文章编号：1006-1355(2018)04-0169-05

基于LMD-MFE和DHMM的滚动轴承故障诊断算法

丁 伟[1]，王松涛[2]，胡 晓[3]

（1. 江苏信息职业技术学院 汽车工程学院，江苏 无锡 214153；
2. 深圳清华大学研究院，广东 深圳 518057；3. 中国矿业大学 机电工程学院，江苏 徐州 221116）

摘 要：针对滚动轴承在恶劣环境影响下，其特征信息难以被有效提取出来的问题，提出一种基于局部均值分解(Local Mean Decomposition，LMD)和多尺度模糊熵(Multiscale Fuzzy Entropy，MFE)的滚动轴承故障诊断算法。首先，利用LMD对轴承振动信号进行分解，得到一系列乘积函数(Product function，PF)分量，并与经验模态分解(Empirical Mode Decomposition，EMD)进行对比，分析其优越性；然后对每一个分量分别提取MFE特征，同时与多尺度样本熵(Multiscale Sample Entropy，MSE)进行对比，分析MFE的优越性；最后结合各个轴承状态的类间平均距离对多个尺度因子下的熵值进行优选，筛选出可分性良好的敏感特征集，并输入到离散隐马尔科夫模型(Discrete Hidden Markov Models，DHMM)模式分类器中对轴承故障类型进行诊断识别。实验结果表明，所提出的基于LMD和MFE的轴承故障诊断算法能较好识别出多种轴承故障类型。

关键词：振动与波；滚动轴承；局部均值分解；多尺度模糊熵；DHMM；故障诊断

中图分类号：TP306 **文献标志码**：A **DOI编码**：10.3969/j.issn.1006-1355.2018.04.033

Fault Diagnosis Algorithm of Rolling Bearings Based on LMD-MFE and DHMM

DING Wei[1], *WANG Songtao*[2], *HU Xiao*[3]

(1. School of Automotive Engineering, Jiangsu Vocational College of Information Technology, Wuxi 214153, Jiangsu China;
2. Research Institute of Tsinghua University in Shenzhen, Shenzhen 518057, Guangdong China;
3. School of Mechatronic Engineering, China University of Mining and Technology, Xuzhou 221116, Jiangsu China)

Abstract: In poor environment, the rolling bearing characteristic information can hardly be extracted effectively. In this paper, a rolling bearing fault diagnosis method based on local mean decomposition (LMD) and multi-scale fuzzy entropy (MFE) is proposed. Firstly, LMD is used to decompose the vibration signals into a series of product function (PF) components and the result is compared with that of the empirical mode decomposition (EMD). The superiority of this method is analyzed. Then, the MFE of each component is extracted and compared with the multi-scale sample entropy (MSE). And the superiority of the MFE method is analyzed. Finally, the best sensitive feature sets are extracted based on the maximum value of average distances between different states. The best sensitive feature sets are input into discrete hidden Markov models (DHMM) and the fault identification of the bearing condition is completed. Experimental study has shown that this bearing diagnosis algorithm can effectively extract the bearing fault feature information.

Keywords: vibration and wave; rolling bearing; local mean decomposition; multi-scale fuzzy entropy; discrete hidden Markov models; fault diagnosis

滚动轴承作为旋转机械设备中常出现故障的零件，其故障诊断研究对保障操作人员安全以及机械设备可靠运行具有重要的意义[1]。

2005年，Smith提出一种局部均值分解法，该方法类似于EMD算法的信号自适应分解和时频分析方法[2]。LMD通过信号局部极值点处理信号，将信号分解为不同频率段的PF分量之和，PF分量为一对调频信号和包络信号的乘积。LMD算法在旋转机

收稿日期：2017-10-27

基金项目：中国博士后科学基金资助项目（2016M602536）；江苏省自然科学基金资助项目（BK20141128）；江苏高校优势学科建设工程资助项目（SZB-2014-37）

作者简介：丁伟（1989–），男，河南省驻马店市人，硕士，助教，主要研究方向为设备振动与故障诊断。
E-mail: cumtdingwei@126.com

械故障诊断领域得到了一定的应用[3]。程军圣等[4]人在齿轮、滚动轴承故障诊断过程中，发现了振动信号的故障特征信息，提出了基于LMD与神经网络的诊断算法。Chen等在样本熵的基础上提出了模糊熵算法，模糊熵和样本熵均是用来表征多维数下信号生成新序列的概率以及时序信号复杂程度[5]。而由于模糊熵利用隶属度函数替代了样本熵运算中硬阈值判据，降低了熵值计算中模糊熵随参数变换的敏感程度。同时，分析信号在单一尺度层面上存在单一性，多尺度算法具有高效率、收敛性好和精度较高等优点[6]，广泛应用于语言识别领域的HMM，作为一种信号动态模式分析的统计工具，目前在故障诊断领域也得到了广泛应用[7-8]。因此，考虑基于信号的LMD与多尺度模糊熵相结合的敏感特征提取手段，结合HMM识别模型对轴承类型进行诊断识别。

1 故障诊断关键技术

1.1 局部均值分解

LMD作为一种信号自适应分解方法，利用原信号的所有局部极值点来求解得出全部的局部均值与包络估计值，将信号分解为一系列AM-FM信号，为具有物理意义的PF分量之和[3]。LMD的分解流程如图1所示。

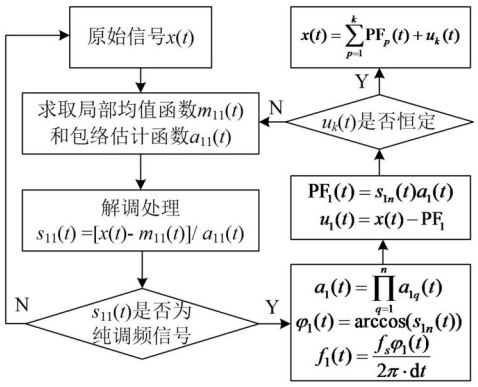


图1 LMD分解流程图

在轴承故障期，其振动信号包含了一些调制现象和低频冲击脉冲，利用LMD算法能有效地将其中包含故障特征的调制信息解调出来。为了进一步提取出振动信号中所包含的故障特征信息，下一步研究信号自身熵的特征提取方法。

1.2 多尺度模糊熵

由于模糊熵利用隶属度函数替代了样本熵运算中硬阈值判据，降低了熵值计算中模糊熵对参数变换的敏感程度，而且由于运算前模糊熵对信号作了均一化处理，避免了信号出现基线漂移的现象[6]。样本类间距离对度量特征向量间可分性起着重要的作用，分析多尺度模糊熵特征类间距离，类间距离越大，表明提取得到的特征向量可分性越好，更有利于进行模式识别。本文以各状态的类间最大平均距离为标准，选择最优的尺度因子进行后续分析。多尺度模糊熵计算过程如下：

首先，粗粒化计算所给时序信号$X=\{x_1、x_2、\cdots、x_N\}$，接着计算各尺度下的新数据$Y=\{y_j^{(\tau)}\}$的模糊熵值。

$$y_j^{(\tau)}=\frac{1}{\tau}\sum_{i=(j-1)\tau+1}^{j\tau}x_i;\quad 1\leqslant j\leqslant\frac{N}{\tau} \tag{1}$$

式中：τ称为尺度因子，本文取值为20。上述时间序列从X到Y的转换称为粗粒化。

其次，计算各个信号模糊熵，其过程为：

(1) 对于去均值化之后的时序信号$u_1、u_2、\cdots、u_N$重新构造成一个m维向量，得出一组样本集，新时序信号为

$$x(i)=[u_i,u_{i+1},\cdots,u_{i+m-1}],\ i=1\sim N-m+1 \tag{2}$$

(2) 计算样本集中任意两个不同样本$x(i)$和$x(j)$之间的距离d_{ij}

$$d_{ij}=d[x(i)-x(j)]=\max|u_{i+k}-u_{j+k}|$$
$$0\leqslant k\leqslant m-1;\ j,\ i=1\sim N-\mathrm{m},\ j\neq i \tag{3}$$

(3) 通过模糊函数$\mu(d_{ij}^m,n,r)=e^{-(d_{ij}^m/r)^n}$定义上述样本间的相识度为$D_{ij}(r)$，求其平均值$B_i^m(r)$

$$B_i^m(r)=\frac{1}{N-m-1}\sum_{j=1}^{N-m+1}D_{ij}(r) \tag{4}$$

其中：r和n分别为模糊函数边界的宽度(相似容限)和梯度。定义样本的平均相似度$\phi_m(r)$

$$\phi_m(r)=\frac{1}{N-m}\sum_{i=1}^{N-m}B_i^m(r) \tag{5}$$

(4) 当重构维数等于$m+1$时，根据相同原理可求得$\phi_{m+1}(r)$；

(5) 对原始时序信号模糊熵的定义如下

$$\mathrm{FuzzyEn}(m,n,r,N)=-\ln\frac{\phi_{m+1}(r)}{\phi_m(r)} \tag{6}$$

由于机械运行工况的影响，采集到的振动信号多包含环境噪声，导致低频段的故障特征信息被淹没，多尺度模糊熵具有良好的抗噪和抗干扰性能，结合类间最大平均距离标准能有效提取出原始振动信号中包含的故障特征信息。

1.3 DHMM识别模型

为了对采集到的振动信号进行直观的分析，以提取出来的故障特征信息集为样本，引入隐马尔科夫模型进行轴承状态识别处理。考虑到本文选择的输入样本为离散型数据，故文中HMM特指DHMM。

HMM是在Markov链的基础上发展起来的一个双重随机过程[7]。包含N个隐含状态的HMM数学模型可表示为$\lambda=(A,B,\pi)$，其中π为隐含状态的初始概率分布，$\boldsymbol{A}$是模型隐含状态变化的初始转移概

率分布，$\boldsymbol{B}$是当隐含状态为q_i时的观测值概率矩阵。

应用HMM方法对轴承故障诊断时，轴承的每一种故障类型$\lambda_i(1\leqslant i\leqslant w)$是一个隐含状态，提取出来的多尺度模糊熵对应于HMM中的可见状态序列，设置HMM模型的初始化参数，识别过程如图2所示。

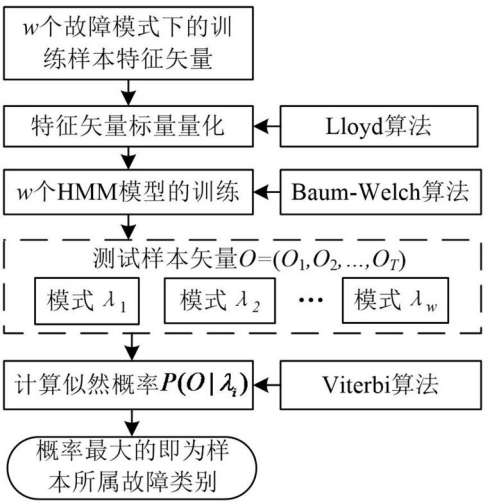


图2 DHMM智能识别过程

2 实验装置及数据采集

在故障模拟实验台上进行实验验证，传感器布置如图3所示。

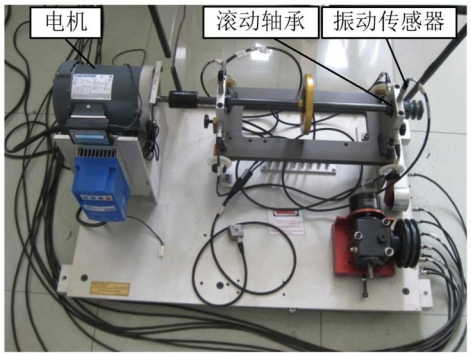


图3 实验传感器布置图

在实验过程中，轴承振动信号的数据通过加速度振动传感器采集，轴承正常状态、内圈点蚀故障、外圈点蚀故障以及滚动体点蚀故障振动信号的模拟通过在实验台上更换相应类型轴承来实现。

设置采样频率为10 kHz，采集得到的轴承振动信号时域图如图4所示。

3 振动信号分析

利用采集到的四种不同状态下轴承的振动信号进行诊断算法研究。由于篇幅有限，以内圈点蚀故障信号为例进行说明，对采集到的内圈点蚀振动信号进行LMD分解，分解得到一个残余分量R和四个PF分量，分解时间为0.105 5 s，分解结果如图5所示。

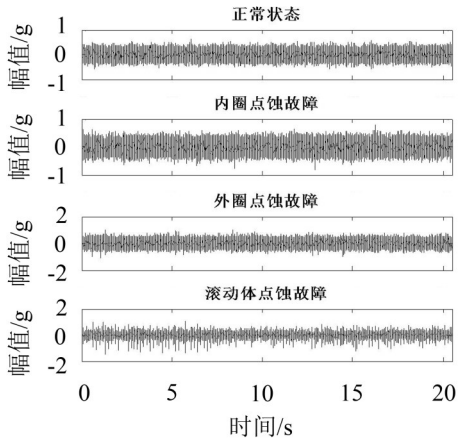


图4 4种状态下轴承振动信号时域图

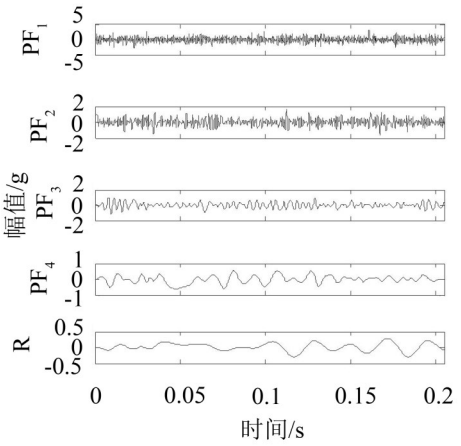


图5 内圈故障振动信号LMD分解结果

所示。

为了分析LMD算法在轴承故障诊断应用中的优越性，把LMD和EMD进行对比。内圈点蚀信号的EMD分解结果如图6所示。

得到9个IMF分量和一个残余分量R，分解时间为0.220 2 s。同时，LMD分解过程中直接得到各PF的瞬时时频，EMD分解后利用Hilbert变换得到各IMF分量的瞬时时频，分析两种算法在端点效应方面的差异性，瞬时时频对比图如图7和图8所示。

从分解层数和分解时间上看，LMD相比于EMD，减少了迭代次数和分解时间，提高了算法的实时性，同时也减少了多次迭代后造成的误差延伸；从瞬时频率曲线来看，LMD分解得到的信号两端波动小，信息保存完整，根据EMD分解得到的时频图上两端波动较大，并且有部分信号缺失。综上所述，本实验验证了LMD在实时性、端点效应抑制和信号保真方面优于EMD。

下面对分解得到的一系列PF分量分别计算多尺度模糊熵特征，在计算模糊熵前需要初始化参数，由于嵌入维数m取值过大会导致需要的数据点过多，因此一般取值为2，与此同时，为了提高抗噪性并

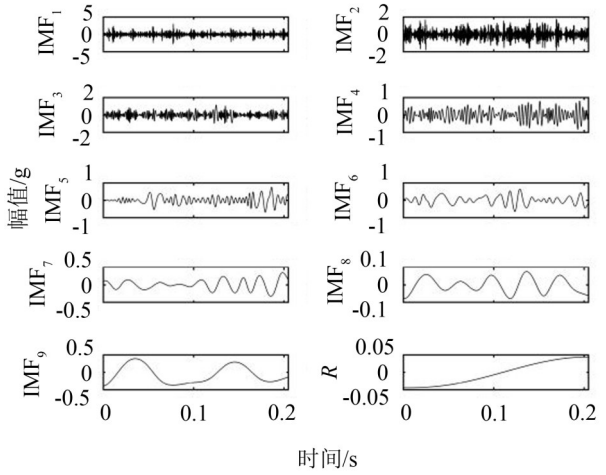


图 6 内圈故障振动信号EMD分解结果

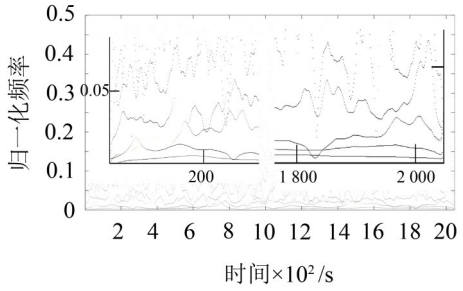


图 7 LMD分解信号瞬时时频图

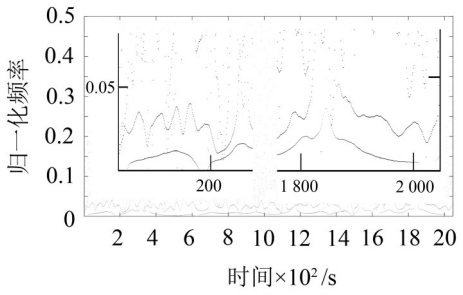


图 8 EMD分解信号瞬时时频图

且较好地保留信号信息，本文对于相似容限取 $r=0.15\sigma$（σ为时序列信号的标准差）、模糊函数边界的宽度n=2。四种轴承状态下信号的多尺度模糊熵值如图9所示。

每种类型各取一个样本。同时，为了说明多尺度模糊熵特征提取算法的优越性，以内圈点蚀故障信号为例进行说明，取3个样本分别计算多尺度模糊熵和多尺度样本熵值并进行对比，如图10所示。

由图9可知，当尺度τ较小时，四种轴承状态下信号的多尺度模糊熵值相对较大，呈现无规律性；而随着尺度τ增大，模糊熵值呈现稳定趋势，各类故障的熵值呈现一定的分层现象，并且故障轴承熵值明显增大。因此不同类型的轴承信号的区分可以通过模糊熵值的变化规律以及趋势反映。

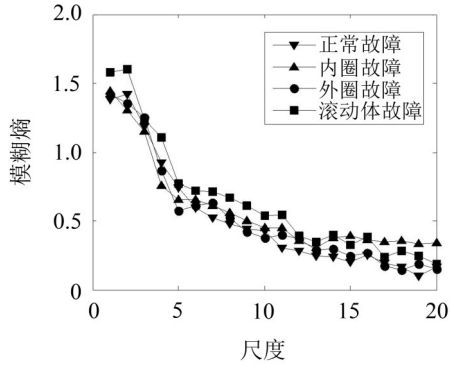


图 9 四种轴承状态信号的多尺度模糊熵值

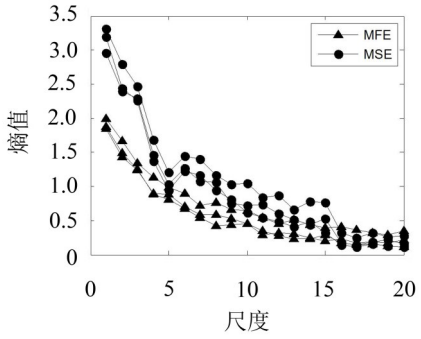


图 10 内圈故障MFE和MSE对比图

从图10可看出，随着尺度τ增加，多尺度模糊熵相比多尺度样本熵，曲线更加平稳和光滑，提取出的特征信息具备更好的稳定性和一致性，证明了多尺度模糊熵相对于多尺度样本熵的优越性。

当尺度因子$\tau=9$时，各故障的类间平均距离最大，为0.778。因此，本文提取出四种轴承信号在$\tau=9$时的模糊熵作为后续识别模型的特征向量。

DHMM建模时采用四个隐含状态，记作λ_1、λ_2、λ_3、λ_4，分别代表正常状态、内圈点蚀故障、外圈点蚀故障以及滚动体点蚀故障状态。模型观测序列是通过计算第9个尺度模糊熵后得出的四维特征向量，选择左右型DHMM模型，初始概率分布矢量$\pi=[1,0,0,0]$；初始状态转移概率矩阵为

$$\boldsymbol{A}=\begin{bmatrix}0.5 & 0.5 & 0 & 0\\ 0 & 0.5 & 0.5 & 0\\ 0 & 0 & 0.5 & 0.5\\ 0 & 0 & 0 & 1\end{bmatrix}$$

基于DHMM识别模型初始观测值概率$\boldsymbol{B}$的设置可以选择随机方式初始化概率值，也可以选择均匀方式初始化概率值。本文$\boldsymbol{B}$在MATLAB中利用函数rand随机得到。

将从轴承信号中提取的多尺度模糊熵特征信息作为多观察样本序列，DHMM识别模型的训练样本从四种状态各75组共300组特征向量中随机选择。本文迭代次数选取为50，收敛误差为1×10^{-4}。在DHMM训练过程中，针对最大似然概率$P(O|\lambda)$太

小的问题，计算其对数值$\lg P(O|\lambda)$。四种轴承状态下的DHMM训练曲线如图11所示，由图可知伴随训练迭代次数的增加，得出的最大对数似然概率值也在不断增大。

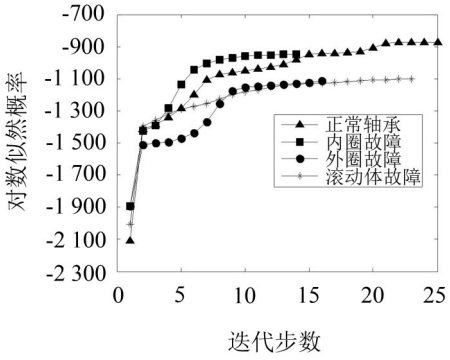


图11 四种轴承状态下的DHMM训练曲线

在完成四种DHMM识别模型训练后，将剩余的100组多尺度熵特征向量输入到完成训练的DHMM模型中测试，观察样本的推理概率通过Viterbi算法来近似计算。对于训练好的DHMM识别模型，认定样本类型等同于给定模型的类型，若计算得到的观察样本对数似然概率值大，则说明该样本与给定模型的相似程度高。根据DHMM状态识别模型，LMD-MFE和LMD-MSE两种算法下四种轴承状态下测试样本的识别率统计结果如表1和表2所示。

表1 四种状态下轴承模糊熵特征识别结果统计

状态	正常	内圈	外圈	滚动体	识别率/(%)
正常	24	1	0	0	96
内圈	0	23	1	0	92
外圈	1	0	24	0	96
滚动体	0	0	0	25	100

表2 四种状态下轴承样本熵特征识别结果统计

状态	正常	内圈	外圈	滚动体	识别率/(%)
正常	24	1	0	0	96
内圈	0	23	1	0	92
外圈	1	1	23	0	92
滚动体	1	0	0	24	96

对比表1和表2可知，LMD-MFE特征提取算法比LMD-MSE算法多正确识别出一个外圈故障和一个滚动体故障类型轴承，基于LMD-MFE算法的轴承类型总体正确识别率要高于LMD-MSE算法，证实了LMD-MFE算法的优越性。在每组25个测试样本中，正常类型中存在一个样本被错误识别为内圈点蚀类型，内圈点蚀类型中存在1个样本被错误地识别为外圈点蚀类型，外圈点蚀类型中存在一个样本被错误识别为正常类型。实验数据表明，基于LMD-MFE和DHMM的滚动轴承故障诊断算法对四种类型轴承状态的总体识别正确率达到92 %，表明该算法对于滚动轴承故障诊断是有效的。

4 结 语

本文采用基于LMD和多尺度模糊熵的滚动轴承故障诊断方法，对采集到的振动信号进行LMD分解，通过与EMD算法进行对比分析，发现LMD在实时性、端点效应抑制和信号保真方面要优于EMD；然后计算得到四种轴承类型信号的各个PF分量的多尺度模糊熵特征，与多尺度样本熵进行对比分析，从稳定性和一致性方面证明了多尺度模糊熵的优越性；同时以类间最大平均距离为准则，选择$\tau=9$时的模糊熵作为信号敏感特征集，最后基于DHMM识别模型对各个轴承类型进行诊断识别。实验研究表明，基于LMD-MFE和DHMM的滚动轴承故障诊断算法对四种类型轴承状态的总体识别正确率达到92 %，表明该算法对于滚动轴承故障诊断是有效的。

参考文献：

[1] 王平，廖明夫. 滚动轴承故障诊断的自适应共振解调技术[J]. **航空动力学报**，2005，20(4)：606-612.

[2] SMITH JS. The local mean decomposition and its application to EEG perception data[J]. **Journal of the Royal Society Interface**, 2005, 2(5): 443-454.

[3] 程军圣，张亢，杨宇. 局部均值分解方法在调制信号处理中的应用[J]. **振动、测试与诊断**，2010，30(4)：362-365.

[4] 张亢，程军圣，杨宇. 基于局部均值分解与形态谱的旋转机械故障诊断方法[J]. **振动与冲击**，2013，32(9)：135-140.

[5] CHEN WT, ZHUANG J, YU WX, et al. Measuring complexity using FuzzyEn, ApEn, and SampEn[J]. **Medical Engineering and Physics**, 2009, 31(1): 61-68.

[6] 郑近德，陈敏均，程军圣，等. 多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. **振动工程学报**，2014，27(1)：145-151.

[7] 孟宗，闫晓丽，王亚超. 基于LMD和HMM的旋转机械故障诊断[J]. **机械工程学报**，2014，25(21)：2942-2946.

[8] 赵荣珍，于昊，徐继刚. 基于LMD近似熵与HMM的转子故障诊断方法[J]. **兰州理工大学学报**，2012，38(6)：24-29.