

# 基于 EEMD 分解与 PCA-FCM 聚类的岸桥减速箱故障诊断方法\*

顾能华<sup>1</sup>, 侯银银<sup>2</sup>, 韩雪龙<sup>1</sup>

(1. 衢州学院 电气与信息工程学院, 浙江 衢州 324000;

2. 国网浙江省电力有限公司衢州供电公司, 浙江 衢州 324000)

**摘要:** 针对岸边桥式起重机(岸桥)减速箱特征提取以及故障诊断问题, 提出了一种集合经验模态分解(EEMD)与主成分分析(PCA)-模糊 C 均值(FCM)聚类的减速箱故障诊断组合方法。首先, 通过 EEMD 分解将减速箱非线性、非平稳振动信号分解为若干个固有模态函数(IMF), 提取每个 IMF 分量的多维故障特征; 然后, 使用主成分分析法对故障特征进行降维, 并分析了减速箱振动信号的特征值与故障模式之间的关系, 通过模糊 C 均值聚类算法对减速箱的状态进行识别。实验结果表明, EEMD-PCA-FCM 方法对减速箱的 3 种状态有很高的识别准确率, 表明该方法是一种准确有效的减速箱故障诊断方法。

**关键词:** 故障诊断; 岸桥减速箱; EEMD 分解; 模糊 C 均值聚类; 主成分分析

中图分类号: TN07

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.200418

中文引用格式: 顾能华, 侯银银, 韩雪龙. 基于 EEMD 分解与 PCA-FCM 聚类的岸桥减速箱故障诊断方法[J]. 电子技术应用, 2021, 47(4): 101-106, 111.

英文引用格式: Gu Nenghua, Hou Yinyin, Han Xuelong. Fault diagnosis for quayside container crane reducer based on EEMD decomposition and PCA-FCM clustering[J]. Application of Electronic Technique, 2021, 47(4): 101-106, 111.

## Fault diagnosis for quayside container crane reducer based on EEMD decomposition and PCA-FCM clustering

Gu Nenghua<sup>1</sup>, Hou Yinyin<sup>2</sup>, Han Xuelong<sup>1</sup>

(1. College of Electrical and Information Engineering, Quzhou University, Quzhou 324000, China;

2. Zhejiang Quzhou Power Supply Company State Grid, Quzhou 324000, China)

**Abstract:** Aiming at the feature extraction and fault diagnosis issue of quayside container crane (quayside crane) reducer, a combination method of reducer fault diagnosis based on ensemble empirical mode decomposition(EEMD) and principal component analysis(PCA)-fuzzy C-means(FCM) clustering is proposed. Firstly, the nonlinear and non-stationary vibration signals of the reducer are decomposed into several intrinsic mode functions(IMF) by EEMD decomposition, and the multi-dimensional fault characteristics of each IMF component are extracted. Then, the principal component analysis method is used to visually reduce the dimension of the fault feature, the relationship between the characteristic value of the vibration signal of the reducer and the fault mode is analyzed, and the state of the reducer is identified by the fuzzy C-means clustering algorithm. The experimental results show that EEMD-PCA-FCM method has high recognition accuracy for the three states of the reducer, which indicates that the method is an accurate and effective reducer fault diagnosis method.

**Key words:** fault diagnosis; quayside container crane reducer; ensemble empirical mode decomposition(EEMD); fuzzy C-means clustering; principal component analysis(PCA)

### 0 引言

岸桥常作业于高速、重载、大冲击的工作环境中, 其起升减速箱由于传动力矩大, 且长时间受到强烈动载的振动冲击, 是岸桥中最容易出现故障的部件之一<sup>[1]</sup>。因

此, 诊断监测岸桥减速箱的状态变得尤其重要。本质上, 对减速箱进行故障诊断是一种模式识别问题, 为了更准确地识别减速箱的状态, 需要对减速箱振动信号进行有效的特征提取和更准确的分类。

起升减速箱振动信号为非平稳、非线性、非周期信号, 传统的时域、频域以及时频域方法缺乏对非平稳和

\* 基金项目: 浙江省公益项目(LGG20F020009); 浙江省衢州市科学技术局项目(2019K16, 2018K28)

非线性信号的多分辨率分析和自适应处理能力<sup>[2]</sup>。HUANG N E 等<sup>[3]</sup>提出的经验模态分解(Empirical Mode Decomposition, EMD)由于其良好的自适应分解特性在处理非线性和非平稳信号时具有很大的优势。然而,EMD 分解会产生模态混叠现象。WU Z 等<sup>[4]</sup>通过改进 EMD 分解方法得到一种新的 EEMD 分解法,能够有效解决该问题。王玉静等<sup>[5]</sup>通过 EEMD 分解得到滚动轴承振动信号的固有模态函数,并结合峭度值、相关系数提取信号的初始特征,能够很好地提取故障特征信息;魏文军等<sup>[6]</sup>采用 EEMD 多尺度样本熵提取特征对 S700K 转辙机进行故障诊断,通过 EEMD 分解提取转辙机不同状态下的特征参数并进行聚类分析,验证了该方法对故障诊断的精度和效率有明显的提高。

通过 EEMD 分解提取到的减速箱故障特征维数较高,会导致故障诊断效率降低,故选取 PCA 法对故障特征降维。PCA 能较好融合减速箱的多个典型故障特征,将高维故障特征集映射到低维空间中,减少特征参数信息冗余<sup>[7]</sup>。故障特征参数的提取和选择是机器诊断的关键,而状态识别则是诊断的核心。FCM 算法作为一种无监督学习算法,可以根据特征参数样本的相似性进行分类,使处于同一类的相似度最大,并保证不同类间的差异性较大<sup>[8]</sup>。王印松等<sup>[9]</sup>将 FCM 应用在控制系统的故障诊断中,不仅可以较好地识别不同部件的故障,还可以对同一部件不同类型的故障进行诊断。樊红卫等<sup>[10]</sup>针对电主轴转子不平衡故障,提出一种对称极坐标图像和 FCM 相结合的失衡故障诊断方法,结果显示具有较高的分类准确率。

本文结合 EEMD 分解和 PCA-FCM 聚类算法对岸桥减速箱进行故障诊断。首先,将减速箱振动信号进行 EEMD 分解并提取故障特征,然后利用 PCA 对高维特征参数进行约简,最后使用 FCM 算法对减速箱的状态进行聚类,并通过实验分析验证了该方法的有效性。

### 1 集合经验模态分解

EEMD 分解是对经典 EMD 分解<sup>[3]</sup>方法的改进,该方法通过在原始信号中加入均值为 0、标准差为常数的高斯白噪声,并对处理后的信号进行多次 EMD 分解,取分解后 IMF 分量的均值作为最终结果<sup>[4]</sup>。EEMD 算法的具体实施步骤如下:

(1)确定所加入的高斯白噪声比值系数  $\alpha$  和总体平均次数  $M$ 。

(2)在原始信号  $x(t)$  中加入均值为零、幅值为原始信号标准差  $\alpha$  倍的高斯白噪声  $p_i(t)$ :

$$x_i(t) = x(t) + p_i(t) \quad (1)$$

式中,  $x_i(t)$  为第  $i$  次加入高斯白噪声后的信号。

(3)对  $x_i(t)$  进行 EMD 分解,得到  $k$  个 IMF 分量  $c_{ij}(t)$  和 1 个余项  $r_i(t)$ ,如式(2)所示:

$$x_i(t) = \sum_{j=1}^k c_{ij}(t) + r_i(t) \quad (2)$$

式中,  $c_{ij}(t)$  为第  $i$  次加入高斯白噪声的信号分解后的第  $j$  个 IMF 分量,  $r_i(t)$  表示第  $i$  次分解的余项。

(4)重复步骤(2)和(3) $M$ 次,将上述步骤所得对应 IMF 分量进行总体平均,以消除高斯白噪声对真实 IMF 分量的影响,得到最终 IMF 分量为  $c_j(t)$ :

$$c_j(t) = \frac{1}{M} \sum_{i=1}^M c_{ij}(t) \quad (3)$$

(5)原始信号  $x(t)$  经过 EEMD 分解的最终结果为:

$$x(t) = \sum_j c_j(t) + r(t) \quad (4)$$

式中,  $r(t)$  为原始信号  $x(t)$  经 EEMD 分解后的余项。

### 2 故障特征的主成分分析

PCA 方法在有效降低原始特征集维数的同时,也可以很好地解释各个故障特征集与减速箱状态的相关性,特征系数表示各个原始特征参数在主成分中所占的权重,数值的大小表示对应故障特征在每个主成分中所占的比例<sup>[11]</sup>。系数值越大,说明对应编号的故障特征对于该主成分的贡献越大,利用该方法可以提取出减速箱更为敏感的故障特征参数。其具体实施步骤如下<sup>[7,12]</sup>:

(1)标准化处理,将故障特征矩阵转换成均值为 0、方差为 1 的标准化矩阵;

(2)计算相关系数矩阵;

(3)求故障特征矩阵的特征值和特征向量;

(4)计算累积贡献率;

(5)计算主成分得分。

### 3 模糊 C-均值聚类算法

FCM 算法是一种基于目标函数迭代优化的聚类算法,可以用隶属度矩阵表示样本中每个数据点属于某一类的程度<sup>[8,13]</sup>。已知聚类特征参数样本  $X = [x_1, x_2, \dots, x_n]$  的隶属度矩阵以及聚类中心,要使得特征参数样本数据非相似性指标的目标函数达到最小<sup>[8]</sup>。利用该方法对减速箱状态进行识别的基本步骤如下所示:

(1)根据减速箱故障特征参数的种类确定聚类中心的个数和模糊加权指数  $m$ ,初始化隶属度矩阵  $U$ ,设置初始迭代次数为  $l=0$ 。

(2)根据目标函数确定特征参数样本数据的聚类中心  $C$ :

$$J(U, C) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (5)$$

式中,  $U$  为减速箱故障特征的模糊隶属度矩阵,  $u_{ij} \in [0, 1]$

且  $\sum_{i=1}^c u_{ij} = 1$ ;  $C = [c_1, \dots, c_c]$ ;  $d_{ij}$  表示第  $i$  组的聚类中心与第  $j$  个故障特征间的欧氏距离;  $m$  是一个加权指数且  $m \in [1, \infty)$ 。

(3)通过引入拉格朗日乘子  $\lambda_j (j=1, 2, \dots, n)$ ,计算目标函数值最小时的隶属度和聚类中心,  $u_{ij}$  和  $c_i$  的更新公式分别如式(6)和(7)所示:

$$u_{ij} = \left[ \sum_{k=1}^c (d_{ij}/d_{kj})^{2/(m-1)} \right]^{-1} \quad (6)$$

式中,  $d_{ij}$  和  $d_{kj}$  分别代表不同故障特征到同一聚类中心的欧式聚类。

$$c_i = \sum_{j=1}^n u_{ij}^m x_j / \sum_{j=1}^n u_{ij}^m \quad (7)$$

(4)对于设置的判别精度  $\varepsilon > 0$ , 若  $\|U^{l+1} - U^l\| < \varepsilon$ , 则停止迭代; 否则, 令  $l=l+1$ , 返回步骤(2)中继续执行, 直到满足条件为止。图1为减速箱故障诊断的流程图。

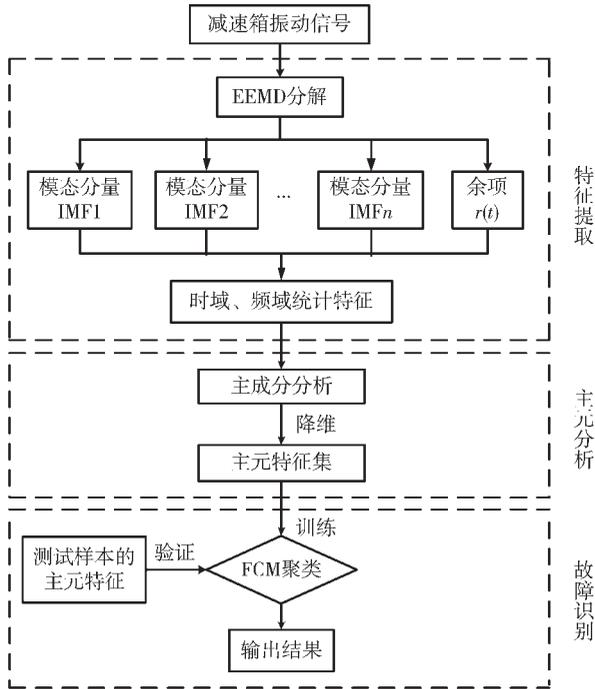


图1 减速箱故障诊断流程图

## 4 实验分析

### 4.1 减速箱振动信号采集

为了说明本文方法对减速箱故障诊断的有效性, 采用岸桥减速箱不同状态下的振动信号进行验证。数据来自于宁波港某集装箱码头的岸桥减速箱, 振动信号通过B608A11型ICP加速度传感器采集得到, 传感器安装于起升电机减速箱的低速轴径向位置, 如图2所示。设置采样频率为2.4 kHz, 采样时间为1 s, 采样间隔为10 s, 数据采集单元(Data Measurement Unit, DMU)计算并存储采样时段的有效值序列, 获取减速箱振动信号时间序列。

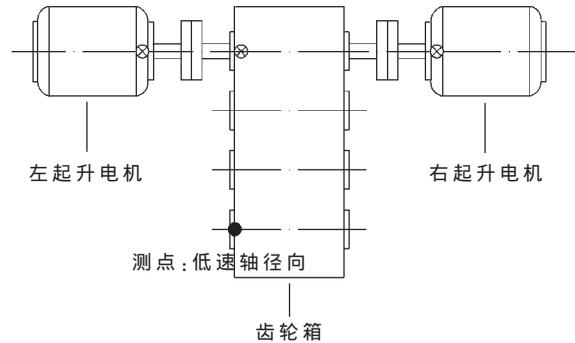


图2 减速箱传感器测点布置图

岸桥在非工作状态时的振动信号会影响故障诊断的结果, 需要剔除该部分数据。直观上可以根据岸桥大梁的俯仰角度来判断, 当大梁仰起时属于非工作状态; 但有时当大梁位于水平位置时岸桥也可能处于非工作状态, 则需要用振动信号的幅值来区分, 当振动信号的波动整体非常小, 且其中夹杂着一些大的波动, 则判定为大梁水平时的非工作状态。非工作状态下减速箱振动信号被剔除前后的时域图如图3所示, 图3(a)、图3(b)

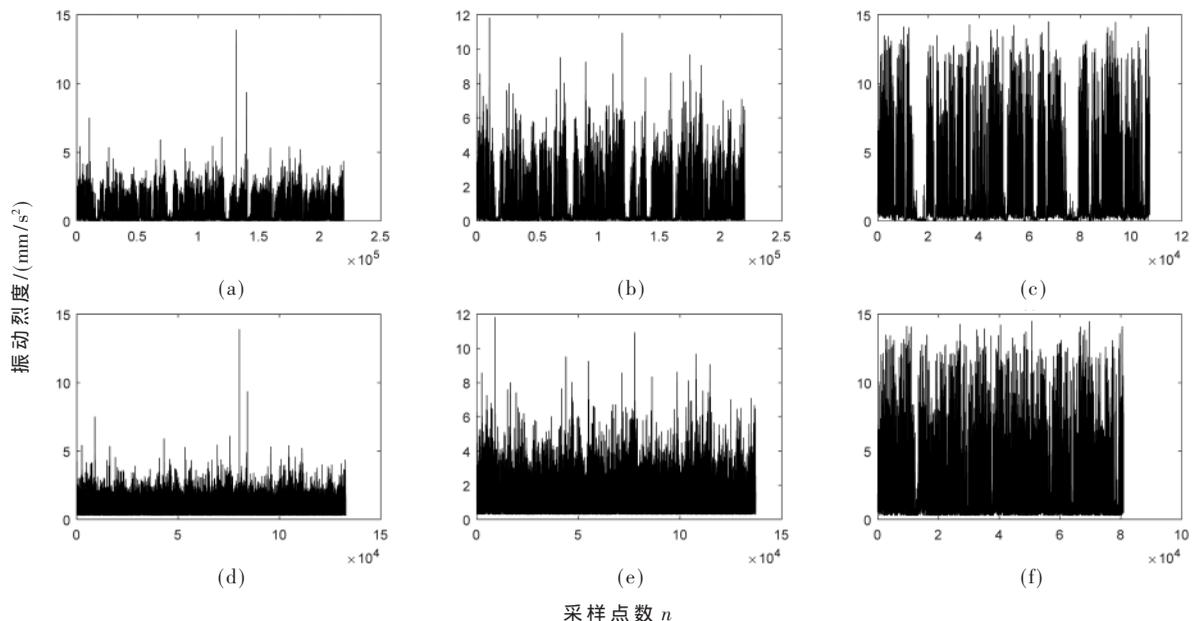


图3 减速箱振动信号时域图

和 3(c)显示了减速箱 3 种状态下的振动信号,分别为健康、亚健康以及预警状态;图 3(d)、图 3(e)和图 3(f)分别显示去除非工作状态后 3 种状态下的振动信号。不同状态下振动信号的幅值(振动烈度)具有较明显的差别,但由于岸桥吊装作业时的瞬间启停也会产生较大冲击,较容易对故障诊断的结果产生干扰,因此需要先进行故障特征提取。

4.2 特征提取与主成分分析

EEMD 分解处理减速箱非线性、非平稳振动信号具有较大优势<sup>[14]</sup>。本文采用文献[15]中的方法确定加入高斯白噪声的比值系数  $\alpha$ , 计算准则为:  $0 < \alpha < \sigma/2$ ;  $\alpha = \varepsilon_n/\varepsilon_0$ ;  $\sigma = \varepsilon_h/\varepsilon_0$ 。其中:  $\varepsilon_n$  为加入高斯白噪声幅值的标准差;  $\varepsilon_0$  为减速箱振动信号幅值的标准差;  $\varepsilon_h$  为减速箱振动信号有效高频成分的幅值标准差;  $\alpha$  取值为  $\sigma/4$  能有效避免信号分解时的模式混叠现象。总体平均次数  $M$  与比值系数的关系为:  $e = \alpha/\sqrt{M}$ 。其中:  $e$  为期望误差,一般取值为 0.01。按照上述方法计算得到  $\alpha = 0.16$ ,  $M = 256$ , 经过 EEMD 分解得到不同状态下减速箱振动信号的各项 IMF 分量,限于文章篇幅,本文仅展示减速箱在健康状态下振动信号的 EEMD 分解图,如图 4 所示。

选取减速箱在健康和亚健康状态下的样本各 80 组,预警状态样本 40 组,通过 EEMD 分解提取每个样本的 IMF1-IMF8 分量,分别计算每个 IMF 分量的 9 个统计特征值,即从每个样本中能提取 72 维特征向量,得到  $200 \times 72$  维特征参数矩阵,具体计算方式见表 1 所示。其中,  $x_i$  为 IMF 分量值,  $\mu_{x_i}$  为  $x_i$  均值。偏态指标对减速箱的状态变化较敏感,当发生局部故障时,减速箱的振动信号会明显偏离正态分布;此外,峭度指标和脉冲指标等特征参数对减速箱的早期故障有较高的敏感性,能很好地反映减速箱的初始状态。为了得到更多的减速箱故障信息,通过提取不同的特征参数,将它们综合应用以兼顾对减速箱的不同故障敏感性和稳定性的需求<sup>[4-5]</sup>。

表 1 减速箱故障特征参数表

序号	减速箱故障特征	故障特征计算公式
1	方差	$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_{x_i})^2$
2	方根幅值	$X_i = (\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i })^2$
3	有效值	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
4	偏态指标	$K_3 = \sqrt{\frac{1}{6N} \sum_{i=1}^N (\frac{x_i - \mu_{x_i}}{\sigma_{x_i}})^3}$
5	峭度指标	$K_4 = \sqrt{\frac{N}{24} \sum_{i=1}^N [(\frac{x_i - \mu_{x_i}}{\sigma_{x_i}})^4 - 3]}$
6	波形指标	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} / (\frac{1}{N} \sum_{i=1}^N  x_i )$
7	峰值指标	$P = \max  x_i  / \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
8	脉冲指标	$I = \max  x_i  / (\frac{1}{N} \sum_{i=1}^N  x_i )$
9	裕度指标	$L = \frac{\max  x_i }{X_i}$

将减速箱故障特征矩阵进行归一化处理,然后对处理后的故障特征进行主成分分析,得到减速箱在一起不同状态下各个特征参数的主成分得分以及降维后的主元个数等,减速箱 72 维故障特征数据的主成分贡献率矩阵如表 2 所示。

由第 2 节计算出减速箱振动信号的前 8 个主成分特征系数的分布图如图 5 所示,左一小图为第 1 个主成分特征系数分布图,右 1 小图为第 2 个主成分特征系数分布图,第 3 个~6 个主成分同理依次排列。图中横坐标为故障特征的维数,每个主成分均由 72 个故障特征组成,纵坐标为每个故障特征所占的比重。由图 5 可知,只有少数几个特征值在主成分中所占比重较高,多数故障

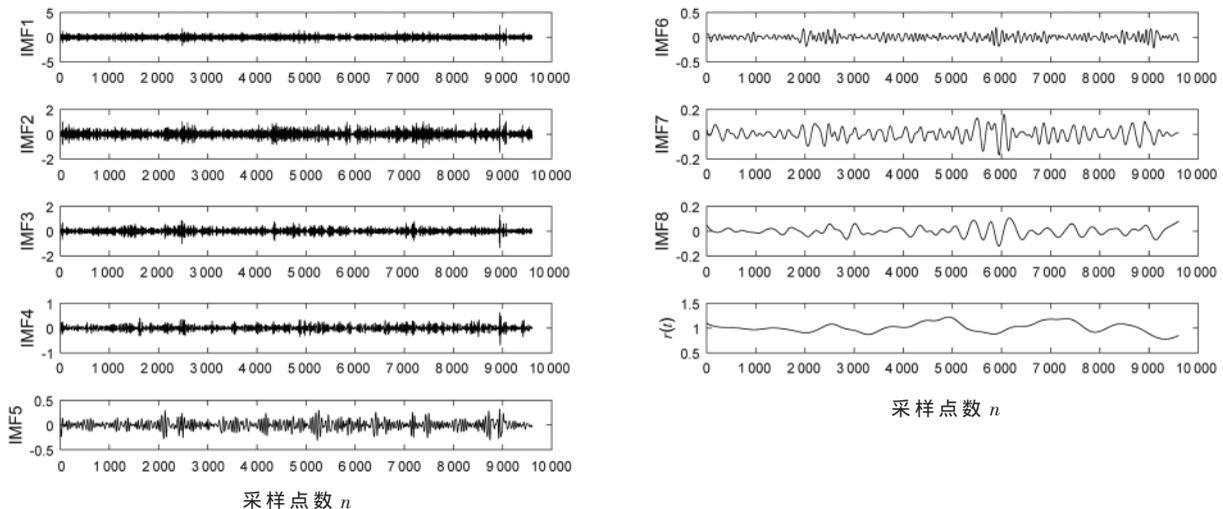


图 4 减速箱振动信号 EEMD 分解结果

表2 减速箱特征参数主成分贡献率矩阵

减速箱的状态	成分	提取平方和载入	
		方差的百分比/%	累积贡献率/%
健康	1	67.484	67.484
	2	32.383	99.867
亚健康	1	83.192	83.192
	2	16.349	99.541
预警	1	80.992	80.992
	2	14.656	95.648

特征系数接近于0。例如,第1个主成分中,系数编号27、36、45、54、63故障特征所占比例最大,其分别对应每个IMF分量的有效值、偏态指标、峭度指标、波形指标和峰值指标,因此认为第1个主元是各个IMF分量的有效值、偏态指标、峭度指标、波形指标和峰值指标按不同权重相加组合的量,其他主成分可以同理分析。通过主成分分析可以提取出更为敏感的故障特征参数,反向追踪每个主成分的构成,可以推测出其实际的物理意义,为减速箱振动信号的故障特征提取提供科学依据。

#### 4.3 减速箱故障识别

设置FCM聚类算法的基本参数:聚类中心个数 $c=3$ ,模糊系数 $m=2$ ,收敛精度 $\varepsilon \leq 1.0 \times 10^{-5}$ ,迭代次数 $k=100$ ,原点定为迭代起点。根据式(7)迭代计算并不断更新聚类中心,直至目标函数收敛为止。4种方法的二维聚类结果如图6所示。其中:图6(a)为减速箱振动信号通过PCA和FCM算法得到的二维聚类分布图,与图6(b)中的PCA-K-means聚类效果对比,FCM算法比K-means方法对减速箱状态识别的准确率更高,但聚类效果仍不

太理想,每种状态的聚类簇分布较散,且不同状态的聚类簇存在部分交叉混叠;图6(c)为减速箱振动信号经EEMD分解,再通过PCA-FCM算法得到的二维聚类分布图,和图6(d)中的K-means算法都具有很好的聚类效果。这是由于EEMD分解能较好地非平稳和非线性振动信号进行多分辨率分析和自适应分解,以便提取更多更准确的故障特征,达到提高岸桥减速箱故障识别准确率的目的。

为了评判FCM算法识别的准确性,统计4种方法对减速箱不同状态样本的识别情况。分别计算不同方法对减速箱不同状态识别的准确率,如表3所示。通过对比PCA+FCM方法和PCA+K-means方法的识别结果可知,FCM方法的识别准确率要高于K-means,说明FCM聚类算法对减速箱的状态识别比K-means算法更优;EEMD-PCA-FCM方法和EEMD-PCA-K-means方法对减速箱的状态识别准确率都高达100%,充分体现了EEMD分解在减速箱特征提取上的较大优势。

表3 4种方法对减速箱故障识别准确率对比

减速箱状态	健康/%	亚健康/%	预警/%
PCA+FCM	95	76.25	78.75
PCA+K-means	91.25	62.5	72.5
EEMD+PCA+FCM	100	100	100
EEMD+PCA+K-means	100	100	100

## 5 结论

本文首先通过EEMD分解得到减速箱振动信号的IMF分量,得到振动信号在不同时间尺度下的特征参

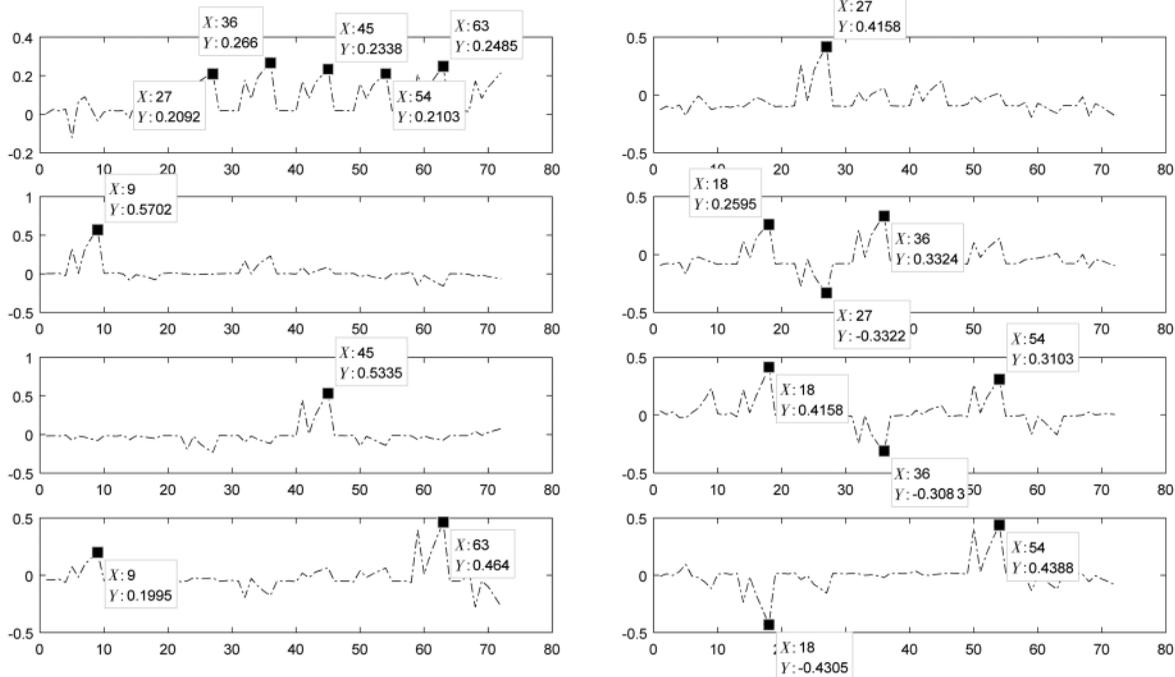


图5 主元系数分布图

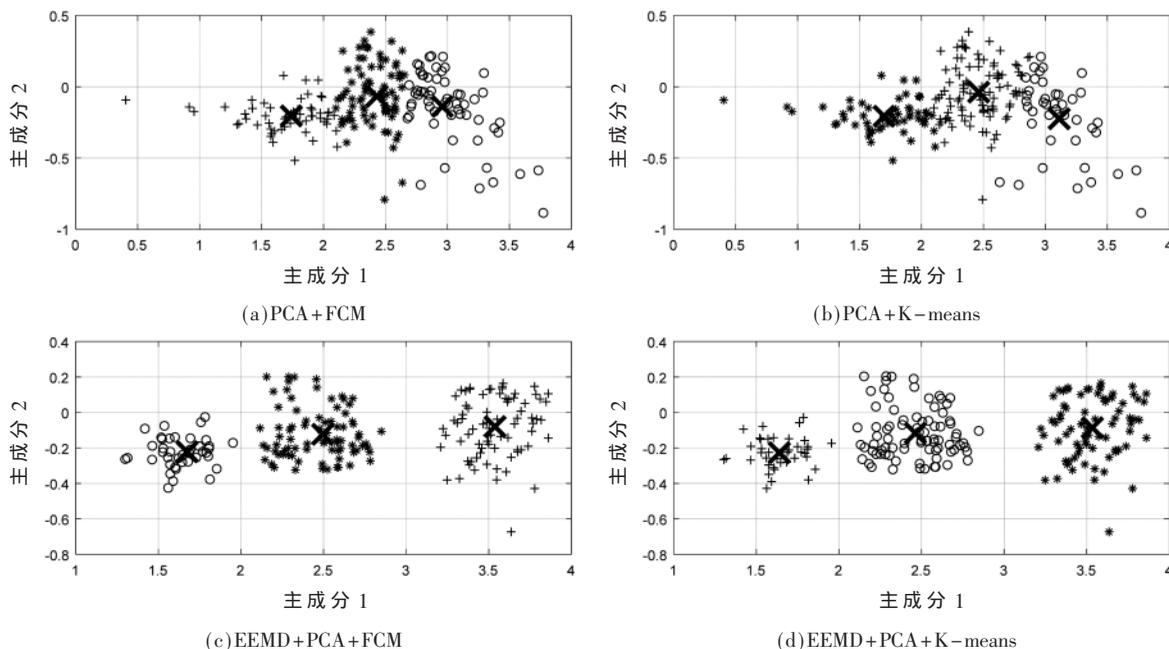


图6 二维聚类效果图

数,能够更加有效地提取减速箱的故障特征,使得减速箱故障诊断的精度和效率更高。其次,使用主成分分析法融合多个典型故障特征参数进行数据降维,减少无关或冗余特征向量,并分析了减速箱振动信号故障特征值与故障模式之间的联系。最后,利用FCM算法对提取的主成分矩阵进行聚类分析,得到聚类中心后对减速箱振动信号样本进行状态识别和故障诊断。实验结果表明,将EEMD分解和PCA-FCM方法相结合能有效提高减速箱故障识别的准确率。

#### 参考文献

- [1] LEE D H, CAO Z, CHEN J H. Simultaneous load scheduling of quay crane and yard crane in port container terminals[J]. *Transportation Research Record*, 2009, 2097(1): 62-69.
- [2] LIU D, ZENG H, XIAO Z, et al. Fault diagnosis of rotor using EMD thresholding-based de-noising combined with probabilistic neural network[J]. *Journal of Vibroengineering*, 2017, 19(8): 5920-5931.
- [3] 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]. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995.
- [4] 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.
- [5] 王玉静, 康守强, 张云, 等. 基于集合经验模态分解敏感固有模态函数选择算法的滚动轴承状态识别方法[J]. *电子与信息学报*, 2014, 36(3): 595-600.
- [6] 魏文军, 刘新发. 基于EEMD多尺度样本熵的S700K转辙机故障诊断[J]. *中南大学学报(自然科学版)*, 2019(11):

2763-2772.

- [7] JOLLIFFE I T, CADIMA J. Principal component analysis: a review and recent developments[J]. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2016, 374(2065): 201-208.
- [8] LI C, CERRADA M, CABRERA D, et al. A comparison of fuzzy clustering algorithms for bearing fault diagnosis[J]. *Journal of Intelligent & Fuzzy Systems*, 2018, 34(6): 3565-3580.
- [9] 王印松, 商丹丹, 王艳飞, 等. 改进的模糊聚类在控制系统故障诊断中的应用[J]. *计算机工程与科学*, 2018(2): 20.
- [10] 樊红卫, 邵德洁, 张旭辉, 等. 一种对称极坐标图像模糊C-均值聚类的电主轴失衡故障诊断方法[J]. *西安交通大学学报*, 2019(12): 1-8.
- [11] WANG F, SUN J, YAN D, et al. A feature extraction method for fault classification of rolling bearing based on PCA[C]. *Journal of Physics: Conference Series*. IOP Publishing, 2015, 628(1): 012079.
- [12] 徐卓飞, 刘凯, 张海燕, 等. 基于经验模式分解和主元分析的滚动轴承故障诊断方法研究[J]. *振动与冲击*, 2014(23): 141-147.
- [13] 温广瑞, 陈征, 张志芬. 基于模糊C-均值聚类和转子轴心轨迹特征的转子状态诊断[J]. *振动与冲击*, 2019, 38(15): 27-35.
- [14] 程军圣, 王健, 桂林. 改进的EEMD方法及其在滚动轴承故障诊断中的应用[J]. *振动与冲击*, 2018(16): 51-56.
- [15] 陈略, 菅艳阳, 何正嘉, 等. 总体平均经验模式分解与1.5维谱方法的研究[J]. *西安交通大学学报*, 2009, 43(5): 100-104.

(下转第111页)

## 4 结论

通过对已有的压缩感知观测矩阵算法进行优化,本文提出一种结合 QR 分解与自适应梯度下降的观测矩阵优化算法,获得了性能较优的观测矩阵。该矩阵具有较高的列独立性,并且与稀疏基之间具有较低的互相关性。实验结果表明了该算法的有效性,并在重建质量方面有较大的优势。后期的研究工作将着力于进一步降低算法的复杂度,提高重建信号的效率。

## 参考文献

- [1] 胡行华, 史明洁. 帐篷混沌序列稀疏测量矩阵构造[J]. 传感器与微系统, 2017, 36(7): 50-54.
- [2] CANDÈS E J. The restricted isometry property and its implications for compressed sensing[J]. Comptes Rendus Mathématique, 2008, 346(9-10): 589-592.
- [3] DONOHO D L, ELAD M. Optimally sparse representation in general (nonorthogonal) dictionaries via L1 minimization[J]. Proceedings of the National Academy of Sciences of the United States of America, 2003, 100(5): 2197-2202.
- [4] GRIBONVAL R, NIELSEN M. Sparse representations in unions of bases[J]. IEEE Transactions on Information Theory, 2004, 49(12): 3320-3325.
- [5] ELAD M. Optimized projections for compressed sensing[J]. IEEE Transactions on Signal Processing, 2007, 55(12): 5695-5702.
- [6] ABOLGHASEMI V, FERDOWSI S, SANEI S. A gradient-based alternating minimization approach for optimization of

the measurement matrix in compressive sensing[J]. Signal Processing, 2012, 92(4): 999-1009.

- [7] 赵瑞珍, 秦周, 胡绍海. 一种基于特征值分解的测量矩阵优化方法[J]. 信号处理, 2012(5): 49-54.
- [8] DONOHO D L. Method and apparatus for compressed sensing: US 2010. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [9] SZAREK S J. Condition numbers of random matrices[J]. Journal of Complexity, 1991, 7(2): 131-149.
- [10] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [11] 李昕艺, 刘三阳, 谢维. 基于共轭梯度法的感知矩阵优化方法[J]. 浙江大学学报(理学版), 2019, 46(1): 18-24.
- [12] 孙超. 基于后验信息和单位范数紧框架的图像测量矩阵优化[D]. 重庆: 重庆邮电大学, 2020.
- [13] 沈子钰, 汪立新. 步长自适应的测量矩阵迭代优化方法[J]. 计算机工程与应用, 2019, 55(1): 272-276.
- [14] 蒋伊琳, 佟岐, 张荣兵, 等. 自适应梯度下降观测矩阵优化算法[J]. 计算机应用研究, 2017, 34(7): 1950-1952.

(收稿日期: 2020-05-23)

## 作者简介:

周琦宾(1995-), 男, 硕士研究生, 主要研究方向: 压缩感知、SAR 图像处理。

吴静(1963-), 通信作者, 女, 副教授, 主要研究方向: 目标识别、感知技术和智能算法等, E-mail: 1320958927@qq.com。

余波(1996-), 男, 硕士研究生, 主要研究方向: 图像检测。

(上接第 100 页)

specific languages in a multi-domain cloud platform[C]. European Conference on Modelling Foundations and Applications, 2014.

- [14] SHUE D, FREEDMAN J M, SHAIKH A. Performance isolation and fairness for multi-tenant cloud storage[C]. Proceedings of the 10th USENIX Conference on Operating Systems Design and Implementation, ser. OSDI'12. Berkeley,

CA, USA: USENIX Association, 2012.

- [15] HUBER N. Evaluating and modeling virtualization performance overhead for cloud environments[C]. Closer-International Conference on Cloud Computing & Services Science. DBLP, 2011.

(收稿日期: 2020-06-04)

## 作者简介:

陈海(1986-), 男, 硕士研究生, 高级工程师, 主要研究方向: 工控软件、嵌入式系统、智能制造。

(上接第 106 页)

(收稿日期: 2020-05-26)

## 作者简介:

顾能华(1978-), 男, 硕士研究生, 中级实验师, 主要研

究方向: 计算机科学、嵌入式系统、电器智能化。

侯银银(1987-), 女, 硕士研究生, 中级工程师, 主要研究方向: 电力系统数据分析、无功补偿。

韩雪龙(1988-), 男, 硕士研究生, 初级实验师, 主要研究方向: 电力电子与电力传动。

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所