

DOI: 10.19650/j.cnki.cjsi.J2312100

# 加权多尺度卷积稀疏表示及其在滚动轴承 复合故障诊断中的应用\*

王爽<sup>1</sup>, 丁传仓<sup>2</sup>, 曹懿<sup>2</sup>, 王报祥<sup>2,3</sup>, 江星星<sup>2</sup>

(1. 苏州城市学院智能制造与智慧交通学院 苏州 215104; 2. 苏州大学轨道交通学院 苏州 215131;  
3. 苏州科技大学机械工程学院 苏州 215009)

**摘要:**故障特征精确提取是实现轴承故障诊断的重要环节。卷积稀疏表示能够刻画特征的移位不变特性,非常适用于滚动轴承故障特征提取。然而,卷积稀疏表示忽略了故障冲击特征的周期性及不同尺度下的信号特性差异,制约了其在谐波成分和背景噪声等干扰下的特征提取能力。因此,提出了加权多尺度卷积稀疏表示用于分离振动信号中的周期性故障冲击特征,从而实现轴承故障诊断。在构建的稀疏表示模型中,利用多尺度变换将原始信号转换到不同尺度下,并在不同尺度下采用不同权重系数以达到抑制谐波成分等干扰的目的。同时,为了凸显故障冲击特征,建立了约束故障特征稀疏系数周期性的正则项,提高冲击特征分离能力。此外,引入交替方向乘子法和受控极小化方法推导出迭代求解算法。最后,通过分析提取特征的波形、包络谱及两种故障信息定量评估指标,验证了提出方法拥有优异的轴承复合故障冲击特征提取和诊断能力。

**关键词:** 加权多尺度卷积稀疏表示; 滚动轴承; 故障诊断; 故障特征提取

**中图分类号:** TH165+.3 TH133.33 **文献标识码:** A **国家标准学科分类代码:** 460.99

## Weighted multiscale convolutional sparse representation and its application in rolling bearing compound fault diagnosis

Wang Shuang<sup>1</sup>, Ding Chuancang<sup>2</sup>, Cao Yi<sup>2</sup>, Wang Baoxiang<sup>2,3</sup>, Jiang Xingxing<sup>2</sup>

(1. Institute of Intelligent Manufacturing and Smart Transportation, Suzhou City University, Suzhou 215104, China;  
2. School of Rail Transportation, Soochow University, Suzhou 215131, China; 3. School of Mechanical  
Engineering, Suzhou University of Science and Technology, Suzhou 215009, China)

**Abstract:** Accurate fault feature extraction is an important part of achieving bearing fault diagnosis. The convolutional sparse representation can characterize the shift-invariant property of features, which is very suitable for rolling bearing fault feature extraction. However, the convolutional sparse representation ignores the periodicity of fault impulse features and the difference of signal characteristics at different scales, which restricts its feature extraction ability under the interference of harmonic components and background noise. Therefore, a weighted multiscale convolutional sparse representation is proposed for separating the periodic fault impulse features in vibration signals to achieve bearing fault diagnosis. Specifically, in the constructed sparse representation model, the original signal is converted to different scales using multiscale transformation, and different weights are utilized in different scales to suppress the interferences such as harmonic components. Meanwhile, to promote fault impulse features, a regularization term that constrains the periodicity of the sparse coefficient of fault features is established to improve fault feature separation ability. In addition, the alternating direction method of multipliers and the majorization-minimization method are introduced to derive an iterative solving algorithm. Finally, by analyzing the waveform and envelope spectrum of extracted features and two quantitative evaluation indicators of fault information, the excellent capability of the proposed method in fault feature extraction and diagnosis of bearing compound faults is verified.

**Keywords:** weighted multiscale convolutional sparse representation; rolling bearing; fault diagnosis; fault feature extraction

## 0 引言

滚动轴承是旋转机械的重要组成部分,为了避免发生灾难性事故,开展滚动轴承故障诊断及状态监测是不可或缺的。当轴承存在故障时,振动信号中会产生周期性故障冲击特征。然而,由于复杂的设备运行环境及机械结构,振动信号中故障冲击特征不可避免地被干扰成分淹没,导致难以准确判别轴承健康状态<sup>[1-2]</sup>。因此,开展故障冲击特征提取方法研究对于实现滚动轴承故障诊断与状态监测具有重要意义。

稀疏表示是近年来信号处理领域的研究热点,也在故障诊断领域中获得广泛应用<sup>[3]</sup>。稀疏表示旨在构建信号相对于字典的最稀疏或接近最稀疏的表示,从而挖掘信号中蕴含的深层次特征。在稀疏表示中,字典主要分为预定义分析字典与自适应学习字典两种,字典与信号中内在结构的匹配程度越高,越能获得信号的最稀疏表示,也就是用最少的原子表示信号。针对表示故障特征的预定义分析字典构建,Sun等<sup>[4]</sup>设计了一种与轴承局部故障特征匹配的参数脉冲字典,能够实现噪声干扰下的冲击特征提取,成功应用于电机和风力发电机组的轴承故障诊断。Huang等<sup>[5]</sup>利用短时傅里叶字典和离散傅里叶字典表示振动信号中故障冲击特征和齿轮啮合成分,实现了齿轮箱振动信号多成分的同时提取。相较于预定义分析字典,从振动信号中学习获得的自适应学习字典能够更精确地表示信号中的复杂故障冲击特征,在特征提取方面展现出更优异的效果<sup>[6-7]</sup>。最优方向法(method of optimal direction, MOD)和K-均值奇异值分解(K-means singular value decomposition, K-SVD)是两种广泛研究的字典学习算法,也被应用于振动信号的故障特征提取。Liang等<sup>[8]</sup>以K-SVD为基础提出了信息导向的K-SVD,其中利用谐波比指标选取与故障最相关的原子进行字典更新,在干扰条件下有较强的特征识别能力。Zhao等<sup>[9]</sup>考虑到信号在不同尺度下的特性,在K-SVD的基础上构建了加权多尺度字典学习方法,有效提取出轴承故障特征。然而,MOD、K-SVD及其改进算法计算复杂度,内存空间占用大,直接计算整个信号的稀疏表示是难以实现的。因此,需要把整个信号分割成多段短信号,然后独立计算每个短信号的稀疏表示形式<sup>[10]</sup>。然而,对于滚动轴承而言,振动信号中故障冲击特征在不同时刻呈现出相似的结构,信号分割策略忽略故障冲击间的相关性,导致MOD、K-SVD及其改进算法在振动信号故障特征提取中的表现不理想。

近年来,一种新颖的字典学习方法——卷积稀疏表示吸引了广泛关注,并在图像处理、声音处理等领域取

得突出成效<sup>[11-13]</sup>。卷积稀疏表示将整个信号表示为稀疏系数与字典的卷积之和,充分地考虑了特征的移位不变特性,是一种更有潜力的故障冲击特征提取方法。因此,为了实现振动信号中故障特征的精确提取,学者们将卷积稀疏表示应用到轴承故障特征提取中,并建立了一系列改进方法。Ding等<sup>[14]</sup>将卷积稀疏表示引入到时移不变特征提取中,利用学习到的冲击字典与稀疏系数,有效地提取出振动信号中的故障冲击特征。Du等<sup>[15]</sup>针对故障冲击包络特征的提取,提出了非负有界卷积稀疏学习模型,并利用发电机轴承试验证实了算法在包络特征识别中的有效性。Zhou等<sup>[16]</sup>利用非对称高斯啁啾模型构建了表征故障冲击的卷积字典,并利用优化正交匹配追踪算法求解卷积稀疏表示优化问题及优化字典中原子参数,成功提取轴承故障引起的冲击特征。He等<sup>[17]</sup>提出了快速卷积稀疏字典学习方法,能够快速提取信号中被噪声淹没的故障特征。Lu等<sup>[18]</sup>考虑到振动信号的非局部自相似特性,建立了一种新颖的基于卷积稀疏表示的特征提取方法,实现了轴承故障诊断。Yi等<sup>[19]</sup>构建了表征故障特征的小波核和时频流形核,建立了双核驱动的卷积稀疏表示以从时频域中分离故障引起的特征成分,成功实现了故障瞬变特征增强。

尽管现有卷积稀疏表示及其改进方法在轴承故障特征提取中取得了一定效果,然而仍然存在如下两方面不足。1)由于机械加工精度与设备安装精度的限制,即使滚动轴承处于健康状态时,振动信号中也不可避免地存在谐波成分及其他干扰成分,现有卷积稀疏表示研究未能全面考虑谐波成分影响,制约了在冲击特征提取方面的性能。2)现有卷积稀疏表示研究没有考虑故障冲击特征的周期性以及不同尺度下信号特性的差异,使得微弱故障特征的辨识与提取十分棘手,同时难以用于诊断轴承复合故障。

因此,为了弥补卷积稀疏表示算法的不足,提出了加权多尺度卷积稀疏表示用于分离振动信号中的周期性故障冲击特征,从而准确诊断滚动轴承故障。在构建的稀疏表示模型中,利用多尺度变换将原始振动信号转换到不同尺度下,并在不同尺度下采用不同权重系数达到抑制谐波成分等干扰成分的目的。同时,为了促进故障冲击特征的精确提取,建立了约束故障特征稀疏系数周期性的正则项,提高冲击特征分离能力。此外,针对稀疏表示模型求解,引入交替方向乘子法和受控极小化方法推导出迭代收敛算法。最后,分析了仿真信号和列车轮对轴承试验台信号,结果表明相较于3种对比方法,提出方法拥有更优异的冲击特征提取和轴承复合故障诊断能力。

## 1 理论回顾

### 1.1 卷积稀疏表示

卷积稀疏表示算法是稀疏表示的一种特殊形式。在卷积稀疏表示算法中,信号被假定表示为稀疏系数与字典的卷积之和,即信号中不同位置出现的相同特征可以利用同一个原子表示。卷积稀疏表示的稀疏模型可以表示为<sup>[13,20]</sup>:

$$\begin{aligned} \{ \mathbf{d}_m, \mathbf{x}_m \} = \\ \arg \min_{\{ \mathbf{d}_m, \mathbf{x}_m \}} \frac{1}{2} \left\| \mathbf{y} - \sum_m \mathbf{d}_m * \mathbf{x}_m \right\|_2^2 + \lambda \sum_m \left\| \mathbf{x}_m \right\|_1 \\ \text{s.t. } \left\| \mathbf{d}_m \right\|_2 = 1 \quad \forall m \end{aligned} \quad (1)$$

式中:  $\mathbf{y}$  为被分析信号;  $*$  为卷积符号;  $\mathbf{d}_m$  为自适应学习字典中的第  $m$  个原子;  $\mathbf{x}_m$  为与原子  $\mathbf{d}_m$  对应的稀疏系数;  $\left\| \cdot \right\|_1$  为  $l_1$  范数;  $\left\| \cdot \right\|_2$  为  $l_2$  范数;  $\lambda > 0$  为正则参数, 用于平衡数据保真项  $\frac{1}{2} \left\| \mathbf{y} - \sum_m \mathbf{d}_m * \mathbf{x}_m \right\|_2^2$  与稀疏正则项  $\sum_m \left\| \mathbf{x}_m \right\|_1$ 。

针对式(1)中的稀疏模型,研究人员开发了多种求解算法<sup>[13,21]</sup>。文献[13]在交替方向乘子法的基础上,提出了一种高效的综合利用空间域与频域参数的求解算法。

### 1.2 受控极小化方法

受控极小化方法利用一系列较简单的稀疏优化问题代替困难的稀疏优化问题,进而实现困难稀疏优化问题的求解<sup>[22]</sup>。在受控极小化方法中,对于凸优化问题(式(2))的唯一的解可以迭代得到式(3)。

$$\{ \mathbf{u}^* \} = \underset{|\mathbf{u}|}{\operatorname{argmin}} F(\mathbf{u}) \quad (2)$$

$$\{ \mathbf{u}^{(i+1)} \} = \underset{|\mathbf{u}|}{\operatorname{argmin}} Q(\mathbf{u}, \mathbf{u}^{(i)}) \quad (3)$$

式中:  $i$  表示第  $i$  次迭代。  $Q: \mathbf{R}^N \times \mathbf{R}^N \rightarrow \mathbf{R}^N$  为目标函数  $F$  的受控优化算子,满足以下约束条件:

$$Q(\mathbf{u}, \mathbf{v}) \geq F(\mathbf{u}) \quad (4)$$

$$Q(\mathbf{v}, \mathbf{v}) = F(\mathbf{v})$$

惩罚函数  $|u|$  的受控优化算子为:

$$q(u, v) = \frac{1}{2v} u^2 + \frac{1}{2} v = \frac{1}{2v} u^2 + C(v) \quad (5)$$

式中:  $C(v)$  是相对于  $v$  的函数,与输入变量  $u$  无关。

## 2 加权多尺度卷积稀疏表示

### 2.1 模型构建

当滚动轴承存在局部故障时,会产生具有特定周期的周期性冲击特征,周期性故障冲击是判断轴承是否发生故障的重要诊断信息。然而,在实际工作环境中,周期

性冲击特征一般会受到谐波分量和环境噪声等成分的干扰,导致难以准确判别轴承健康状态。在振动信号中,故障引起的周期性冲击特征与谐波成分等其他干扰成分具有不同的特性,因此构建如下稀疏表示模型用于提取振动信号中的故障冲击特征。

$$\begin{aligned} \{ \mathbf{d}_{j,m}, \mathbf{x}_{j,m} \} = \\ \arg \min_{\{ \mathbf{d}_{j,m}, \mathbf{x}_{j,m} \}} \frac{1}{2} \sum_j \mathbf{w}_j \left\| (\mathbf{A}^T \mathbf{y})_j - \sum_m \mathbf{d}_{j,m} * \mathbf{x}_{j,m} \right\|_2^2 + \\ \sum_j \lambda \sum_m \sum_{n_j} \mathbf{b}_j \odot [\mathbf{x}_{j,m}]_{n_j, K_j} \\ \text{s.t. } \left\| \mathbf{d}_{j,m} \right\|_2 = 1 \quad \forall j, m \end{aligned} \quad (6)$$

式中:  $\mathbf{A}^T$  为多尺度变换,将信号  $\mathbf{y}$  转换到多尺度空间。本文将  $\mathbf{A}^T$  设置为调  $Q$  因子小波变换,用于将信号  $\mathbf{y}$  转换为  $J+1$  个尺度空间中的小波系数,其中  $(\mathbf{A}^T \mathbf{y})_j$  为第  $j$  个尺度下的小波系数,且  $j \in [1, J+1]$ ;  $\mathbf{w}_j$  为第  $j$  个尺度的权重系数,取决于每个尺度中的故障信息密度;  $\mathbf{d}_{j,m}$  为第  $j$  个尺度下自适应学习字典中的第  $m$  个原子;  $\mathbf{x}_{j,m}$  为与原子  $\mathbf{d}_{j,m}$  对应的稀疏系数;  $\lambda$  为正则参数;  $\odot$  为元素点乘操作。

同时,  $\mathbf{b}_j$  为周期二进制向量,用于约束周期性,定义为:

$$\mathbf{b}_j = \left[ \underbrace{1, \dots, 1}_{N_{j1}}, \underbrace{0, \dots, 0}_{N_{j0}}, \dots, \underbrace{1, \dots, 1}_{N_{j1}}, \underbrace{0, \dots, 0}_{N_{j0}} \right] \quad (7)$$

$K_j$ 个元素,  $N_p$ 个周期

式中:  $N_{j1}$  为第  $j$  个尺度下每个周期  $T_j$  中非零点的数量;  $N_{j0}$  为每个周期  $T_j$  中零点的数量。  $N_{j0}, N_{j1}$  和  $K_j$  应该满足如下条件  $N_{j0} + N_{j1} = K_j / N_p$ , 其中  $N_p$  为周期二进制向量  $\mathbf{b}_j$  中包含的周期个数。根据自相关理论可知,信号自相关函数的峰值可以作为周期的估计值<sup>[23]</sup>,因此本文采用自相关法估计周期。如图1所示,除  $\tau=0$  外,  $r_x$  在  $\tau_{\max}$  处达到最大值,因此估计周期  $T_j$  为  $\tau_{\max}$ , 即  $T_j = \tau_{\max}$ 。

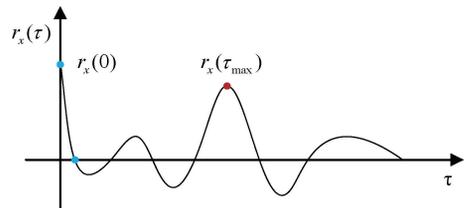


图1 信号自相关函数

Fig. 1 Autocorrelation function of signal

此外,  $[\mathbf{x}_{j,m}]_{n_j, K_j}$  表示稀疏系数  $\mathbf{x}_{j,m}$  的第  $n_j$  个组,该组共包含了  $K_j$  个元素,定义为:

$$[\mathbf{x}_{j,m}]_{n_j, K_j} = [[\mathbf{x}_{j,m}]_{n_j}, [\mathbf{x}_{j,m}]_{n_j+1}, \dots, [\mathbf{x}_{j,m}]_{n_j+K_j-1}] \quad (8)$$

在振动信号中,轴承故障特征既具有周期性又具有冲击性,而其他干扰成分如谐波成分、随机冲击、背景噪

声等则不同时具备两种特性。由于相关峭度指标<sup>[24]</sup>综合评估了信号的周期性和冲击性,利用相关峭度指标能够有效区分故障特征与干扰成分。因此,为了使稀疏表示模型(式(6))能够凸显故障特征并抑制干扰成分,将第 $j$ 个尺度的权重系数 $w_j$ 设置为:

$$w_j = \frac{CK_j}{\max(CK)} \quad (9)$$

式中: $CK_j$ 为第 $j$ 个尺度下小波系数对应的时域信号的相关峭度, $CK = [CK_1, CK_2, \dots, CK_{J+1}]$ 表示 $J+1$ 个尺度空间中的相关峭度。

由于每个尺度是独立的,对于第 $j$ 个尺度,稀疏表示模型(式(6))可以简化为如下单一尺度稀疏表示模型:

$$\begin{aligned} & \{d_{j,m}, x_{j,m}\} = \\ & \arg \min_{\{d_{j,m}, x_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 + \\ & \lambda \sum_m \sum_{n_j} b_j \odot [x_{j,m}]_{n_j, K_j} \\ & \text{s. t. } \|d_{j,m}\|_2 = 1 \quad \forall j, m \end{aligned} \quad (10)$$

因此,稀疏表示模型(式(6))的求解可以转化为在单个尺度上依次求解单一尺度稀疏表示模型(式(10))。

## 2.2 算法推导

针对稀疏表示模型(10)求解,采用稀疏系数与自适应学习字典交替更新的策略推导迭代求解算法。

假设事先已知字典 $d_{j,m}$ ,可以通过求解式(11)得到与 $d_{j,m}$ 对应的稀疏系数 $x_{j,m}$ 。

$$\begin{aligned} & \{x_{j,m}\} = \arg \min_{\{x_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 + \\ & \lambda \sum_m \sum_{n_j} b_j \odot [x_{j,m}]_{n_j, K_j} \end{aligned} \quad (11)$$

固定稀疏系数 $x_{j,m}$ ,可以通过求解式(12)得到最优字典 $d_{j,m}$ 。

$$\begin{aligned} & \{d_{j,m}\} = \arg \min_{\{d_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 \\ & \text{s. t. } \|d_{j,m}\|_2 = 1 \quad \forall j, m \end{aligned} \quad (12)$$

对于式(11)中的稀疏优化问题,引入辅助变量 $z_{j,m}$ ,利用交替方向乘子法,便可以通过迭代求解以下子问题得到最优解 $x_{j,m}$ 。

$$\begin{aligned} & \{x_{j,m}\} = \arg \min_{\{x_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 + \\ & \frac{\mu}{2} \sum_m \|x_{j,m} - z_{j,m} + u_{j,m}\|_2^2 \end{aligned} \quad (13)$$

$$\begin{aligned} & \{z_{j,m}\} = \arg \min_{\{z_{j,m}\}} \frac{\mu}{2} \sum_m \|x_{j,m} - z_{j,m} + u_{j,m}\|_2^2 + \\ & \lambda \sum_m \sum_{n_j} b_j \odot [z_{j,m}]_{n_j, K_j} \end{aligned} \quad (14)$$

$$u_{j,m} = u_{j,m} + x_{j,m} - z_{j,m} \quad (15)$$

对于式(12)中的稀疏优化问题,可以写成如下等价

的无约束优化问题:

$$\begin{aligned} & \{d_{j,m}\} = \arg \min_{\{d_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 + \\ & \sum_m l_{C_{PN}}(d_{j,m}) \end{aligned} \quad (16)$$

式中: $C_{PN}$ 为约束集,定义为 $C_{PN} = \{x \in \mathbf{R}^N : (I - PP^T)x = 0, \|x\|_2 = 1\}$ ,其中 $P$ 表示补0操作。此外,集合 $S$ 的指示函数定义为<sup>[13]</sup>:

$$l_S(X) = \begin{cases} 0, & X \in S \\ \infty, & X \notin S \end{cases} \quad (17)$$

类似地,引入辅助变量 $g_{j,m}$ ,利用交替方向乘子法,便可以通过迭代求解以下问题得到最优解 $d_{j,m}$ 。

$$\begin{aligned} & \{d_{j,m}\} = \arg \min_{\{d_{j,m}\}} \frac{1}{2} w_j \left\| (A^T y)_j - \sum_m d_{j,m} * x_{j,m} \right\|_2^2 + \\ & \frac{\rho}{2} \sum_m \|d_{j,m} - g_{j,m} + h_{j,m}\|_2^2 \end{aligned} \quad (18)$$

$$\begin{aligned} & \{g_{j,m}\} = \arg \min_{\{g_{j,m}\}} \frac{\rho}{2} \sum_m \|d_{j,m} - g_{j,m} + h_{j,m}\|_2^2 + \\ & \sum_m l_{C_{PN}}(g_{j,m}) \end{aligned} \quad (19)$$

$$h_{j,m} = h_{j,m} + d_{j,m} - g_{j,m} \quad (20)$$

1) 求解子问题式(13)

定义线性算子 $D_{j,m}$ ,满足条件 $D_{j,m}x_{j,m} = d_{j,m} * x_{j,m}$ 。

同时,变量 $D_{j,m}x_{j,m}$ 、 $(A^T y)_j$ 、 $z_{j,m}$ 和 $u_{j,m}$ 在频域中为 $\hat{D}_{j,m}$ 、 $\hat{x}_{j,m}$ 、 $\widehat{(A^T y)}_j$ 、 $\hat{z}_{j,m}$ 和 $\hat{u}_{j,m}$ 。此外,定义如下矩阵:

$$\begin{aligned} & \hat{D}_j = (\hat{D}_{j,0} \quad \hat{D}_{j,1} \quad \dots) \\ & x_j = \begin{pmatrix} \hat{x}_{j,0} \\ \hat{x}_{j,1} \\ \vdots \end{pmatrix}, z_j = \begin{pmatrix} \hat{z}_{j,0} \\ \hat{z}_{j,1} \\ \vdots \end{pmatrix}, u_j = \begin{pmatrix} \hat{u}_{j,0} \\ \hat{u}_{j,1} \\ \vdots \end{pmatrix} \end{aligned} \quad (21)$$

式(13)可以等价表示为:

$$\begin{aligned} & \{\hat{x}_j\} = \arg \min_{\{\hat{x}_j\}} \frac{1}{2} w_j \left\| \widehat{(A^T y)}_j - \hat{D}_j \hat{x}_j \right\|_2^2 + \\ & \frac{\mu}{2} \|\hat{x}_j - \hat{z}_j + \hat{u}_j\|_2^2 \end{aligned} \quad (22)$$

式(22)的解可以利用 Sherman-Morrison 公式<sup>[13]</sup>获得:

$$\begin{aligned} & \hat{x}_j = \frac{1}{\mu} \left( (w_j \hat{D}_j^T \widehat{(A^T y)}_j + \mu(\hat{z}_j - \hat{u}_j)) - \right. \\ & \left. \frac{w_j \hat{D}_j (w_j \hat{D}_j^T \widehat{(A^T y)}_j + \mu(\hat{z}_j - \hat{u}_j))}{\mu w_j \hat{D}_j \hat{D}_j^T} \hat{D}_j^T \right) \end{aligned} \quad (23)$$

2) 求解子问题式(14)

为了求解子问题式(14),利用受控极小化方法推导出一种收敛算法。首先,式(14)中目标函数 $F(z_{j,m}) =$

$\frac{\mu}{2} \sum_m \|x_{j,m} - z_{j,m} + u_{j,m}\|_2^2 + \lambda \sum_m \sum_{n_j} b_j \odot [z_{j,m}]_{n_j, K_j}$ 的受

控优化算子为:

$$Q(\mathbf{z}_{j,m}, \mathbf{v}) = \frac{\mu}{2} \sum_m \|\mathbf{x}_{j,m} - \mathbf{z}_{j,m} + \mathbf{u}_{j,m}\|_2^2 + \frac{\lambda}{2} \sum_m \sum_{n_j} [\mathbf{r}(\mathbf{v})]_{n_j, n_j} [\mathbf{z}_{j,m}]_{n_j}^2 + C(\mathbf{v}) \quad (24)$$

式中:  $\mathbf{r}$  为对角矩阵。

$$[\mathbf{r}(\mathbf{v})]_{n_j, n_j} = \sum_{k=0}^{K_j-1} \frac{[\mathbf{b}_j]_k}{\|\mathbf{b}_j \odot [\mathbf{v}]_{n_j-k, K_j}\|_2} \quad (25)$$

根据受控极小化方法的框架, 式(14)的最优解可以通过迭代求解  $\{\mathbf{z}_{j,m}^{(i+1)}\} = \underset{\{\mathbf{z}_{j,m}^{(i)}\}}{\operatorname{argmin}} Q(\mathbf{z}_{j,m}, \mathbf{z}_{j,m}^{(i)})$  获得, 其中  $i$  表示第  $i$  次迭代。因此, 式(14)最优解可以通过迭代式(26)获得:

$$\mathbf{z}_{j,m}^{(i+1)} = \mu [\mu \mathbf{I} + \lambda \mathbf{r}(\mathbf{z}_{j,m}^{(i)})]^{-1} (\mathbf{x}_{j,m}^{(i)} + \mathbf{u}_{j,m}^{(i)}) \quad (26)$$

3) 求解子问题式(18)

在频域中, 定义  $\hat{\mathbf{X}}_{j,m} = \operatorname{diag}(\hat{\mathbf{x}}_{j,m})$ 。同时, 定义如下矩阵:

$$\hat{\mathbf{X}}_j = (\hat{\mathbf{X}}_{j,0} \quad \hat{\mathbf{X}}_{j,1} \quad \dots)$$

$$\hat{\mathbf{d}}_j = \begin{pmatrix} \hat{\mathbf{d}}_{j,0} \\ \hat{\mathbf{d}}_{j,1} \\ \vdots \end{pmatrix}, \quad \hat{\mathbf{g}}_j = \begin{pmatrix} \hat{\mathbf{g}}_{j,0} \\ \hat{\mathbf{g}}_{j,1} \\ \vdots \end{pmatrix}, \quad \hat{\mathbf{h}}_j = \begin{pmatrix} \hat{\mathbf{h}}_{j,0} \\ \hat{\mathbf{h}}_{j,1} \\ \vdots \end{pmatrix} \quad (27)$$

则优化子问题式(18)可以表示为:

$$\{\hat{\mathbf{d}}_j\} = \underset{\{\hat{\mathbf{d}}_j\}}{\operatorname{argmin}} \frac{1}{2} \mathbf{w}_j \|\widehat{(\mathbf{A}^T \mathbf{y})}_j - \hat{\mathbf{X}}_j \hat{\mathbf{d}}_j\|_2^2 + \frac{\rho}{2} \|\hat{\mathbf{d}}_j - \hat{\mathbf{g}}_j + \hat{\mathbf{h}}_j\|_2^2 \quad (28)$$

式(28)的解可以利用 Sherman-Morrison 公式获得:

$$\hat{\mathbf{d}}_j = \frac{1}{\rho} \left( (\mathbf{w}_j \hat{\mathbf{X}}_j^T \widehat{(\mathbf{A}^T \mathbf{y})}_j + \rho(\hat{\mathbf{g}}_j - \hat{\mathbf{h}}_j)) - \frac{\mathbf{w}_j \hat{\mathbf{X}}_j (\mathbf{w}_j \hat{\mathbf{X}}_j^T \widehat{(\mathbf{A}^T \mathbf{y})}_j + \rho(\hat{\mathbf{g}}_j - \hat{\mathbf{h}}_j))}{\rho \mathbf{w}_j \hat{\mathbf{X}}_j \hat{\mathbf{X}}_j^T} \widehat{\mathbf{X}}_j^T \right) \quad (29)$$

4) 求解子问题式(19)

优化子问题式(19)的形式为:

$$\underset{\mathbf{x}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{x} - \mathbf{y}\|_2^2 + l_{C_{PN}}(\mathbf{x}) = \operatorname{prox}_{l_{C_{PN}}}(\mathbf{y}) \quad (30)$$

其中,  $\operatorname{prox}_{l_{C_{PN}}}(\mathbf{y})$  表示为:

$$\operatorname{prox}_{l_{C_{PN}}}(\mathbf{y}) = \frac{\mathbf{P}\mathbf{P}^T \mathbf{y}}{\|\mathbf{P}\mathbf{P}^T \mathbf{y}\|_2} \quad (31)$$

根据式(30)和(31), 解可以由式(32)给出:

$$\mathbf{g}_{j,m} = \frac{\mathbf{P}\mathbf{P}^T(\mathbf{d}_{j,m} + \mathbf{h}_{j,m})}{\|\mathbf{P}\mathbf{P}^T(\mathbf{d}_{j,m} + \mathbf{h}_{j,m})\|_2} \quad (32)$$

综上所述, 通过稀疏编码与字典学习交替更新策略, 构建了稀疏表示模型式(6)的迭代收敛求解算法, 总结

为算法 1。

算法 1 稀疏表示模型式(6)求解算法

1. 输入: 振动信号  $\mathbf{y}$ ,  $\mu$ ,  $\rho$ ,  $\mathbf{b}_j$ ,  $iter$ ,  $\lambda$
2. 对  $j \in [1, J+1]$
3. 对  $i \in [0, iter]$ , 执行循环
4. 利用式(23)计算  $\hat{\mathbf{x}}_j$ , 进而得到  $\mathbf{x}_{j,m}$
5. 利用式(25)计算  $\mathbf{r}(\mathbf{z}_{j,m})$
6. 利用式(26)计算  $\mathbf{z}_{j,m}$
7. 利用式(15)计算  $\mathbf{u}_{j,m}$
8. 利用式(29)计算  $\hat{\mathbf{d}}_j$ , 进而得到  $\mathbf{d}_{j,m}$
9. 利用式(32)计算  $\mathbf{g}_{j,m}$
10. 利用式(20)计算  $\mathbf{h}_{j,m}$
11. 输出:  $J+1$  个尺度下  $\mathbf{d}_{j,m}$  和  $\mathbf{x}_{j,m}$

在得到  $J+1$  个尺度下  $\mathbf{d}_{j,m}$  和  $\mathbf{x}_{j,m}$  后, 随即利用逆多尺度变换  $\mathbf{A}$  将其转换为相对应的时域信号, 在本文中采用逆调 Q 因子小波变换。对于第  $j \in [1, J+1]$  个尺度, 相对应的时域信号表示为  $\mathbf{A}(\sum_m \mathbf{d}_{j,m} * \mathbf{x}_{j,m})$ 。然后, 利用自相关方法估计每个尺度下故障冲击特征的周期。如果故障周期相同则意味着时域冲击特征表征同一种轴承故障, 因此可以合并具有相同故障周期的时域信号。最后, 分析合并后的时域信号及其包络谱, 便能够有效检测轴承的潜在故障。

### 3 仿真分析

首先介绍了故障轴承的振动信号模型, 用于模拟实际工作环境下的振动信号。然后, 利用仿真振动信号验证提出方法在提取冲击特征方面的性能, 并与卷积稀疏表示算法<sup>[13]</sup>、快速卷积稀疏字典学习算法<sup>[17]</sup>和加权多尺度字典学习算法<sup>[9]</sup>进行比较验证。

在实际故障轴承振动信号中, 故障引起的冲击特征被多种信号成分干扰。本振动信号模型考虑了振动信号中常见的信号成分, 数学表达式如下:

$$x(t) = \sum_i D_i S_i(t - iT - \tau_i) + \sum_n H_n \cos(2\pi f_n t + \alpha_n) + \sum_r R_r S_r(t - T_r) + n(t) \quad (33)$$

$\sum_i D_i S_i(t - iT - \tau_i)$  为故障引起的周期性故障冲击,

其中  $D_i$  是故障冲击的幅值,  $T$  是故障周期,  $\tau_i$  用于模拟滚动体的随机滑动, 一般设置为  $0.01T \sim 0.02T$ 。此外, 指数衰减的正弦波用于模拟单个故障冲击, 其表达式如下:

$$S = e^{-\xi t} \sin(2\pi f_r t) \quad (34)$$

式中:  $\xi$  为阻尼系数;  $f_r$  为共振频率。

$\sum_n H_n \cos(2\pi f_n t + \alpha_n)$  为齿轮啮合或者轴不对中引起的谐波成分,其中  $H_n$  和  $\alpha_n$  为谐波成分的幅值和初始相位。 $\sum_r R_r S_r(t - T_r)$  为振动信号采集过程中电磁干扰或意外敲击引起的随机冲击,由于随机冲击幅值和发生时刻的未知性,随机设置幅值  $R_r$  和发生时间  $T_r$ 。 $n(t)$  为噪声,可以利用均值为 0、方差为  $\sigma$  的高斯白噪声进行模拟。

仿真参数如表 1 所示,模拟轴承同时存在外圈和内圈故障时的振动信号,此处轴承外圈故障特征频率  $f_o = 17$  Hz,内圈故障特征频率  $f_i = 28$  Hz,轴的转频  $f_1 = 7$  Hz。此外,仿真信号的采样频率和时间长度分别设为 20 000 Hz 和 1 s。

表 1 仿真信号参数

Table 1 Parameters of simulated signal

信号成分	参数	数值	
故障冲击	$D_i$	1.3	
	$T$	$\frac{1}{17}$	
	$f_r$	1 500	
	$\xi$	180	
	$D_i$	$0.8 \times \sin\left(2\pi \times 7 \times i \times \frac{1}{28}\right)$	
内圈	$T$	$\frac{1}{28}$	
	$f_r$	3 200	
	$\xi$	230	
	谐波成分	$H_1$	0.8
		$f_1$	7
$\alpha_1$		$\frac{\pi}{3}$	
$H_2$		0.6	
$f_2$		14	
随机冲击	$f_r$	6 000	
	$\xi$	1 000	
噪声	$\sigma$	1.5	

仿真轴承复合故障振动信号的时域波形及其包络谱如图 2(a)、(b)所示。在时域波形中,外圈和内圈故障引起的周期性故障冲击被干扰成分完全掩盖,难以准确识别。同时,在包络谱中,轴不平衡导致的谐波成分的频率非常明显,而外圈故障特征频率  $f_o$ 、内圈故障特征频率  $f_i$  以及他们的倍频则难以识别,因此未能有效识别出轴承健康状态,造成误诊断。

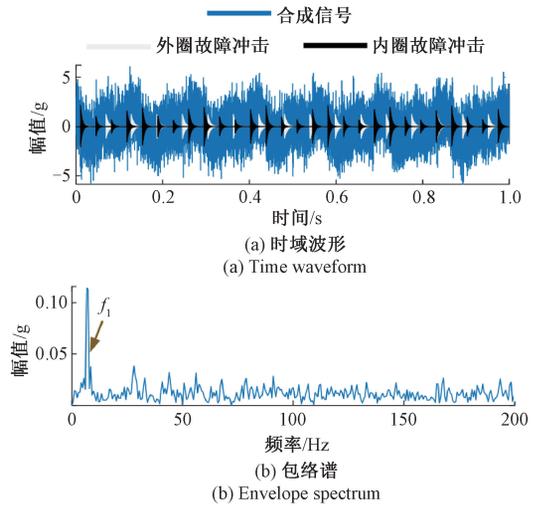
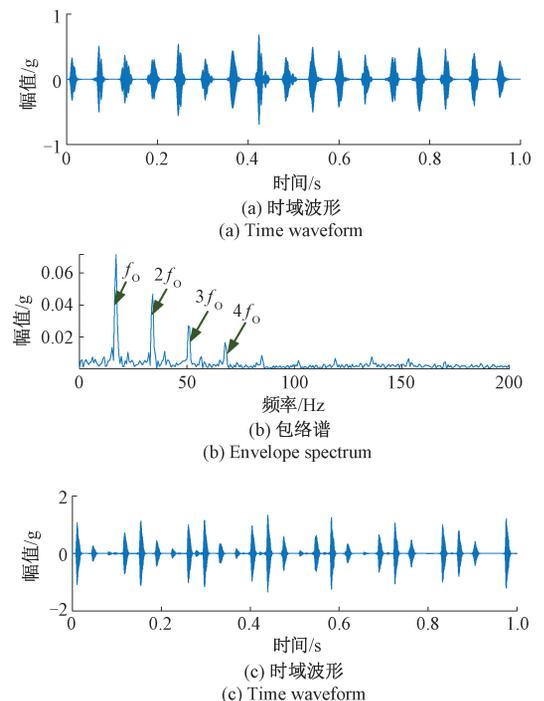


图 2 仿真振动信号

Fig. 2 Simulated vibration signal

为了准确确定轴承的健康状态,将提出的加权多尺度卷积稀疏表示方法应用于分析仿真信号,分析结果如图 3 所示。图 3(a)和(c)中,可以准确识别周期性故障冲击,表明提出方法具有良好的消除噪声和谐波成分的能力。此外,图 3(b)和(d)中,外圈故障特征频率及其倍频  $f_o \sim 4f_o$ ,内圈故障特征频率及其倍频  $f_i \sim 6f_i$  以及边频带清晰地显示出来,表明提出方法准确诊断出轴承外圈和内圈故障,实现了对复合故障的同步识别。



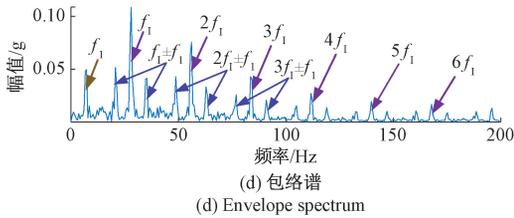


图 3 提出方法分析结果

Fig. 3 Analysis results of the proposed method

进一步地,为了阐释提出方法的有效性与优越性,将卷积稀疏表示算法、快速卷积稀疏字典学习算法和加权多尺度字典学习算法也应用于仿真信号。卷积稀疏表示算法和快速卷积稀疏字典学习算法的分析结果如图 4、5 所示,两种方法的分析结果非常相似。从包络谱可以发现,谐波成分的频率 7 Hz 及其倍频非常明显,而无法识别反映轴承故障的冲击特征信息,表明当原始振动信号中存在谐波成分时,卷积稀疏表示算法和快速卷积稀疏字典学习算法无法表现出令人满意的故障冲击特征提取能力。

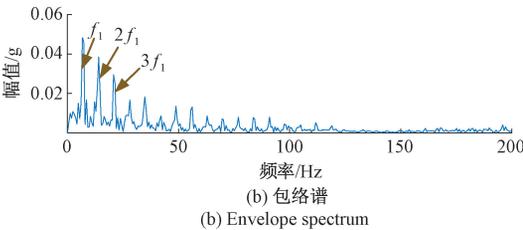
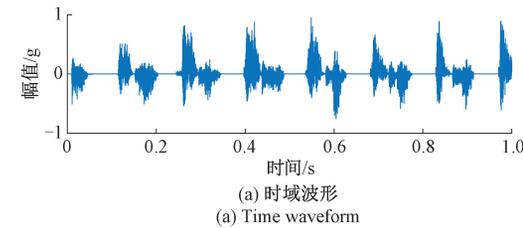


图 4 卷积稀疏表示分析结果

Fig. 4 Analysis results of convolutional sparse representation

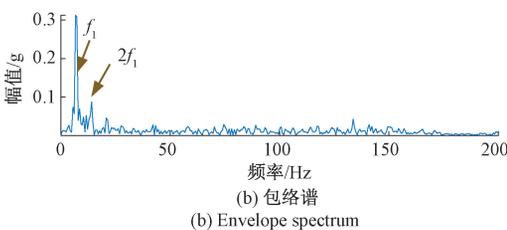
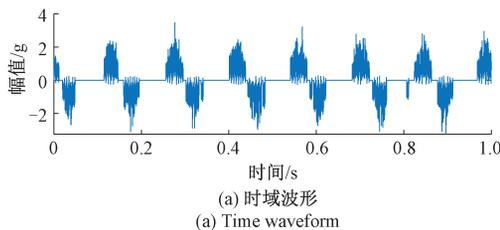


图 5 快速卷积稀疏字典学习算法分析结果

Fig. 5 Analysis results of fast convolutional sparse dictionary learning

图 6 所示为加权多尺度字典学习算法的分析结果。尽管在包络谱中能够观察到内圈故障特征频率及其倍频  $f_1 \sim 4f_1$  以及部分边频带,然而相较于图 3 (d) 效果较差。同时,在时域波形中周期性故障冲击仍被其他干扰冲击影响,极大降低了故障冲击特征的可辨别性。此外,由于加权多尺度字典学习算法中未考虑轴承故障冲击的周期性,因此其仅识别出内圈故障而未能诊断出外圈故障,造成漏诊问题。

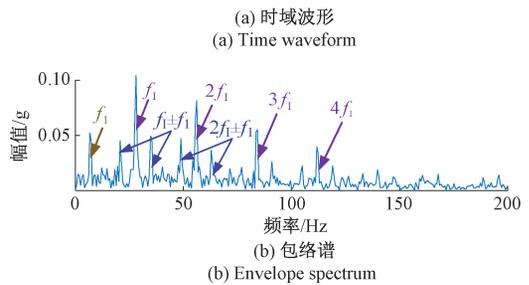
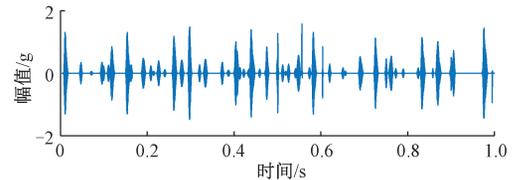


图 6 加权多尺度字典学习分析结果

Fig. 6 Analysis results of weighted multiscale dictionary learning

此外,利用峭度<sup>[25]</sup>和故障特征比<sup>[26]</sup>两个指标定量评估提取的故障冲击特征中的故障信息含量,更精确地说明提出方法的优势。对于这两种指标,数值越大,意味着故障信息含量越高。表 2 为本文提出方法及 3 种对比方法的时域波形峭度及包络谱故障特征比的计算结果。本文提出方法由于考虑了故障冲击特征的周期性,能够分别提取出外圈和内圈故障特征,因此提出方法峭度和故障特征比的计算值各有两个,而其他方法则各有一个。从表 2 可以看出,对于 3 种对比方法,卷积稀疏表示算法和快速卷积稀疏字典学习算法两种方法的峭度和故障特征比均相较于提出方法较小;同时,尽管加权多尺度字典学习算法的峭度、故障特征比和提出方法的相差不大,但是其仅能提取单个故障引起的冲击特征,未能准确诊断轴承复合故障。

表 2 评估指标结果

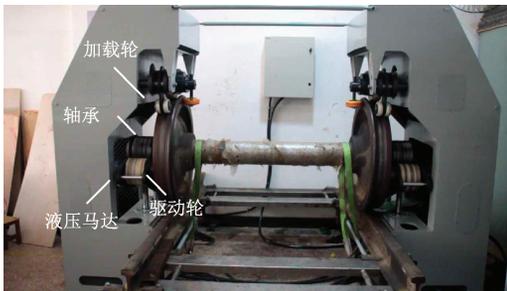
Table 2 Values of evaluation criterion

方法	峭度	故障特征比
提出方法	14. 31/22. 74	0. 92/0. 94
卷积稀疏表示算法	10. 31	0. 49
快速卷积稀疏字典学习算法	4. 13	0. 45
加权多尺度字典学习算法	17. 79	0. 89

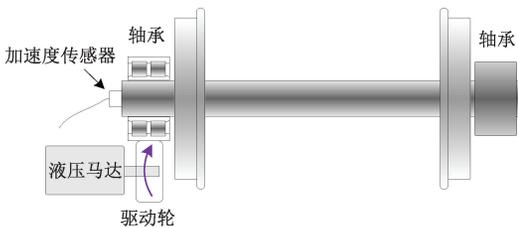
根据以上分析可以看出,提出的加权多尺度卷积稀疏表示方法准确提取内外圈轴承故障特征,并实现内外圈复合故障同步诊断。然而,卷积稀疏表示算法和快速卷积稀疏字典学习算法未能诊断出轴承故障,加权多尺度字典学习算法仅识别出内圈故障且提取的故障冲击特征中仍存在干扰。因此,提出方法相较于3种对比方法具有更优异的干扰条件下故障特征提取及故障诊断能力。

## 4 实验验证

通过分析从轮对轴承试验台采集的振动信号进一步阐明提出方法的故障冲击识别和复合故障诊断能力。图7所示是由驱动轮、液压马达和加载轮等组成的轴承试验台。不同于常规的轴承试验台,在本轴承试验台中轴承内圈是固定的,轴承外圈则由驱动轮驱动从而实现转动。在本次测试中,利用PCB加速度传感器采集振动信号,传感器安装在轴端面,振动信号采样频率为76 800 Hz。同时,利用转速计测量试验台转速信息。列车轴承结构参数如表3所示。



(a) 实物图  
(a) Real picture



(b) 示意图  
(b) Schematic view

图7 轮对轴承试验台

Fig.7 Locomotive bearing test rig

表3 轴承结构参数

Table 3 Parameters of locomotive bearing

滚动体个数	接触角/(°)	滚动体直径/mm	轴承节径/mm
20	9	23.775	180

利用轮对轴承试验台,开展外圈和内圈复合故障轴

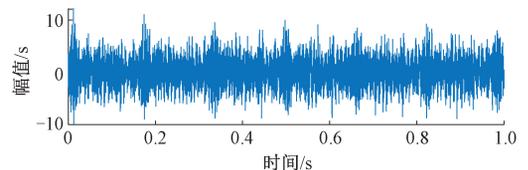
承测试,采集转速信息并测量振动信号。图8所示为本次测试的复合故障轴承,轴承故障为工作时自然磨损产生的,而非人为加工的故障。根据转速信息及轴承结构参数,便可以计算出轴承故障特征频率。在此次测试中,轴承外圈旋转频率 $f_s$ 为5.3627 Hz,相应的轴承外圈故障特征频率 $f_o$ 、内圈故障特征频率 $f_i$ 和滚动体故障特征频率 $f_r$ 分别为46.6307、60.6226和19.9548 Hz。



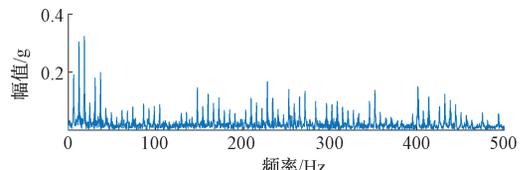
图8 复合故障轴承

Fig.8 Compound-fault bearing

图9所示为内外圈复合故障轴承测试过程中采集到的原始振动信号的时域波形及其包络谱。在时域波形中,尽管存在冲击特征,然而不是轴承故障引起的周期冲击特征。同时,包络谱中中频成分及其倍频较为明显,外圈故障特征频率 $f_o$ 和内圈故障特征频率 $f_i$ 则完全不可见。这种现象意味着振动信号中故障引起的冲击特征被其他干扰成分完全掩盖,难以从原始信号中识别出轴承故障。



(a) 时域波形  
(a) Time waveform



(b) 包络谱  
(b) Envelope spectrum

图9 原始振动信号

Fig.9 Raw vibration signal

为了准确判断轴承的健康状态,将提出的加权多尺度卷积稀疏表示方法应用于分析试验台信号,分析结果如图10所示。从图10(a)和(c)可以看出,一系列周期性脉冲被准确提取,说明提出的方法具有良好的消除干扰成分的能力。此外,通过观察图10(b)和(d)可以清晰地看到,外圈故障特征频率及其倍频 $f_o \sim 8f_o$ 、内圈故障特征频率及其倍频 $f_i \sim 6f_i$ ,表明轴承同时发生了内圈和外圈故障,实现了对轴承复合故障的有效诊断。

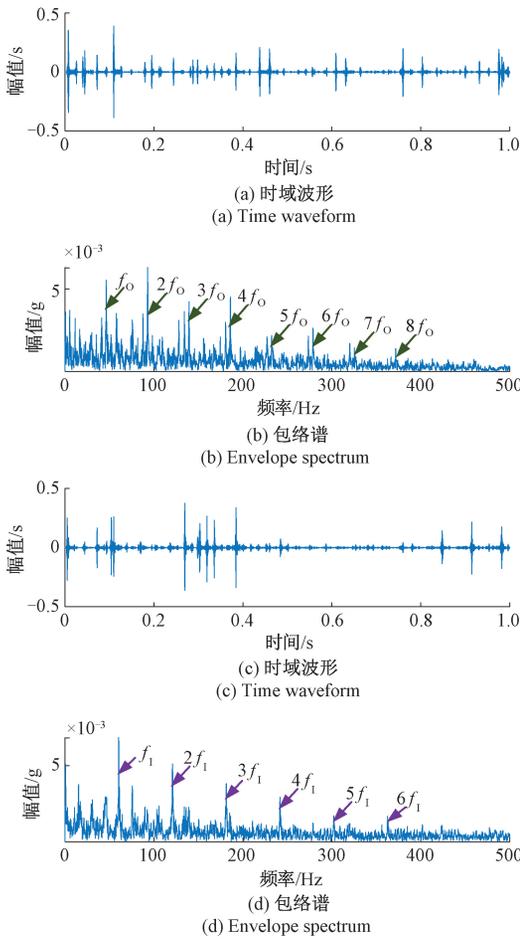


图 10 提出方法分析结果

Fig. 10 Analysis results of the proposed method

然后,卷积稀疏表示算法、快速卷积稀疏字典学习算法和加权多尺度字典学习算法 3 种对比方法也被应用于从原始振动信号中提取轴承故障冲击特征,分析结果分别如图 11~13 所示。然而,从分析结果可知,时域波形图及包络谱中均无法提供可靠的轴承故障信息,即显著的周期性故障冲击特征及故障特征频率,因此 3 种对比方法均未能诊断出复合故障及实现轴承健康状态的准确识别。造成 3 种对比方法效果不理想的主要原因为该振动信号中故障特征较为微弱,而这 3 种方法倾向于提取大能量的成分,同时未能考虑充分故障冲击特征的周期性,限制了其在强干扰下微弱故障冲击特征的提取性能。

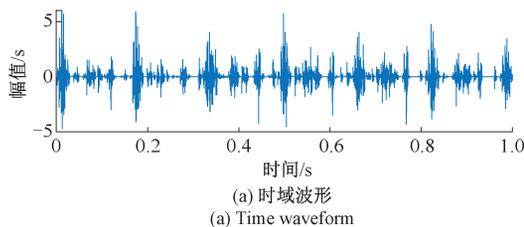


图 11 卷积稀疏表示分析结果

Fig. 11 Analysis results of convolutional sparse representation

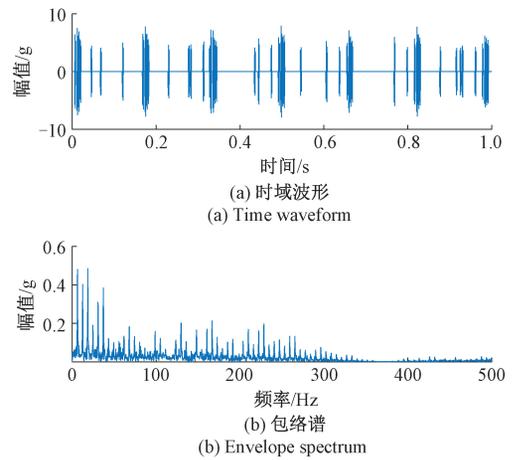


图 12 快速卷积稀疏字典学习算法分析结果

Fig. 12 Analysis results of fast convolutional sparse dictionary learning

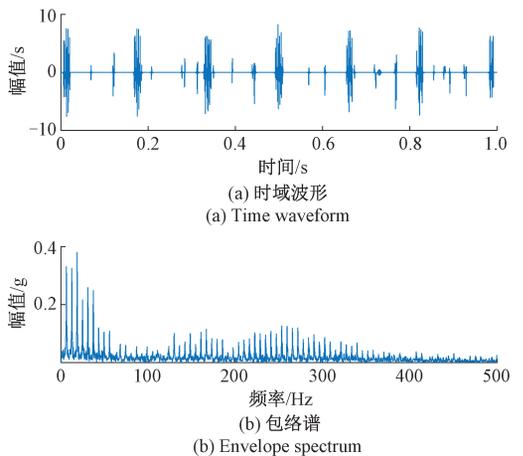


图 13 加权多尺度字典学习分析结果

Fig. 13 Analysis results of weighted multiscale dictionary learning

根据上述分析结果,可以看出相较于 3 种对比方法,提出方法在强干扰条件下拥有更优异的故障冲击特征提取能力,由此表明提出方法提供了一种更可靠的轴承复合故障诊断手段。

## 5 结 论

本文提出了加权多尺度卷积稀疏表示方法,解决了传统卷积稀疏表示研究忽略故障冲击特征周期性及不同尺度下信号特性差异的问题,能够实现复杂干扰条件下故障特征提取及滚动轴承复合故障诊断。

1) 通过在不同尺度下设置不同权重系数,以及构建约束故障特征稀疏系数周期性的正则项,提高了加权多尺度卷积稀疏表示在抑制干扰成分及提升冲击特征分离精度方面的能力。

2) 利用交替方向乘子法和受控极小化方法推导出一种可行的迭代求解算法,能够有效求解构建的加权多尺度卷积稀疏表示中的优化问题。

3) 通过分析仿真信号和列车轮对轴承试验台信号,证明相较于3种对比方法,提出方法拥有更强的冲击特征提取和轴承复合故障诊断能力。

## 参考文献

- [ 1 ] 苗建国,李茂银,邓聪颖,等.非理想数据下基于仿真数据辅助迁移学习的滚动轴承故障诊断[J].仪器仪表学报,2023,44(4):28-39.  
MIAO J G, LI M Y, DENG C Y, et al. Rolling bearing fault diagnosis for non-ideal dataset based on finite element simulation and transfer learning [J]. Chinese Journal of Scientific Instrument, 2023, 44 ( 4 ): 28-39.
- [ 2 ] 江星星,宋秋昱,杜贵府,等.变分模式分解方法研究与应用综述[J].仪器仪表学报,2023,44(1):55-73.  
JIANG X X, SONG Q Y, DU G F, et al. Review on research and application of variational mode decomposition [J]. Chinese Journal of Scientific Instrument, 2023, 44 ( 1 ): 55-73.
- [ 3 ] 刘小峰,黄洪升,柏林,等.循环脉冲指数最大化的共振稀疏分解法及应用 [J]. 仪器仪表学报, 2022, 43 ( 5 ): 209-217.  
LIU X F, HUANG H SH, BO L, et al. A resonance sparse decomposition method based on maximizing cyclic pulse index and its application [J]. Chinese Journal of Scientific Instrument, 2022, 43 ( 5 ): 209-217.
- [ 4 ] SUN R, YANG Z, ZHAI Z, et al. Sparse representation based on parametric impulsive dictionary design for bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2019, 122: 737-753.
- [ 5 ] HUANG W, LI S, FU X, et al. Transient extraction based on minimax concave regularized sparse representation for gear fault diagnosis [J]. Measurement, 2020, 151: 107273.
- [ 6 ] ZHANG M, LIANG K, MIAO Y, et al. Application of

improved double-dictionary K-SVD for compound-fault diagnosis of rolling element bearings [J]. Measurement, 2022, 187: 110168.

- [ 7 ] WANG H, REN B, SONG L, et al. A novel weighted sparse representation classification strategy based on dictionary learning for rotating machinery [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(3): 712-720.
- [ 8 ] LIANG K, ZHAO M, LIN J, et al. An information-based K-singular-value decomposition method for rolling element bearing diagnosis [J]. ISA Transactions, 2020, 96: 444-456.
- [ 9 ] ZHAO Z, QIAO B, WANG S, et al. A weighted multi-scale dictionary learning model and its applications on bearing fault diagnosis [J]. Journal of Sound and Vibration, 2019, 446: 429-452.
- [ 10 ] 袁浩东. 基于稀疏表征及字典学习的故障诊断方法研究 [D]. 上海:上海交通大学,2018.  
YUAN H D. Fault diagnosis method based on sparse representation and dictionary learning [D]. Shanghai: Shanghai Jiaotong University, 2018.
- [ 11 ] ZISSELMAN E, SULAM J, ELAD M. A local block coordinate descent algorithm for the CSC model [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 8208-8217.
- [ 12 ] WANG Y, YAO Q, KWOK J T, et al. Scalable online convolutional sparse coding [J]. IEEE Transactions on Image Processing, 2018, 27(10): 4850-4859.
- [ 13 ] WOHLBERG B. Efficient algorithms for convolutional sparse representations [J]. IEEE Transactions on Image Processing, 2015, 25(1): 301-315.
- [ 14 ] DING J. Fault detection of a wheelset bearing in a high-speed train using the shock-response convolutional sparse-coding technique [J]. Measurement, 2018, 117: 108-124.
- [ 15 ] DU Z, CHEN X, ZHANG H, et al. Nonnegative bounded convolutional sparse learning method for envelope feature deconvolution [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8666-8679.
- [ 16 ] ZHOU Q, ZHANG Y, YI C, et al. Convolutional sparse coding using pathfinder algorithm-optimized orthogonal matching pursuit with asymmetric Gaussian chirplet model in bearing fault detection [J]. IEEE Sensors Journal, 2021, 21(16): 18132-18145.
- [ 17 ] HE L, YI C, ZHOU Q, et al. Fast convolutional sparse dictionary learning based on LocOMP and its application to bearing fault detection [J]. IEEE Transactions on

Instrumentation and Measurement, 2022, 71: 1-12.

- [18] LU Y, LIANG C, ZHU D, et al. Bearing fault diagnosis using convolutional sparse representation combined with nonlocal similarity [J]. IEEE Sensors Journal, 2023, 23(6): 5937-5948.
- [19] YI H, DING X, LI Q, et al. Dual-kernel driven convolutional sparse learning for bearing transient feature enhancement [J]. Measurement, 2023, 216: 112643.
- [20] HU X, HEIDE F, DAI Q, et al. Convolutional sparse coding for RGB+ NIR imaging [J]. IEEE Transactions on Image Processing, 2017, 27(4): 1611-1625.
- [21] PAPPAN V, ROMANO Y, SULAM J, et al. Convolutional dictionary learning via local processing [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 5296-5304.
- [22] DING C, ZHAO M, LIN J, et al. Sparsity-based algorithm for condition assessment of rotating machinery using internal encoder data [J]. IEEE Transactions on Industrial Electronics, 2019, 67(9): 7982-7993.
- [23] MIAO Y, ZHANG B, LI C, et al. Feature mode decomposition: New decomposition theory for rotating machinery fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2022, 70(2): 1949-1960.
- [24] WANG B, DING C. Transient feature identification from internal encoder signal for fault detection of planetary gearboxes under variable speed conditions [J]. Measurement, 2021, 171: 108761.
- [25] LIANG K, ZHAO M, LIN J, et al. Maximum average kurtosis deconvolution and its application for the impulsive fault feature enhancement of rotating machinery [J]. Mechanical Systems and Signal Processing, 2021, 149: 107323.
- [26] YAN X, JIA M. Application of CSA-VMD and optimal scale morphological slice bispectrum in enhancing outer race fault detection of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2019, 122: 56-86.

## 作者简介



王爽, 2012年于太原科技大学获得学士学位, 2015年于太原科技大学获得硕士学位, 现为苏州城市学院讲师, 主要研究方向为机械设备智能故障诊断和剩余寿命预测。

E-mail: wangshuang\_sdyy@163.com

**Wang Shuang** received her B. Sc. degree from Taiyuan University of Science and Technology in 2012, and M. Sc. degree from Taiyuan University of Science and Technology in 2015. She is currently a lecture at Suzhou City University. Her main research interests include machine intelligent fault diagnosis and remaining useful life prediction.



丁传仓(通信作者), 2016年于山东大学获得学士学位, 2021年于西安交通大学获得博士学位, 现为苏州大学讲师, 主要研究方向为机械信号分析与设备状态监测。

E-mail: ccding@suda.edu.cn

**Ding Chuancang** (Corresponding author) received his B. Sc. degree from Shandong University in 2016, and Ph. D. degree from Xi'an Jiaotong University in 2021. He is currently a lecture at Soochow University. His main research interests include mechanical signal analysis and machine condition monitoring.



王报祥, 2016年于山东农业大学获得学士学位, 2023年于西安交通大学获得博士学位, 现为苏州科技大学讲师, 主要研究方向为机械信号分析与设备故障诊断。

E-mail: wangbaoxiang@usts.edu.cn

**Wang Baoxiang** received her B. Sc. degree from Shandong Agricultural University in 2016, and Ph. D. degree from Xi'an Jiaotong University in 2023. She is currently a lecture at Suzhou University of Science and Technology. Her main research interests include mechanical signal analysis and machine fault diagnosis.