男,1986年3月生,安徽临泉人。2009年毕业于安徽师范大学数学系,现为湖南大学博士研究生,研究方向为动态信号处理,时频分析及机械设备故障诊断等。已发表相关论文近十篇。  
E-mail: lqdlzheng@126.com; jdzheng1986@gmail.com



程军圣 男,1968年出生,博士,湖南大学教授,博士生导师。从事机械故障诊断、动态信号分析与处理等方面的研究。  
E-mail: signalp@tom.com

杨宇 女,1971年生,博士,湖南大学教授。从事机械故障诊断、模式识别等方面的研究。  
E-mail: dzy0122@hotmail.com