DOI: 10.3901/JME.2019.07.035

基于终止准则改进 K-SVD 字典学习的稀疏表示特征增强方法*

王华庆 任帮月 宋浏阳 董 方 王梦阳
(北京化工大学机电工程学院 北京 100029)

摘要: 针对传统 K 奇异值分解(K-Singular value decomposition, K-SVD)算法在稀疏表示过程中, 由于目标信号稀疏度难以确定以及字典原子受噪声干扰导致稀疏表示效果较差的问题, 结合变分模态分解(Variational mode decomposition, VMD)算法, 提出了基于 VMD 与终止准则改进 K-SVD 字典学习的稀疏表示方法。借助 VMD 算法剔除信号中的干扰分量, 依据相关分析与峭度准则选择最优模态分量; 采用终止准则改进的 K-SVD 字典学习算法对最优分量的特征信息进行学习, 优化目标函数与约束条件, 在无需设置稀疏度的前提下, 构造出准确匹配故障冲击成分的字典; 此外, 构建一种残差阈值改进的正交匹配追踪算法(OMPerr)实现稀疏重构及微弱故障特征增强。通过仿真及试验信号进行验证, 结果表明: 基于 VMD 与改进 K-SVD 字典学习的稀疏表示方法在字典原子构建、稀疏重构精度以及故障特征增强等方面均优于传统 K-SVD 稀疏表示方法, 可以有效实现微弱故障的诊断。

关键词: 稀疏表示; 故障特征增强; K 奇异值分解; 特征提取

中图分类号: TH17

Sparse Representation Method Based on Termination Criteria Improved K-SVD Dictionary Learning for Feature Enhancement

WANG Huaqing REN Bangyue SONG Liuyang DONG Fang WANG Mengyang
(School of Mechanical and Electrical Engineering, Beijing University of Chemical Technology, Beijing 100029)

Abstract: A sparse representation method based on VMD and termination criteria improved K-SVD dictionary learning algorithm is proposed to solve the issues about the choice of signal sparsity and the interference of noise. With the aid of VMD algorithm, the interference components can be removed. According to correlation analysis and kurtosis criterion, the optimal modal component can be selected successfully. Then the characteristic information of the optimal component is learned by termination criteria improved K-SVD algorithm, optimizing the objective function and constraints, and the sparse representation dictionary matched the fault impact components can be constructed without setting the sparsity. In addition, an improved orthogonal matching pursuit algorithm with residual error threshold is constructed to achieve sparse reconstruction and weak fault feature enhancement. Verification by simulated and experimental signals show that the sparse representation method based on VMD and modified K-SVD could effectively diagnose the weak fault, which outperformed the traditional K-SVD algorithm in terms of the construction of dictionary atom, sparse reconstruction accuracy and fault feature enhancement.

Key words: sparse representation; fault feature enhancement; K-singular value decomposition; feature extraction

0 前言

随着科技的发展及现代工业设备自动化程度的提高, 高速化、大型化、精密化正成为机械设备发展的必要趋势^[1]。设备的安全可靠运行直接影响了工业生产系统的正常运转, 因此, 对设备的状态监

测与故障诊断意义重大^[2-3]。由于机械设备规模庞大、安装测点多、数据采样频率高, 装备从开始服役到寿命终止的数据收集历时较长, 因此便形成了多源、复杂的海量数据, 推动了故障诊断领域进入了“大数据”时代^[4-6]。如何有效地获取大数据中的故障信息, 成为了亟待解决的重要问题。

稀疏表示为解决上述问题提供了一个新途径, 对信号稀疏表示的意义在于, 将信号在给定的稀疏字典中表示成少量原子的线性组合, 以尽可能少的

* 国家自然科学基金资助项目(51675035, 51805022)。20180528 收到初稿, 20181116 收到修改稿

非零元素表示信号的主要特征, 获取“大数据”中的故障信息^[7-9]。针对旋转机械冲击类故障, 稀疏表示后得到的少量稀疏系数即表示了信号的故障冲击成分。因此, 稀疏表示方法可以有效降低信号中冗余成分, 利用有限个数据点解决机械微弱故障特征提取的难题^[10-11]。

稀疏表示的一个关键问题就是如何设计有效的稀疏表示字典。目前, 已有固定式的分析字典, 如: DCT 字典、Gabor 字典等, 该类字典针对简单平稳的信号可以达到很好的稀疏效果, 但针对复杂含噪信号的稀疏表示效果较差^[12-13]。因此, 对于特定的信号, 找到合适的稀疏表示字典尤为关键。近两年, 稀疏基的选取从固定式字典逐渐向学习型字典转换^[14]。通过学习目标信号的特征信息自适应地更新字典原子, 构造适合特定信号的稀疏表示字典是目前研究的热点内容。常用的字典学习算法有: 最优方向法(Method of optimal directions, MOD)^[15]、K 奇异值分解法(K-singular value decomposition, K-SVD)^[16-17]等。MOD 方法在每次迭代过程中更新整个字典原子, 计算量大、算法较复杂; K-SVD 算法在每次迭代过程中仅更新一个原子, 因此, K-SVD 算法更为收敛。然而, 当信号的信噪比较低时, 噪声等其他干扰成分对信号影响较大, 使字典在学习过程中同时学习到其他干扰成分, 导致稀疏表示效果较差。

目前, K-SVD 算法存在两个关键问题: ① 传统 K-SVD 方法在字典学习过程中易受噪声干扰混入虚假原子; ② 目标信号稀疏度不确定导致稀疏表示效果不理想。针对上述问题, 改进了传统 K-SVD 字典学习算法的终止准则, 结合变分模态分解(VMD)方法, 提出了基于 VMD 与终止准则改进的 K-SVD 字典学习故障特征提取方法。首先, 基于 VMD 算法对初始信号进行变分模态分解, 剔除信号中的干扰成分, 借助相关分析与峭度准则^[18]选择最优变分模态分量; 其次, 提出一种改进的 K-SVD 字典学习算法对最优分量的特征信息进行学习, 以改进的终止准则作为字典更新的收敛条件, 构造出准确匹配故障冲击成分的字典; 最后, 构建一种残差阈值改进的正交匹配追踪算法对振动信号进行稀疏求解得到稀疏信号, 对其进行包络谱分析, 提取微弱故障特征。

1 终止准则改进的 K-SVD 学习算法

AHARON 等^[19]为解决稀疏表示中学习字典构建的问题, 提出了 K-SVD 字典学习算法, 该算法的思想是由 K-means 聚类算法泛化而来, 不同的是

K-means 以均值作为聚类的类中心, 而 K-SVD 是通过奇异值分解(SVD)得到的特征向量作为类中心。传统的 K-SVD 算法的目标函数可以使用下式来表示

$$\min_{D, X} \left\{ \|Y - DX\|_F^2 \right\} \quad \text{s.t.} \quad \forall i \quad \|x_i\|_0 \leq T \quad (1)$$

式中, $Y = \{y_i\}_{i=1}^N$ 为目标信号, $D \in \mathbf{R}^{n \times K}$ ($K \ll N$) 为稀疏表示字典, $X = \{x_i\}_{i=1}^N$ 为稀疏表示系数, $\|\cdot\|_F$ 表示采用 Frobenius 范数估计误差, $\|\cdot\|_0$ 表示 l_0 范数, 即非零元素个数, T 为稀疏度。

上述原理是基于信号稀疏度已知的前提下, 通过设定稀疏度作为迭代终止参数, 当系数 x_i 的零范数趋于稀疏度 T 时迭代终止, 目标函数实现最小化求解。然而通常情况下, 目标信号的稀疏度难以确定。要实现传统 K-SVD 算法则需要对目标信号的稀疏度进行预估, 这无疑增加了字典学习的难度; 同时, 由于稀疏度的未知性使字典在学习过程中易学习到噪声等其他干扰成分, 导致稀疏表示效果较差。因此, 提出了基于终止准则改进的 K-SVD 字典学习算法。

终止准则改进的 K-SVD 字典学习算法基于稀疏表示的基本原理对目标函数进行了调整变换, 更换了约束条件与目标方程, 以下式表示

$$\min_{D, X} \left\{ \|x_i\|_0 \right\} \quad \text{s.t.} \quad \forall i \quad \|Y - DX\|_F^2 \leq \varepsilon \quad (2)$$

式中, ε 为极小的稀疏表示逼近误差, 通常取 0.1, 或者更小。当目标信号与稀疏信号的差值趋于极小值时迭代终止, 使得稀疏系数中的非零元素个数达到最少。由式(2)可知, 改进后的迭代终止条件无需设置稀疏度, 可以解决稀疏度参数的选取问题, 同时可以有效避免学习到干扰成分, 实现目标信号的稀疏极大化。

算法包含两个阶段: 稀疏编码、字典更新^[20-21]。

(1) 稀疏编码阶段: 初始固定一个稀疏表示字典 D , 构建残差阈值改进的正交匹配追踪(OMPerr)算法对样本信号进行稀疏表示, 获得稀疏表示系数 x_i , 即

$$\hat{x}_i = \arg \min_{x_i} \left\{ \|x_i\|_0 \right\} \quad \text{s.t.} \quad \|y_i - Dx_i\|_F^2 \leq \varepsilon, \forall i \in [1, N] \quad (3)$$

(2) 字典更新阶段: K-SVD 算法在每次迭代过程中仅更新一个原子, 假设为第 k ($k=1, 2, \dots, K$) 个原子 d_k , 可由如下表达式表示

$$\|Y - DX\|_F^2 = \left\| Y - \sum_{j=1}^K d_j x_j^T \right\|_F^2 = \left\| Y - \sum_{j \neq k} d_j x_j^T - d_k x_k^T \right\|_F^2 \quad (4)$$

式中, x_j^T 为稀疏系数矩阵 X 的第 j 行, 定义 E_k 为

除第 k 个原子以外所有原子产生的误差, 则式(4)可表示为

$$\|Y - DX\|_F^2 = \|E_k - d_k \mathbf{x}_k^T\|_F^2 \quad (5)$$

那么, 误差 E_k 可以表示为

$$E_k = Y - \sum_{j \neq k} d_j \mathbf{x}_j^T \quad (6)$$

定义 $\omega_k = \{i | 1 \leq i \leq K, \mathbf{x}_k^T(i) \neq 0\}$ 表示使用原子 d_k 的样本信号 Y 的索引, 以防止结果发散, 定义 Ω_k 为 $N \times \omega_k$ 的矩阵, 其中 $(\omega_k(i), i)$ 是非零值, 其余都是零值, 则式(5)等价于

$$\|E_k \Omega_k - d_k \mathbf{x}_k^T \Omega_k\|_F^2 = \|E_k^R - d_k \mathbf{x}_k^R\|_F^2 \quad (7)$$

式中, $\mathbf{x}_k^R = \mathbf{x}_k^T \Omega_k$ 表示 $\mathbf{x}_k^T$ 去掉零值项的行矢量, $E_k^R = E_k \Omega_k$ 表示稀疏编码过程中使用的原子 d_k 的误差列。

将 E_k^R 采用奇异值分解法(SVD)得到如下分解表达式

$$E_k^R = U \nabla V^T \quad (8)$$

通过分解得到的 U 的第一列来更新初始字典中的 d_k 。同时以矩阵 V 的第一列与 $\Delta(1,1)$ 的乘积来更新替换稀疏表示系数 x_j , 以上即完成稀疏表示字典的更新。

2 变分模态分解原理

变分模态分解(VMD)是一种基于经典维纳滤波、Hilbert 变换和混频的变分问题求解方法。该方法是通过频域迭代的方式搜寻变分模型的最优解, 确定每个分量的频率中心及带宽, 从而可以实现不同频率分量的有效分离^[22]。根据变分模态的基本原理, 通过以下变换获取模态函数 $u_k(t)$ 的带宽。

(1) 对不同频率的离散模态 $u_k(t)$ 进行 Hilbert 变换

$$\left[\delta(t) + \frac{j}{\pi t} \right] \mu_k(t) \quad (9)$$

(2) 上式加入指数项, 即加入中心频率项, 对各分量的解析信号的中心频率进行预估, 同时将各分量的频谱调制到相应的基带上

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] \exp(-j\omega_k t) \quad (10)$$

(3) 基于式(10)的计算, 获得每个模态分量的中心频率 ω_k ; 计算解调信号的梯度的平方 L^2 估计出各分量的带宽, 对应的约束变分模型表示式为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] \exp(-j\omega_k t) \right\|^2 \right\} \quad (11)$$

s.t. $\sum_k u_k = f$

式中, $\{u_k\} = \{u_1, \dots, u_K\}$ 表示 K 个模态分量, $\{\omega_k\} = \{\omega_1, \dots, \omega_K\}$ 表示各模态分量的中心频率。

3 改进 K-SVD 的稀疏表示方法

针对旋转机械强背景噪声下, 微弱故障特征难以准确提取的问题, 提出了一种稀疏表示理论下的故障诊断模型。以改进的终止准则作为 K-SVD 字典更新的收敛条件, 构建适合特定信号的稀疏表示字典, 实现微弱故障信号的稀疏表示及特征增强。由于 K-SVD 算法在字典学习过程中受噪声等干扰成分影响较大, 导致稀疏表示效果不理想, 为此引入了 VMD 算法对信号进行预处理, 提出了基于 VMD 与改进 K-SVD 字典学习的故障特征提取方法。方法流程如图 1 所示。

图 1 微弱故障特征提取策略

方法的具体实现步骤如下。

(1) 利用旋转机械故障模拟试验台采集故障信号, 采用 VMD 方法对故障信号进行变分分解, 获取 K 个变分模态分量。

(2) 借助相关分析-峭度准则, 选取最优变分模态分量。

(3) 基于终止准则改进的 K-SVD 算法对最优分量的特征信息进行学习。固定初始字典实现稀疏编码环节, 以编码后的稀疏系数作为字典更新训练的初始输入, 利用奇异值分解法不断更新迭代, 获取能够准确匹配故障冲击成分的字典。

(4) 借助学习所得的字典, 构建残差阈值改进的正交匹配追踪算法进行信号的稀疏优化求解, 获得稀疏信号。

(5) 对稀疏信号进行包络谱分析, 提取故障特征频率, 判断故障类型。

4 仿真信号验证

为了验证所提方法的有效性, 进行了仿真试验, 定义仿真信号表达式为

$$y(t_n) = A(t_n) \exp(-2\pi f_n \xi(t_n - T_k)) \times \sin(2\pi f_n(t_n - T_k) + \phi_0) + v(t),$$

$$T_k = T_{k-1} + \Delta T_k \quad n, k = 1, 2, \dots, N-1 \quad (12)$$

式中, $\{A(t_n), n=0, 1, \dots, N-1\}$ 为信号幅值; $f_n = 3000 \text{ Hz}$ 为系统固有频率; $\phi_0 = 5 \text{ rad}$ 为初始相位角; $\xi = 0.1$ 为相对阻尼系数; T_k 为第 k 个故障冲击的触发时间; $\Delta T_k = 0.01$ 为第 $k-1$ 与第 k 个故障冲击时间间隔, 故障特征频率为 $f = 100 \text{ Hz}$; 采样频率为 10000 Hz 。为模拟背景噪声, 加入了高斯白噪声 $v(t)$ 。

图 2a 为仿真加噪信号时域图, 对其进行包络分析, 如图 2b 所示, 无法准确提取出故障特征频率。采用稀疏表示策略对仿真信号进行特征增强, 首先, 对仿真信号进行 VMD 分解, 得到十个变分模态分量 u_i , 计算各分量的峭度值及相关系数, 如表 1 所示。根据相关分析-峭度准则, u_1 分量的峭度值与相关系数值最大, 因此选取分量 u_1 作为最优分量。利用改进的 K-SVD 字典学习算法对 u_1 的特征信息进行学习, 构造出如图 3a 所示的稀疏表示字典, 字典原子波形与仿真信号中的周期性正弦成分一致。采用残差阈值改进的正交匹配追踪算法对仿真信号进行稀疏优化求解, 得到稀疏信号如图 3b 所示, 从时域图中可以观察到信号的周期性冲击特征; 同时, 从图 3c 的包络频谱图中可以准确提取出故障特征频率及其高次谐波。此外, 以重构误差的趋势变化情况证明字典更新的收敛性, 如图 3d 所示。

图 2 仿真加噪信号

图 3 改进算法的特征增强结果

表 1 变分模态分量 u_i 的峭度值和相关系数

分量	u_1	u_2	u_3	u_4	u_5	u_6	u_7	u_8	u_9	u_{10}
峭度值	5.380 8	3.044 2	3.254 8	3.119 0	2.872 8	3.120 7	3.059 4	3.034 7	3.175 9	2.982 6
相关系数	0.563 1	0.024 5	0.003 8	0.001 9	0.001 8	0.000 6	0.000 8	0.000 3	0.000 3	0.000 3

为验证所提方法在字典原子构建及稀疏表示效果方面优于传统 K-SVD 字典学习方法,此处采用传统 K-SVD 方法对上述信号进行稀疏表示。从图 4a 的字典原子波形图中可以发现,稀疏字典受噪声影响较大,与仿真信号的余弦波形差别较明显。同时,稀疏表示信号中引入了虚假的冲击成分,如图 4b 所示,其原因在于字典在学习过程中混杂了噪声的特征信息。对其进行包络谱分析,由图 4c 的包络频

谱中难以有效提取出故障特征频率。随着字典原子的更新,稀疏重构误差收敛于 0.292 9,如图 4d 所示。针对以上分析结果可以发现,所提方法在字典原子构建、故障特征增强方面均优于传统 K-SVD 稀疏表示方法;此外,改进的 K-SVD 算法在稀疏重构精度及收敛速度上也有所提升。

5 试验验证

5.1 试验条件

为再次验证所提方法,以轴承为研究对象,在图 5 所示旋转机械故障模拟试验平台上,开展轴承故障信号的采集。通过电动机带动主轴转动,在轴承座 CH1 处安装加速度传感器进行振动信号的采集。故障轴承采用 NTN-N204 圆柱滚子轴承,用线切割的方法在轴承的内、外圈切割出宽度为 0.5 mm,深度为 0.15 mm 的凹痕。试验过程中,设定主轴转速为 1 300 r/min,采样频率为 100 kHz,计算得到该轴承的内、外圈故障特征频率分别为 145.84 Hz、86.32 Hz。

图 5 旋转机械故障模拟试验台

5.2 试验结果分析

图 6a 为外圈故障轴承振动信号经过归一化处理后的时域波形图,由于故障尺寸较小,振动能量较微弱,导致信号中的冲击成分被噪声等其他干扰成分所淹没。根据轴承故障振动特性,对振动信号进行高通滤波及包络谱分析,由图 6b 所示的包络谱中可以发现,故障特征频率淹没在其他干扰频率中,无法识别出故障状态。因此,基于稀疏表示策略对外圈故障信号进行特征增强处理,表 2 为 VMD 分解后各分量相关系数与峭度值,选取 U_6 为最优分量。得到特征增强结果如图 7 所示,从图中可以有效提取轴承的微弱故障特征,实现故障状态的准确识别。

图 4 传统算法的特征增强结果

(a) 时域波形图

(b) 包络谱图

图6 轴承外圈故障信号

图8为采用传统K-SVD方法的稀疏表示及故障特征增强结果。从图8a的字典原子波形图中可以发现,字典原子受噪声影响较大,得到的信号稀疏表示效果较差,如图8b所示。对稀疏信号进行包络谱

(a) 字典原子波形图

(b) 稀疏信号时域波形图

(c) 稀疏信号包络谱图

(d) 稀疏表示重构误差

图7 改进算法的特征增强结果

分析,发现故障特征频率仍不能准确提取,如图8c所示。同时,由图8d可以看出,基于传统算法的稀疏重构误差最终收敛于0.3636,远大于改进算法。

(a) 字典原子波形图

(b) 稀疏信号时域波形图

(c) 稀疏信号包络谱图

(d) 稀疏表示重构误差

图8 传统算法的特征增强结果

表 2 变分模态分量 U_i 的峭度值和相关系数

分量	U_1	U_2	U_3	U_4	U_5	U_6	U_7	U_8	U_9	U_{10}
峭度值	2.968 3	2.987 6	3.069 1	3.043 5	3.748 0	25.779 4	2.980 7	3.020 4	3.024 4	2.876 2
相关系数	0.189 3	0.020 79	0.049 73	0.021 76	0.098 04	0.453 5	0.022 76	0.006 65	0.004 21	0.002 15

以内圈故障轴承为研究对象,开展试验研究。内圈故障轴承的时域波形如图 9a 所示。图 9b 为高通滤波信号的包络频谱图,可以发现故障特征频率不明显,难以准确提取。基于稀疏表示策略对内圈故障信号进行特征增强处理。表 3 为 VMD 分解后各分量相关系数与峭度值,选取 U_6 为最优分量。得到特征增强结果如图 10 所示,从图中可以准确提取出转频(21.36 Hz)、故障特征频率(145 Hz)及其高次谐波(289.9 Hz)。

(a) 时域波形图

(b) 包络谱图

图 9 轴承内圈故障信号

(a) 字典原子波形图

(b) 稀疏信号包络谱图

图 10 改进算法的特征增强结果

采用传统 K-SVD 方法对轴承内圈故障信号进行稀疏表示。基于传统 K-SVD 方法得到的字典原子波形受噪声干扰较大,与冲击类故障波形差别较明显,如图 11a 所示。借助该字典对振动信号进行稀疏表示,从图 11b 所示的包络频谱图中难以准确提取出故障特征频率。以上分析结果表明,所提方法可以实现故障信号的稀疏极大化,有效提取微弱故障特征。同时,针对信噪比低、故障特征微弱的振动信号,所提方法在稀疏表示及特征增强的效果上优于传统 K-SVD 算法。

(a) 字典原子波形图

(b) 稀疏信号包络谱图

图 11 传统算法的特征增强结果

6 结论

提出了一种基于稀疏表示理论的故障诊断方法,可以有效获取“大数据”中的故障信息。为解决传统 K-SVD 方法在字典学习过程中信号稀疏度难以确定以及字典原子受噪声干扰大的问题,提出了基于 VMD 与终止准则改进的 K-SVD 字典学习方法。借助 VMD 方法选取最优模态分量,有效剔除了信号中干扰成分;基于 K-SVD 字典学习的稀疏表示原理,以改进后终止准则作为字典更新的收敛条件,有效解决了稀疏度选取的难题;采用残差阈值改进的正交匹配追踪算法对振动信号进行稀疏优化求解,实现了信号的稀疏表示及特征增强。由试验

表 3 变分模态分量 U'_i 的峭度值和相关系数

分量	U'_1	U'_2	U'_3	U'_4	U'_5	U'_6	U'_7	U'_8	U'_9	U'_{10}
峭度值	3.035 7	3.068 1	3.059 4	2.931 4	3.055 7	17.955 7	3.443 9	3.446 2	6.150 0	3.063 6
相关系数	0.081 3	0.018 2	0.039 5	0.018 3	0.047 4	0.342 0	0.094 7	0.066 0	0.112 8	0.015 2

结果可以看出, 所提方法可以有效提取微弱故障特征, 实现信号稀疏条件下的故障诊断。此外, 由对比试验可以得出, 所提方法在字典原子构建、稀疏重构误差及故障特征增强方面均优于传统 K-SVD 稀疏表示方法。

参 考 文 献

- [1] CUI L, ZHANG Y, GONG X, et al. Application of pattern recognition in gear faults based on the matching pursuit of a characteristic waveform[J]. Measurement, 2017(104): 212-222.
- [2] SONG L, WANG H, CHEN P. Vibration-based intelligent fault diagnosis for roller bearings in low-speed rotating machinery[J]. IEEE Transactions on Instrumentation & Measurement, 2018, 8(67): 1887-1899.
- [3] HAO Y, SONG L, CUI L, et al. A three-dimensional geometric features-based SCA algorithm for compound faults diagnosis[J]. Measurement, 2019(134): 480-491.
- [4] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [5] 刘盛纲. 大数据时代信息的高效获取与分析—评《稀疏感知导论》[J]. 电子与信息学报, 2018(3): 83.
LIU Shenggang. Efficient acquisition and analysis of information in the era of big data — review of “Introduction to sparse perception”[J]. Journal of Electronics and Information, 2018(3): 83.
- [6] SONG L, WANG H, CHEN P. Step-by-step fuzzy diagnosis method for equipment based on symptom extraction and trivalent logic fuzzy diagnosis theory[J]. IEEE Transactions on Fuzzy Systems, 2018(99): 1-13.
- [7] HAN T, JIANG D, SUN Y, et al. Intelligent fault diagnosis method for rotating machinery via dictionary learning and sparse representation-based classification[J]. Measurement, 2018, 118: 181-193.
- [8] 石娟娟, 王林, 罗春艳, 等. 基于优化最小算法的齿轮箱复合故障特征稀疏表示[J]. 振动工程学报, 2017(6): 1045-1055.
SHI Juanjuan, WANG Lin, LUO Chunyan, et al. Sparse representation for gearbox compound fault feature extraction based on majorization-minimization algorithm[J]. Journal of Vibration Engineering, 2017(6): 1045-1055.
- [9] CUI L, LI B, MA J, et al. Quantitative trend fault diagnosis of a rolling bearing based on Sparsogram and Lempel-Ziv[J]. Measurement, 2018(128): 410-418.
- [10] REN B, HAO Y, WANG H, et al. A sparsity-promoted method based on majorization-minimization for weak fault feature enhancement[J]. Sensors, 2018, 18(4): 1003-1022.
- [11] 樊薇, 李双, 蔡改改, 等. 瞬态成分 Laplace 小波稀疏表示及其轴承故障特征提取应用[J]. 机械工程学报, 2015, 51(15): 110-118.
FAN Wei, LI Shuang, CAI Gaigai, et al. Sparse representation for transients in Laplace wavelet basis and its application in feature extraction of bearing fault[J]. Journal of Mechanical Engineering, 2015, 51(15): 110-118.
- [12] WANG L, CAI G, YOU W, et al. Transients extraction based on averaged random orthogonal matching pursuit algorithm for machinery fault diagnosis[J]. IEEE Transactions on Instrumentation & Measurement, 2017, 66(12): 3237-3248.
- [13] WANG H, KE Y, SONG L, et al. A sparsity-promoted decomposition for compressed fault diagnosis of roller bearings[J]. Sensors, 2016, 16(9): 1524-1544.
- [14] 张峻宁, 张培林, 张云强, 等. 融合字典学习的滑动轴承摩擦故障趋势自记忆预测[J]. 振动工程学报, 2017, 30(3): 519-526.
ZHANG Junning, ZHANG Peilin, ZHANG Yunqiang, et al. Self-memorization model for predicting the wearing trend of sliding bearing with fusion dictionary learning[J]. Journal of Vibration Engineering, 2017, 30(3): 519-526.
- [15] 刘畅, 伍星, 毛剑琳, 等. 基于改进 MOD 学习的滚动轴承振动信号稀疏表示[J]. 计算机工程与应用, 2016, 52(17): 257-260.
LIU Chang, WU Xing, MAO Jianlin, et al. Sparse representation of rolling bearing vibration signal based on improved MOD dictionary learning[J]. Computer Engineering and Applications, 2016, 52(17): 257-260.
- [16] 余发军, 周凤星, 严保康. 基于字典学习的轴承早期故障稀疏特征提取[J]. 振动与冲击, 2016, 35(6): 181-186.
YU Fajun, ZHOU Fengxing, YAN Baokang. Bearing

- initial fault feature extraction via sparse representation based on dictionary learning[J]. *Journal of Vibration and Shock*, 2016, 35(6): 181-186.
- [17] 郭俊锋. 基于 K-SVD 字典学习算法的稀疏表示振动信号压缩测量重构方法[J]. *机械工程学报*, 2017, 54(7): 97-106.
- GUO Junfeng. A method of reconstruction of compressed measuring for mechanical vibration signals based on K-SVD dictionary-training algorithm[J]. *Journal of Mechanical Engineering*, 2017, 54(7): 97-106.
- [18] 马增强, 李亚超, 刘政, 等. 基于变分模态分解和 Teager 能量算子的滚动轴承故障特征提取[J]. *振动与冲击*, 2016, 35(13): 134-139.
- MA Zengqiang, LI Yachao, LIU Zheng, et al. Rolling bearings' fault feature extraction based on variational mode decomposition and teager energy operator[J]. *Journal of Vibration and Shock*, 2016, 35(13): 134-139.
- [19] 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.
- [20] YANG B, LIU R, CHEN X. Fault diagnosis for a wind turbine generator bearing via sparse representation and shift-invariant K-SVD[J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(3): 1321-1331.
- [21] YANG H, LIN H, DING K. Sliding window denoising K-singular value decomposition and its application on rolling bearing impact fault diagnosis[J]. *Journal of Sound & Vibration*, 2018, 421: 205-219.
- [22] 钱林, 康敏, 傅秀清, 等. 基于 VMD 的自适应形态学在轴承故障诊断中的应用[J]. *振动与冲击*, 2017, 36(3): 227-233.
- QIAN Lin, KANG Min, FU Xiuqing, et al. Application of adaptive-morphology in bearing fault diagnosis based on VMD[J]. *Journal of Vibration and Shock*, 2017, 36(3): 227-233.

作者简介: 王华庆(通信作者), 男, 1973 年出生, 博士, 教授, 博士研究生导师。主要研究方向为机械装备健康监测及故障智能诊断、信号处理与特征提取。

E-mail: hqwang@mail.buct.edu.cn

任帮月, 女, 1994 年出生, 硕士研究生。主要研究方向为机械故障诊断、稀疏表示。

E-mail: rby_buct@163.com

宋浏阳, 女, 1988 年出生, 博士后。主要研究方向为机械故障诊断。

E-mail: xq_0703@163.com

董方, 男, 1993 年出生, 硕士研究生。主要研究方向为机械故障诊断、动力学仿真。

E-mail: doveel1028@163.com

王梦阳, 男, 1992 年出生, 硕士研究生。主要研究方向为机械故障诊断、盲源分离。

E-mail: mengyang1992@163.com