

DOI: 10.7652/xjtub201906005

采用非相关字典学习的滚动轴承故障诊断方法

张志强¹, 孙若斌², 徐冠基¹, 杨志勃², 陈雪峰²

(1. 中车青岛四方机车车辆股份有限公司, 266000, 山东青岛;

2. 西安交通大学机械工程学院, 710049, 西安)

摘要: 针对轴承振动信号中早期故障特征难以识别的问题,提出了利用非相关字典学习稀疏提取微弱冲击特征,进而完成故障诊断的方法。字典的构造是影响稀疏表示算法性能的关键步骤,而传统字典学习方法构造的冗余字典,原子之间具有很强的相关性,不足以表现信号不同的结构特性,也不利于信号准确稀疏重构,进而影响了冲击故障特征信号的提取。因此,在 K 均值奇异值分解算法(K -SVD)的基础上加入了原子解相关的步骤,形成了非相关字典学习算法(INK-SVD)。采用 INK-SVD 算法在含噪振动信号段样本中,学习构造低相关性自适应字典;在此基础上,利用稀疏表示方法准确提取冲击故障特征,从而实现更准确的轴承故障诊断。通过仿真分析及实验数据分析,与传统字典学习方法相比,该方法稀疏系数恢复精确度更高,重构信号的包络解调谱更有利于故障特征的辨识,从而验证了该方法的有效性。

关键词: 稀疏表示;非相关字典学习;特征提取;故障诊断

中图分类号: TH212;TH213.3 **文献标志码:** A **文章编号:** 0253-987X(2019)06-0029-06

Bearing Fault Diagnosis Based on Incoherent Dictionary Learning

ZHANG Zhiqiang¹, SUN Ruobin², XU Guanji¹, YANG Zhibo², CHEN Xuefeng²

(1. Engineering Laboratory of CRRC Qingdao Sifang Co. Ltd., Qingdao, Shandong 266000, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To identify the weak fault features of bearing vibration signals at the early stage, incoherent dictionary learning methods are utilized to extract impact features of the signals and diagnose the fault. The dictionary construction is a key step that determines the performance of the sparse representation algorithm. The redundant dictionaries constructed by the traditional dictionary learning methods, however, have a great correlation between atoms. They are not enough to represent different structural characteristics of the signals and are not conducive to the accurate sparse reconstruction of the signals. Therefore, the incoherent dictionary learning method (INK-SVD) is adopted to reconstruct the adaptive dictionaries with low correlation. The low correlation dictionary is learned adaptively in the samples of noisy vibration by the INK-SVD, and the impact fault features are extracted accurately with sparse representation algorithm, so as to achieve more precise bearing fault diagnosis. In terms of the simulation and experiment analysis, the proposed method is able to obtain more accurate sparse coefficients compared with classical dictionary learning methods. Therefore, the envelope demodulation spectrum of the reconstructed signal is more conducive to fault feature identification, which verifies the

收稿日期: 2019-01-15。 作者简介: 张志强(1969—),男,高级工程师;陈雪峰(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(51875433)。

网络出版时间: 2019-03-09

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190309.1557.002.html>

effectiveness of the method.

Keywords: sparse representation; incoherent dictionary learning; feature extraction; fault diagnosis

滚动轴承是旋转机械重要的支撑部件,也是易损部件,广泛应用于各种大型工业装备中,如风力发电机、航空发动机、高铁动车组等。滚动轴承故障轻则造成装备停机影响运行生产,重则机毁人亡造成灾难性事故。因此,进行滚动轴承早期故障监测诊断是减少运行维护损失、保证设备运行安全的有效途径,具有重要的工程意义^[1]。

振动监测是轴承故障诊断最有效的途径之一^[2-3]。稀疏表示将振动信号在冗余的波形函数集合(称为过完备字典)中展开,增强了信号的表示能力,具有自适应、对噪声鲁棒性强的优点,适合轴承早期微弱故障特征提取。近几年来,越来越多的研究采用稀疏表示方法分析机械振动信号,并取得了一定的研究成果。如文献[4-5]利用小波字典稀疏表示齿轮箱振动信号,成功匹配出瞬态故障特征成分;文献[6]在压缩感知框架下,从信号集合中学习冗余字典,提取了轴承振动的冲击成分;文献[7]采用 K 均值奇异值分解训练字典,成功诊断了行星轮系中齿轮的局部和均布式故障。

一个适合于提取故障特征的字典需要满足两个条件:首先字典中原子要与待提取的特征相匹配;另外字典要满足低相关度要求。字典的相关度 μ 定义为原子间内积绝对值中的最大值。Tropp等证明了只有 μ 小于某个特定值时,稀疏系数才能由算法成功恢复^[8]。从以上研究中可见,固定的参数化解析字典和字典学习方法构造的字典中,原子都与故障特征具有较高的匹配度,但不能满足低相关度要求。传统字典学习方法,如最大似然法^[9]、最优方法(MOD)^[10]、K-SVD算法^[11]等,训练出的字典原子之间具有很强的相关性,不能够表现出信号不同的结构特性,不能确保信号准确稀疏重构,影响了故障特征提取精度。

因而,本文利用文献[12]提出的非相关字典学习算法(INK-SVD)训练低相关性字典,稀疏提取轴承微弱故障特征信号。该方法在K-SVD算法的基础上,加入了解相关的步骤,迭代地选择出字典中的高相关性原子组,并把它们解相关,直到达到给定的相关性,训练出一个具有低相关性的自适应字典。通过仿真分析及故障模拟实验表明,与传统字典学习算法相比,该方法更有利于在强噪声中提取微弱

冲击特征,更适合滚动轴承早期的故障诊断。

1 稀疏表示理论

与在正交基上分析重构信号的方法不同,稀疏表示是将信号在一组冗余的基函数下展开,这组基函数叫做字典,记为矩阵 $\mathbf{A} \in \mathbf{R}^{n \times m}$ ($n < m$)。矩阵的每一列 $\{\mathbf{a}_\gamma \in \mathbf{R}^n\}$ 称为原子,它们是参数化的波形基函数,或者是在稀疏约束下通过近似误差最小得到的基函数。观测到的信号 $\mathbf{y}$,由目标信号 $\mathbf{y}_0$ 与高斯白噪声 $\mathbf{e}$ 组成, $\mathbf{y}_0$ 可以稀疏展开为原子的线性组合,如下式所示

$$\mathbf{y} = \mathbf{y}_0 + \mathbf{e} = \sum_{\gamma \in \Gamma} x_\gamma \mathbf{a}_\gamma + \mathbf{e} \quad (1)$$

式中: x_γ 是对应于 $\mathbf{a}_\gamma$ 的表示系数; Γ 是原子索引的参数集合。

由于字典是过完备的,也就是说原子集合是线性相关的,对 $\mathbf{y}$ 的分解是无穷多的。为了得到唯一解,稀疏模型假设信号是由少数几个原子表示的,即对解引入了稀疏正则化约束,这个问题可以表示为如下优化问题

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0; \quad \text{s. t. } \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2 \leq \epsilon \quad (2)$$

式中: $\mathbf{x} \in \mathbf{R}^m$ 表示系数向量, $\mathbf{x}$ 的 l_0 范数表示其中的非零项的个数; ϵ 是分解允许的误差。这个优化问题是非确定性多项式问题,可以采用如匹配追踪(MP)^[13-14]、正交匹配追踪(OMP)^[15-16]等贪婪算法求解;或者采用凸松弛方法,用 l_1 范数替换 l_0 范数,将问题转化为凸优化问题来求解,即基追踪去噪(BPDN)^[17]方法。

2 滚动轴承故障诊断

2.1 字典学习问题与K-SVD算法

在振动信号的稀疏表示中,字典 $\mathbf{A}$ 的选择是另一个重要问题。解析字典拥有快速算法,但只局限于表示某类振动信号。为了能根据信号原本的结构特征,构建出自适应字典,需要采用字典学习方法。字典学习的本质是在稀疏约束下,最小化信号表示误差,也就是如下优化问题

$$\min_{\mathbf{A}, \mathbf{X}} \|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2; \quad \text{s. t. } \|\mathbf{x}_i\|_0 \leq S \quad (3)$$

式中:训练信号集合 $\{\mathbf{y}_i\}_{i=1}^k$ 组成样本矩阵 $\mathbf{Y} \in \mathbf{R}^{n \times k}$; $\mathbf{X} \in \mathbf{R}^{m \times k}$ 是样本在字典 $\mathbf{A}$ 下的稀疏表示系数矩阵; S

为每个信号表示系数中允许的最大非零项个数;
 $\|\cdot\|_F$ 表示 F 范数,是矩阵中全部元素平方和的平方根。

K -SVD 字典学习算法采用交替系数 $\mathbf{X}$ 和字典 $\mathbf{A}$ 的策略,在以下步骤中迭代。

(1)稀疏编码阶段。已知 $\mathbf{Y}$ 和 $\mathbf{A}$,用贪婪追踪算法如 OMP 估计表示系数矩阵 $\mathbf{X}$;

(2)字典更新阶段。已知 $\mathbf{Y}$ 和 $\mathbf{X}$,逐个更新 $\mathbf{A}$ 中每一列原子,同时更新该原子对应的表示系数。对于某个原子 $\mathbf{a}_{j_0}$,首先确定使用了该原子的样本集合 $\Omega_{j_0} = \{i | 1 \leq i \leq m, x_{j_0}(i) \neq 0\}$;然后计算该集合下的残差矩阵 $\mathbf{E}_{j_0}^R = (\mathbf{Y} - \sum_{j \neq j_0} \mathbf{a}_j \mathbf{x}_j^T) \mathbf{P}_{j_0}$, $\mathbf{P}_{j_0}$ 是约束算子,用来消去不在集合 Ω_{j_0} 中的列;最后应用 SVD 分解 $\mathbf{E}_{j_0}^R = \mathbf{U} \Delta \mathbf{V}^T$,更新原子 $\mathbf{a}_{j_0} = \mathbf{u}_1$ 和对应系数 $\mathbf{x}_{j_0}^R = \Delta(1,1) \mathbf{v}_1$ 。

2.2 INK-SVD 算法

用贪婪算法求解稀疏表示系数时,低相关性的字典是获得最优表示的保障^[18]。低相关性字典使原子能够表现出信号不同的结构特性,从而覆盖大部分信号集空间,利于用信号稀疏表示^[19]。INK-SVD 算法就是在 K -SVD 算法的基础上,加入了原子解相关的步骤。字典的相关性定义为不同归一化原子的内积绝对值中的最大值,公式如下

$$\mu(\mathbf{A}) = \max_{1 \leq i, j \leq m, i \neq j} \frac{|\mathbf{a}_i^T \mathbf{a}_j|}{\|\mathbf{a}_i\|_2 \|\mathbf{a}_j\|_2} \quad (4)$$

相关性 μ 的取值在 0 到 1 之间。当字典是正交时, μ 取得最小值 0;当字典中包含有两个原子共线时, μ 取得最大值 1。

要获得低相关性的字典,可以求解如下优化问题

$$\begin{cases} \hat{\mathbf{A}} = \arg \min_{\mathbf{A}} \mu(\mathbf{A}) \\ \text{s. t. } \|\mathbf{A} - \bar{\mathbf{A}}\|_F^2 \leq \rho; \|\mathbf{a}_i\|_2 = 1, i \in [1, m] \end{cases} \quad (5)$$

式中: $\bar{\mathbf{A}}$ 是待解相关的字典; ρ 是解相关后字典与原始字典允许的误差,字典具有归一化的原子。该问题的求解:通过选择出高相关性的原子组,然后将其中的原子逐对解相关,最后使得字典达到设定的相关性 $\bar{\mu}$ 。具体步骤如下。

(1)在字典 $\bar{\mathbf{A}}$ 中找出高相关性原子集合,使得剩余原子的相关性达到 $\bar{\mu}$,找高相关性原子集合 E 的贪婪算法如下。

算法 1 $E = \text{partition}(\bar{\mathbf{A}}, \bar{\mu})$

$\mathbf{A} \leftarrow \bar{\mathbf{A}}$

$E \leftarrow \emptyset$

while $\mu(\mathbf{A}) > \bar{\mu}$ do

$(i, j) = \arg \max |\mathbf{A}^H \mathbf{A} - \mathbf{I}|$

$\mathbf{A} \leftarrow \mathbf{A} \setminus \{\mathbf{a}_i, \mathbf{a}_j\}$

$E \leftarrow E \cup \{\mathbf{a}_i, \mathbf{a}_j\}$

end while

(2)将 E 中的原子逐对解相关。只考虑 $\bar{\mathbf{A}}$ 中一对归一化原子 $\bar{\mathbf{a}}_1$ 和 $\bar{\mathbf{a}}_2$,不失一般性假设 $\langle \bar{\mathbf{a}}_1, \bar{\mathbf{a}}_2 \rangle > 0$ 。 $(\mathbf{u}_1 \ \mathbf{u}_2) = ((\bar{\mathbf{a}}_1 + \bar{\mathbf{a}}_2) / \|\bar{\mathbf{a}}_1 + \bar{\mathbf{a}}_2\|_2 \ (\bar{\mathbf{a}}_1 - \bar{\mathbf{a}}_2) / \|\bar{\mathbf{a}}_1 - \bar{\mathbf{a}}_2\|_2)$ 组成信号子空间的一组标准正交基。设 $\bar{\mathbf{a}}_1$ 和 $\bar{\mathbf{a}}_2$ 的半夹角为 $\bar{\theta}$,解相关后原子 $\hat{\mathbf{a}}_1$ 和 $\hat{\mathbf{a}}_2$ 的半夹角为 $\hat{\theta}$, $\bar{\mathbf{a}}_1 + \bar{\mathbf{a}}_2$ 与 $\hat{\mathbf{a}}_1 + \hat{\mathbf{a}}_2$ 的夹角为 α ,如图 1 所示。




图 1 两个原子解相关示意图

原子在标准正交基下的向量表示分别为

$$\mathbf{A} = (\bar{\mathbf{a}}_1 \ \bar{\mathbf{a}}_2) = \begin{bmatrix} \cos \bar{\theta} & \cos(-\bar{\theta}) \\ \sin \bar{\theta} & \sin(-\bar{\theta}) \end{bmatrix} \quad (6)$$

$$\hat{\mathbf{A}} = (\hat{\mathbf{a}}_1 \ \hat{\mathbf{a}}_2) = \begin{bmatrix} \cos(\alpha + \hat{\theta}) & \cos(\alpha - \hat{\theta}) \\ \sin(\alpha + \hat{\theta}) & \sin(\alpha - \hat{\theta}) \end{bmatrix} \quad (7)$$

可以推导出问题(5)的目标函数和约束分别为

$$|\langle \hat{\mathbf{a}}_1, \hat{\mathbf{a}}_2 \rangle| = |\cos 2\hat{\theta}| \leq \bar{\mu} \quad (8)$$

$$\|\bar{\mathbf{A}} - \hat{\mathbf{A}}\|_F^2 = 4 - 4\cos(\bar{\theta} - \hat{\theta})\cos(\alpha) \quad (9)$$

不失一般性,假设 $\cos(\bar{\theta} - \hat{\theta}) > 0$,式(9)在 $\alpha = 0$ 且 $\hat{\theta}$ 与 $\bar{\theta}$ 越接近时,取得最小值。因此,问题(5)通过对称地旋转 $\bar{\mathbf{a}}_1$ 与 $\bar{\mathbf{a}}_2$,直到它们相关性达到 $\bar{\mu}$ 来解决,即 $\hat{\theta} = (\arccos \bar{\mu})/2$,代入式(7)得到解相关后的原子。

迭代地进行(1)(2)两步,就可以获得低相关性的字典,具体算法如下。

算法 2 $\mathbf{A} = \text{decorrelate}(\bar{\mathbf{A}}, \bar{\mu})$

$\mathbf{A} \leftarrow \bar{\mathbf{A}}$

while $\mu(\mathbf{A}) > \bar{\mu}$ do

$E = \text{partition}(\mathbf{A}, \bar{\mu})$

for $\forall (\mathbf{a}_i, \mathbf{a}_j) \in E$ do

$(\mathbf{a}_i, \mathbf{a}_j)$ 解相关

end for

end while

2.3 故障特征提取

考虑到字典学习算法的计算量较大,原子的长度不能过长。在提取轴承冲击故障特征时,首先将测得的信号按步长 Δn ,分解成 k 列长度为 n 的信号段,组成样本矩阵 $\mathbf{Y}$ 。原子的长度需要满足包含一个完整故障冲击衰减波形的长度,但是过长的原子会带来过大的计算量,影响算法的使用性。因此,实际中通常原子的长度选择略大于一个完整故障冲击衰减的长度。

在转速已知条件下,轴承的冲击信号频谱(即故障特征频率)是诊断的先验条件,再根据采样频率就可以大概推算出信号段长度应该满足的条件。利用字典学习算法对噪声的鲁棒性,直接在含噪样本矩阵 $\mathbf{Y}$ 上用 INK-SVD 算法训练低相关性字典,根据字典及其表示系数得到故障特征信号矩阵 $\hat{\mathbf{Y}}$ 。最后,通过重叠部分求平均,将 $\hat{\mathbf{Y}}$ 中列信号拼接还原成信号 $\hat{\mathbf{y}}$, $\hat{\mathbf{y}}$ 即为对冲击故障特征 $\mathbf{y}_0$ 的估计。对估计信号 $\hat{\mathbf{y}}$ 进行包络解调就可以找出故障特征频率,从而确定滚动轴承的故障类型。算法流程见图 2。




图2 基于 INK-SVD 的滚动轴承故障特征提取算法流程

3 仿真分析

在故障初期,滚动轴承的振动信号常常表现为周期性的冲击振荡和其他振动成分的叠加。因此,通过叠加周期冲击成分和高斯白噪声,构建轴承故障仿真信号,具体数学表达式如下

$$\left. \begin{aligned} y(t) &= y_i(t - iT) + n(t) \\ y_i(t) &= A_i \exp(-\zeta_i \omega_i t) \sin(\omega_i \sqrt{1 - \zeta_i^2} t) \end{aligned} \right\} \quad (10)$$

式中: $y_i(t)$ 是单边衰减的冲击响应信号。为了更好地模拟实际信号中的不确定性,冲击衰减信号的波形参数取为服从均匀分布的随机量:冲击幅值 A_i 服从区间 $[0.5, 1] \text{ m/s}^2$ 的均匀分布,阻尼比 ζ_i 服从区间 $[0.1, 0.15]$ 的均匀分布,无阻尼固有频率 ω_i 服从区

间 $[4\,000\pi, 6\,000\pi] \text{ rad} \cdot \text{s}^{-1}$ 的均匀分布,冲击周期 $T = 0.01 \text{ s}$, $n(t)$ 是独立同分布的零均值标准差 $\sigma = 0.1$ 的高斯随机信号。数据的采样频率是 20 kHz , 采样点数为 $1\,024$, 仿真信号的波形如图 3 所示。

仿真信号的信噪比(σ_{SNR})等于 -1.70 dB 。取信号段长度 $n = 128$, 截取步长 $\Delta n = 2$, 共取得 449 个训练样本。从中选择样本组成初始字典,字典的冗余度取 2 , 即包含 256 个原子。在相关性 $\bar{\mu}$ 分别等于 $0.2, 0.3, \dots, 0.9$ 时,采用 INK-SVD、K-SVD 方法训练字典,最终比较它们提取特征信号的信噪比,结果如图 4 所示。




图3 仿真信号的波形




图4 两种算法提取特征信号的信噪比对比

从图 4 中可见,当 $\bar{\mu} = 0.5$ 时,INK-SVD 算法提取特征信号的信噪比最高为 4.35 dB 。当相关性设置值低于 0.5 时,不相关对于字典的约束过强,字典匹配故障冲击波形的能力变差;当相关性大于 0.5 时,由于字典相关性变大,由贪婪算法求稀疏表示的精度变差,也不利于特征波形的提取。因此,相关性 $\bar{\mu}$ 要设置得当,一般取值在 $0.4 \sim 0.6$ 之间。

这个实验中,K-SVD 算法训练得到的字典相关性为 0.75 、信噪比为 3.45 dB ,比 INK-SVD 算法在 $\bar{\mu} = 0.8$ 时得到信噪比低。这是由于采用了样本信号作为初始字典,且样本间的步长很小,导致初始

字典具有很强的相关性。INK-SVD 算法在最初几步迭代中有解相关的操作,提高了信号稀疏表示精度,取得了较好的结果。 K -SVD 算法虽然得到了较低相关性的字典,但是最初几步迭代中的稀疏表示误差影响了训练字典的性能。

4 故障模拟实验

为了进一步验证方法在提取滚动轴承早期微弱故障特征时的有效性,进行了如下电机轴承故障模拟实验。实验台由一个 2.2 kW 的电机连接的转子系统以及拖动的负载组成。在电机的轴承外圈内置了一个微弱故障,如图 5 所示。轴承的型号是 SKF6203,外圈故障特征频率计算公式如下

$$f_c = 0.5Zf_a(1 - (d/D)\cos\alpha) \tag{11}$$

式中: Z 是滚动体个数; d 是滚动体的直径; D 是节圆直径; α 是滚动体的接触角。当输入轴转频 1 Hz 时,特征频率为 4.932 Hz。

振动信号是由一个粘贴在电机轴承座上的加速度传感器采集,经由 Sony 数据采集系统,最终在电脑上处理并显示。采样频率为 12.8 kHz。振动信号测试系统如图 6 所示。



(a)实验台 (b)外圈预制微弱故障


图 5 故障模拟实验




图 6 故障模拟实验振动测试系统

对信号进行希尔伯特变换,再对得到复数信号的模值进行快速傅里叶变换,得到信号的包络解调谱。原始信号的时域波形以及包络解调谱如图 7 所示。从时域波形中,没有发现明显的冲击成分,在包络解调谱中,也没有突出的故障特征频率,因此不能直接诊断出轴承的故障。

采用本文提出方法处理该信号,参数选择如下:训练信号段的长度为 128,样本为 500,字典冗余度为 2,最大相关性取为 0.5。由提取的故障特征波形得到的包络解调谱如图 8a 所示。在该电机转速下,对应的 f_c 是 188.8 Hz,从中可以明显看到故障特征频率,及其 2、3 倍频成分,说明本文算法成功地诊




(a)原始信号时域波形




(b)包络解调谱

图 7 原始信号波形及包络解调谱


断出滚动轴承的早期微弱故障。作为对比,用原始的 K -SVD 算法与 MOD 算法处理该段信号,得到的故障特征波形包络解调谱如图 8b、8c 所示,从中只能看出故障特征频率及其 2 倍频,不能看到明显的



(a)本文算法



(b) K -SVD 算法



(c)MOD 算法

图 8 几种算法提取特征的包络解调谱比较

3 倍频,表明其故障特征提取效果不如本文算法。

5 结 论

采用 INK-SVD 算法可以得到低相关性的字典,保证了稀疏表示的求解精度,提高了原子与故障特征信号的匹配程度。通过合理设定相关性、训练样本长度等参数,基于非相关字典学习可以有效提取滚动轴承故障稀疏特征。仿真分析及实验分析表明,与传统字典学习方法相比,本文算法可以更加精确地恢复稀疏系数,在重构信号的包络解调谱中更有利于故障特征的辨识。

参考文献:

- [1] 王国彪,何正嘉,陈雪峰,等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
WANG Guobiao, HE Zhengjia, CHEN Xuefeng, et al. Basic research on machinery fault diagnosis: what is the prescription [J]. Chinese Journal of Mechanical Engineering, 2013, 49(1): 63-72.
- [2] 张晗,杜朝辉,方作为,等. 基于稀疏分解理论的航空发动机轴承故障诊断 [J]. 机械工程学报, 2015 (1): 97-105.
ZHANG Han, DU Zhaohui, FANG Zuowei, et al. Sparse decomposition based aero-engine's bearing fault diagnosis [J]. Chinese Journal of Mechanical Engineering, 2015(1): 97-105.
- [3] 张西宁,唐春华,周融通,等. 一种自适应形态滤波算法及其在轴承故障诊断中的应用 [J]. 西安交通大学学报, 2018, 52(12): 1-8.
ZHANG Xining, TANG Chunhua, ZHOU Rongtong. Adaptive morphological filtering algorithm with applications in bearing fault diagnosis [J]. Journal of Xi'an Jiaotong University, 2018, 52(12): 1-8.
- [4] FAN W, CAI G, ZHU Z K, et al. Sparse representation of transients in wavelet basis and its application in gearbox fault feature extraction [J]. Mechanical Systems and Signal Processing, 2015, 56: 230-245.
- [5] 王晓冬,何正嘉,訾艳阳. 滚动轴承故障诊断的多小波谱峭度方法 [J]. 西安交通大学学报, 2010, 44(3): 77-81.
WANG Xiaodong, HE Zhengjia, ZI Yanyang. Spectral kurtosis of multiwavelet for fault diagnosis of rolling bearing [J]. Journal of Xi'an Jiaotong University, 2010, 44(3): 77-81.
- [6] CHEN X, DU Z, LI J, et al. Compressed sensing based on dictionary learning for extracting impulse

components [J]. Signal Processing, 2014, 96: 94-109.

- [7] FENG Z, LIANG M. Complex signal analysis for planetary gearbox fault diagnosis via shift invariant dictionary learning [J]. Measurement, 2016, 90: 382-395.
- [8] TROPP J A. Greed is good: algorithmic results for sparse approximation [J]. IEEE Transactions on Information Theory, 2004, 50(10): 2231-2242.
- [9] OLSHAUSEN B A, FIELD D J. Natural image statistics and efficient coding [J]. Network: computation in Neural Systems, 1996, 7(2): 333-339.
- [10] ENGAN K, AASE S O, HUSØY J H. Multi-frame compression: theory and design [J]. Signal Processing, 2000, 80(10): 2121-2140.
- [11] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [12] MAILH B, BARCHIESI D, PLUMBLEY M D. INK-SVD: learning incoherent dictionaries for sparse representations [C]//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway, NJ, USA: IEEE, 2012: 3573-3576.
- [13] MALLAT S G, ZHANG Z. Matching pursuits with time-frequency dictionaries [J]. IEEE Transactions on Signal Processing, 1994, 41(12): 3397-3415.
- [14] VU T H, MOUSAVI H S, MONGA V. Adaptive matching pursuit for sparse signal recovery [C] // IEEE International Conference on Acoustics. Piscataway, NJ, USA: IEEE, 2017: 4331-4335.
- [15] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
- [16] BEI L, YING S, LI G, et al. Gesture recognition based on modified adaptive orthogonal matching pursuit algorithm [J]. Cluster Computing, 2017(3): 1-10.
- [17] CHEN S S, DONOHO D L, SAUNDERS M A. Atomic decomposition by basis pursuit [J]. SIAM Review, 2001, 43(1): 129-159.
- [18] TROPP J A. Greed is good: algorithmic results for sparse approximation [J]. IEEE Transactions on Information Theory, 2004, 50(10): 2231-2242.
- [19] 王君地. 基于稀疏表示的音频修复算法研究 [D]. 成都: 电子科技大学, 2016: 25-30.

(编辑 杜秀杰)