

基于稀疏特征的连轧机故障信号分离方法*

严保康, 周凤星, 宁博文, 李维刚

(武汉科技大学信息科学与工程学院 武汉, 430081)

摘要 连轧机组的稳定性对于保障轧制产品的质量精度起着决定性的作用,连轧机组中监测各轧机状态的信号具有强耦合性,从复杂的信号中分离出各轧机独立的状态信号,对连轧机组的状态监测和故障诊断具有重要的意义。提出了一种基于稀疏特征的连轧机故障信号分离方法,并进行了仿真和现场验证。首先,通过基于时频谱分割的稀疏分解方法将各混合信号中的微弱冲击特征提取出来;其次,对所有稀疏表示信号的原子按照一定规律排序,得到各混合信号的稀疏矩阵;然后,根据稀疏原子的相似性对稀疏表示的原子进行聚类,确定盲源分离的源个数;最后,根据稀疏矩阵的系数和源个数比较准确地估计出混叠矩阵,实现混合信号的盲分离。

关键词 连轧机; 稀疏特征; 稀疏分解; 盲源分离; 故障诊断

中图分类号 TN911.7; TH113.1

1 问题的引出

在冶金轧制过程中,连轧机机组起着关键的作用,直接决定产品的质量精度和性能指标。连轧机机组在长期连续、高强度工作中,经常会出现轧辊表层裂纹、轧辊表层局部剥落、轧辊支撑轴承失效等故障,进而影响产品质量精度,甚至导致设备停产及重大人员伤亡等事故,因此,连轧机的状态监测和故障诊断对保证生产稳定性、提高产品质量、降低生产成本具有重要意义^[1-3]。图 1 所示为某大型钢厂的精轧连轧机示意图,该机组共有 7 台精轧机组成($F_1 \sim F_7$),每台精轧机核心部件主要包括工作辊和支撑辊,其中工作辊直接与坯料接触使其变形,支撑辊主要是增加工作辊的刚度,防止工作辊轧制时断辊及过大的弹跳,在工作辊和支撑辊两端均有轴承座进行支撑。每台轧机的主要故障点在工作辊表层、支撑辊表层以及 8 个轴承座,而通常每台轧机只布置 4 个振动传感器,分别布置在上、下支撑辊和上、下工作辊的轴承座上,在轧机出现复合故障或连轧机组其他轧机出现故障时,由于振动在材料中的传递,使得所采集的振动数据均为不同部件振动信号强耦合的混合数据,难以直接根据振动数据进行故障分析^[4-5]。因此,连轧机故障信号的盲分离对故障的精准定位和诊断具有重大意义。




图 1 精轧连轧机示意图

Fig. 1 The structure of finishing mills

盲源分离方法仅根据测量信号可得到混合模型及各源信号,在理论上为多源振动分析提供了强有力的技术手段。基于信号高阶统计特性的独立分量分析方法在信号处理和特征提取中有着广泛的应用,但是在工程应用中,由于强噪声的干扰及各振源交叉频率成分的存在,导致独立成分分析算法(independent component correlation algorithm,简称 ICA)无法满足独立性假设而失效。

李纪永等^[6]针对线性时频相交混合信号,提出白化-均匀加权非正交联合对角化方法估计混合矩阵,能分离出断齿与磨损复合故障源。Bofill 等^[7]针对具有 6 个信号源稀疏信号、2 个传感器的盲分离问题,提出了势函数方法,但是参数的设定缺乏理论指导,难以适用到更多的传感器情形。何昭水等^[8]克服了 Bofill 方法的局限性,建立了 K-聚类与主成分分析相结合的方法,可以方便地应用于 3 个

* 湖北省自然科学基金资助项目(2019CFB133);国家自然科学基金资助项目(51975433)
收稿日期:2018-03-09;修回日期:2018-06-03

及以上传感器的情况,且实现简单、混叠矩阵估计精度高。于刚等^[9]针对相关机械源盲分离问题,提出了一种基于信号稀疏特性的盲源分离方法,使得相关成分被有效剔除,从而准确地估计出混合矩阵。Sadhu等^[10]通过小波变换推断出全局结构模态信息,再通过主成分分析,达到盲源分离的目的。

笔者针对连轧机故障的强耦合特征和盲源分离过程中噪声对分离效果的影响问题,提出了一种基于稀疏特征的连轧机故障信号分离方法,该方法结合稀疏分解方法对复杂非平稳信号有精确表示能力,对混合信号进行稀疏表示,提取出混合信号中的微弱故障特征信息,再通过稀疏原子的相似性对原子进行聚类分析,确定混合信号的稀疏矩阵和盲源个数,实现连轧机混合故障信号的盲分离。

2 基于稀疏分量的盲分离算法

2.1 盲源分离的基本概念

盲源分离(blind source separation, 简称 BSS)是指在源信号和传输信道参数未知的情况下,仅通过一系列传感器测量的信号分离出各源信号的一种信号处理方法。BSS的数学模型可以描述为

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (t=1, 2, \dots, T) \quad (1)$$

其中: $\mathbf{x}(t) = (x_1(t), x_2(t), \dots, x_m(t))^T$ 为通过传感器测量的 m 维向量; $\mathbf{s}(t) = (s_1(t), s_2(t), \dots, s_n(t))^T$ 为 n 个未知源构成的 n 维向量; \mathbf{A} 为一个 $m \times n$ 的混叠矩阵。

盲分离的目的就是在相差一个排列矩阵和尺度矩阵的意义上使得分离信号与源信号的波形保持一致。在分离过程中,混叠矩阵的先验知识是未知的,需要在源信号统计独立的前提下进行估算^[7]。

2.2 基于稀疏分量的盲分离基本原理

稀疏性信号是指信号在很小部分的时刻取值较大,而在很多时刻取值为零或者接近于零。当源信号具有较好的稀疏性时,观测信号在同一时刻出现 2 个或以上稀疏源信号的可能性很小^[9]。对于属于同一源信号的较大幅值点正比于观测信号中的混合系数,因此,可以用信号的稀疏特征估计源信号的混合矩阵。

n 个源信号混合的 m 个观测信号,可以展开为

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{bmatrix} \quad (2)$$

其中: $s_i(t)$ 为第 i 个源信号; $x_j(t)$ 为第 j 个观测信号; a_{ij} 为第 j 个源信号到第 i 个观测信号的混合系数^[8]。

假设在某一时刻点 t , 只有源信号 $s_i(t)$ 取值非零,其他源信号取值很小或接近于零,则式(2)可近似地写成

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \begin{bmatrix} a_{1i} \\ a_{2i} \\ \vdots \\ a_{mi} \end{bmatrix} s_i(t) \quad (3)$$

进一步写成

$$\frac{x_1(t)}{a_{1i}} = \frac{x_2(t)}{a_{2i}} = \dots = \frac{x_m(t)}{a_{mi}} = s_i(t) \quad (4)$$

因此,在信号具有稀疏性时,某一个源信号 $s_i(t)$ 取值占优时的时刻可以确定一条直线,这条直线的方向为混合矩阵的第 i 个列向量 $(a_{1i}, a_{2i}, \dots, a_{mi})^T$ 。这样,每个源信号将分别确定一条直线, n 维源信号将确定 n 条直线。通过混合信号散点图中的直线方向,即可确定混合矩阵列向量方向,因此,通常采用“K-均值聚类”方法估计混合矩阵^[9]。然而因为噪声的干扰,“K-均值聚类”方法对于直线方向的估计准确性和鲁棒性不好,无法达到对混合矩阵的良好估计。

3 基于稀疏特征的连轧机信号分离方法

连轧机设备在轴承或轧辊出现裂纹、点蚀等故障时,会产生冲击信号。由于设备的复杂性和轧制现场的恶劣性,冲击信号呈现以下特点:a. 微弱的冲击信号淹没在强背景噪声下;b. 冲击信号具有稀疏性;c. 信号具有强耦合性,且振源位置通常超过 3 处。如何将耦合在一起的微弱冲击成分提取并分离出来是连轧机故障信号分离的关键。笔者提出的基于稀疏特征的连轧机信号分离方法的流程如图 2 所示。




图 2 基于稀疏特征的连轧机信号分离方法流程图
Fig. 2 The flow-chart of blind source separation based on sparse feature for fault signals of continuous mills

3.1 基于时频谱的稀疏特征提取方法

广义 S 变换 (generalized S-transform, 简称 GST) 实质上是加窗的傅里叶变换, 窗的宽度是随着频率而变化的, 频率越高, 宽度越窄; 频率越低, 宽度越宽, 从而具备类似多分辨率的特性^[11-12]。GST 的正反变换定义表示如下

$$\begin{cases} \text{GST}(\tau, f) = \int_{-\infty}^{\infty} x(t) \frac{\lambda |f|}{\sqrt{2\pi}} e^{-\frac{\lambda^2 f^2 p}{2} (\frac{t-\tau}{\lambda})^2} e^{-i2\pi f t} dt \\ x(t) = \int_{-\infty}^{\infty} \left\{ \int_{-\infty}^{\infty} \text{GST}(\tau, f) d\tau \right\} e^{i2\pi f t} df \end{cases} \quad (5)$$

其中: λ 和 p 为调节参数, 且 $\lambda > 0, p > 0$ 。

由于冲击类故障信号中的冲击成分是振荡衰减信号, 且具有稀疏性, 因此在滑动窗进入冲击信号和离开冲击信号的整个区间, 都会与冲击信号进行有效的内积运算, 从而在时频谱上呈现出一定强度的幅值; 而在其他非冲击信号区间, 则不会与冲击信号进行有效的内积运算, 从而在时频谱上呈现出微弱的幅值。因此, 在冲击类故障信号广义 S 变换的时频谱的特点主要有: a. 在冲击信号的振荡频率周围会呈现出能量集中区域; b. 该能量集中区域会分布在每一个冲击信号的时频范围内。

由 Heisenberg 测不准原理可知, 为了兼顾时间分辨率和频率分辨率, 让信号在低频段的时窗较宽, 从而获得较高的频率分辨率; 而在高频段的时窗较窄, 从而获得较高的时间分辨率^[13-15]。

对于一个稀疏性的冲击信号, 其 GST 频谱随着调节参数的变化而变化, 但是能量主要集中在冲击出现的时频附近, 且能量集中区域的形状各不相同。随着调节参数的增大, 能量集中区域在时间轴上越来越窄, 在频率轴上越来越宽。在与故障信号一致的调节因子下的时频谱图, 其能量最为集中。

为获取稀疏分解过程中的各个最佳原子, 需要将多分辨率下 GST 时频谱中各区域的最大值点提取出来, 从而构建稀疏表示的最佳原子序列^[18]。

基于时频谱分割的稀疏特征提取方法算法流程如图 3 所示。

经过 GST 所获取不同调节参数下的时频谱图, 尽管能量集中区域的时频尺寸是变化的, 但是能量集中区域的极值点位置都是分布在冲击信号时频点附近。因此, 需要对所有时频谱图做以下处理: a. 二值化处理成二值时频谱; b. 通过图像融合处理生成最佳二值时频谱; c. 通过图像分割分离出最佳二值时频谱中各独立的连通域。

1) 二值化处理。二值化处理是将多尺度所有

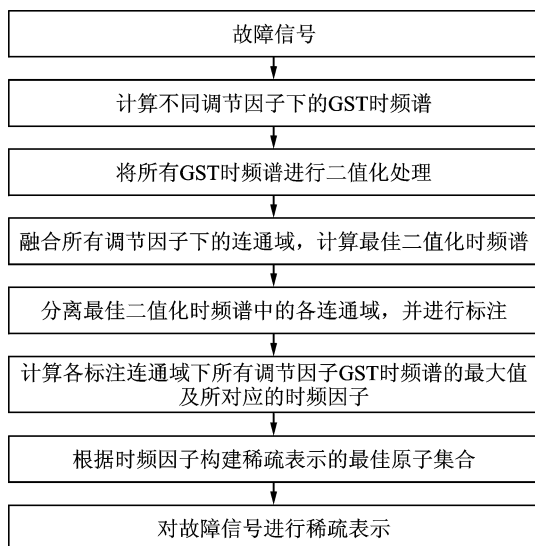


图 3 基于时频谱分割的稀疏特征提取方法算法流程
Fig. 3 Flow-chart of sparse extraction method based on spectrum segmentation

时频谱图通过适当的阈值选取而获得可以反映局部特征的二值化图像, 时频谱的二值化处理使得数据量大幅减少, 有利于对时频谱的局部特征分割。

阈值的选取对生成二值图像十分关键, 阈值太大, 尽管很大程度上抑制了噪声, 但是也会过滤掉部分微弱的冲击成分; 而阈值太小, 则引入了大量噪声, 同时增加后续图像分割的计算量, 并降低了算法的稀疏度和精度。因此, 二值化处理的阈值满足以下条件

$$t = 2 \|a\|_2 / \sqrt{N} \quad (6)$$

其中: a 为时频谱对应的数据矩阵; N 为矩阵 a 的数据总个数^[16-17]。

二值化处理的数学表达式为

$$a(i, j) = \begin{cases} 1 & (a(i, j) \geq t) \\ 0 & (a(i, j) < t) \end{cases} \quad (7)$$

其中: i 为矩阵 a 的行索引值; j 为矩阵 a 的列索引值。

2) 二值时频谱融合。根据时频谱图的能量分布性质, 将同一个冲击成分的所有调节参数下的二值时频谱图进行融合, 可得到能量更加集中的区域。笔者所采用的为交集融合, 最终形成最佳二值时频谱图。

3) 二值时频谱分离。最佳二值时频谱中包含若干个连通域, 为提取各连通域下对应时频谱的能量最大值, 需将这些连通域分离出来。通过搜索二值化数组中各像素之间的连接关系, 可分离出各连通域并进行顺序标注。

通过时频谱分割所获取的连通域即为各冲击信号时频能量最大值所在的区域。将各连通域映射到

原始不同调节参数下的时频谱图中,即可得到各连通域在不同调节参数下的时频能量极大值序列,提取各序列下的最大值及其所对应的时频因子,即可精准定位各冲击信号出现的时频位置。根据提取的连通域下的一组最佳时频因子,结合故障过完备原子库的数学模型,即可构建一组用于稀疏表示故障信号的原子集合,最终得到故障信号的稀疏表示。

3.2 源个数的估计

传统的源个数的估计是依据数据时域散点图中的直线方向个数,常采用“K-均值聚类”方法^[7-9]。该类方法对2个或3个源信号的源个数估计效果较好,而当源个数超过3个,则由于时域散点图的维数过多而难以凑效。

根据不同结构的设备其振动信号振荡衰减特性的差异性可知,不同振源产生的冲击信号的结构不同,特别是尺度因子和频率因子不同,而同一振源产生的冲击信号具有相似性^[18]。因此,将所有稀疏表示提取的原子以尺度因子为横坐标、频率因子为纵坐标做出原子分布图,然后根据K-均值聚类方法对其进行分类,聚类的个数即为源个数。每个聚类的聚类中心所对应的原子可近似地替代该聚类下的其他原子,以简化后面的混合矩阵计算。

3.3 混合矩阵的估计

传统的基于稀疏分量的盲分离方法可以根据混合信号的散点图得到一系列代表列向量方向的直线,然而该方法坐标维度与观测信号数量一致,因此,仅适合欠定盲源分离,而对多路传感器的连轧机故障信号分析难以凑效。通过以下步骤可以更好地估算出混合矩阵的系数。

1) 更新稀疏表示。根据上一步的聚类分析,将每个聚类下的稀疏表示原子用该聚类的聚类中心所对应的原子替代,并重新计算各通道信号在新的原子集合下的稀疏表示。

2) 计算聚类系数。混合信号中的各通道信号均包含各振源信号,即各聚类信号,计算每个通道各聚类信号对应幅值的平均值,并按照同一顺序排列,得到一个由聚类系数组成的矩阵,该矩阵描述了各振源信号在各通道的能量衰减情况。

3) 估计混合矩阵系数。将上一步计算的矩阵每一列均进行归一化处理,即可估算出混合矩阵。

通过以上步骤估计的混合矩阵,首先,对振源和观测通道数量没有限制,可用于3个及以上观测通道的混合矩阵估计;其次,由于信号经过了稀疏特征

提取,过滤了绝大部分噪声,从而使得混合矩阵的系数更加精确,克服了由散点图拟合列向量方向时的偏移问题。

4 仿真分析

仿真实验采用4个振源、2个观测通道的仿真数据。分别通过本研究方法和传统基于稀疏分量的盲源分离方法进行比较和分析。

根据式(8)模拟振源中的冲击成分

$$s(t) = e^{-\frac{\lambda^2 f^2 (t-u)^2}{2}} \cos(2\pi ft) \quad (8)$$

其中: λ 为尺度因子; u 为位移因子; f 为频率因子。

4个振源冲击成分的时频因子如表1所示。

表1 冲击成分的时频因子

Tab. 1 Time-frequency factors of impulse signal

序号	λ	u	f
1	1.5	0.1	250
	1.5	0.5	250
2	1.2	0.2	200
	1.2	0.6	200
3	0.9	0.3	150
	0.9	0.7	150
4	0.6	0.4	100
	0.6	0.8	100

混合矩阵如式(9)所示

$$a = \begin{bmatrix} 0.7071 & 0.9659 & 0.2588 & -0.7071 \\ 0.7071 & 0.2588 & -0.9659 & 0.7071 \end{bmatrix} \quad (9)$$

加噪后,2个观测通道的波形如图4所示,其中 S_1, S_2 分别表示混合后两个通道的信号。




图4 2个观测通道的波形

Fig. 4 The waveform of two channels

采用传统基于稀疏分量的盲源分离方法所得到的散点图及方向向量如图5所示。

根据图5的方向向量可估算出混合矩阵为




图5 传统方法的散点图及方向向量

Fig. 5 The scatter diagram and direction vector of the traditional method

$$\mathbf{a}_{e1} = \begin{bmatrix} 0.7953 & 0.9745 & 0.4164 & -0.7186 \\ 0.6062 & 0.2244 & -0.9092 & 0.6954 \end{bmatrix} \quad (10)$$

图5和式(10)的结果表明,在信号掺杂部分噪声后,散点图的大多数点集中在噪声附件,根据K-均值聚类计算的方向向量具有一定的偏差。

采用本研究方法,首先通过基于时频谱分割的稀疏特征提取方法提取出各通道的稀疏信号,如图6所示。其中:SP₁为S₁稀疏表示信号;SR₁为S₁稀疏表示后的残差信号;SP₂为S₂稀疏表示信号;SR₂为S₂稀疏表示后的残差信号。



(a) S₁的波形、稀疏表示和残差(a) Waveform, sparse representation and residual of S₁(b) S₂的波形、稀疏表示和残差(b) Waveform, sparse representation and residual of S₂

图6 本研究方法提取的稀疏信号

Fig. 6 The sparse signal through proposed method

通过图6可以看出,2个通道信号中的冲击成分被准确提取出来了,而且各残差信号中基本没有冲击成分,稀疏表示的信号将噪声滤除了。

表2所示为各通道信号稀疏表示的原子时频因子信息。

表2 稀疏提取的原子时频因子

Tab. 2 Time-frequency factors of selected atoms

序号	S ₁			S ₂		
	λ	u	f	λ	u	f
1	1.5	0.099 6	248	1.5	0.099 6	251
2	1.5	0.500 0	250	1.5	0.500 0	252
3	1.2	0.200 2	200	1.2	0.200 2	196
4	1.2	0.599 6	200	1.3	0.600 6	200
5	0.9	0.299 8	150	0.9	0.299 8	151
6	0.8	0.700 2	151	0.9	0.700 2	150
7	0.6	0.400 4	100	0.6	0.399 4	100
8	0.6	0.799 8	100	0.6	0.799 8	100

从表2可以看出,提取的时频因子信息与构成信号冲击成分的时频因子信息基本一致,由于噪声的影响,部分原子信息有微小的偏差。

图7所示为根据提取原子的结构信息产生的散点图及聚类中心。




图7 本研究方法的散点图及聚类中心

Fig. 7 The scatter diagram and cluster center of proposed method

由图7可以看出,结构相似的原子主要聚集在4个点附近,根据4个聚类中心,即可完成稀疏表示的更新、聚类系数和混合矩阵的计算。计算后的混合矩阵为

$$\mathbf{a}_{e2} = \begin{bmatrix} 0.6926 & 0.9670 & 0.2413 & -0.7108 \\ 0.7213 & 0.2548 & -0.9704 & 0.7034 \end{bmatrix} \quad (11)$$

比较式(9~11)不难发现,式(11)更加接近实际的混合矩阵,即抗干扰能力更强。

5 故障实例分析

通过旋转机械故障实验平台,在4个可更换轴承位置放置4路加速度传感器,并分别加上不同载荷。其中,3个轴承外圈有裂纹故障,1个轴承正常,分别采集4个测点的振动数据,并采用本方法进行

分析。

图8所示为4个测点采集的振动数据,图9所示为本方法稀疏表示后的信号,图10所示为采用本方法分离出的各振源信号。




图8 4个测点采集的振动数据

Fig. 8 The vibration signals of four measuring points




图9 本研究方法稀疏表示后的信号

Fig. 9 Sparse representation through proposed method




图10 本研究方法分离出的各振源信号

Fig. 10 The sources signals through proposed method

图8的4路振动信号 S_1, S_2, S_3 和 S_4 含有部分噪声。经过本研究方法的稀疏特征提取,可以看出图9中各自的稀疏表示信号 SP_1, SP_2, SP_3 和 SP_4 基本滤掉了噪声,保留了冲击成分。根据原子相似性原则进行混合矩阵的估算,最终得到图10所示的各独立振源信号 C_1, C_2 和 C_3 。由于噪声的干扰,各源信号中冲击成分的幅值有微弱的波动。

6 结论

1) 本研究采用基于多分辨率广义S变换的稀疏特征提取方法进行信号的稀疏特征提取,提高信号的信噪比,从而降低了混合均值计算中噪声带来的影响。

2) 本研究通过原子结构相似性的策略对提取原子进行聚类,从而估算振源个数及混合矩阵。由于原子结构仅与尺度因子和频率因子相关,与盲源个数无关,因此,适用于3个及以上观察通道的盲源分离。

参 考 文 献

- [1] 孙建亮,刘宏民,李琰赞,等. 热连轧机水平振动及其与轧制参数影响关系[J]. 钢铁, 2015, 50(1): 43-49.
Sun Jianliang, Liu Hongmin, Li Yanyun, et al. Horizontal vibration of hot rolling mill and its relationship with rolling parameters[J]. Iron & Steel, 2015, 50(1): 43-49. (in Chinese)
- [2] 刘彬,潘贵翔,李鹏,等. 液压缸非线性刚度的轧机辊系振动分析[J]. 钢铁, 2017, 52(3): 93-99.
Liu Bin, Pan Guixiang, Li Peng, et al. Vibration analysis of roll system with nonlinear stiffness of hydraulic cylinder[J]. Iron & Steel, 2017, 52(3): 93-99. (in Chinese)
- [3] 张明,彭艳,孙建亮,等. 2160 mm热连轧机组F2精轧机振动机理及测试[J]. 钢铁, 2016, 51(12): 103-111.
Zhang Ming, Peng Yan, Sun Jianliang, et al. Test of vibration on F2 of 2160 mm hot strip mill[J]. Iron & Steel, 2016, 51(12): 103-111. (in Chinese)
- [4] 焦卫东,蒋永华,施继忠,等. 一种旋转机械系统耦合故障诊断的新方法[J]. 仪器仪表学报, 2016, 37(7): 1449-1456.
Jiao Weidong, Jiang Yonghua, Shi Jizhong, et al. New approach for diagnosis on coupled faults of rotating machine system[J]. Chinese Journal of Scientific Instrument, 2016, 37(7): 1449-1456. (in Chinese)
- [5] 赵光权,葛强强,刘小勇,等. 基于DBN的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1952.
Zhao Guangquan, Ge Qiangqiang, Liu Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1952. (in Chinese)

- [6] 李纪永, 李舜酩, 田国成, 等. 多分量调频信号源混合相交非正交联合对角化盲分离[J]. 振动工程学报, 2015, 28(4): 633-639.
Li Jiyong, Li Shunming, Tian Guocheng, et al. NOJD for multi-components FM source mixed signal separation based on time-frequency distributions[J]. Journal of Vibration Engineering, 2015, 28(4): 633-639. (in Chinese)
- [7] Bofill P, Zibulevsky M. Underdetermined blind source separation using sparse representations [J]. Signal Process, 2001, 81(11): 2353-2362.
- [8] 何昭水, 谢胜利, 傅予力. 稀疏表示与病态混叠盲分离[J]. 中国科学 E 辑信息科学, 2006, 36(8): 864-879.
He Zhaoshui, Xie Shengli, Fu Yuli. Sparse representation and blind source separation of ill-condition mixed sources[J]. Science in China Series E Information Sciences, 2006, 36(8): 864-879. (in Chinese)
- [9] 于刚, 周以齐, 张卫芬. 一种新的相关机械振源盲分离方法[J]. 振动与冲击, 2016, 35(15): 216-222.
Yu Gang, Zhou Yiqi, Zhang Weifen. Blind source separation of correlated vibration sources[J]. Journal of Vibration and Shock, 2016, 35(15): 216-222. (in Chinese)
- [10] Sadhu A, Hazra B, Narasimhan S, et al. Decentralized modal identification using sparse blind source separation[J]. Smart Materials and Structures, 2011, 20(12): 1-15.
- [11] Li B, Zhang P L, Liang S B, et al. Feature extraction for engine fault diagnosis utilizing the generalized S-transform and non-negative tensor factorization[J]. Journal of Mechanical Engineering Science, 2011, 225: 1936-1949.
- [12] Chen J L, Li Z P, Pan J, et al. Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review [J]. Mechanical Systems and Signal Process, 2016, 70/71: 1-35.
- [13] Yang Y, Nagarajah S. Output-only modal identification with limited sensors using sparse component analysis[J]. Journal of Sound and Vibration, 2013, 332(19): 4741-4765.
- [14] Yu K, Yang K, Bai Y. Estimation of modal parameters using the sparse component analysis based underdetermined blind source separation [J]. Mechanical Systems and Signal Processing, 2014, 45(2): 302-316.
- [15] Lin J S, Dou C H. The diagnostic line: a novel criterion for condition monitoring of rotating machinery[J]. ISA Transactions, 2015, 59: 232-242.
- [16] Mallat S G, Zhang Z F. Matching pursuits with time-frequency dictionaries[J]. IEEE Transactions on Signal Processing, 1993, 41(12): 3397-3415.
- [17] Donoho D L, Tsai Y, Drori I, et al. Sparse solution of underdetermined systems of linear equations by stagewise orthogonal matching pursuit [J]. IEEE Transactions on Information Theory, 2012, 58(2): 1094-1121.
- [18] 严保康, 周凤星. 基于相干累积量分段正交匹配追踪方法的轴承早期故障稀疏特征提取[J]. 机械工程学报, 2014, 50(13): 88-96.
Yan Baokang, Zhou Fengxing. Initial fault identification of bearing based on coherent cumulant stagewise orthogonal matching pursuit[J]. Journal of Mechanical Engineering, 2014, 50(13): 88-96. (in Chinese)



第一作者简介: 严保康, 男, 1987年6月生, 讲师。主要研究方向为机械设备故障监测与故障诊断。曾发表《基于相干累积量分段正交匹配追踪方法的轴承早期故障稀疏特征提取》(《机械工程学报》2014年第50卷第13期)等论文。

E-mail: ybk870610@126.com

通信作者简介: 周凤星, 男, 1952年10月生, 教授。主要研究方向为机械设备故障监测与故障诊断。

E-mail: 565725981@qq.com

