

文章编号:1671-251X(2021)01-0074-08

DOI:10.13272/j.issn.1671-251x.2020070070

自适应局部迭代滤波在齿轮故障识别中的应用

郭德伟^{1,2}, 普亚松^{1,2}, 江洁^{1,2}, 俞利宾^{1,2}, 闵洁^{1,2}, 张文斌^{1,2}

(1.红河学院 工学院,云南 蒙自 661199;

2.云南省高校高原机械性能分析与优化重点实验室,云南 蒙自 661199)



扫码移动阅读

摘要:针对齿轮实测信号因受噪声干扰而不能准确反映故障特征的问题,提出将自适应局部迭代滤波应用到齿轮故障识别中,与样本熵、灰色关联度相结合实现齿轮的故障识别。利用自适应局部迭代滤波将齿轮非平稳信号分解为有限个平稳的本质模态函数,通过计算各本质模态函数的样本熵,发现以齿轮系统的转频信号对应的本质模态函数的样本熵为界,前几个本质模态函数的样本熵能表征不同故障类型的特征;计算齿轮系统正常、齿面轻度磨损、齿面中度磨损和断齿 4 种工况下多个训练样本的样本熵的平均值,将其作为对应工况标准故障模式的参考值;计算待检测样本的样本熵与各状态下训练样本的样本熵平均值之间的灰色关联度,与待识别样本灰色关联度最大的标准故障模式即被认为是待识别样本的故障类型。实例分析结果表明,通过自适应迭代滤波能有效抑制模态混叠现象,发现明显的齿轮转频信号,而采用集合经验模式分解(EEMD)方法进行信号分解后,模态混叠现象比较明显,且在 EEMD 的分解结果中基本看不出齿轮的转频分量;4 种工况的样本熵曲线形状存在明显差异,说明样本熵能有效表征齿轮故障特征的变化;灰色关联度方法能有效地将 4 种不同的故障类型进行分类识别,分类识别性能优于 BP 神经网络,对小样本数据具有较好的分类识别能力。

关键词:齿轮故障识别;自适应局部迭代滤波;样本熵;灰色关联度;转频信号

中图分类号:TD67 文献标志码:A

Application of adaptive local iterative filtering in gear fault identification

GUO Dewei^{1,2}, PU Yasong^{1,2}, JIANG Jie^{1,2}, YU Libin^{1,2}, MIN Jie^{1,2}, ZHANG Wenbin^{1,2}

(1.College of Engineering, Honghe University, Mengzi 661199, China; 2.Key Laboratory of Mechanical Performance Analysis and Optimization of Plateau in Yunnan Province, Mengzi 661199, China)

Abstract:In order to solve the problem that the measured signal of gears cannot accurately reflect the fault characteristics due to noise interference, adaptive local iterative filtering is proposed to be applied to gear fault identification, which is combined with sample entropy and grey correlation to realize gear fault identification. By using adaptive local iterative filtering to decompose the gear non-stationary signal into a finite number of stationary intrinsic mode functions, and calculating the sample entropy of each intrinsic mode function, it is found that the sample entropy of the first few intrinsic mode functions can represent different fault types, bounded by the sample entropy of the intrinsic mode function corresponding to the frequency conversion signal of the gear system. The average value of the sample entropy of multiple training samples under four working conditions of gear system, including normal, mild tooth surface wear, moderate tooth surface wear and broken tooth, is calculated and used as the reference value of the standard

收稿日期:2020-07-21;修回日期:2020-12-19;责任编辑:胡娴。

基金项目:国家自然科学基金资助项目(51769007);云南省地方本科高校基础研究联合专项重点项目(2019FH001-007);云南省高校重点实验室建设计划资助项目(2018ZD022)。

作者简介:郭德伟(1978—),男,云南通海人,副教授,硕士,主要研究方向为模式识别与智能诊断,E-mail:28657983@qq.com。通信作者:张文斌(1981—),男,云南建水人,教授,博士,主要研究方向为模式识别与智能诊断,E-mail:georgezwb@sohu.com。

引用格式:郭德伟,普亚松,江洁,等.自适应局部迭代滤波在齿轮故障识别中的应用[J].工矿自动化,2021,47(1):74-80.

GUO Dewei,PU Yasong,JIANG Jie,et al. Application of adaptive local iterative filtering in gear fault identification[J]. Industry and Mine Automation,2021,47(1):74-80.

failure mode of the corresponding working condition. The grey correlation between the sample entropy of the sample to be detected and the average value of the sample entropy of the training samples under each condition is calculated, and the standard failure mode with the largest grey correlation with the sample to be identified is considered as the failure type of the sample to be identified. The results of the case analysis show that the adaptive iterative filtering can suppress the modal aliasing phenomenon effectively and find obvious gear frequency conversion signals. On the other hand, the modal aliasing phenomenon is more obvious after the signal decomposition by EEMD method, and the frequency conversion component of the gear is basically invisible in the decomposition results of EEMD method. The obvious differences in the shapes of the sample entropy curves of the four working conditions indicate that the sample entropy can represent the changes of gear fault characteristics effectively. The grey correlation method, which can classify and identify the four different fault types effectively, has better classification identification performance than that of BP neural network and has better classification identification ability for small sample data.

Key words:gear fault identification; adaptive local iterative filtering; sample entropy; grey correlation degree; frequency conversion signal

0 引言

齿轮箱是机械设备中进行运动和动力传动的主要部件。在齿轮传动过程中,齿轮的失效常常会诱发机器故障,进而引发设备停机甚至损坏,因此,研究强噪声环境下的齿轮故障特征参数提取技术一直是旋转机械故障诊断的研究热点^[1-2]。N. E. Huang等^[3]提出的经验模式分解方法吸引了众多学者的关注,它从传统的正交基函数展开,跨越到完全由数据驱动的对任意复杂信号具有自适应能力的信号表示。但是,经验模式分解方法存在如信号中的奇异点容易导致模式混淆、在噪声干扰下不稳定等问题。集合经验模式分解(Ensemble Empirical Mode Decomposition, EEMD)方法在对白噪声进行经验模式分解的基础上,将白噪声加入信号来补充一些缺失的尺度,可较好地减轻模态混叠现象,但仍然不能有效地消除模态混叠现象。在经验模式分解思想的启发下,一些学者提出了新的自适应模式分解方法,自适应局部迭代滤波^[4]就是其中比较有代表性的一种。自适应局部迭代滤波方法在保留经验模式分解方法思想的基础上,通过引入 Fokker-Planck 方程设计滤波器的方式,有效避免了在分解过程中产生虚假分量,更加适用于分析非线性非平稳信号。自适应局部迭代滤波方法已被应用于电力系统非平稳信号的特征提取^[5]、滚动轴承的故障特征提取^[6]中,取得了较好效果。但在齿轮系统的故障特征提取中应用自适应局部迭代滤波方法的研究还比较少。

针对现场采集信号往往包含大量的噪声干扰而无法准确反映故障特征的问题,提出将自适应局部

迭代滤波、样本熵和灰色关联度相结合的齿轮故障识别方法。在齿轮箱模拟实验平台上对齿轮系统的4种不同工况进行实验,采用自适应局部迭代滤波对采样信号进行自适应分解,计算分解得到的各本质模态函数分量的样本熵^[7],再计算待识别样本与标准故障模式的灰色关联度,根据灰色关联度进行故障识别和分类。

1 自适应局部迭代滤波

在经验模式分解中,瞬时均值定义为上下包络的均值函数。因为应用对奇异点敏感的三次样条分别连接局部极大值和局部极小值来拟合上下包络,所以这种瞬时均值在扰动下不稳定。为了克服该缺陷,L. Lin等^[8]提出了迭代滤波算法。该算法遵循和经验模式分解相同的算法框架,通过对信号进行低通滤波获得瞬时均值。为了保证扰动下的稳定性和收敛性,迭代滤波应用均一的双重长度的平均滤波器。但是,这种滤波器不够平滑,可能会在本质模态函数中引起虚假波动。自适应局部迭代滤波算法应用非均一滤波器拓展迭代滤波算法,将滤波器设计为 Fokker-Planck 方程(式(1)),使得滤波器在时域内具有紧致支撑且长度灵活变化,避免在迭代滤波过程中产生虚假波动^[9]。

$$\frac{\partial}{\partial z}g(h,z)=-\alpha\frac{\partial}{\partial h}[p(h,z)g(h,z)]+\beta\frac{\partial^2}{\partial h^2}[q^2(h,z)g(h,z)]\tag{1}$$

式中: h 为信号长度; z 为设定参数,取值范围为 $1.6\sim 2$; $g(h,z)$ 为滤波函数; α,β 为稳态系数,取值范围为 $(0,1)$; $p(h,z)$ 和 $q(h,z)$ 为光滑可导函数。

自适应局部迭代滤波算法实现过程:

(1) 初始化:令迭代次数 $i=1$,残余信号 $r_0(t)=x(t)$, $x(t)$ 为采样信号, t 为采样时间。

(2) 提取第 i 个本质模态函数 $c_i(t)$ 。

(3) 更新残余信号 $r_i(t)$:

$$r_i(t) = r_{i-1}(t) - c_i(t) \quad (2)$$

(4) 若残余信号 $r_i(t)$ 满足算法的终止准则,即最多只有一个极值点而成为趋势项时,终止自适应局部迭代滤波分解;否则令迭代次数 $i=i+1$,返回步骤(2)。

提取第 i 个本质模态函数的具体实现步骤:

(1) 令筛选次数 $j=0$,原型本质模态函数

$$h_{ij}(t)=r_{i-1}(t)。$$

(2) 设计自适应局部 Fokker-Planck 滤波器 $g_{ij}(t,\tau)$ (τ 为 t 的无穷小量),确定相应的时变滤波器长度 $l_{ij}(t)$ 。

(3) 计算瞬时均值 $m_{ij}(t)$:

$$w_{ij}(t) = \int_{-l_{ij}(t)}^{l_{ij}(t)} h_{ij}(t+\tau) g_{ij}(t,\tau) d\tau \quad (3)$$

(4) 更新原型本质模态函数:

$$h_{ij}(t) = h_{ij}(t) - w_{ij}(t) \quad (4)$$

(5) 若原型本质模态函数 $h_{ij}(t)$ 满足本质模态函数的条件要求,则用式(5)设置第 i 个本质模态函数;否则令筛选次数 $j=j+1$,返回步骤(2)。

$$c_i(t) = h_{ij}(t) \quad (5)$$

2 样本熵的定义

样本熵常用于衡量非线性时间序列的复杂度,其具备抗干扰能力强、在参数较大取值范围内一致性好等特性,便于进行故障特征的提取。设采样序列为 $x(1), x(2), \dots, x(N)$, 共 N 个样本,样本熵^[10-12]计算方法如下。

按序号连续抽取 m 个数据构造一组 m 维向量 $\mathbf{X}(i)$:

$$\mathbf{X}(i) = [x(i), x(i+1), \dots, x(i+m-1)] \quad (i = 1, 2, \dots, N-m+1) \quad (6)$$

m 维空间中 $\mathbf{X}(i)$ 与 $\mathbf{X}(j)$ 之间的距离为

$$d[\mathbf{X}(i), \mathbf{X}(j)] = \max_{k=0,1,\dots,m-1} |x(i+k) - x(j+k)| \quad (j = 1, 2, \dots, N-m+1) \quad (7)$$

给定阈值 u ($u>0$),对每一个 $i \leq N-m+1$, 可得

$$B_i^m(u) = \frac{\text{num}\{d[\mathbf{X}(i), \mathbf{X}(j)] < u\}}{N-m} \quad (8)$$

$$B_m(u) = \frac{\sum_{i=1}^{N-m+1} B_i^m(u)}{N-m+1} \quad (9)$$

式中: $B_i^m(u)$ 为模板匹配数与总向量个数的比值;

$B_m(u)$ 为所有 $B_i^m(u)$ 的平均值。

将维数 m 加 1,重复以上步骤,可得样本熵:

$$\text{SampEn}(m, u) = \lim_{N \rightarrow \infty} \left[-\ln \frac{B_{m+1}(u)}{B_m(u)} \right] \quad (10)$$

当 N 为有限值时,样本熵的估计值为

$$\text{SE}(m, u) = -\ln \frac{B_{m+1}(u)}{B_m(u)} \quad (11)$$

显然,参数 m 和 u 直接影响样本熵的值。根据 S. M. Pincus^[13] 的研究成果,本文中取 $m=2, u=0.2\text{Std}$, Std 为标准差。

3 齿轮故障识别步骤

(1) 搭建齿轮系统故障实验平台,进行故障模拟实验。

(2) 采集不同工况下的齿轮故障信号。

(3) 对采样信号进行自适应局部迭代滤波分解,得到若干个本质模态函数。

(4) 选择前 m 个包含齿轮故障信息的本质模态分量作为研究对象,求取样本熵。

(5) 求出同类状态下 N 个训练样本的样本熵的平均值,将其作为标准故障模式的参考值。

(6) 计算待检测信号的样本熵与各状态下的标准故障模式样本熵平均值的灰色关联度,进行故障分类识别。

在齿轮实验系统中模拟不同工况的故障状态。采用灰色关联度进行故障类型识别,用灰色关联度识别的详细过程可参见作者前期的研究成果^[14-15]。

4 实测信号分析

4.1 自适应局部迭代滤波结果

在齿轮箱模拟实验平台上采集齿轮系统正常、齿面轻度磨损、齿面中度磨损和断齿 4 种工况下的数据,用于检测本文提出的方法在齿轮故障识别中的实际效果。实验台由变速驱动电动机、轴系总成、齿轮箱、加载装置等组成,如图 1 所示。被试齿轮转速为 $f_r=23.6$ Hz,啮合频率为 $f_z=686$ Hz,振动信号的采样频率为 16 384 Hz。




图 1 齿轮故障识别实验平台

Fig. 1 Experiment platform of gear fault identification

分别对 4 种齿轮工况进行采样,各取 20 个样

本,以齿面轻度磨损故障信号为例,利用自适应局部迭代滤波对采样信号进行自适应分解,得到 10 个 IMF(本征模式函数)分量 $\text{IMF}_1\text{—}\text{IMF}_{10}$ 和 1 个残余分量,如图 2 所示,其中 a 为加速度。从图 2 可知,自适应局部迭代滤波把非平稳的齿轮故障信号分解为若干个平稳的 IMF 分量,齿面轻度磨损故障的特征主要集中在 IMF_1 分量上。在 IMF_8 分量中可看出较明显的周期成分,计算该成分的频率可知,该成分对应齿轮的转频信号。






图 2 齿轮轻度磨损自适应局部迭代滤波分解结果
Fig. 2 Adaptive local iterative filtering decomposition results of mild wear signal of gear

为便于比较,采用 EEMD 方法对同一信号进行自适应分解,结果如图 3 所示。在 EEMD 分解中,多个 IMF 分量均存在故障特征,这说明虽然 EEMD 方法通过在分解过程中添加噪声来减轻模态混叠程度,但与自适应局部迭代滤波分解相比,模态混叠现象还比较明显。为便于比较,对 2 种分解结果的前 8 个 IMF 分量设置相同的纵坐标范围,由于幅值波动小的模态混叠程度较轻,可以明显看出, EEMD 方法的分解结果波动范围比较大,而且在 EEMD 的







图 3 齿面轻度磨损 EEMD 分解结果

Fig. 3 EEMD results of mild wear signal of gear
分解结果中基本看不出齿轮的转频分量。这也充分说明自适应迭代滤波能有效抑制模态混叠现象。

4.2 样本熵计算

随机抽取每种状态的 10 个样本作为训练样本，根据齿轮故障识别步骤，将每种状态分解得到的 10 个本质模态函数作为采样序列，分别代入式(6)一式(11)进行样本熵计算。计算 10 个训练样本的样本熵平均值，结果如图 4 所示。从图 4 可看出，4 种工况的样本熵曲线形状存在明显差异，这对于后续进行故障分类识别十分有利。仔细观察样本熵曲线还可发现，每种工况的最后 3 个样本熵值很小且变化趋于平缓；由于 IMF₈ 对应齿轮转频，表明齿轮的故障信息主要包含于前 7 个 IMF 中，这说明样本熵能有效表征齿轮故障特征的变化。取前 7 个 IMF 分量的样本熵作为故障特征，采用灰色关联度方法对不同故障类型进行分类识别。




图 4 齿轮不同工况下的样本熵分布曲线

Fig. 4 Sample entropy distribution curves of gear under different working conditions

限于篇幅，从每种工况的剩余 10 个样本中随机抽取 5 个作为待检测样本，同样作为采样序列，分别代入式(6)一式(11)进行样本熵计算，得到前 7 个 IMF 信号的样本熵 SE₁—SE₇，结果见表 1。

4.3 灰色关联度计算

用灰色关联度方法计算待检测样本的样本熵与各状态下训练样本的样本熵平均值之间的灰色关联

表 1 齿轮不同工况下的样本熵

Table 1 Sample entropy of gear under different working conditions

工况	序号	SE ₁	SE ₂	SE ₃	SE ₄	SE ₅	SE ₆	SE ₇
正常	1	1.291 2	0.913 4	0.578 0	0.577 0	0.391 7	0.168 5	0.071 8
	2	1.276 8	0.870 3	0.593 0	0.585 7	0.391 7	0.173 7	0.073 3
	3	1.275 2	0.865 2	0.585 0	0.591 7	0.430 5	0.172 1	0.070 6
	4	1.310 0	0.888 0	0.580 8	0.573 3	0.397 2	0.171 6	0.077 1
	5	1.359 0	0.899 8	0.597 7	0.560 1	0.418 0	0.174 8	0.068 8
齿面轻度磨损	1	1.653 6	0.628 8	0.635 9	0.585 1	0.467 3	0.197 8	0.083 5
	2	1.625 4	0.649 3	0.633 0	0.580 7	0.463 6	0.188 7	0.083 2
	3	1.668 4	0.652 5	0.644 5	0.584 2	0.443 6	0.180 1	0.087 0
	4	1.668 8	0.669 5	0.649 9	0.574 3	0.473 9	0.188 5	0.083 5
	5	1.677 9	0.664 1	0.635 9	0.591 9	0.487 4	0.184 3	0.081 6
齿面中度磨损	1	1.647 8	0.786 0	0.702 4	0.591 8	0.475 3	0.188 9	0.107 1
	2	1.671 4	0.806 2	0.696 2	0.585 7	0.471 1	0.192 2	0.092 9
	3	1.697 6	0.808 6	0.693 8	0.586 2	0.475 8	0.192 8	0.110 6
	4	1.664 1	0.813 5	0.705 0	0.603 5	0.474 4	0.186 3	0.101 0
	5	1.674 6	0.819 2	0.709 0	0.602 2	0.487 5	0.198 1	0.122 0
断齿	1	1.092 1	0.584 6	0.535 3	0.552 4	0.493 2	0.206 3	0.092 8
	2	1.045 6	0.519 6	0.550 2	0.551 8	0.494 4	0.184 5	0.109 4
	3	1.143 3	0.526 8	0.580 8	0.568 6	0.513 4	0.190 4	0.089 7
	4	1.141 1	0.587 8	0.540 6	0.534 4	0.432 5	0.181 5	0.096 2
	5	1.107 2	0.605 8	0.560 6	0.547 1	0.491 0	0.178 1	0.108 8

度。根据关联度的值进行齿轮故障模式的分类识别,与待识别样本灰色关联度最大的标准故障模式即被认为是待识别样本的故障类型。灰色关联度计算结果及故障识别结果见表 2。

从表 2 可看出,齿轮故障模式识别效果显著,尤其是齿面轻度磨损故障和齿面中度磨损故障。由图 4 可知,两者的样本熵曲线类似,而从表 1 的样本熵值可以看到,两者的区别仅在于第 2 个和第 3 个样本熵值,但灰色关联度方法能有效地将 4 种不同的故障类型进行分类识别,相应故障类型的灰色关联度与其余故障类型的灰色关联度之间的差值较大。对剩余的故障样本进行识别,也能得到正确的分类结果。

4.4 对比分析

为测试灰色关联度方法是否适合小样本数据的分类识别,将常用的 BP 神经网络与灰色关联度方法进行对比。将每种工况的 20 组数据进行平分,一半作为训练样本,一半作为测试样本,2 种方法的识别结果见表 3。可见,灰色关联度方法的分类识别性能优于 BP 神经网络,对小样本数据具有较好的分类识别能力。

表 2 待检测样本与标准故障模式的灰色关联度

Table 2 Grey incidence between samples to be tested and standard fault patterns

样本 编号	灰色关联度				识别 结果
	正常	齿面轻度磨损	齿面中度磨损	断齿	
1	0.966 2	0.647 9	0.634 1	0.656 1	正常
2	0.921 4	0.642 7	0.657 0	0.644 7	正常
3	0.912 2	0.646 1	0.661 7	0.642 9	正常
4	0.929 4	0.658 8	0.635 9	0.653 8	正常
5	0.928 6	0.665 6	0.654 2	0.662 4	正常
6	0.578 9	0.934 4	0.715 2	0.623 7	齿面轻度磨损
7	0.589 8	0.947 7	0.686 3	0.629 5	齿面轻度磨损
8	0.611 4	0.922 9	0.691 9	0.611 5	齿面轻度磨损
9	0.600 7	0.939 6	0.745 9	0.659 4	齿面轻度磨损
10	0.599 4	0.921 1	0.719 5	0.649 4	齿面轻度磨损
11	0.606 5	0.740 1	0.928 9	0.683 0	齿面中度磨损
12	0.634 0	0.753 5	0.925 9	0.667 1	齿面中度磨损
13	0.623 3	0.722 3	0.936 2	0.679 1	齿面中度磨损
14	0.608 5	0.738 8	0.908 1	0.649 4	齿面中度磨损
15	0.658 0	0.730 4	0.912 1	0.691 0	齿面中度磨损
16	0.621 3	0.666 2	0.638 7	0.885 9	断齿
17	0.712 4	0.750 6	0.743 8	0.875 0	断齿
18	0.722 8	0.759 5	0.700 2	0.894 5	断齿
19	0.642 7	0.651 9	0.617 3	0.872 5	断齿
20	0.616 3	0.644 1	0.662 9	0.893 8	断齿

表 3 BP 神经网络与灰色关联度分类识别性能对比

Table 3 Classification identification performance comparison of BP network and grey incidence

识别方法	训练样本数	测试样本数	识别精度/%			
			正常	齿面轻度磨损	齿面中度磨损	断齿
BP 神经网络	10	10	100	70	80	100
灰色关联度	10	10	100	100	100	100

5 结论

(1) 与 EEMD 方法的对比分析结果表明,采用自适应局部迭代滤波后,能够发现明显的齿轮转频信号,而采用 EEMD 方法进行信号分解后,模态混叠现象比较明显,且在 EEMD 的分解结果中基本看不出齿轮的转频分量,说明自适应迭代滤波能有效抑制模态混叠现象。

(2) 样本熵计算结果表明,4 种工况的样本熵曲线形状存在明显差异,每种工况的最后 3 个样本熵值很小且变化趋于平缓;由于 IMF8 对应齿轮转频,表明齿轮的故障信息主要包含于前 7 个 IMF 中,这说明样本熵能有效表征齿轮故障特征的变化。

(3) 灰色关联度方法能有效对 4 种不同的故障类型进行分类识别,相应故障类型的灰色关联度与其余故障类型的灰色关联度之间的差值较大。对比分析结果表明,灰色关联度方法的分类识别性能优于 BP 神经网络,对小样本数据具有较好的分类识别能力。

参考文献(References):

[1] 王细洋,孔志高,董海,等. 基于自回归模型的齿轮轴破损诊断[J]. 机械工程学报,2009,45(4):265-272.
WANG Xiyang, KONG Zhigao, DONG Hai, et al. Autoregressive model-based gear shaft fault diagnosis [J]. Journal of Mechanical Engineering, 2009, 45(4): 265-272.

[2] 彭富强,于德介,武春燕. 基于多尺度线调频基稀疏信号分解的包络解调方法及其在齿轮故障诊断中的应用[J]. 机械工程学报,2010,46(12):1-7.
PENG Fuqiang, YU Dejie, WU Chunyan. AM-FM signal extraction method by the sparse signal decomposition based on multi-scale chirplet and its application to gear fault diagnosis [J]. Journal of Mechanical Engineering, 2010, 46(12): 1-7.

[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 A, 1998, 454(1971):903-995.

[4] CICONI A, LIU J, ZHOU H. Adaptive local iterative filtering for signal decomposition and instantaneous frequency analysis [J]. Applied and Computational Harmonic Analysis, 2016, 41(2):384-411.

[5] 杨德友,王博,蔡国伟,等. 适用于电力系统非平稳功率振荡信号特征提取的自适应迭代滤波算法研究[J]. 中国电机工程学报,2016,36(20):5431-5439.
YANG Deyou, WANG Bo, CAI Guowei, et al. Extracting oscillation modes from nonstationary signals for power system using adaptive local iterative filter[J]. Proceedings of the CSEE, 2016, 36(20): 5431-5439.

[6] 陈保家,汪新波,赵春华,等. 基于自适应局部迭代滤波和能量算子解调的滚动轴承故障特征提取[J]. 南京理工大学学报,2018,42(4):445-452.
CHEN Baojia, WANG Xinbo, ZHAO Chunhua, et al. Fault feature extraction of rolling bearing based on ALIF and energy operator demodulation[J]. Journal of Nanjing University of Science and Technology, 2018, 42(4):445-452.

[7] 来凌红,吴虎胜,吕建新,等. 基于 EMD 和样本熵的滚动轴承故障 SVM 识别[J]. 煤矿机械,2011,32(1):249-252.
LAI Linghong, WU Husheng, LYU Jianxin, et al. SVM recognition method based on EMD and sample entropy in rolling bearing fault diagnosis [J]. Coal Mine Machinery, 2011, 32(1):249-252.

[8] LIN L, WANG Y, ZHOU H. Iterative filtering as an alternative algorithm for empirical mode decomposition [J]. Advances in Adaptive Data Analysis, 2009, 1(4):543-560.

[9] 冯志鹏,褚福磊,左明健. 机械系统复杂非平稳信号分析方法原理及故障诊断应用[M]. 北京:科学出版社,2019.
FENG Zhipeng, CHU Fulei, ZUO Mingjian. Principles and fault diagnosis application of complex non-stationary signal analysis methods of mechanical systems[M]. Beijing: Science Press, 2019.

[10] ALCARAZ R, RIETA J J. A review on sample entropy applications for the non-invasive analysis of atrial fibrillation electrocardiograms [J]. Biomedical Signal Processing and Control, 2010, 5(1):1-14.

[11] RICHMAN J S, MOORMAN R J. Physiological time-series analysis using approximate entropy and sample entropy[J]. American Journal of Physiology-Heart and Circulatory Physiology, 2000, 278:2039-2049.

[12] 赵志宏,杨绍普. 一种基于样本熵的轴承故障诊断方

- 法[J]. 振动与冲击, 2012, 31(6): 136-140.
- ZHAO Zhihong, YANG Shaopu. Sample entropy-based roller bearing fault diagnosis method [J]. Journal of Vibration and Shock, 2012, 31 (6): 136-140.
- [13] PINCUS S M. Assessing serial irregularity and its implications for health[J]. Annals of the New York Academy of Sciences, 2000, 954: 245-267.
- [14] 张文斌, 江洁, 俞利宾, 等. 互补集合经验模式分解与奇异值能量谱在风电齿轮故障识别中的应用[J]. 太阳能学报, 2020, 41(2): 137-143.
- ZHANG Wenbin, JIANG Jie, YU Libin, et al. Application of complementary ensemble empirical mode decomposition and singular value energy spectrum in wind power gear fault identification[J]. Acta Energiæ Solaris Sinica, 2020, 41(2): 137-143.
- [15] 张文斌, 郭德伟, 普亚松, 等. 谐波窗分解样本熵与灰色关联度在转子故障识别中的应用[J]. 中国电机工程学报, 2013, 33(21): 132-137.
- ZHANG Wenbin, GUO Dewei, PU Yasong, et al. Harmonic window decomposition sample entropy and grey relation degree in rotor fault recognition [J]. Proceedings of the CSEE, 2013, 33(21): 132-137.