第 31 卷 第 2 期 石家庄铁道大学学报(自然科学版) Vol. 31 No. 2
2018 年 6 月 Journal of Shijiazhuang Tiedao University(Natural Science Edition) Jun. 2018

基于字典学习形态分量分析的轴承故障诊断

吴 洋， 郝如江， 李 非

(石家庄铁道大学 机械工程学院,河北 石家庄 050043)

摘要:在基于固定字典的形态分量分析(Morphological Component Analysis, MCA)方法基础上,提出了字典学习形态分量分析的滚动轴承故障诊断方法。分别以轴承内圈、外圈故障信号为训练样本,应用 K-SVD(K-Singular Value Decomposition)字典学习算法对训练样本学习字典,寻求最优的字典空间;将学习到的字典取代 MCA 中的固定字典,根据信号所包含各成分的形态差异性,利用 MCA 对滚动轴承故障信号中的内、外圈故障特征和噪声成分进行分离;对包络后的故障特征分量做频谱分析诊断轴承的故障及部位。应用实例结果表明:该方法能在强噪声环境下有效地提取滚动轴承内、外圈的故障特征,性能优于固定字典的 MCA 方法,为 MCA 方法在选取字典时提供了新思路。

关键词:形态分量分析;字典学习;轴承;故障诊断

中图分类号:TH133.33 **文献标志码**: A **文章编号**: 2095-0373(2018)02-0040-06

0 引言

在负载和工况变化时,滚动轴承的振动信号通常为非平稳信号,故障产生的冲击会引起不同程度和形态的振动信号调制、耦合现象,因此,如何有效地提取轴承故障特征是轴承故障诊断技术研究的重要内容。杨红娜将随机共振与共振解调相结合来提取故障特征[1],但仅适用相对线性的系统。2004 年,Starck et al[2]提出了形态分量分析方法,其基本思想是利用信号组成成分的形态差异性,不同形态的信号可以用不同的字典稀疏表示,结果把源信号分解成若干个形态各异的稀疏信号,且被分解出的各分量具有实际的物理意义。有学者用基于固定字典的 MCA 方法从轴承和齿轮箱的复合故障振动信号中提取出各故障特征[3-5],取得了比较好的效果,但每个固定字典具有确定的数学模型,如 Dirac 字典、Fourier 字典、小波字典等,不能最佳匹配被分析复杂信号的结构特征,所以在强噪声下难以提取到故障特征。最近研究成果表明,通过学习获得的字典比固定字典在图像去噪、图像修复、图像超分辨率等方面有更出色的性能[6-7],Liu et al[8-10]提出一种移不变的稀疏编码进行字典学习并应用于轴承故障诊断。因此,如果根据故障信号本身学习出振动信号中包含故障特征的波形函数作为字典,无疑会促进形态分量分析方法对故障特征的提取。

根据以上分析,将 MCA 方法与 K-SVD 字典学习算法相结合,提出了基于字典学习形态分量分析的轴承故障诊断方法。采用 K-SVD 算法对轴承内圈、外圈故障信号的训练样本进行学习,获得能够对故障信号进行稀疏表示的字典;将学习到的字典替换表征冲击成分的 Symlet 小波字典,使用 MCA 对复杂信号提取故障特征分量;对包络后的故障特征分量做频谱分析,诊断轴承的故障及部位。研究结果表明:在采提取故障特征时,K-SVD 学习到的字典优于构造的固定字典。

1 MCA 介绍

MCA 方法的原理为:假设输入信号 $s(s\in R)$是由 K 个具有不同形态的信号分量 s_k 线性组合而成,即 $s=\sum_{k=1}^{K}s_k$,每个 s_k 都存在与其对应的稀疏表示字典 Φ_k,即 $s_k=\Phi_k\alpha_k$,其中 α_k 为变换系数。假设 Φ_k 能且仅

收稿日期:2017-01-12 责任编辑:车轩玉 DOI:10.13319/j.cnki.sjztddxxbzrb.2018.02.08
基金项目:国家自然科学基金(51375319);河北省杰出青年科学基金(E2013210113);河北省百名优秀创新人才支持计划(BR2-222)
作者简介: 吴洋(1990—),男,硕士研究生,研究方向为机械设备状态检测与故障诊断。E-mail:wuyang1099@163.com
吴洋,郝如江,李非.基于字典学习形态分量分析的轴承故障诊断[J].石家庄铁道大学学报:自然科学版,2018,31(2):40-45.

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

能稀疏表示 s_k,而对于其它的 $s_{k'}(k\neq k')$则不能有效稀疏表示,根据 BP 算法理论,信号 S 的稀疏性可用 1 范数来定义,即

$$\{\alpha_1,\cdots,\alpha_k{}^{opt}\}=\arg\min_{\{\alpha_1,\cdots,\alpha_k\}}\sum_{k=1}^{K}\|\alpha_k\|_1 \tag{1}$$

而 $s=\sum_{k=1}^{K}\Phi_k\alpha_k$,放宽式(1)的约束条件,可将式(1)转换为

$$\{\alpha_1,\cdots,\alpha_k{}^{opt}\}=\arg\min_{\{\alpha_1,\cdots,\alpha_k\}}\sum_{k=1}^{K}\|\alpha_k\|_1+\lambda\|s-\sum_{k=1}^{K}\Phi_k\alpha_k\|_2^2 \tag{2}$$

式中,λ 为给定的阈值,考虑到计算效率问题,选用硬阈值[1]。根据 $s_k=\boldsymbol{\Phi}_k^*\alpha_k$,给定 s_k 可得到

$$\alpha_k=\boldsymbol{\Phi}_k^*s_k \tag{3}$$

式中,$\boldsymbol{\Phi}_k^*=\boldsymbol{\Phi}_k^{\mathrm{T}}(\boldsymbol{\Phi}_K\boldsymbol{\Phi}_K^{\mathrm{T}})^{-1}$,$\boldsymbol{\Phi}_k^*$ 为 $\boldsymbol{\Phi}_k$ 的伪逆矩阵。将式(3)代入式(2),则式(1)中变换系数 $\{\alpha_1,\cdots,\alpha_k\}$ 的优化求解问题转变为式(4)中分量 $\{s_1,\cdots,s_k\}$ 的优化求解问题

$$\{s_1,\cdots,s_k{}^{opt}\}=\arg\min_{\{s_1,\cdots,s_k\}}\sum_{k=1}^{K}\|\boldsymbol{\Phi}_k^*s_k\|_1+\lambda_k\|s-\sum_{k=1}^{K}s_k\|_2^2 \tag{4}$$

通过以上过程将原始信号分解成表示不同特征的信号分量。

2　K-SVD 原理

K-SVD 字典学习算法本质是范数稀疏约束追踪和奇异值分解算法交替应用,使字典和稀疏系数同步更新。假设矩阵 $\boldsymbol{D}\in\boldsymbol{R}^{n\times k}$ 表示训练得到的超完备字典,向量 $\boldsymbol{y}\in\boldsymbol{R}^n$,$\boldsymbol{x}\in\boldsymbol{R}^n$ 分别表示训练样本及其对应的稀疏表示系数向量,矩阵 $Y=\{y_i\}_{i=1}^N$ 为 N 个训练样本的集合,矩阵 $\boldsymbol{X}=\{x_1\}_{i=1}^N$ 为 N 个系数向量的集合,则字典学习过程可优化问题表示为

$$\min_{D,X}\{\|\boldsymbol{Y}-\boldsymbol{DX}\|_F^2\}=\min\sum_{i=1}^{N}\{\|y_i-Dx_i\|_2^2\}\qquad \text{s.t}\qquad \forall i,\|x_i\|_0\leq T_0 \tag{5}$$

式中,T_0 为稀疏表示系数中非零元素个数的最大值。K-SVD 字典学习技术的具体实施步骤为[7]

(1)字典初始化。初始字典使用部分原数据,设置字典矩阵 $\boldsymbol{D}^{(0)}\in\boldsymbol{R}^{n\times K}$,并用 ρ^2 范数对字典的每一列单位标准化。

(2)稀疏编码。根据初始字典 $\boldsymbol{D}$,采用任意一种追踪算法(选用正交匹配追踪(OMP)),求解每个样本 y_i 的稀疏系数向量 $\boldsymbol{x}_i$,即

$$\min\{\|y_i-\boldsymbol{D}x_i\|_2^2\}\ \text{s.t}\qquad \|\boldsymbol{x_i}\|_0\leq T_0\quad i=1,2,\cdots,N \tag{6}$$

(3)字典更新。固定向量 $\boldsymbol{x}_i$ 更新字典 $\boldsymbol{D}$ 的每一列,设向量 $\boldsymbol{d}_k$ 为要更新的字典 $\boldsymbol{D}$ 的第 k 列原子;$\boldsymbol{X}$ 的第 k 行表示为 x_T^k,即 $\boldsymbol{d}_k$ 对应的稀疏系数矩阵 $\boldsymbol{X}$ 中的第 k 行向量,$\boldsymbol{E}_k$ 代表抽取原子 $\boldsymbol{d}_k$ 后的误差矩阵。此时式(6)可表示为

$$\|\boldsymbol{Y}-\boldsymbol{DX}\|_F^2=\|(\boldsymbol{Y}-\sum_{j\neq k}d_jx_T^j)-\boldsymbol{d}_k\boldsymbol{x}_T^j\|_F^2=\|E_i-d_kx_T^j\|_F^2 \tag{7}$$

通过式(7)来优化字典空间,完成字典的学习过程。

3　字典学习形态分量分析的轴承故障诊断

基于字典学习形态分量分析的轴承故障诊断方法步骤如下:(1)分别以含有单个故障特征的信号为训练样本,利用 K-SVD 算法对训练样本进行学习,得到每个故障特征的字典;(2)使用学习到的字典替换固定字典,将复合故障的信号作为测试样本进行 MCA 分解,得到包含轴承外圈、内圈故障特征的冲击分量;(3)对各个冲击分量做 Hilbert 变换得到各自的包络谱;(4)根据各自故障特征频率结合包络谱诊断轴承故障。

4　算法仿真及对比

设置如下含有两种成分的信号进行仿真分析(采样频率为 4 096 Hz,采样点数 N 为 2 048)

$$s(t)=h(t)+y(t)+n(t) \tag{8}$$

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

$$h(t)=A\cdot\cos(2\pi f_i t) \tag{9}$$

$$y(t)=B\cdot\sum_{i=1}^{K}\exp(-2\pi f_n t)\cdot\cos(2\pi f_n\sqrt{1-g^2}t) \tag{10}$$

式中,$h(t)$为余弦信号;幅值 A 是 0.5;特征频率 f_i 为 70 Hz;$y(t)$为冲击信号;幅值 B 取 0.5;阻尼系数 g 取 0.1;固有频率 f_n 为 270 Hz;重复次数 K 取 15,合成后冲击信号的特征频率为 30 Hz。两种成分的信号如图 1 所示,加入噪声信号 $n(t)$并调整其信噪比为 6 dB,复合信号如图 2(a)所示,可见复合信号中的冲击特征被噪声淹没。使用固定的字典,构建离散余弦字典来稀疏表示信号中的简谐成分,构建 8 阶消失矩 Symlet 小波字典来稀疏表示信号中的冲击成分。对复合信号 $s(t)$进行形态分量分析,结果如图 2 所示,其中图 2(c)为分离出的冲击成分(Part_1),对比图 1(a)可知冲击成分未被完全分离出,对 Part_1 进行 Hilbert 包络解调做谱分析,如图 3(a)所示,在其频谱图中未找到特征频率;图 2(d)为分离出的简谐成分(Part_2),与图 1(b)对比可知两种信号的形态接近,对 Part_2 直接进行傅里叶变换如图 3(b),在 70 Hz 处出现一个峰值,与简谐信号的特征频率一致;图 2(b)为 Part_1 与 Part_2 的叠加,其形态与复合信号相似。经以上仿真试验可知,基于固定字典的形态分量分析在强噪声情况下不能有效分离出复合信号中的冲击成分。

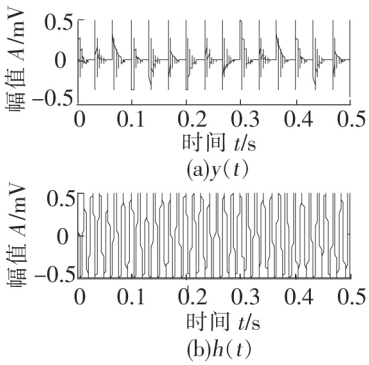

图 1 冲击与简谐的仿真信号

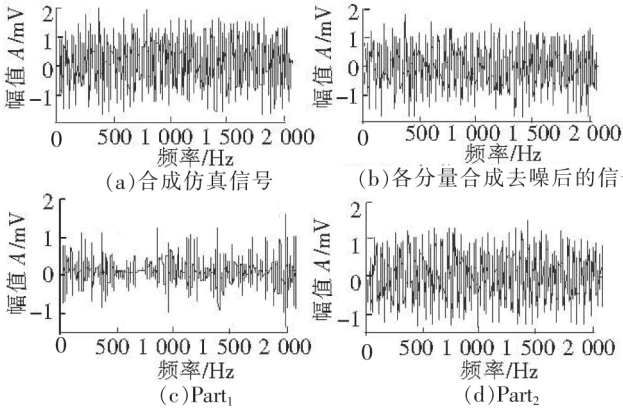

图 2 形态分量分析方法分解信号结果

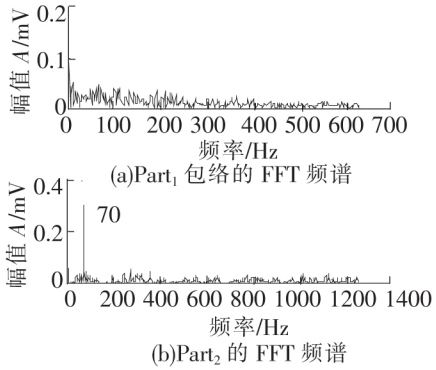

图 3 各分量的频谱图

使用本文提出的方法,以冲击信号、余弦信号作为训练样本,使用 K-SVD 算法对训练样本进行学习,将学习到的字典替换 Symlet 小波字典和离散余弦字典,应用 MCA 方法分解复合信号,结果见图 4。在图 4(c)中能够找出冲击成分,对其做 Hilbert 包络谱分析,如图 5(a)所示频谱图发现冲击成分的特征频率 30 Hz 及其倍频成分;图 4(d)为分解出的简谐成分,虽然出现了调幅现象,但从形态上更接近图 1(b)。以上分析说明 K-SVD 方法学习到的字典比固定字典更能稀疏表示源信号。

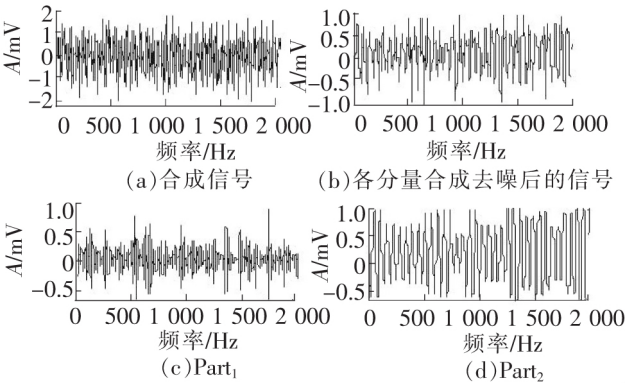

图 4 改进算法后分解到的各个分量

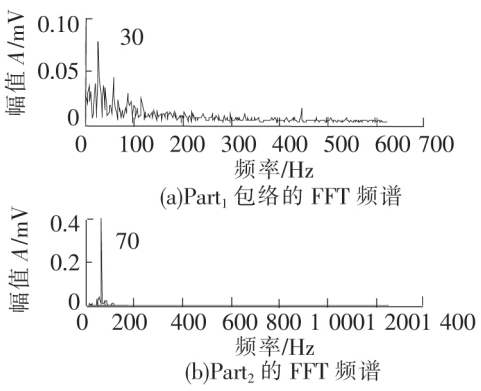

图 5 改进算法后各个分量的频谱图

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

5　应用实例

实验轴承型号为 SKF6205 在轴承外圈、内圈上使用电火花机床分别加工了直径为 0.18 mm、深 0.28 mm 的凹槽,故障特征频率见表 1。

表 1　SKF6205 轴承在不同负载下故障数据

电机负载/HP	电机转速/(r·min^{-1})	轴承外圈故障数据	轴承内圈故障数据	外圈特征频率/Hz	内圈特征频率/Hz
1	1 772	a	d	105.86	159.91
2	1 750	b	e	104.57	157.96
3	1 730	c	e	103.39	156.17

复合故障信号如图 6(a)所示,使用固定的字典,构建 8 阶消失矩 Symlet 小波字典来稀疏表示信号中的冲击成分。对复合故障信号进行 MCA 分解,结果如图 6 所示,图 6(b)为去噪后的信号,图 6(c)为分离出的外圈分量,图 7(d)为内圈分量,可知外圈的冲击成分丢失,内圈分量的包络谱中同时包含了内圈与外圈的特征故障频率成分,不能分离出内、外圈的故障特征。

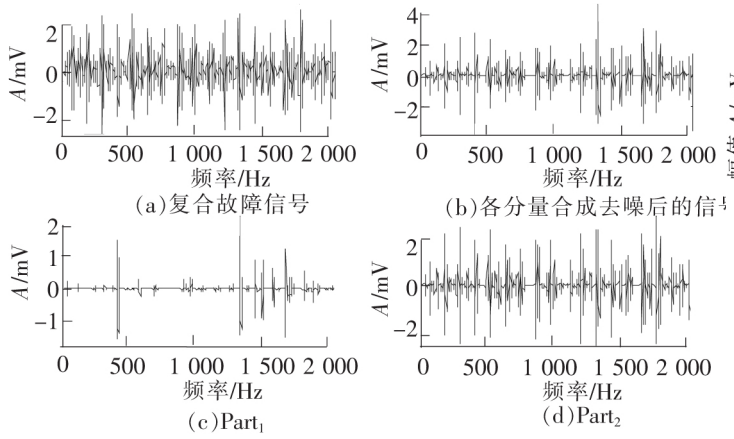

图 6　固定字典 MCA 分解到的各个分量

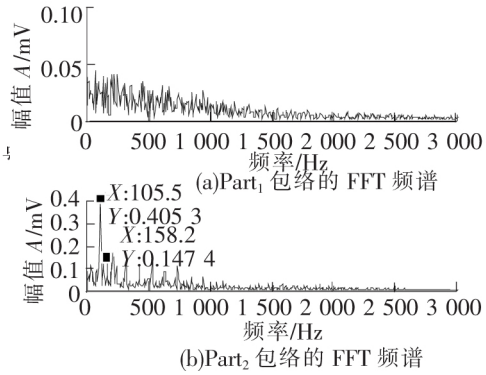

图 7　固定字典 MCA 分解到的各个分量包络谱

分别以外圈故障数据 b、内圈故障数据 e 为样本信号,使用 K-SVD 算法学习字典,将学习到的字典替换固定字典,分解信号结果如图 8(c)、图 8(d)所示。图 8(c)为外圈分量,其包络谱见图 9(a),出现 105.6 Hz 及其倍频成分,与表 1 中的外圈理论故障特征频率 105.86 Hz 一致,图 8(d)为内圈分量,其包络谱见图 9(b),158.2 Hz 处有峰值,与表 1 中的内圈理论故障特征频率 157.96 Hz 一致。

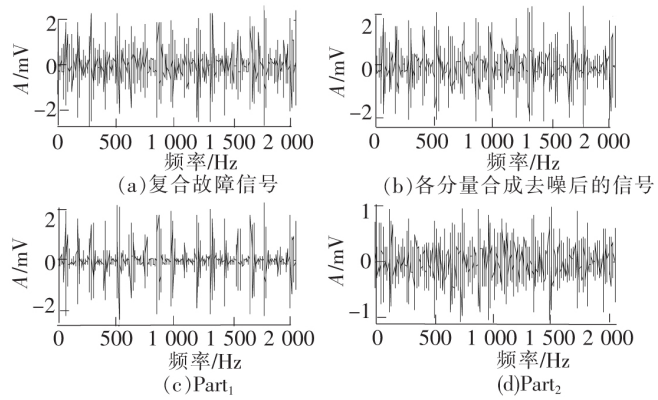

图 8　学习字典的 MCA 分解到的各个分量

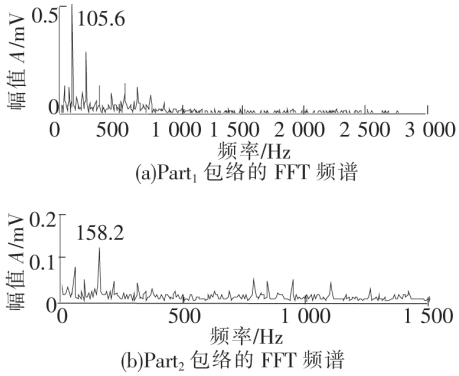

图 9　学习字典的 MCA 分解到的各个分量频谱

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

将以上的复合故障信号加入噪声,调整其信噪比为 0 dB,加噪声后的信号见图 10(a),再次使用字典学习的形态分量分析方法,结果如图 10(c)、10(d)和图 11 所示,可知,信噪比为 0 dB 时,仍可成功提取出外圈、内圈的故障特征波形。但图 9(a)的峰值及其倍频成分显然比图 11(a)清晰,调整原始信号的信噪比为−3 dB 时,则在频谱图中难以找到故障特征频率及其倍频成分(限于篇幅不再列出−3 dB 时的频谱图)。可知原始信号的信噪比大小影响诊断的结果,信噪比较大的样本能训练出更加匹配信号的字典,从而实现故障诊断。

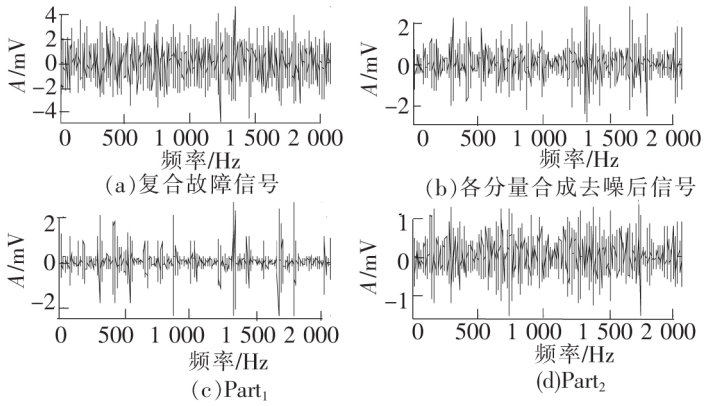

图 10 强噪声下分解到的各个分量

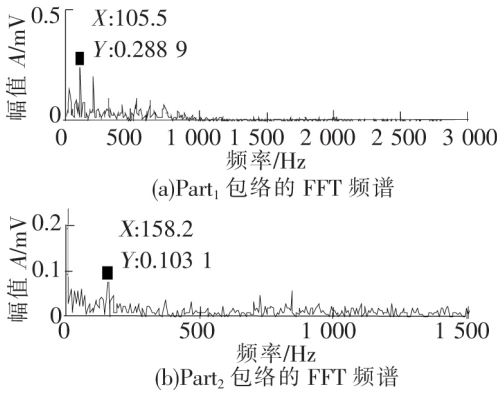

图 11 强噪声下分解到的各个分量频谱

再使用 2 HP 负载工况下学习到的字典,以 1 HP 负载下复合故障信号为测试样本,使用本文提出方法分解信号。图 12 中(c)、(d)分别为外圈、内圈分量,在各自的频谱图(图 13(a)、图 13(b))中同时找到外圈与内圈的故障特征频率,但出现频率混叠现象。

在使用 K-SVD 训练字典时,选取的样本信号故障特征明显。

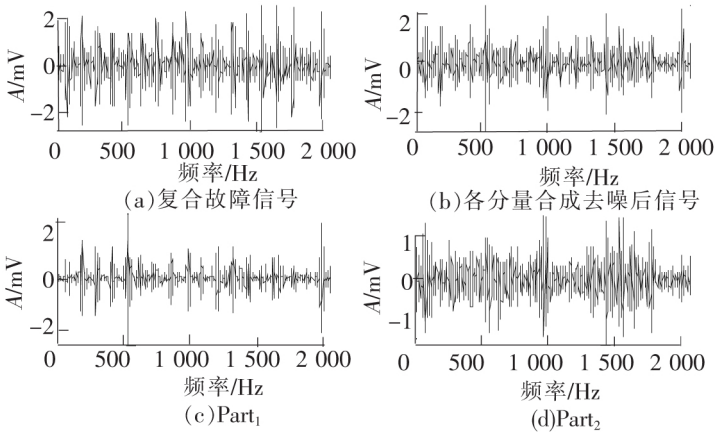

图 12 1 HP 负载下分解到的各个分量

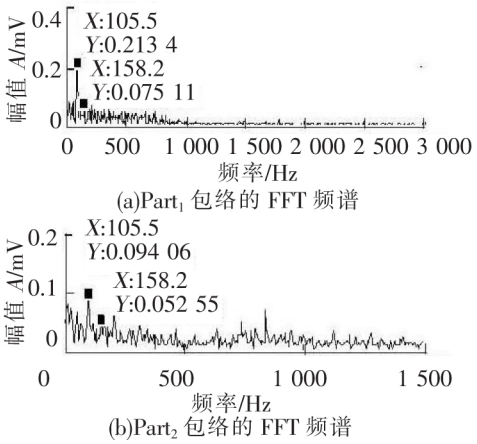

图 13 1 HP 负载下分解到的各个分量频谱

6 结论

在基于固定字典的形态分量分析方法基础上,提出了字典学习形态分量分析的滚动轴承复合故障诊断方法,用于从滚动轴承复合故障信号中提取出包含轴承外圈、内圈的冲击成分,主要研究结论如下:

(1)算法仿真表明,在强噪声情况下,通过学习得到的字典比固定字典更能匹配复杂信号的结构特征;应用实例表明,利用字典学习的形态分量分析方法对滚动轴承故障振动信号进行分析,能有效地提取滚动轴承复合故障信号中的冲击成分。

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

(2)在强噪声或某种负载下,学习到的字典能够提取出该种工况下轴承外圈、内圈故障波形;在不同工况下的故障特征提取时,虽然在各自的频谱图中能够找到外圈与内圈的故障特征频率,但出现了频率混叠现象,需进一步研究解决。

参 考 文 献

[1]杨红娜, 郝如江. 基于随机共振的齿轮箱早期故障诊断研究[J]. 石家庄铁道大学学报:自然科学版, 2016, 29(2): 61-66.

[2]Starck J L, Moudden Y, Bobin J, et al. Morphological component analysis[J]. Journal of the Brazilian Computer Society, 2004, 10(3):31-41.

[3]杨杰, 郑海起, 关贞珍,等. 基于形态成分分析的轴承复合故障诊断[J]. 轴承, 2011(8):38-42.

[4]陈向民, 于德介, 李蓉. 齿轮箱复合故障振动信号的形态分量分析[J]. 机械工程学报, 2014, 50(3):108-115.

[5]李辉, 郑海起, 唐力伟. 形态分量分析在齿轮箱复合故障诊断中的应用[J]. 振动、测试与诊断, 2013, 33(4):620-626.

[6]Michael E, Michal A. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on Image Processing, 2007, 15(12):3736-3745.

[7]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.

[8]朱会杰, 王新晴, 芮挺,等. 基于稀疏编码的振动信号特征提取算法与实验研究[J]. 振动与冲击, 2015, 33(21):59-64.

[9]Grosse R, Raina R, Kwong H, et al. Shift-invariance sparse coding for audio classification[J]. Computer Science Learning, 2012(9):149-158.

[10]Liu H, Liu C, Huang Y. Adaptive feature extraction using sparse coding for machinery fault diagnosis[J]. Mechanical Systems & Signal Processing, 2011, 25(2):558-574.

Fault Diagnose of Bearing Based on Morphological Component Analysis of Dictionary Learning

Wu Yang,　Hao Rujiang,　Li Fei

(School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

Abstract: Based on the fixed dictionary of morphological component analysis (MCA), a new method for fault diagnosis of rolling bearings with learning dictionary of MCA was proposed. Taking the faults data of inner ring and outer ring as training samples, this article sought the optimal dictionary space through K-singular value decomposition (K-SVD). The fixed dictionary in MCA was replaced by the learning dictionary. The inner and outer fault characteristics and noise components in the rolling bearing fault signal were separated by MCA according to the morphological differences of components contained in the signal. Spectrum analysis of faults characteristic component after envelopment was accomplished to diagnose the faults and location of bearing. Application example results show that the proposed method is effective in extracting fault characteristics from the strong noise vibration signal, and is better than MCA based on fixed dictionary, which provides a new idea for choosing dictionary in MCA.

Key words: morphological component analysis; dictionary learning; bearing; fault diagnose

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net