

基于稀疏表达特征提取的发动机爆震状态检测*

沈鹏飞¹, 毕凤荣¹, 马小强², 李鑫¹, 汤代杰¹, 杨晓¹

(1. 天津大学内燃机燃烧学国家重点实验室 天津, 300072) (2. 天津内燃机研究所 天津, 300072)

摘要 研究了利用发动机缸体振动信号进行爆震检测和强度评价的方法, 提出了一种基于广义正交匹配追踪的改进 K-均值奇异值分解(K-means singular value decomposition, 简称 K-SVD)信号处理方法, 将稀疏表达理论引入了发动机爆震特征识别领域。首先, 对缸体振动信号进行稀疏分解, 得到涵盖爆震特征的稀疏字典以及针对单个信号的稀疏系数; 然后, 计算重构信号的四阶累积量的自然对数, 提出了一种爆震强度评价指标。计算结果表明, 该方法对于混有强烈背景噪声的缸体振动信号表现出了良好的降噪和特征提取能力, 且提高了运算效率, 能够准确区分强烈爆震、轻微爆震和正常燃烧 3 种状态, 证明了该方法在发动机爆震识别领域的应用价值。

关键词 稀疏表达; 内燃机; 爆震特征; K-均值奇异值分解; 广义正交匹配追踪; 四阶累积量
中图分类号 TK411; TH17

引言

为有效提高发动机整体性能, 同时增加节能减排方面的优势, 小型强化技术成为发动机领域近年来的重要研究方向, 但随之提升的发动机爆震趋势却制约了小型强化技术的发展^[1]。强烈爆震会影响发动机的整体性能, 甚至对发动机造成破坏; 轻微爆震也可能使发动机缸内燃烧接近等容燃烧状态, 提高发动机效率。因此, 有效精确识别与预测发动机爆震及其强度并加以控制, 是发动机故障状态监测领域的一项重要任务。目前, 监测发动机爆震的主要方法有燃烧噪声监测、气缸压力监测、离子电流法与机体振动监测等, 其中, 利用机体的振动信号监测爆震的方法具有传感器结构简单、维修方便和成本低等特点, 在实际工程中得到广泛应用。

在利用振动信号对爆震进行检测时, 一般采集发动机缸体振动时域信号作为原始信号, 经过一系列的信号分解和特征提取过程识别发动机运行状态。国内外学者对振动信号的分析方法进行了大量研究, 比较成熟的方法包括快速傅里叶变换、小波变换及其衍生算法、经验模态分解^[2]等, 但都存在一定程度的问题, 如自适应能力差等, 无法准确有效地表征信号。近年来, 信号稀疏表达(sparse representation)理论的兴起和发展为信号处理领域引入了一种新的“过完备表示”的发展方向^[3]。Mallat 等^[4]于

1993 年最早提出了一种信号稀疏分解算法并得到了广泛应用。文献[5]提出了基于超完备字典稀疏分解的 K-均值奇异值分解算法, 具有自适应能力强、收敛速度快等优点。目前, 稀疏表达理论的相关信号处理方法绝大多数应用于机器视觉领域, 对于机械领域故障诊断的应用较少, 在发动机故障检测尤其是爆震故障监测领域的应用鲜有发表。

1 信号稀疏表达算法

信号的稀疏性定义为: 若信号仅有有限个非零采样点, 而其他采样点均为零(或接近于零), 则称信号是稀疏的。数学变换会追求稀疏表达, 即通过最小数量的系数尽可能更多地描述信号的数量。信号稀疏表达包括两大内容: 字典设计和模型求解(稀疏编码), 旨在利用设计好的超完备字典中尽可能少的原子来表示信号, 从而更容易地获取信号中蕴含的信息, 进而更有利地进行分类等下一步操作。

1.1 稀疏表达模型

给定原始信号 $y \in R^p$, 表示具有 p 个数据点的向量。根据稀疏表达理论, 该信号可以被表示为被选定字典中的某些原子的线性表达。假设过完备字典为 D , 那么信号 y 可以表示为

* 内燃机可靠性国家重点实验室开放课题资助项目(WCDL-GH-2021-0017)

收稿日期: 2019-07-01; 修回日期: 2019-08-18

$$y = Dx = \sum_{j=1}^n d^j x^j \quad (1)$$

其中: d^j 为字典 D 的列向量, 定义为字典中的原子; $x = \{x^j\}_{j=1}^n$ 为 y 在字典 D 下的表达系数。

稀疏表达问题的目的就是要在已知 x 为稀疏系数的情况下, 根据观测向量 y 以及线性模型来估计(复原) x 。由于 $m < n$, 该线性模型是欠定系统, 因此该问题存在多解。

为了解决多解问题, 需要对原问题添加约束以获得稀疏表达的优化模型。在信号处理中, 信号分解希望用尽量少的原子来达到最稀疏的解, 即系数 x 中的非零值系数最少。数学模型为

$$\min \|x\|_0, \text{ s.t. } y = Dx \quad (2)$$

如果再考虑噪声, 可以得到如下模型

$$\min \|x\|_0, \text{ s.t. } \|Dx - y\|_2^2 \leq \epsilon \quad (3)$$

其中: $\|\cdot\|_0$ 即 l_0 范数, 度量向量(或矩阵)中非零元素的个数, 即 x 的稀疏度。

但是, l_0 范数稀疏表达模型最小化求解存在两点困难: 一是 l_0 范数为非凸的^[6], 二是求解属于非确定性多项式(non-deterministic polynomial, 简称 NP)问题。求解的难度随维数升高呈指数增长, 导致在实际工作中几乎无法求得最优解^[7]。

文献[8-9]证明了 l_1 范数稀疏表达模型在一定条件与 l_0 范数下的解是一致的, 因此发展出了一系列松弛优化数学模型, 如式(4)所示

$$\begin{cases} \min \|x\|_1, \text{ s.t. } y = Dx \\ \min \|x\|_1, \text{ s.t. } \|y - Dx\|_2^2 \leq \epsilon \\ \hat{x} = \arg \min_{x \in \mathbb{R}^n} \|y - Dx\|_2^2 + \lambda \|x\|_1 \end{cases} \quad (4)$$

贪婪算法是求解以上模型最常用的方法, 其中最典型的是匹配追踪算法^[4](matching pursuit, 简称 MP)以及正交匹配追踪算法^[10](orthogonal matching pursuit, 简称 OMP)。其核心内容是通过迭代选取与当前样本最接近的原子, 投影之后计算残差, 直至残差满足一定的条件, 但贪婪算法存在局部最优解以及计算效率低等缺点。

1.2 K-SVD 算法

以上稀疏表达模型的所有讨论都是基于字典 D 是已知的假定下进行的, 显然字典并不是随意设定的, 字典设计是稀疏表达的重要内容之一。超完备字典的本质作用为信号变换, 即观测信号在字典所代表的超完备变换域中系数是稀疏的, 并使该系数

能够表示信号的主要特征, 或能够区分信号与噪声。现在大多数字典选择方法可以分为两类: 字典设计狭义或称为基于解析的方法与字典学习。字典设计是从已知的基函数中选择或采用预定义的字典, 字典学习是从训练样本集合中推断字典, 通过大量的信号数据进行训练与学习, 将数据集分为训练集和测试集, 训练集用于学习过程, 生成字典; 测试集用来测试字典性能, 一般情况下, 通过学习过程得到的非参数字典在信号表示方面要优于预先定义好的字典^[11]。K-SVD 算法就是一种优秀的字典学习方法。

K-SVD 算法^[5]可以看作是 K 均值聚类的一种泛化形式, 指该算法会进行 K 次迭代, 每次迭代都要使用奇异值分解。K-SVD 算法的目标求解模型为

$$\begin{aligned} \hat{D} &= \arg \min_D \|Y - DA\|_F^2 = \\ & \arg \min_D \left\| Y - \sum_{j=1}^p d_j x_j^T \right\|_F^2 = \\ & \arg \min_D \left\| \left(Y - \sum_{j \neq l} d_j x_j^T \right) - d_l x_l^T \right\|_F^2 \end{aligned} \quad (5)$$

表示对字典 D 进行初始化后, 每次仅对 d_l 列进行更新。首先, 计算残差部分, 即 $E_l = Y - \sum_{j \neq l} d_j x_j^T$, 且只选取 x_j^T 的非零部分进行计算, 得到需要的残差 E_l^R ; 其次, 对残差 E_l^R 进行奇异值分解 $E_l^R = U \Delta V^T$; 最后, 得到字典 D 和稀疏系数 x 的更新

$$\begin{cases} d_l = u_1 \\ (x_j^T)^R = \Delta(1, 1)v_1 \end{cases} \quad (6)$$

其中: u_1 和 v_1 分别为奇异值分解结果 U 和 V 的第 1 列。

2 改进 K-SVD 算法及其验证

2.1 基于广义正交匹配追踪的改进 K-SVD 算法

传统的 K-SVD 算法在进行稀疏编码时, 通常会使用 OMP 算法, 其核心思想是在贪婪算法的基础上, 在每次迭代选出的原子依次进行施密特正交化, 这意味着同一个原子不会被选择两次, 即可在有限次的迭代中实现收敛, 但这种算法每次迭代只选取一个原子更新, 计算效率较低。

广义正交匹配追踪^[12](generalized OMP, 简称 gOMP)是 OMP 算法的一种泛化扩展, 在每次迭代过程中选择多个原子更新, 在信号重构的过程中保证了计算精度, 降低了算法的复杂度, 加快了算法的

执行时间。该算法的流程如下。

输入: 传感矩阵 $A = \Phi\Psi$; 观测向量 y ; 稀疏度 K ; 单词迭代原子数 S (默认取值 $K/4$)。

输出: 稀疏表达系数 $\hat{\theta}$; 残差 $r_K = y - A_K\hat{\theta}_K$ 。

计算步骤:

1) 初始化 $r_0 = y, \Lambda_0 = \emptyset, A_0 = \emptyset, t = 1$;

2) 计算 $u = \text{abs}[A^T r_{t-1}]$, 选择 u 中最大的 S 个值, 将其在矩阵 A 中对应的列序号 j 构成索引集合 J_0 ;

3) 令 $\Lambda_t = \Lambda_{t-1} \cup J_0, A_t = A_{t-1} \cup a_j$ (对于 $j \in J_0$);

4) 求 $y = A_t \theta_t$ 的最小二乘解: $\hat{\theta}_t = \arg \min_{\theta} \|y - A_t \theta_t\| = (A_t^T A_t)^{-1} A_t^T y$;

5) 更新残差 $r_t = y - A_t \hat{\theta}_t = y - A_t (A_t^T A_t)^{-1} A_t^T y$;

6) $t = t + 1$, 如果 $t \leq K$ 则返回步骤 2, 否则停止迭代;

7) 重构所得 $\hat{\theta}$ 在 Λ_t 处有非零项, 其值分别为最后一次迭代所得的 $\hat{\theta}_t$;

8) 利用稀疏矩阵重构信号 $\hat{x} = \Psi \hat{\theta}$ 。

根据上文对基于 gOMP 的改进 K-SVD 原理的描述, 其特征提取的过程大致可分为以下过程: ① 字典学习得到字典 D , 字典学习可以认为是模型训练的过程, 截取原始数据 Y 构成训练样本集, 利用样本通过改进 K-SVD 方法训练得出能够有效反映原始信号特征的稀疏字典 D ; ② 利用 D 对原始信号进行 gOMP 稀疏编码, 重构故障信号。

2.2 模拟信号的方法验证

为验证改进 K-SVD 算法对振动信号特征提取能力与降噪性能, 对一段模拟信号进行了 K-SVD 处理, 以验证其降噪能力。如图 1 所示, 模拟信号由一段高频正弦波、一段低频正弦波、一组冲击信号和一组高斯白噪声组成 (模拟信号的振幅无意义, 因此单位无量纲), 信噪比为 8.1。

首先, 对该模拟信号进行了 K-SVD 分解, 得到了训练好的稀疏字典与稀疏系数。搜索字典的所有原子波形, 尽管稀疏表达的原子是冗余的, 即很多波形可能是无意义的, 但仍能找到大量的类似于冲击信号的原子波形, 以及正弦形式的原子波形, 如图 2 所示。这表明该学习字典是可以有效反映信号的组成的。

其次, 利用得到的稀疏系数对模拟信号以 4 稀

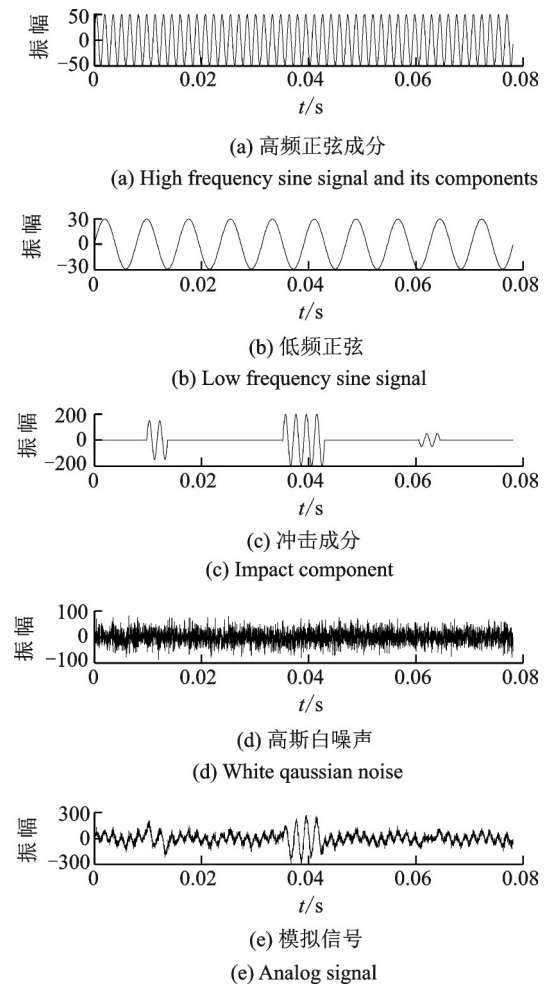


图 1 模拟信号及其组成

Fig.1 The simulated signal and its components

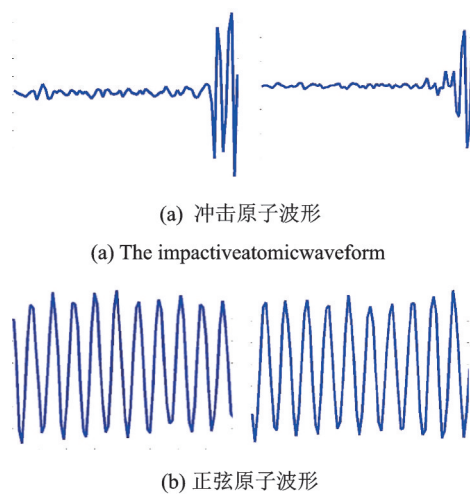


图 2 字典中的部分原子波形

Fig.2 The waveform of part of the atoms in the dictionary

疏度为例进行了重构, 对原始模拟信号与重构模拟信号进行了 FFT 处理, 得到了 2 组频域图像, 如图 3 所示。经过 K-SVD 处理后的信号, 冲击特征的幅值

得到了完全保留,而噪声部分得到了大幅削弱,幅值从 2 降到了 0.8 以下,降噪之后 14.9 的高信噪比也说明了改进 K-SVD 方法对含冲击特征信号良好的处理能力。对同一模拟信号采用传统的离散小波变换 (discrete wavelet transformation, 简称 DWT) 方法去噪作对比,得到重构信号的信噪比为 13.853 0,同样证实了改进 K-SVD 算法优秀的降噪能力。




图 3 K-SVD 处理前后模拟信号的频域特征
Fig.3 Frequency domain characteristics of analog signals with and without K-SVD processing

2.3 实际信号的方法验证

如图 4 所示,选取了某型号四缸汽油机的缸体振动信号作为原始信号,并参照对应的缸压信号判定 1,4 号缸发生了不同程度的爆震。以稀疏度 4,迭代次数 80 为例,对该原始信号进行了 K-SVD 稀疏表达。每次迭代的残差 E_i 随迭代次数的变化趋势如图 5 所示。由图中可知,残差最终收敛于 2.3 左右,相较于初始残差值 3.6,重构信号的降噪效果应较明显。

将重构信号与原始信号进行快速傅里叶变换,对比两者的时域曲线和频域曲线,如图 6 所示。从波形中可以发现,重构信号的曲线更为平滑,尤其是峰值附近的振荡程度降低;信号成分中无关的背景噪声成分幅值降低,7.5 kHz 等主要成分频率更为凸




图 4 爆震工况缸体振动信号

Fig.4 Cylinder vibration signal under knock condition






图 5 残差随迭代次数的变化曲线



Fig.5 The change curve of the residual with the number of iterations

显。对信号处理前后的主要参数进行对比如表1所示。以稀疏度3和4对原始信号进行处理均获得了不错的效果,其中,对冲击信号敏感的峭度、脉冲指标和波形指标均有提升,表明信号的冲击特征得到强化。以上均表明K-SVD方法对发动机爆震信号具有良好的特征提取能力。



(a) 原始信号的时域、频域特征

(a) Time-domain and frequency-domain characteristics of the original signal



(b) 重构信号的时域、频域特征

(b) Time-domain and frequency-domain characteristics of the reconstructed signal

图6 信号的快速傅里叶变换结果

Fig.6 The FFT result of the signal

3 基于K-SVD与高阶累积量的爆震特征识别

基于K-SVD良好的爆震特征提取能力,现提出一种基于K-SVD与高阶累积量的爆震强度的评价标准,以此通过发动机的缸体振动信号,区分正常工况、轻微爆震工况或强烈爆震工况。

表1 原始信号与重构信号参数对比

Tab.1 Parameter comparison of original signal and reconstructed signal

项目	原始信号	重构信号稀疏度		
		3	4	8
峭度	71.353 8	72.988 4	72.262 1	70.502 4
波形指标	2.834 1	3.141 5	3.096 8	2.988 2
峰值指标	15.512 5	15.382 6	15.362 9	15.252 8
脉冲指标	43.964 4	48.323 8	47.575 3	45.577 9
裕度指标	5.124 0	6.632 9	6.413 7	5.871 6
4阶累积量 $\times 10^6$	2.87	3.13	3.14	3.15

3.1 基于缸压信号的爆震特征识别

传统的发动机爆震监测是依靠缸压传感器实现的,典型的爆震强度评价指标为压力振荡最大幅值^[13](maximum amplitude of pressure oscillation,简称MAPO)为

$$MAPO = \max(|\hat{p}|_{\theta_0}^{\theta_0 + \zeta}) \quad (7)$$

该方法主要利用巴特沃斯滤波器对含有爆震燃烧过程的压力信号进行带通滤波,将滤波后震荡压力的最大幅值作为爆震强度的判定指标。基于此指标,对实验发动机的发动工况定义为

强烈爆震: $MAPO \geq 0.70$;

轻微爆震: $0.7 > MAPO > 0.25$;

正常工况: $MAPO \leq 0.25$ 。

文中选取了150个工况点其中正常燃烧工况、轻微爆震工况、强烈爆震工况各50个,其MAPO值如图7所示。

就以上数据来看,利用缸压信号的MAPO方法可以对爆震强度进行有效区分,也是最直观的判定方法。但在实际工程应用中,缸压传感器造价昂贵且安装困难,一定程度上会影响发动机缸内环境,尤




图7 选取工况的MAPO值

Fig.7 MAPO values of the selected conditions

其是小型高速汽油机安装空间更狭窄,也不便于车载状态下试验检测,因此工程应用成本较高。

3.2 基于K-SVD与高阶累积量的爆震特征识别

对上述150个工况对应的振动信号,进行基于K-SVD方法的稀疏表达并对稀疏系数进行重构,之后对重构信号进行4阶累积量计算^[13],这种方法可以从统计角度对振动信号进行分析,确定相应的爆震强度指标。

150个工况的识别结果如图8所示。




图8 3种工况振动信号的4阶累积量

Fig.8 Fourth-order cumulants of vibration signals in three conditions

分析该结果,可以看出4阶累积量对不同工况具有明显的区分作用,且对比MAPO值的区分情况有放大效果。由于强烈爆震工况的数量值远大于其他两个工况,掩盖了轻微爆震与正常燃烧工况的区分情况,因此将上述4阶累积量值取自然对数以便观察,如图9所示。




图9 3种工况振动信号的4阶累积量自然对数

Fig.9 The natural logarithm of the fourth-order cumulant of the vibration signal in three conditions

分析图9中3种工况的区分情况,可以十分明显地将强烈爆震与其他工况区分开来,而对于轻微爆震工况也有一定的区分能力。实际工程应用中,轻微爆震对发动机正常运转的影响很小或几乎没有影

响,甚至会有促进发动机燃烧的有利影响,但对轻微爆震工况的有效区分有利于对爆震趋势作出准确预测,进而精确控制发动机的运行状态,提高平均热效率。因此,文中所提出的爆震强度评价标准是具有工程应用价值的。

图10为前10号工况原始振动信号的四阶累积量的自然对数。可以发现,当信号未经处理时,正常工况下的4号,5号,8号,9号数据点并不能与轻微爆震有效区分开,轻微爆震下的3号,9号数据点也不能有效区分,经分析是由于轻微爆震下背景噪声对冲击信号的掩蔽效应,而正常工况也会因为背景噪声的的干扰不易区分。另外,对比图7与图9可以发现,尽管振动信号K-SVD处理得出的结论与缸压信号MAPO方法的结论是一致的,但在个别工况的变化趋势并不是完全相同的,这主要是因为发动机缸体的振动信号是由发动机多个部件的振动传递耦合得到的,但从振动信号频域图中可以看出发动机气缸内燃烧造成的振动应占主要成分,且强烈爆震工况下爆震特征成分更为明显。




图10 原始振动信号的4阶累积量自然对数

Fig.10 The natural logarithm of the fourth-order cumulant of the original vibration signal

因此,对于论文所采用的实验机型,可以定义爆震指标(knock index,简称KI)为

强烈爆震: $KI \geq 14.5$;

轻微爆震: $14.5 > KI > 12.5$;

正常爆震: $KI \leq 12.5$ 。

对于不同机型的发动机,需要重新标定KI值范围,即K-SVD重构信号4阶累积量的自然对数,即可达到识别爆震强度的目标。

4 结束语

提出了一种基于广义正交匹配追踪的改进K-SVD稀疏表达方法,应用于发动机缸体振动信号的爆震分析。分析结果表明,该方法可以对振动信号

的不同特征进行冗余表示,可以实现凸显冲击特征、降低背景噪声的目的,且具有自适应性强的优越性,并一定程度上克服了传统K-SVD方法效率差的缺点。利用改进K-SVD信号处理后的稀疏字典和稀疏系数,对信号进行重构,并计算其爆震窗口内4阶累积量的自然对数作为爆震指标KI,可以有效区分强烈爆震、轻微爆震和正常燃烧3种状态。无论是基于振动信号的发动机爆震监测领域,还是其他机械故障的振动信号诊断领域,稀疏表达理论都是一种新颖的研究方法。虽然现阶段的研究结果表明这种方法具有较强的潜力,近年来稀疏表达的各种算法也不断被提出和优化,但这种算法仍不成熟,其在工程领域的应用与创新将是今后的工作方向。

参 考 文 献

- [1] NILSSON Y, FRISK E, NIELSEN L. Weak knock characterization and detection for knock control [J]. Proceedings of the Mechanical Engineers, 2009, 223 (1): 107-129.
- [2] 毕凤荣, 李鑫, 马腾. 基于变模式分解的爆震特征识别方法[J]. 振动、测试与诊断, 2018, 38(5):27-31. BI Fengrong, LI Xin, MA Teng. Knock detection using the variational mode decomposition [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(5): 27-31. (in Chinese)
- [3] 王聪. 基于稀疏表达的机械信号处理方法及其在滚动轴承故障诊断中的应用研究[D]. 合肥:中国科学技术大学,2017.
- [4] MALLAT S G, ZHANG Z. Matching pursuits with time-frequency dictionaries [J]. IEEE Transactions on Signal Processing, 1993, 41(12):3397-3415.
- [5] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54:4311-4322.
- [6] DONOHO D L, ELAD M. Optimally sparse representation in general (nonorthogonal) dictionaries via L1 minimization [J]. Proceedings of the National Academy of Sciences, 2003, 100(5):2197-2202.
- [7] DONOHO D L. For most large underdetermined systems of linear equations the minimal L1-norm solution is also the sparsest solution [J]. Communications on Pure and Applied Mathematics, 2006, 59(7):907-934.
- [8] CANDÈS E, TAO T. Decoding by linear programming [J]. IEEE Transactions on Information Theory, 2005, 51(12):4203-4215.
- [9] CANDÈS E J, TAO T. Near-optimal signal recovery from random projections: universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52(12):5406-5425.
- [10] REZAIIFAR Y, KRISHNAPRASAD P S. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition [C] // Proceedings of 27th Asilomar Conference on Signals, Systems and Computers. Pacific Grove: IEEE, 1993:40-44.
- [11] JIAN Z F, SONG L, XIAO K Y, et al. Sub clustering K-SVD: size variable dictionary learning for sparse representations [C] // IEEE International Conference on Image Processing. Cairo: IEEE, 2009:2149-2152.
- [12] WANG J, KWON S, SHIM B. Generalized orthogonal matching Pursuit [J]. IEEE Transactions on Signal Processing, 2012, 60(12):6202-6216.
- [13] 李鑫. 基于变分模式分解与高阶累积量的爆震信号特征识别[D]. 天津:天津大学,2018.



第一作者简介:沈鹏飞,男,1995年9月生,硕士生。主要研究方向为动力机械NVH及故障诊断。

E-mail: shenpengfei@tju.edu.cn