

应用时频图像纹理特征的行星齿轮故障诊断*

崔宝珍^{1,2}, 王 斌^{1,3}, 任 川¹, 彭智慧¹, 王浩楠¹, 王泽兵¹

(1. 中北大学机械工程学院 太原, 030051)

(2. 中北大学先进制造技术山西省重点实验室 太原, 030051)

(3. 晋西铁路车辆有限责任公司 太原, 030027)

摘要 行星齿轮箱结构复杂, 当发生故障时其振动信号呈非线性非平稳特点且故障信号微弱, 为了能够准确提取行星齿轮磨损故障信息的特征, 提出局部均值分解(local mean decomposition, 简称LMD)结合S变换(LMD-S)的信号处理方法, 且转化为时频分布图像, 应用时频图像纹理特征进行行星齿轮故障诊断。首先, 把振动信号经由LMD-S变换处理后利用相关分析方法滤除干扰且转化为时频分布图像; 其次, 利用非均匀局部二值模式(local binary patterns, 简称LBP)提取不同工况下采集数据的图像纹理特征; 最后, 采用极限学习机识别出3种故障类型, 故障识别准确率达到90%, 证明了此方法的有效性。

关键词 行星齿轮; 模式识别; 故障诊断; 局部均值分解-S变换; 时频图像纹理特征

中图分类号 TH132.425

引 言

行星齿轮箱具有传动效率高、承载能力强的优点, 被广泛应用于军事装备和民用设备中^[1]。由于其工作环境恶劣, 长期承受着挤压、扭转、摩擦等力的作用, 齿轮极易产生磨损、裂纹、断齿等故障, 如果受损齿轮继续运行工作, 将会导致整个系统瘫痪, 造成巨大的经济损失, 甚至带来灾难性的后果。当齿轮发生故障时, 其特征会反映在振动信号中, 但行星齿轮箱自身结构复杂, 所产生的振动信号存在明显的非线性、非平稳性特点, 且故障信号微弱。对于非平稳信号, 常规的频谱分析(傅里叶分析)及简单的波形变换均无法准确表达频率随时间的变化特征, 因此研究适用于非线性和非平稳信号特征提取的方法具有重要的意义。

汤宝平等^[2]提出一种多共振分量融合卷积神经网络(multi-resonance component fusion based convolutional neural network, 简称MRCF-CNN)的行星齿轮箱故障诊断方法, 能够有效分析并诊断行星齿轮箱中滚动轴承和齿轮的故障。张俊等^[3]在诊断行星齿轮箱故障时, 先采用经验模态分解获取信号分量, 结合Teager能量算子对分量信号

进行解调, 再利用粒子群优化算法增强故障特征的提取, 并通过仿真和实验同时验证了该解调方法与随机共振对行星齿轮箱故障提取的高效性。张东等^[4]利用迭代广义短时傅里叶变换解调分离出频率恒定的单分量成分, 根据时频分布诊断出了齿轮故障。郭远晶等^[5]利用适于处理非平稳冲击信号的S变换方法, 结合奇异值分解方法对滚动轴承振动信号进行降噪处理, 并逆向使用S变换, 获取了原始信号中冲击特性的频率。S变换是源于短时傅里叶变换与小波变换的新型可逆时频分析方法, 其对多分量信号具有可加性优点, 是一种适合分析与处理非平稳信号特别是包含冲击特征的非平稳信号^[6]的自适应时频分析方法。但是, 如果直接对信号进行S变换, 其故障特征极易被噪声淹没且所得结果数据过多。考虑到时频图本质上是一种图像, 不同工况信号的时频图像呈现出的纹理也不同, 因此笔者使用LMD-S方法将行星齿轮箱振动信号转换为时频谱图像, 引入局部二值模式理论提取行星齿轮故障信号时频图像的纹理特征, 并利用极限学习机(extreme learning machine, 简称ELM)算法完成对行星齿轮故障模式的识别。

* 国家自然科学基金资助项目(51175480); 山西省重点研发计划(国际合作)资助项目(201903D421008); 中北大学先进制造技术山西省重点实验室开放基金资助项目(XJZZ202007)

收稿日期: 2020-06-25; 修回日期: 2020-11-28

1 LMD-S原理

LMD能够把多分量信号自适应地分解成有限个乘积函数(product function,简称PF)之和,利用S变换对信号进行自适应滤波并将其转换成时频分布图像。其步骤如下:

1) 将待处理信号 $u_0(t)=x(t)$ 进行LMD分解,计算均值函数 $m_{1n}(t)$ 和包络估计函数 $a_{1n}(t)$,根据式(1)、式(2)和 $\lim_{n \rightarrow \infty} a_{1n}(t)=1$ 的条件,从 $x(t)$ 中分离出纯调频信号 $s_{1n}(t)$ 和包络信号 $a_1(t)$,两者相乘得到PF₁分量

$$s_{1n}(t)=(x(t)-m_{1n}(t))/a_{1n}(t) \quad (1)$$

$$a_1(t)=a_{11}(t)a_{12}(t)\cdots a_{1n}(t)=\prod_{i=1}^n a_{1i}(t) \quad (2)$$

2) 将待处理信号 $x(t)$ 中PF₁分量去除得到 $u_1(t)=x(t)-PF_1(t)$;

3) 把 $u_1(t)$ 当做新的待处理信号重复步骤1和2,产生新的信号 u_i ,直到 $u_i(t)=u_{i-1}(t)-PF_i(t)$ 是单调函数时停止分解,其中 $i=1,2,\dots,k,k$ 为重复本步骤的次数;

4) 根据 $x(t)$ 和PF_{*i*}的相关性分析结果,将选出的PF分量保留并进行信号重构,得到 $x^*(t)=\sum PF_i$,其中 $i \in k$;

5) 将信号 $x^*(t)$ 代入式(3)获取时频分布图

$$S(\tau, f)=\int_{-\infty}^{+\infty} x^*(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{f^2(t-\tau)^2}{2}} e^{-j2\pi ft} dt \quad (3)$$

其中: τ 为时移因子参数; f 为频率。

2 时频图像特征的提取方法

LBP^[7]是一种有效的描述图像局部纹理特征的算子,虽然计算简单但却具有较高的特征识别能力。LBP特征算子通常定义在一个 3×3 正方形区域范围内。将中心像素值 i_p 作为阈值分别与邻近像素值 i_c 进行比较,像素值大于中心像素值的为1,反之为0,生成8位二进制数,并且执行十进制转换以生成LBP代码,即为中心像素的LBP值。为了满足各种不同尺度纹理的需求,现将传统的LBP算子区域改进为圆形,改进的局部二值模式可表示为

$$LBP_{(P,R)}=\sum_{p=0}^{P-1} T(i_p - i_c) * 2^p \quad (4)$$

其中: P 为相邻区域像素点数; R 为改进后算子区域的半径; $T(x)=\begin{cases} 1 & (x \geq 0) \\ 0 & (\text{其他}) \end{cases}$ 。

P 越大,局部二值模式的种类越多,且呈现指数增长。局部二值模式过多,但不是所有的模式都是有效的。为了避免这一缺点,引入了非均匀的思想,目的在于利用跳变次数 $U(LBP_{P,R})$,根据形成的二进制编码完成分类,其中均匀模式为二进制串中0/1或1/0的跳变次数小于等于2,而非均匀模式的跳变次数大于2。利用这样的方式优化特征维数,使得特征维数减少至 $P(P-1)+2^{[8]}$ 。

$$U(LBP_{P,R})=|T(i_{p-1}-i_c)-T(i_0-i_c)| + \sum_{p=1}^{P-1} |T(i_p-i_c)-T(i_{p-1}-i_c)| \quad (5)$$

3 实验验证

3.1 仿真实验

将非平稳的随机信号 $x(t)$ 进行小波变换,可以获得振动信号时频分布图像为

$$WT(\tau, a)=a^{-1/2} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-\tau}{a}\right) dt \quad (6)$$

其中: $\psi(t)$ 为小波基函数; $\psi^*(t)$ 为 $\psi(t)$ 的复共轭; τ 为平移因子; a 为尺度因子。

S变换是在小波变换的基础上对相位的一个改进,使得各频率的相位基准一致,所以S变换的定义是以特定小波基函数的小波变换,再乘上一个相位因子 $e^{-j2\pi ft}$,并把小波变换时的基函数设定为高斯窗函数,即可得到S变换的表达式(3)。

根据行星齿轮局部故障振动测试信号模型^[9]进行仿真处理,得

$$x(t)=\left[1-\cos(2\pi f_c t)\right]\left[1+A\cos(2\pi f_p t+\varphi)\right] \times \cos\left[2\pi f_m t+B\sin(2\pi f_p t+\varphi)+\theta\right] \quad (7)$$

其中: f_c 为行星架转频; f_p 为行星轮的故障特征频率; f_m 为齿轮的啮合频率。

实验平台如图1所示。模型中所需的参数依照

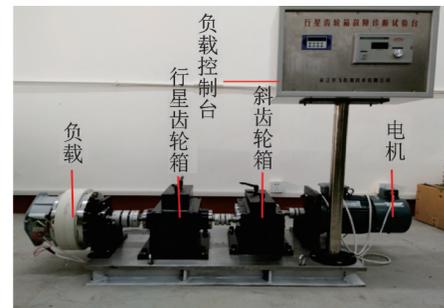


图1 实验平台

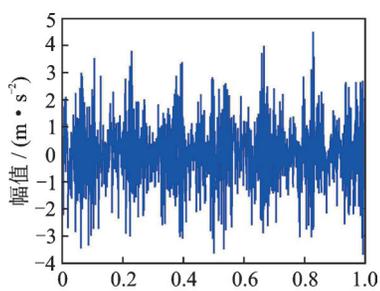
Fig.1 Experimental platform

HFXZ-I行星齿轮故障诊断实验平台情况设定,行星齿轮箱在一级减速箱之后运行,行星齿轮箱齿轮参数如表 1 所示。令转频为 50 Hz,计算出啮合频率为 487.8 Hz,将其代入式(7)后进行仿真。使用局部化性能和对称性都较好的 Complex Morlet 小波变换、S 变换和 LMD-S 变换的方法分别得到仿真信号的时频分布图像,如图 2 所示。图 2(a)为行星轮发生故障时的时域仿真信号,其非平稳、非线性特征明显,但仅从时域信号中无法得出有价值的信息。图 2(b,c)分别为信号经过小波变换和 S 变换后的时频分布图像,行星轮在发生故障时信号的特点比较明显。在小波变换时频图像 0~100 Hz 频率段中有较大的失真现象,导致提取的特征与运行工况不匹配,不利于信号特征的提取;S 变换不存在此缺点,但低频处信号成分较杂乱,使得有用信息很可能被干扰信息所淹没。图 2(d)为仿真信号经过 LMD-S 变换后得到的时频图像,与图 2(a,b,c)相比,不仅保留了原始信号的特征信息,在滤除一部分与原始信号相关性较小成分的同时增强了特征信息,使啮合频率 487.8 Hz 附近的信号成分更明显。因此,LMD-S 方法更有利于行星齿轮箱振动信号时频分布图像的转换。

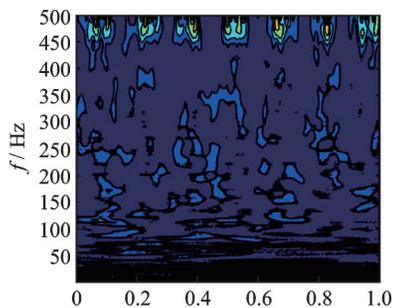
表 1 齿轮参数

Tab.1 Gear parameters

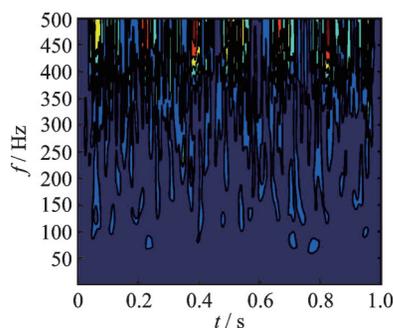
关键部件	行星齿轮	太阳轮	齿圈
齿数	27×3	18	72



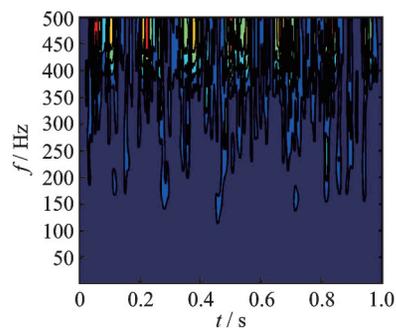
(a) 仿真信号
(a) Simulated signal



(b) 小波时频分布图
(b) Wavelet time-frequency distribution



(c) S变换时频分布图
(c) S-transform time-frequency distribution



(d) LMD-S时频分布图
(d) LMD-S time-frequency distribution

图 2 信号时频分布图像转换方法的对比图

Fig.2 Comparison of image conversion methods for signal time-frequency distribution

3.2 实验设置

为了验证笔者提出的方法在识别行星齿轮故障方面的应用价值,以 HFXZ-I 型行星齿轮箱故障诊断实验平台作为实验对象,模拟了行星齿轮箱在工程环境中的工作状态。由交流变频电机提供动力,实验过程中的负载由行星齿轮箱输出端联接的磁粉离合制动器提供。本次实验将故障设置在行星轮上,4 种工况模式如图 3 所示,分别完成了行星齿轮正常工况、1 个齿面、2 个齿面及 3 个齿面的磨损 4 种工况的实验测试。实验过程中,在行星齿轮箱输出轴轴承座对应的顶箱盖位置和行星齿轮箱顶部箱体上安装了振动加速度传感器,其位置如图 4 所示。设置采样频率为 10.24 kHz,将采集到的数据分为 3 组,其工况如表 2 所示,其中每个数据集包括 4 种不同工况的数据,重采样点数为 2 048,每种工况下分别取出 20 个分析样本,共处理(3×4×20)个样本数据。

3.3 相关性分析与时频分布图像的获取

根据 LMD-S 原理,信号在转换为时频分布图像过程中会得到多个 PF 分量,但不是每个 PF 分量都包含有用信息。对 3 组数据集每种工况下的 PF 分量与原始信号都进行相关性分析,如图 5 所示。



图 3 4 种工况模式
Fig.3 Four operating modes

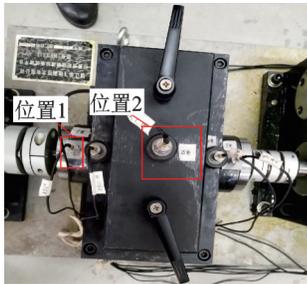


图 4 传感器的安装位置
Fig.4 Location of sensor

表 2 3 组数据的不同工况

Tab.2 Different working conditions of the three sets of data

数据集	传感器位置	负载/A	转频/Hz
1	1	1	50
2	2	1	30
3	2	1	50

由图可以看出,不同工况或者不同采集位置都会影响 PF 分量相关系数大小的变化,观察实际处理信号 PF 分量的相关性发现,从第 4 个分量到第 8 个分量的相关系数主要集中在 0.1 附近。为了避免因为行星齿轮微弱故障成分造成的信号混叠现象而使相关系数出现误差的问题,根据图 5 选定相关系数阈值为 0.1,将保留相关系数大于 0.1 的 PF 分量进行信号重构,重构后的信号再依照 LMD-S 原理处理后便可得到信号的时频分布图像。图 6 为数据集 1 不同工况的时频分布图像样本。

按照上述原理得到行星齿轮箱振动信号时频分布图像,设定 LBP 算子参数为(8,1),提取时频图像特征的步骤如下:

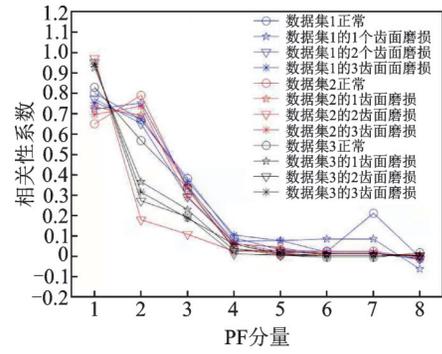


图 5 PF 分量的相关性分析
Fig.5 Correlation analysis of PF components

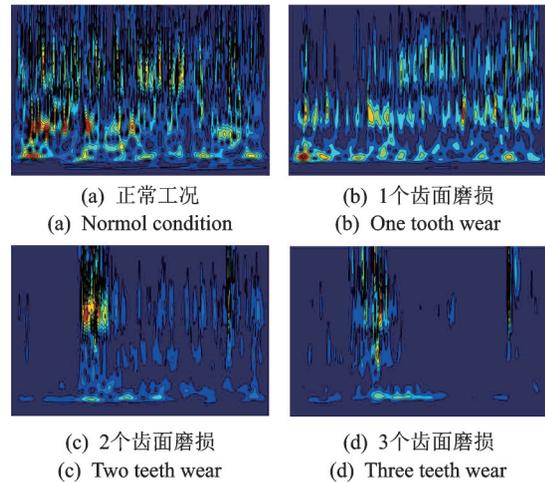


图 6 数据集 1 不同工况的时频分布图像样本
Fig.6 Time-frequency distribution image samples of different working conditions of dataset 1

1) 将行星齿轮箱不同工况下振动信号的时频图像样本划分为半径为 1、相邻区域像素点个数为 8 的圆形区域;

2) 把中心点处与每一个相邻区域处的像素值求差,当差值大于等于 0 时(中心点处数值较大)标记为 0,否则为 1,把比较结果记为 8 位二进制数,提取的 LMD-S 时频图像特征示意图如图 7 所示;

3) 计算每个圆形区域的每种局部二值模式的

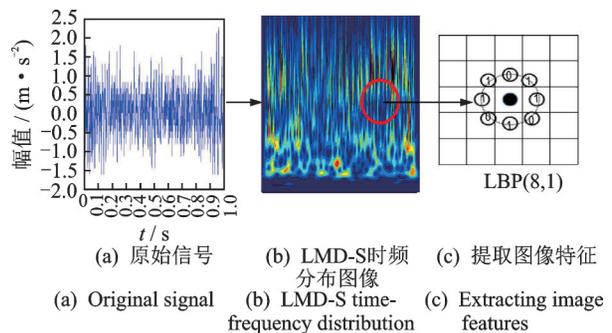


图 7 提取 LMD-S 时频图像特征示意图
Fig.7 Schematic diagram of extracting LMD-S time-frequency image features

频率,并且对二进制数的跳变次数进行均匀模式和非均匀模式分类,以减少模式维数;

4) 统计第3步降维后整个图像的LBP频率,并对LBP值进行归一化处理;

5) 将处理结果用时频图像的特征直方来表示,4种工况的LBP直方图如图8所示。

虽然每种工况的LBP值是不同的,但是由图8可知,正常工况和1个齿面磨损工况的LBP直方图相近,2个齿面磨损工况和3个齿面磨损工况的LBP直方图相近,所以仅通过分析LBP直方图不能有效区分4种工况类型,还需要进一步分析振动信号时频分布图像的纹理特征。

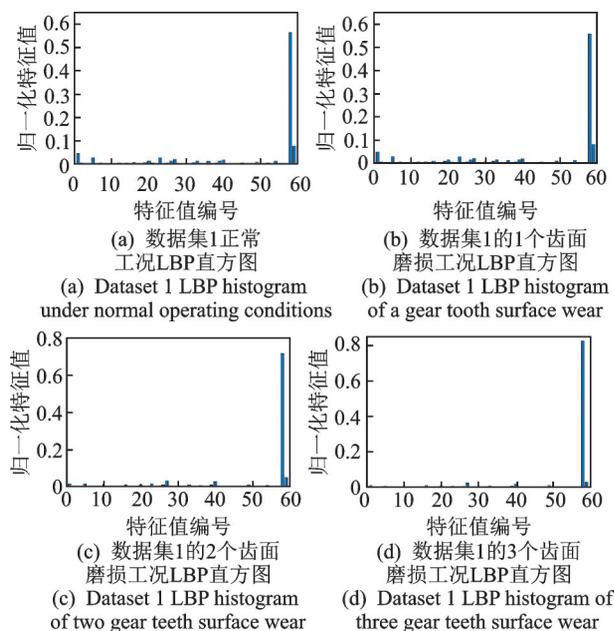


图8 4种工况的LBP直方图

4 故障识别

Huang等^[10]提出了极限学习机(extreme learning machine,简称ELM)算法,用来求解单隐层神经网络。ELM算法最大的特点是对输出层权值通过最小二乘法直接计算,整个学习过程1次完成而无需迭代^[11],在保证学习精度的前提下比传统的学习算法速度更快,该算法应用于许多故障诊断领域且都取得了良好的效果。

首先,将表2中3组数据集的信号分别采用S变换(方法1)处理后提取啮合频率段的方差值作为特征;其次,采用LMD-S变换(方法2)进行信号处理并提取信号的方差值作为特征;最后,采用LMD-S时频图像特征方法(方法3)提取信号故障特征。把从每个数据集用不同方法提取出的时频图像局部二

值模式特征分成2组,任意选取10个样本作为训练集,其余10个样本作为测试集,将训练集和测试集分别输入到极限学习机中进行训练和测试,完成对行星齿轮故障的诊断。3种方法的识别结果准确率如表3所示,ELM故障模式识别结果如图9所示。

表3 识别结果准确率
Tab.3 Accuracy of recognition results %

数据集	故障类型标签	样本编号	S变换+方差	LMD-S+方差	LMD-S+图像特征
1	正常	1~10	100	100	100
	1齿磨损	11~20	100	100	100
	2齿磨损	21~30	30	70	90
2	3齿磨损	31~40	80	70	90
	正常	1~10	100	100	100
	1齿磨损	11~20	100	100	100
3	2齿磨损	21~30	90	90	100
	3齿磨损	31~40	60	60	70
	正常	1~10	100	100	100
1	1齿磨损	11~20	100	100	100
	2齿磨损	21~30	80	80	90
	3齿磨损	31~40	60	80	90

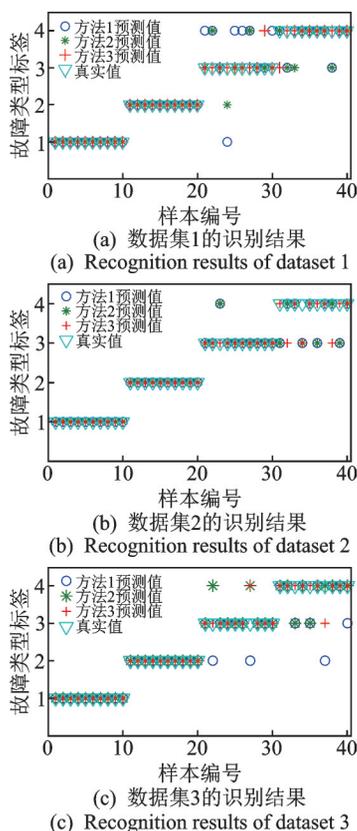


图9 ELM故障模式识别结果

Fig.9 The result of failure mode recognition with ELM

由表3可以看出:3种方法对正常工况与行星齿轮1个齿面磨损工况的识别准确率达到100%;在识别行星齿轮2个齿面磨损与3个齿面磨损故障时,S变换+方差的方法识别准确率最低;采用LMD-S+方差的方法使故障识别准确率有小幅提高,但不明显;采用本研究LMD-S+图像特征的方法使故障识别准确率有了大幅度的提高,充分说明该方法的有效性。

5 结束语

在对行星齿轮故障振动信号进行时频分析时,LMD-S方法不仅可以有效滤除相关性较低的信号成分,而且对其中的冲击成分敏感,增强了有用信息。同时,以较高的分辨率将信号转变为时频分布图像,展示了信号分量的数目、能量变化的梯度和能量集中的区域。通过实验验证了图像特征代替传统时频特征的可行性,对比实验结果证明了本研究方法的有效性。

参 考 文 献

- [1] 游子跃,王宁,李明明,等.基于EEMD和BP神经网络的风机齿轮箱故障诊断方法[J].东北电力大学学报,2015,35(1):64-72.
YOU Ziyue, WANG Ning, LI Mingming, et al. Method of fault diagnosis of gearbox based on EEMD and BP neural network[J]. Journal of Northeast Electric Power University, 2015, 35(1): 64-72. (in Chinese)
- [2] 汤宝平,熊学嫣,赵明航,等.多共振分量融合CNN的行星齿轮箱故障诊断[J].振动、测试与诊断,2020,40(3):507-512.
TANG Baoping, XIONG Xueyan, ZHAO Minghan, et al. Multi-resonance component fusion based convolutional neural network for fault diagnosis of planetary gearboxes [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3): 507-512. (in Chinese)
- [3] 张俊,钟敏,张建群,等.集成TEO解调和随机共振的行星齿轮箱早期故障诊断方法[J].振动工程学报,2019,32(6):1084-1093.
ZHANG Jun, ZHONG Min, ZHANG Jianqun, et al. An integrating methodology of Teager energy operator and stochastic resonance for incipient fault diagnosis of planetary gearboxes [J]. Journal of Vibration Engineering, 2019, 32(6): 1084-1093. (in Chinese)
- [4] 张东,冯志鹏.迭代广义短时Fourier变换在行星齿轮箱故障诊断中的应用[J].工程科学学报,2017,39(4):604-610.
ZHANG Dong, FENG Zhipeng. Application of iterative generalized short-time Fourier transform to fault diagnosis of planetary gearboxes [J]. Chinese Journal of Engineering, 2017, 39(4): 604-610. (in Chinese)
- [5] 郭远晶,魏燕定,周晓军,等.S变换时频谱SVD降噪的冲击特征提取方法[J].振动工程学报,2014,27(4):621-628.
GUO Yuanjing, WEI Yanding, ZHOU Xiaojun, et al. Impact feature extracting method based on S transform time-frequency spectrum denoised by SVD [J]. Journal of Vibration Engineering, 2014, 27(4): 621-628. (in Chinese)
- [6] 潘高元,李舜酩,杜华蓉,等.齿轮箱断齿特征识别的S变换-SVD降噪组合方法[J].振动与冲击,2019,38(18):256-263.
PAN Gaoyuan, LI Shunming, DU Huarong, et al. Feature extracting method for gearbox tooth breakage under impact based on the S-transform time-frequency spectrum combined with the denoising by SVD [J]. Journal of Vibration and Shock, 2019, 38(18): 256-263. (in Chinese)
- [7] OJALA T, PIETIKÄINEN M, MÄENPÄÄ T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. 2002, 24(7): 971-987.
- [8] 熊俊杰.基于改进局部二值模式的纹理分类算法研究[D].南昌:南昌航空大学,2019.
- [9] 冯志鹏,赵镭镭,褚福磊.行星齿轮箱齿轮局部故障振动频谱特征[J].中国电机工程学报,2013,33(5):119-127,19.
FENG Zhipeng, ZHAO Leilei, CHU Fulei. Vibration spectral characteristics of localized gear fault of planetary gearboxes [J]. Proceedings of the CSEE, 2013, 33(5): 119-127, 19. (in Chinese)
- [10] HUANG G B, WANG D H, LAN Y. Extreme learning machines: a survey [J]. International Journal of Machine Learning & Cybernetics, 2011, 2(2): 107-122.
- [11] 王斌,崔宝珍.基于CEEMD-MPE和ELM的齿轮箱故障诊断研究[J].组合机床与自动化加工技术,2019(4):103-106.
WANG Bin, CUI Baozhen. Fault diagnosis of gearbox based on CEEMD-MPE and ELM [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2019(4): 103-106. (in Chinese)



第一作者简介:崔宝珍,女,1974年2月生,博士、副教授。主要研究方向为现场工程测试、智能轴承关键技术、旋转机械的状态检测及故障诊断等。曾发表《基于广义形态滤波和Hibert边缘谱的滚动轴承故障诊断》(《中国机械工程》2016年第27卷第11期)等论文。

E-mail: cuibaozhen@nuc.edu.cn