

时频流形自适应稀疏重构的遥测振动信号 特征增强方法

刘学¹, 孙翱¹, 李冬¹, 黄锐²

(1. 中国人民解放军 91550 部队, 辽宁 大连 116023; 2. 南京航空航天大学振动工程研究所, 江苏 南京 210016)

摘要: 针对遥测振动信号非线性、非平稳性、瞬态冲击性等特点, 提出一种基于时频流形自适应稀疏重构的遥测振动信号特征增强方法, 对振动信号进行相空间重构提取其时频流形; 以时频流形为基础, 采用 KSVD 算法自适应构建完备字典, 并从中找到最匹配的时频原子, 根据得到的原子与相空间展开信号的时频分布, 依次匹配计算获得其重构的稀疏系数; 利用稀疏系数和时频原子对相空间中各维信号的时频分布进行重构, 通过时频分布的逆运算和相空间还原得到特征增强信号。仿真和实测信号处理结果验证了算法的有效性。

关键词: 信号处理; 遥测振动信号; 时频流形; 稀疏重构; 特征增强

中图分类号: TN911.7 **文献标志码:** A **文章编号:** 1004-4523(2022)01-0246-09

DOI: 10.16385/j.cnki.issn.1004-4523.2022.01.027

引言

遥测振动信号是由安装在被试飞行器内的振动加速度或位移、温度、压力等传感器采集的反映系统运行状态的时间序列。受飞行器本身振动、飞行环境、电磁环境和传输条件等因素的影响, 各结构部位的振动会相互影响、调制和叠加, 振动的传输路径复杂多变, 采集的遥测振动信号往往夹杂着大量的高频、低频和冲击噪声、各阶次的谐波分量, 频谱成分异常复杂, 且相关性耦合程度高, 呈现较强的非线性性和非平稳性^[1]。如何遥测振动信号在不改变其所反映的系统动力学特征情况下进行特征增强直接关系到飞行状态分析的准确性。

信号的稀疏分解重构降噪一直是非线性信号降噪领域的研究热点, 传统的特征增强分析往往从单一的时域或频域构造一系列瞬态脉冲原子对信号进行稀疏分解, 如 Cui 等^[2]利用振动信号进行 Gabor 变换生成一组脉冲原子实现对信号的稀疏分析; Wang 等^[3]采用 Morlet 小波作为时域原子构造过完备字典, 采用正交匹配追踪 (Orthogonal Matching Pursuit, OMP) 对旋转机械信号进行稀疏分解; Fan 等^[4]采用 Laplace 小波变换结合谱分析技术在时域实现对轴承信号的稀疏表示。但是实际系统工况多变, 冲击过程复杂, 如果只用单一的、确定性的、公式化

的原子很难表征实际的信号特征, 最近, 为提高对信号的表征能力, 很多改进的变公式原子模型相继被提出, 如连续双 Laplace 小波原子^[5]、双边非对称 Morlet 小波原子^[6-7]、变窗宽 Gabor 小波等^[8], 根据先验信息不断改变原子公式模型去逼近真实信号冲击情况, 取得了一定的效果, 但是这种变公式模型存在固有缺陷。需要有先验信息, 但在实际情况下很难提前获知冲击过程, 且实际信号瞬态特征波形大多为非公式化的, 这就需要搜索优化更多的公式化原子模型参数, 使得稀疏过程变得更加复杂。

另外, 经 He 等^[9-10]研究发现, 传统的时域稀疏方法对信号中的相位信息具有较差的匹配效果, 导致恢复出的结果较原信号存在较大的误差, 由于时频分布综合了时间域与频率域的联合分布信息, 可以有效描述动态系统中的非平稳特性。因此, He 等^[11]采用时频域重构可以有效解决相位匹配的问题, 并可获取更高的重构精度, 但该文献依然采用公式化原子的时频分布构造时频原子对原信号的时频分布进行稀疏匹配, 不可避免还会受到公式化模型固有缺陷的限制, 为了解决上述问题, 本文提出一种基于时频流形 (Time-Frequency Manifold, TFM) 自适应稀疏重构的信号特征增强方法, 采用 KSVD 算法^[12]从时频流形中自适应构建过完备字典, 并从中找到最匹配的时频原子, 避免对原子库模型构造的依赖性, 利用保持时频分布的相位信息, 有效提高了信号

瞬态特征增强的准确性以及稀疏方法的通用性。

1 时频流形

时频流形是嵌入在非平稳信号时频分布中的一种内在的非线性流形结构,采用流形学习从信号相空间重构分量的时频分布(高维空间)提取到该信号嵌入低维空间的特征结构^[9]。在流形学习过程中综合了信号本身的非平稳性和非线性两种信息,因此可有效地挖掘和表征信号的时频模态,刻画信号时频分布特性。

1.1 相空间重构和时频分布

采用相空间重构的方法将振动信号扩展到多维相空间,使混叠的各源信号在多维空间中重新展开,以确保满足 Takens 定理要求和尺度空间的统一性。对于振动信号 $x(t)=[x_1, x_2, \dots, x_N]$, 相点向量可通过下式重构得到:

$$\begin{aligned} X_i^m &= [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}], \\ i &= 1, 2, \dots, N-(m-1)\tau \end{aligned} \quad (1)$$

式中 m 和 τ 分别为嵌入维数和延迟时间,相空间的重构质量与嵌入维数和延迟时间的选择有直接关系。对比算法性能和计算效率,本文采用互信息量法获取延迟时间 τ , 然后根据 τ 和 Takens 原理^[13], 采用 Cao 算法^[14] 得到嵌入维数 m 。

利用相点向量 X_i^m 重构 $n \times m$ 维相空间, $n = N - (m - 1)\tau$ 为重构后的向量点数。

$$\begin{bmatrix} X_1^m \\ X_2^m \\ \vdots \\ X_i^m \\ \vdots \\ X_n^m \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_i & x_{i+\tau} & \cdots & x_{i+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_n & x_{n+\tau} & \cdots & x_N \end{bmatrix} = \begin{bmatrix} P_x^1 \\ P_x^2 \\ \vdots \\ P_x^j \\ \vdots \\ P_x^m \end{bmatrix}^T \quad (2)$$

式中 $P_x^j (j=1, 2, \dots, m)$ 为重构相空间第 j 维子序列, 当延迟时间 τ 和嵌入维数 m 满足 Takens 理论, 原信号的动态系统特性就能完全反映在重构相空间所对应的拓扑结构上^[12]。对重构相空间每一维子序列 P_x^j , 采用短时傅里叶变换 (Short-Time Fourier Transform, STFT) 求取其时频分布:

$$\begin{aligned} S_j(k, f) &= \sum_{l=-\infty}^{+\infty} P_x^j(l) \omega(k-l) e^{-i2\pi f l / N_{\text{STFT}}} = \\ & A_j(k, f) e^{-i\theta_j(k, f)} \end{aligned} \quad (3)$$

式中 k 和 f 分别为时间点和频率点, $\omega(k)$ 和 N_{STFT} 分别为 STFT 的短时分析窗和变换点数, 时频复数矩阵 $S_j(k, f)$ 由幅值矩阵 $A_j(k, f)$ 和相位矩阵 $\theta_j(k, f)$ 两部分组成。

1.2 LTSA 时频流形提取

局部切空间排列算法 (Local Tangent Space Alignment, LTSA) 基于数据流形满足局部线性条件假设, 即高维数据空间的局部区域和局部切空间之间存在着一个线性投影, 同时全局低维空间的局部区域和局部切空间之间也存在着一个线性投影^[15]。LTSA 通过逼近每一样本点的切空间来构建低维流形的局部几何结构, 观测数据点在局部切空间的投影获得局部低维坐标, 由局部仿射变换而得到低维的全局坐标^[16]。

(1) 构造样本邻域: 对高维样本集 $X = \{x_i \in \mathbb{R}^M, i=1, 2, \dots, N\}$ 中的每个样本点用欧氏距离确定其 k 个距离最小的邻域点 $X_i = [x_{i1}, x_{i2}, \dots, x_{ik}]$;

(2) 局部信息获取: 以 X 的嵌入维数作为主流形维数 d , 构建邻接图 G , 在数据点 x_i 的邻域内选择一组正交基 Q_i 构成点的 d 维切空间, Q_i 为中心化矩阵 $X_i - \bar{x}_i L_k^T$ 的最大 d 个奇异值对应的右奇异特征向量, 其中 $\bar{x}_i = \sum_{j=1}^k x_{ij} / k$, 局部切空间坐标为:

$$\Theta_i = Q_i (X_i - \bar{x}_i L_k^T) \quad (4)$$

(3) 局部切空间全局排列: 根据局部投影 $\Theta_i = [\theta_{i1}, \theta_{i2}, \dots, \theta_{ik}]$, 其中 θ_{ij} 为 x_i 的邻域中每一个点 x_{ij} 到切空间中的正交投影, 通过局部仿射变换得到全局主流形坐标, 局部坐标转换为全局坐标必须满足全局坐标应尽可能地保留每个数据点邻域的几何结构信息, 即等价于一个最小化近似求解问题:

$$\arg \min \sum_{i=1}^N E_i = \arg \min \sum_{i=1}^N \|T_i H_k - L_i \Theta_i\|^2 \quad (5)$$

式中 $T_i = [t_{i1}, t_{i2}, \dots, t_{ik}]$ 为 X_i 的全局低维坐标, $H_k = I - ee^T / k$ 为 T_i 的中心化矩阵 (e 为元素全为 1 的列向量), 因此:

$$T_i T_i^T = I \quad (6)$$

L_i 为待映射矩阵, 由式 (5) 可知, 当 $L_i = T_i H_k \Theta_i^+$ 时仿射变换误差最小, Θ_i^+ 为 Θ_i 的 Moore-Penrose 广义逆。

(4) 主流形重构: 得到所有数据点对应的低维全局坐标 $T = [t_1, t_2, \dots, t_i]$ 后, 利用低维坐标重构高维空间中的主流形:

$$\tilde{x}_i = \bar{x}_i + Q_i L_i^{-1} (t_i - \bar{t}_i) \quad (7)$$

式中 \bar{t}_i 为 T_i 均值, L_i^{-1} 为转换矩阵 L_i 的广义逆。通过式 (7) 即可得到高维空间中的主流形 $Y = \{\tilde{x}_i \in \mathbb{R}^D, i=1, 2, \dots, N\}$ 。

采用上述 LTSA 算法提取时频流形的主要思想: 在高维的重构相空间中, 相对于嵌入维数而言, 系统有用信号吸引子所在的主流形是低维的, 其分

布只局限于相空间中某个低维的子空间内,而白噪声则在相空间的所有维度中都有分布。根据信号和噪声分布的不同,通过LTSA流形学习,在时间序列的嵌入相空间降维过程中,保留系统的主流形结构^[9]。但LTSA算法的输入为二维,而相空间 m 维子序列的时频分布矩阵均为三维矩阵,因此要把它们转换成二维矩阵,以时间轴为基准,将幅值矩阵 $A_j(k, f)$ 的每一列首尾相连,构造一个一维向量 T_{TFD}^j ,将 m 个一维向量组成二维数据集 X_{TFD} 为:

$$X_{TFD} = [T_{TFD}^1, T_{TFD}^2, \dots, T_{TFD}^m]^T$$

采用LTSA算法对 X_{TFD} 进行降维得到 d ($d \ll m$)维流形 $X_{TFM} = [T_{TFM}^1, T_{TFM}^2, \dots, T_{TFM}^d]^T$ 。由于降维后第一维流形数据 T_{TFM}^1 就能表征时频分布(Time-Frequency Distribution, TFD)的本质流形结构,因此,将 T_{TFM}^1 作为主流形,通过一维时频序列到二维时频矩阵逆重排,便可恢复出时频流形分布 $T(k, f)$ 。

2 时频流形自适应稀疏重构

稀疏重构就是使用过完备字典对信号进行稀疏表示,将信号的能量集中在字典的少量原子上,通过少量原子来表征信号的本质特征。从数学和信号的角度,大多数零分量或小幅度分量和少数非零大幅度分量揭示了信号的内在结构和本质属性,由于遥测振动信号具有瞬态冲击性,满足稀疏分解条件,同时采用时频流形可以有效提取信号的瞬态特征,也能消除带内噪声,但是受流形学习算法式(6)的限制,提取的时频流形特征幅值损失严重,为了在去噪的同时还原信号的幅值信息,以时频流形为基础,自适应提取时频原子,结合相位信息保持,通过学习到时频原子对信号进行稀疏重构,恢复幅值信息,对信号特征进行增强。

2.1 基于图像块的稀疏域建模

对于时频流形分布 $T \in \mathbf{R}^{M \times N}$ ($M \leq N$),以滑动窗口方式进行图像块划分,块大小为 $\sqrt{n} \times \sqrt{n}$ ($n < M$),定义过完备字典 $D \in \mathbf{R}^{n \times l}$, $l > n$,将图像块进行一维向量重排得到 $p \in \mathbf{R}^{n \times 1}$,则基于图像块的三元组 (L, D, ϵ) 稀疏域模型可表示为:

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_0, \quad s.t. \|D\alpha - p\|_2 \leq \epsilon \quad (8)$$

式中 L 为稀疏度, α 为稀疏系数, ϵ 为误差限。通过式(8)模型可以对图像块进行稀疏重构 $\hat{p} = D\hat{\alpha}$,可以将约束项转换为惩罚项对模型求解:

$$\hat{\alpha} = \arg \min_{\alpha} \|D\alpha - p\|_2^2 + \mu \|\alpha\|_0 \quad (9)$$

式中 μ 为惩罚因子。式(9)属于NP难求解问题,理论上需要转化为1范数才能进行多项式解析求解,但依然求解困难,通常采用稀疏表达近似求解方法,主要分为两大类,一是匹配追踪算法,通过构造一系列具有稀疏表达能力的原子字典,通过相关匹配分析,学习出信号中的主要特征成分,采用的是贪婪迭代方法;另一种是基追踪算法,通过稀疏约束在全局范围内的极值问题,使用线性规划方法来实现对信号稀疏分解,采用的是优化重构。本文采用正交匹配追踪OMP算法进行近似求解。在对时频流形分布 T 的每一个图像块建立稀疏域模型的基础上,对 T 进行贝叶斯最大后验估计,得到:

$$\{\hat{\alpha}_{ij}, \hat{T}\} = \arg \min_{\alpha_{ij}, T} \lambda \|T - \tilde{T}\|_2^2 + \sum_{ij} \|D\hat{\alpha}_{ij} - R_{ij}T\|_2^2 + \sum_{ij} \mu_{ij} \|\alpha_{ij}\|_0 \quad (10)$$

式中 λ 为拉格朗日乘子。等式右边第一项为全局对数似然强制约束项,用于保证测量时频流形分布 \tilde{T} 与原分布 T 之间的整体相似性,第二和第三约束项用于保证整体时频流形分布 T 中的每一个图像块 $p_{ij} = R_{ij}T$ 均具有误差约束的稀疏表示, $R_{ij} \in \mathbf{R}^{n \times N}$ 表示从 T 中提取序号为 (i, j) 的图像块的转换矩阵。

2.2 自适应时频原子字典构造

为了克服公式化模型原子字典固有缺陷的限制,本节采用K-SVD算法自适应训练时频原子字典,基本思想是利用时频流形瞬态特征提取与带内噪声去除的能力,采用DCT字典或从时频流形分布中随机抽取冗余时频原子作为初始化的过完备字典 D ,使用OMP算法求解NP问题得到稀疏系数 $\hat{\alpha}_{ij}$ 的近似优化解,然后根据稀疏系数 $\hat{\alpha}_{ij}$,使用K-SVD算法^[12,17]依次对字典 D 中的每一个原子进行更新。算法流程如下:

(1)初始化:设置图像块大小为 $\sqrt{n} \times \sqrt{n}$,字典大小 k ,训练次数 J ,依据时频流形分布 T 初始化过完备字典 D ;

迭代循环训练开始,训练次数(J 次)。

(2)稀疏编码:采用OMP算法对公式(10)进行优化求解,在每一次对原子迭代更新过程中,理论上应采用误差限 $\|D\hat{\alpha}_{ij} - R_{ij}T\|_2 \leq \epsilon$ 作为迭代终止条件,但实际操作过程中,因每一个图像块包含信息的重要程度各不相同,因此设定固定的 ϵ 不具有普适性,这里采用更具通用性的迭代终止条件:连续 K 次残差能量变化率均小于给定的阈值,定义如下:

$$\frac{E_r^{i+1} - E_r^i}{E_0} \leq \epsilon, \quad \text{for } i = k+1, k+2, \dots, k+K \quad (11)$$

式中 E_i^l 表示第 i 次迭代后的残差能量, E_0 表示原信号能量, 通过实测遥测振动信号验证一般 $K \leq 7$, 式(11)即可保证稀疏主成分被提取完毕。因此使用式(11)作为匹配追踪算法的迭代终止条件, 对每一个图像块 $R_{ij}T$ 进行上述的迭代优化得到其对应的稀疏系数 $\hat{\alpha}_{ij}$;

(3)字典迭代更新:对 D 中的每一个时频原子 $d_l(l=1, 2, \dots, k)$ 进行逐一更新:

①以 d_l 所对应的稀疏矩阵中的非零元素组成集合 $\omega_l = \{(i, j) | \alpha_{ij}(l) \neq 0\}$ 计算集合中每组元素 $(i, j) \in \omega_l$ 的稀疏误差:

$$\epsilon_{ij}^l = R_{ij}T - \sum_{m \neq l} d_m \alpha_{ij}(m) \quad (12)$$

②以 $\{\epsilon_{ij}^l\}_{(i,j) \in \omega_l}$ 作为列向量构造残差矩阵 E_l , 对其进行SVD分解得到 $E_l = U\Lambda V^T$;

③更新的时频原子:更新后的 \tilde{d}_l 为酉矩阵 U 的第一列, 稀疏系数 $\{\alpha_{ij}(l)\}_{(i,j) \in \omega_l} = V\Lambda(1, 1)$ 。

2.3 相空间信号时频分布稀疏重构

根据上节训练得到的基于时频流形的过完备字典 D , 则模型求解问题即可等价于求解局部稀疏系数 $\hat{\alpha}_{ij}$ 和重构时频分布 \hat{T} , 可分两步求解, 第一步为局部图像块稀疏匹配, 令 $T = \tilde{T}$, 采用块系数最小化方法计算 $\hat{\alpha}_{ij}$ 的最优值, 则式(10)可转换为

$$\hat{\alpha}_{ij} = \arg \min_{\alpha_{ij}} \|D\alpha_{ij} - R_{ij}T\|_2^2 + \mu_{ij} \|\alpha_{ij}\|_0 \quad (13)$$

采用OMP算法对式(13)进行求解, 同2.2节一样依然使用式(11)作为匹配追踪算法的迭代终止条件;

第二步采用已获得的 $\hat{\alpha}_{ij}$ 对 \hat{T} 进行更新, 则式(10)可转化为:

$$\hat{T} = \arg \min_T \lambda \|T - \tilde{T}\|_2 + \sum_{ij} \|D\hat{\alpha}_{ij} - R_{ij}T\|_2 \quad (14)$$

上式的近似解析解为:

$$\hat{T} = (\lambda I + \sum_{ij} R_{ij}^T R_{ij})^{-1} (\lambda T + \sum_{ij} R_{ij}^T D\hat{\alpha}_{ij}) \quad (15)$$

3 时频流形自适应稀疏重构特征增强方法

稀疏重构方法的降噪能力与原子选取有关, 通常采用公式化的原子创建过完备字典, 但在实际情况信号瞬态特征波形大多为非公式化的, 且很难提前获知冲击过程以及相位变化等先验信息, 这就导致匹配追踪时对原子形态要求过高, 因此, 公式化原子字典很难在实际工况下对原信号进行较好的稀疏逼近。另外, 如果直接在时频域上做匹配追踪稀疏分析, 虽然可以保持信号的相位信息, 使得恢复出的信号与原信号具有相同的波形特征, 但受噪声的影响(特别是带内噪声), 匹配稀疏的特征表达能力将受到严重的削弱。

针对这些问题, 本文将时频流形与稀疏分析相结合, 充分利用时频流形良好的瞬态特征提取与带内噪声去除的能力, 以及稀疏表示良好的特征表达能力, 从时频流形中自适应构建过完备字典, 并从中找到最匹配的时频原子, 在保持原信号时频分布相位信息的同时, 采用时频原子匹配稀疏的方法, 对相空间中含噪信号时频的分布进行稀疏表达, 实现冲

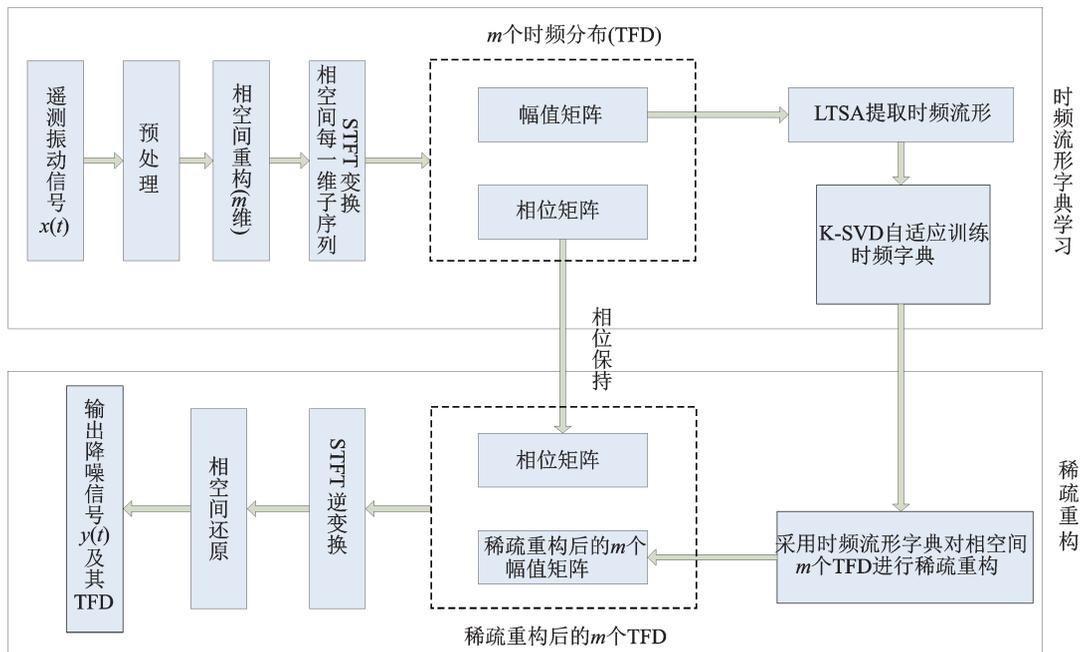


图1 算法流程图

Fig. 1 Algorithm flowchart

击特征的提取和信号幅值的恢复。算法流程如图 1 所示。算法分为基于时频流形的自适应字典学习和相空间信号时频分布的稀疏重构两个部分。

(1) 首先对采集的遥测振动信号依据指令时刻进行特征段顺序选取,若相邻指令时刻间隔较近(前一指令响应未结束,后一指令响应即开始),可按前一特征段最大幅值能量的 10% 进行截取;若重叠部分超过 50%,则将相邻两特征段合并处理。对所选特征段进行预处理:根据《GJB2238A—2004》的规范进行零漂修正、趋势项去除、野值剔除等;

(2) 对特征段信号 $x(t)$ 采用式(1)和(2)进行相空间重构,对重构相空间每一维子序列 $P_x^j(j=1, 2, \dots, m)$, 采用式(3)计算其时频复数矩阵 $S_j(k, f)$, 将幅值矩阵 $A_j(k, f)$ 和相位矩阵 $\theta_j(k, f)$ 进行分离;

(3) 对由 m 维相空间子序列时频分布的 $A_j(k, f)$ 的幅值矩阵组成高维矩阵进行 LTSA 主流形提取,得到时频流形分布 $T(k, f)$;

(4) 采用 2.2 节的方法从 $T(k, f)$ 自适应训练过完备字典 D ;

(5) 利用学习得到的过完备字典 D , 采用式(12)~(15)对 m 维相空间子序列时频分布的 $A_j(k, f)$ 进行稀疏重构,得到重构后的幅值矩阵 $\hat{T}_j(k, f)$, 结合步骤(2)得到的相位矩阵 $\theta_j(k, f)$ 对时频复数矩阵进行重新合成,得到 $\hat{S}_j(k, f)$;

(6) 对 $\hat{S}_j(k, f)$ 进行 STFT 逆变换更新相空间每一维子序列 $\hat{P}_x^j(j=1, 2, \dots, m)$;

(7) 对相空间矩阵进行还原得到去噪信号 $y(t)$ 及采用式(3)计算其时频分布。

$$y_i = \frac{\sum_{q \in I_i} \hat{P}_x^q}{C_i}, \quad i=1, 2, \dots, N \quad (16)$$

式中 N 为信号长度,集合 I_i 为包含信号元素 i 的下标集, C_i 为 I_i 中元素个数。

4 仿真与实测信号分析

采用仿真和实测信号对本文所提方法(Time-Frequency Manifold Adaptive Sparse Reconstruction, TFMASR)同基于时域稀疏重构(Time Domain Sparse Reconstruction, TDSR)、时频域稀疏重构方法(Time-Frequency Domain Sparse Reconstruction, TFDSR)进行性能对比验证,为实现对瞬时脉冲特征的挖掘,时域稀疏重构采用双尺度 Gabor 变换构造时域原子^[8],时频域稀疏重构采用时域原子的 STFT 变换得到的时频分布作为初始时频原

子^[11],各算法均采用 OMP 匹配追踪算法进行稀疏重构,OMP 算法参数有稀疏度、最大迭代次数和迭代终止条件。稀疏度可默认为字典的维数,即使得所有字典遍历一次,最大迭代次数设置为 100,迭代终止条件如式(13)所示,残差能量的变化率阈值 ϵ 设置为 0.005。经实验验证,一般不超过 50 次即可满足迭代终止条件,跳出循环。结果采用信噪比(Signal to Noise Ratio, SNR)和衡量时频域上瞬态脉冲的敏感特征特性-联合时频熵^[11](Joint Time-Frequency Entropy, JTFE)作为量化指标。算法的运行平台: Inter Core i7-4790(主频 3.6 GHz)CPU, 8GBDDR3 内存, Matlab 2015b, Windows 7 64 位专业版操作系统。

4.1 仿真分析

构造含有 4 个瞬时脉冲的仿真振动信号:

$$x(t) = \sum_{i=1}^4 A_i \phi(\tau_i, \theta_i) + n(t),$$

$$\phi(\tau_i, \theta_i) = \begin{cases} \frac{\xi}{\sqrt{1-\xi^2}} [2\pi f_r(t-\tau_i)]^2 \cos[2\pi f_r(t-\tau_i) + \theta_i], & |t-\tau| \leq \eta \\ 0, & \text{else} \end{cases} \quad (17)$$

驱动频率 $f_r=1$ kHz, 采样频率 $f_s=1$ kHz, 信号长度 $N=1024$, $A=[0.76, 0.96, 0.92, 1.09]$ 和 $\theta=[\pi/6, \pi/4, \pi/3, \pi/2]$ 分别为给定的幅值和初始相位向量, 阻尼系数 $\xi=0.01$, $\tau=[0.02, 0.04, 0.06, 0.08]$ 为脉冲起始时刻, $\eta=0.02$ s 为脉冲持续时间, $n(t)$ 为加入 -8 dB 的高斯白噪声, 结果如表 1 和图 2~7 所示。

表 1 不同方法输出信号的 SNR 和 JTFE 对比

Tab. 1 Comparison of SNR and JTFE of output signals acquired by different methods

方法	SNR/dB	JTFE	运行时间/s
原始信号	-8	0.9032	-
TDSR	-5.19	0.8328	3.14
TFDSR	-3.82	0.8174	14.66
TFMASR	6.21	0.7655	539.56

图 2 和 3 分别给出了仿真信号和加噪信号的时域波形、频谱和时频分布。通过对比发现,加噪信号中的 4 个瞬态冲击成分被噪声严重污染,导致瞬态特征被削弱。图 4 给出了时域稀疏重构方法获得的结果图。从表 1 给出的输出信噪比看仅为 -5.19 dB, 提升不明显, 重构出的结果与原信号存在较大的误差, 这说明在初始相位不同的情况下, 相位匹配在一定程度上会影响时域稀疏重构算法的性能, 由

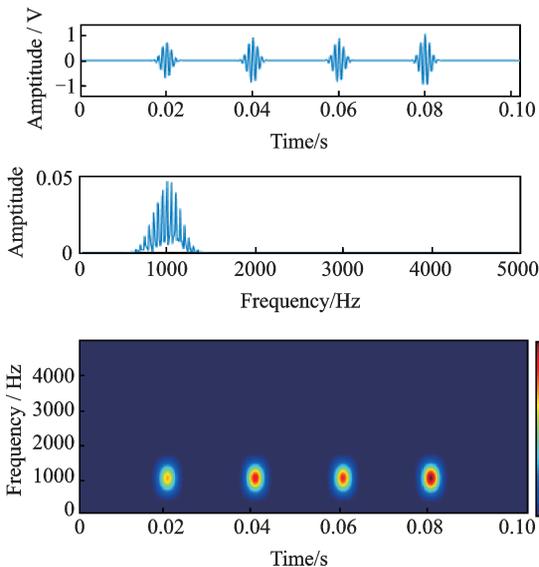


图 2 仿真信号时域波形、频谱和时频分布

Fig. 2 Waveform, spectrum and time-frequency distribution of the simulation signal

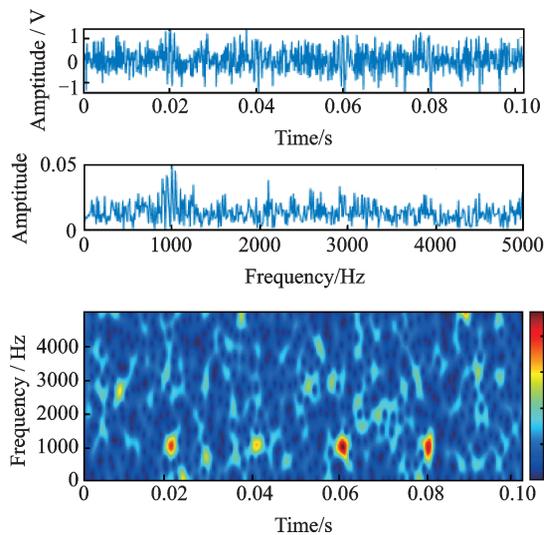


图 3 加噪信号时域波形、频谱和时频分布

Fig. 3 Waveform, spectrum and time-frequency distribution of the noised simulation signal

于稀疏重构只是采用少数原子去对原信号进行稀疏表达,噪声将严重降低(消弱)其匹配稀疏的特征表达能力,时域稀疏仅在时域内进行匹配追踪,这就对时域原子的形态要求过高,很难对幅值和相位同时匹配以保证重构波形不失真,这也验证了文献[11]的结论。

图 5 为时频域稀疏重构方法的结果图,可以看出重构的结果远比时域重构的结果要好,输出信噪比为 -3.82,这说明时频域稀疏重构方法采用时频分析(STFT 变换)对幅值和相位进行分离,通过相位保持降低了对原子库模型构造的依赖性,与仿真信号的波形特点更为吻合,保证了瞬态特征提取的准确性,但时频域稀疏重构方法将噪声也恢复出来,

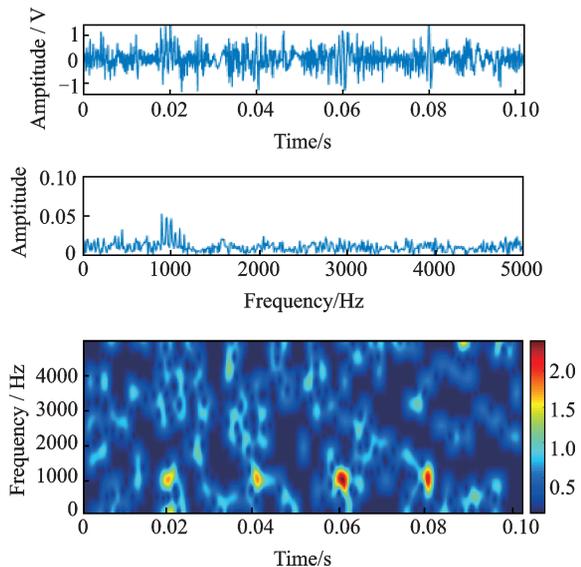


图 4 时域稀疏重构方法输出结果

Fig. 4 Results of TDSR

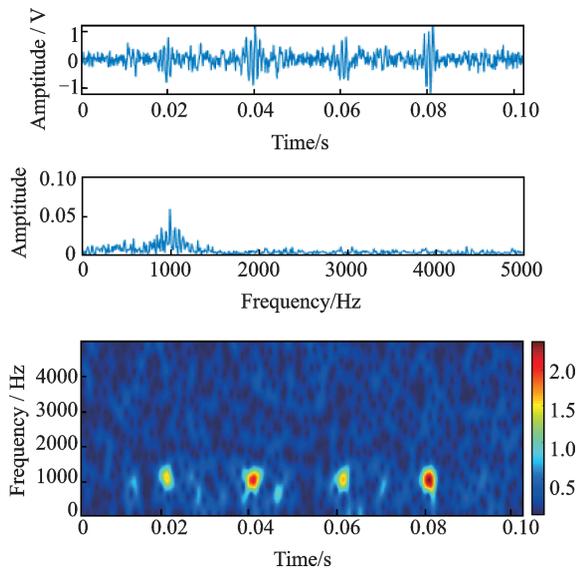


图 5 时频域稀疏重构方法输出结果

Fig. 5 Results of TFDSR

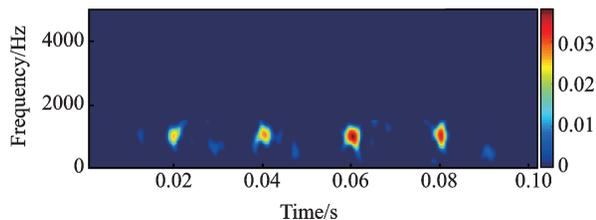


图 6 时频流形分布

Fig. 6 Distribution of time-frequency manifold

瞬态特征增强效果不强;图 6 为加噪信号的时频流形分布图,从图中可以看出,带内噪声基本被去除,具有良好的瞬态特征提取能力,但受 LTSA 流形学习算法公式(7)的约束,提取的时频流形特征对比原信号幅值损失严重,最高幅值仅为 0.037,相差约 2 个数量级,这将严重影响后续的信号分析;

图 7 给出了 TFMASR 方法的输出结果图,可以

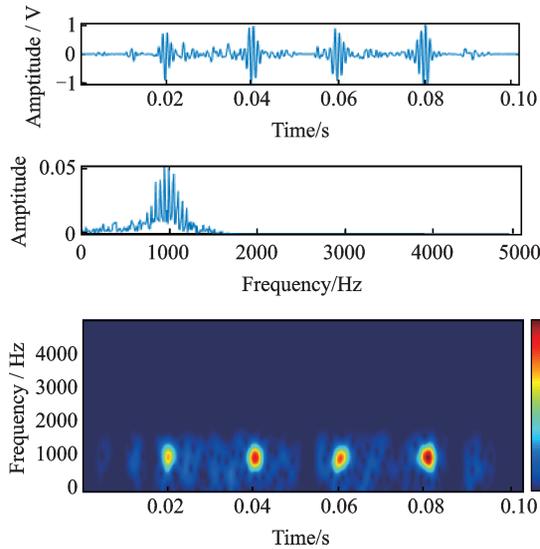


图7 时频流形自适应稀疏重构方法输出结果
Fig. 7 Results of TFMASR

明显可以看出,基于时频流形稀疏重构方法具有高效准确的瞬态特征增强能力。表1给出输出信噪比为 6.21 dB, *JTFE* 为最小的 0.7655, 反映出输出信号的频带能量分布更为集中, 且具有更少的带内噪声, 这表明所提方法利用了时频流形带内噪声去除能力, 降低了噪声对时频原子构造学习的影响, 通过相位保持对信号波形特点增强的准确性, 极大地提高了瞬态冲击特征的挖掘与增强能力。

4.2 实测信号验证

为验证所提方法的有效性, 采用某型飞行器试验任务中高频振动传感器采集的遥测振动信号进行处理验证, 采样频率为 5.12 kHz, 结果如图 8~12 所示。由于 SNR 的计算需要无噪声的先验信息, 因此其在仿真研究中可以作为较好的量化指标, 但对

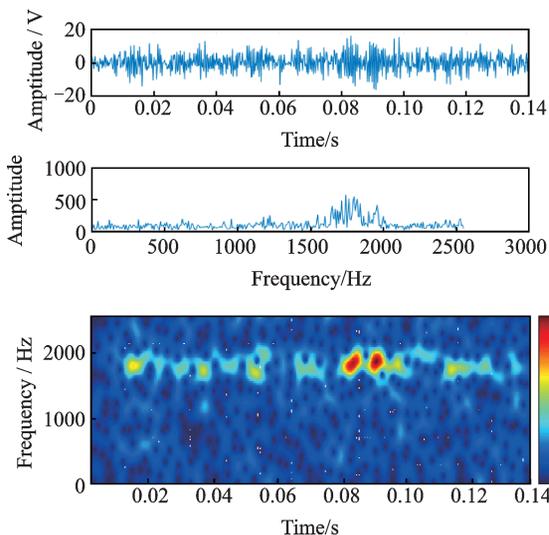


图8 实测信号时域波形、频谱和时频分布
Fig. 8 Waveform, spectrum and time-frequency distribution of the measured signal

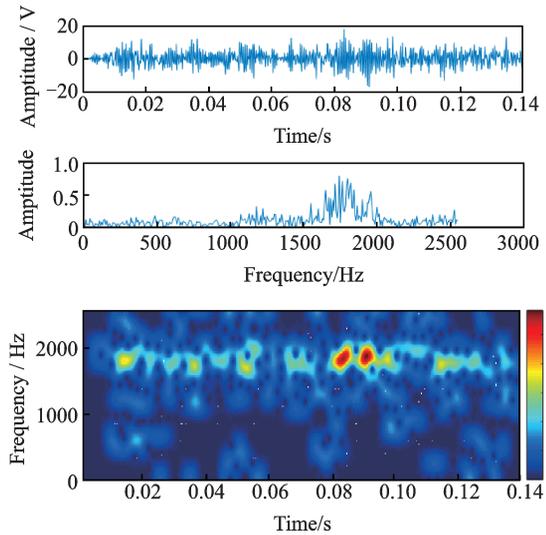


图9 时域稀疏重构方法输出结果
Fig. 9 Results of TDSR

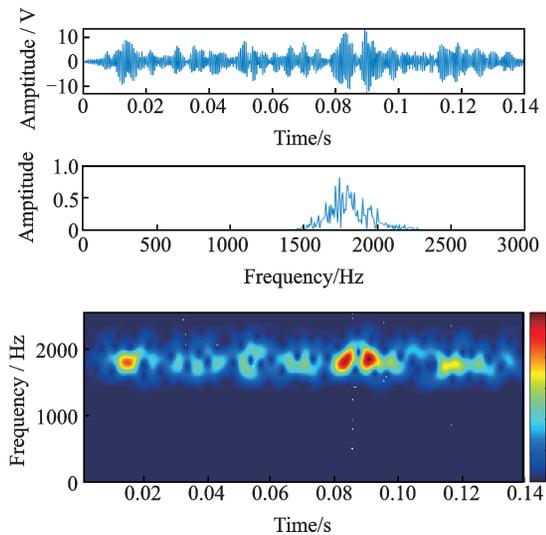


图10 时频域稀疏重构方法输出结果
Fig. 10 Results of TFDSR

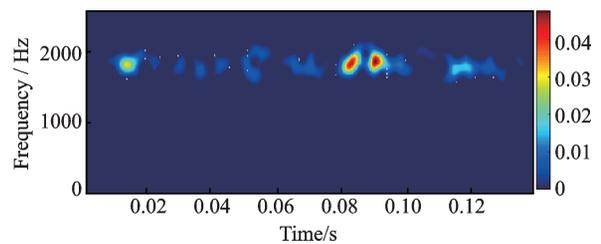


图11 时频流形分布
Fig. 11 Distribution of time-frequency manifold

实测信号却无法使用。因此对于实测遥测振动信号, 只采用 *JTFE* 对时频能量分布情况进行量化。

图8给出了实测遥测振动信号的时域波形、频谱和时频分布, 驱动频率大致在 1600~2000 Hz 之间, 噪声覆盖整个时频平面, 信号瞬态特征被严重削弱, 且这种瞬态特征呈现较强的非线性, 波形特征也随时变化。图9给出了时域稀疏重构的结果, 可以看出时域稀疏虽然可以去除一部分噪声, 但带内噪

声去除得不够明显, $JTFE=0.7633$ 时, 由于没有对相位信息进行保持, 同上一节的仿真结果一样, 重构出的信号波形较原信号有一定的差异。

表2 不同方法输出信号的 $JTFE$ 对比

Tab. 2 Comparison of $JTFE$ of output signals acquired by different methods

方法	$JTFE$	运行时间/s
实测信号	0.8184	-
TDSR	0.7633	2.52
TFDSR	0.7697	10.39
TFMASR	0.7418	417.31

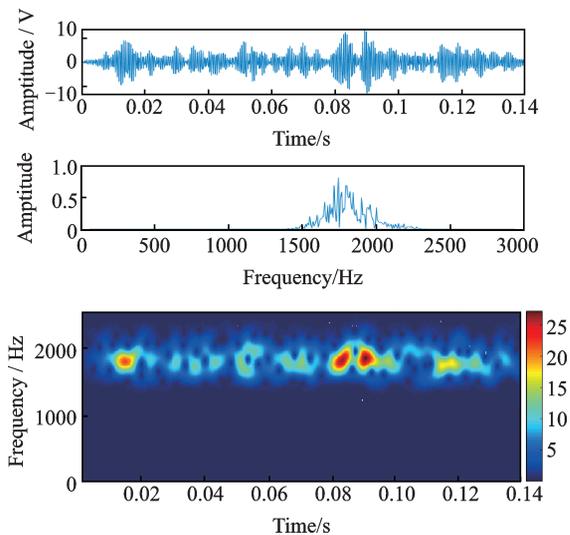


图12 时频流形自适应稀疏重构方法输出结果

Fig. 12 Results of TFMASR

图10给出了时频域稀疏重构的结果图, 采用时频分析技术将幅值和相位分离, 通过相位保持使得恢复出的信号同原信号的波形特点较为吻合, 在一定程度上提升了信号瞬态特征的稀疏表达效果, 仅当 $JTFE=0.7697$ 时, 反而比时域稀疏重构方法大, 这说明受噪声的影响, 特别是带内噪声, 使得在时频原子构造过程中添加了噪声信息, 在重构过程中难免将噪声信息也一并恢复, 使得降噪效果不佳; 图11给出了实测信号的时频流形分布图, 可以看出其具有良好的带内噪声去除效果, 但提取的时频流形的幅值受LTSA算法数据中心化的影响有较大衰减, 最高幅值仅为0.045, 较原信号幅值28.24相差约3个数量级, 这将严重影响后续信号分析的准确性; 图12为基于时频流形自适应稀疏重构方法的输出结果图, 不难发现, 该方法具有最小的 $JTFE=0.7418$, 重构出的信号时频分布具有最高的时频能量聚集性, 瞬态特征增强效果最好。这说明从时频流形中自适应学习构造时频字典充分利用时频流形的带内噪声去除能力, 降低了噪声对构造原子质量

的影响, 因此, 本文所提方法在波形特点保持、带内噪声去除、瞬态特征增强以及降低原子库模型构造的依赖性等方面较时域稀疏重构和时频域稀疏重构方法具有更好的效果。但从表1和2各算法运行时间对比来看, TFMASR方法的主要缺点是运行时间较长, 1024点的时序仿真信号需要539.56s的计算时间, 经算法流程分析和实验得出, 算法的计算量主要集中在时频流形的提取上, 由于相空间信号时频分布样本数据量较大, 导致后续的LTSA非线性流形学习效率降低, 计算损耗增加; 另外, TFMASR在字典自适应学习和相空间信号时频分布需要2次的全局匹配追踪搜索, 也需要一定的时间损耗, 为了提高算法的运行效率, 可采取只对感兴趣的分析频段、时间段进行时频流形提取和匹配追踪搜索, 降低时频分布样本数据量和提高匹配搜索的效率。

5 结论

针对遥测振动信号非线性、强噪声、瞬态冲击性等特点, 提出一种基于时频流形自适应稀疏重构的信号特征增强方法, 以时频流形为基础自适应构建完备字典, 避免对原子库模型构造的依赖性; 利用保持时频分布的相位信息, 有效提高了信号瞬态特征增强的准确性以及稀疏方法的通用性。仿真和实测信号实验结果表明新方法在波形特点保持、带内噪声去除、瞬态特征增强以及降低原子库模型构造的依赖性等方面优于时域稀疏重构和时频域稀疏重构方法。

参考文献:

- [1] 刘学. 虚部噪声辅助LCD方法及其在遥测振动信号处理中的应用[J]. 振动与冲击, 2017, 36(12): 1-6.
Liu Xue. An image noise assisted local characteristic scale decomposition method and its application in telemetry vibration signal processing[J]. Journal of Vibration and Shock, 2017, 36(12): 1-6.
- [2] Cui L, Wang J, Lee S C. Matching pursuit of an adaptive impulse dictionary for bearing fault diagnosis [J]. Journal of Sound and Vibration, 2014, 333: 2840-2862.
- [3] Wang S, Cai G, Zhu Z, et al. Transient signal analysis based on Levenberg-Marquardt method for fault feature extraction of rotating machines[J]. Mechanical Systems and Signal Processing, 2015, 54: 16-40.
- [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] Tang H, Chen J, Dong G. Sparse representation based latent components analysis for machinery weak fault detection[J]. *Mechanical Systems and Signal Processing*, 2014, 46(2):373-388.
- [6] Lin J, Qu L. Feature extraction based on Morlet wavelet and its application for mechanical fault diagnosis[J]. *Journal of Sound and Vibration*, 2000, 234(1):135-148.
- [7] Cui L, Wu N, Wang W, et al. Sensor-based vibration signal feature extraction using an improved composite dictionary matching pursuit algorithm [J]. *Sensors*, 2014, 14(9):16715-16739.
- [8] Feng Z P, Liang M. Complex signal analysis for planetary gearbox fault diagnosis via shift invariant dictionary learning[J]. *Measurement*, 2016, 90:382-395.
- [9] He Q, Liu Y, Long Q, et al. Time-frequency manifold as a signature for machine health diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(5):1218-1230.
- [10] He Q. Time-frequency manifold for nonlinear feature extraction in machinery fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2013, 35(2):200-218.
- [11] He Q B, Ding X X. Sparse representation based on local time-frequency template matching for bearing transient fault feature extraction [J]. *Journal of Sound and Vibration*, 2016, 370:424-443.
- [12] Ahron M, Elad M, Bruckstein A M. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Instrumentation and Measurement*, 2006, 15(11):4311-4322.
- [13] Takens F. Detecting strange attractors in turbulence[J]. *Lecture Notes in Mathematics*, 1981, 898:361-381.
- [14] 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应用[M]. 武汉: 武汉大学出版社, 2002.
- [15] Zhang Z, Zha H. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment [J]. *SIAM Journal on Scientific Computing*, 2004, 26(1):313-338.
- [16] 杨庆, 陈桂明, 江良洲, 等. 带标志点的LTSA算法及其在轴承故障诊断中的应用[J]. *振动工程学报*, 2012, 25(6):732-738.
Yang Qing, Chen Guiming, Jiang Liangzhou, et al. Local tangent space alignment algorithm based on selecting landmark points and its application in fault diagnosis for rolling bearing [J]. *Journal of Vibration Engineering*, 2012, 25(6):732-738.
- [17] Zhu H, Wang X, Zhao Y, et al. Sparse representation based on adaptive multi-scale features for robust machinery fault diagnosis [J]. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2015, 229(12):2303-2313.

Telemetry vibration signal feature enhancement method based on time-frequency manifold adaptive sparse reconstruction

LIU Xue¹, SUN Ao¹, LI Dong¹, HUANG Rui²

(1. Unit 91550 of PLA, Dalian 116023, China; 2. Institute of Vibration Engineering Research, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: Aiming at the characteristics of nonlinearity, non-stationary and transient impact of telemetry vibration signal, a telemetry vibration signal feature enhancement method based on time-frequency manifold adaptive sparse reconstruction was proposed. The phase space reconstruction of the vibration signal was performed to extract its time-frequency manifold. Based on the time-frequency manifold, the KSVD algorithm was used to adaptively construct an over-complete dictionary and find the best matching time-frequency atoms. According to the selected atoms, the time-frequency distribution of each dimension signal in phase space was sequentially matched to calculate the reconstructed sparse coefficient. The time-frequency distribution of each dimension signal in phase space was reconstructed by using sparse coefficient and time-frequency atoms, and the feature enhancement signal was acquired by inverse operation of time-frequency distribution and phase space reduction. Simulation and measured signal processing results verified the effectiveness of the method.

Key words: signal processing; telemetry vibration signal; time-frequency manifold; sparse reconstruction; feature enhancement

作者简介: 刘学(1983—),男,高级工程师,博士后,IEEE Member。电话:(0411)80858445; E-mail: liuxue002@163.com。