

基于流形学习的滚动轴承故障盲源分离方法^{*}

王奉涛¹, 薛宇航², 王雷², 李宏坤², 于晓光³

(1. 汕头大学机械工程系 汕头, 515063) (2. 大连理工大学机械工程学院 大连, 116024)

(3. 辽宁科技大学机械工程与自动化学院 鞍山, 114051)

摘要 滚动轴承的故障信号是一种典型的非线性非平稳信号,其信号中常常混有噪声信号及其他干扰成分。提出了一种基于流形学习的滚动轴承故障盲源分离方法,首先,利用经验模态分解(empirical mode decomposition,简称 EMD)对单通道模拟信号进行分解,对得到的多通道信号构造其协方差矩阵,计算矩阵的奇异值下降速比得到原始信号数目;其次,利用峭度等指标选择最优观测信号,利用核主成分分析(kernel principal components analysis,简称 KPCA)提取信号的流形成分;最后,利用快速独立成分分析(fast independent component analysis,简称 FastICA)还原得到源信号。该方法不但解决了故障信号的欠定盲源分离问题,还提出了最优观测信号的确定准则,并通过实例验证了方法的有效性。

关键词 滚动轴承; 盲源分离; 流形学习; 协方差矩阵; 源信号

中图分类号 TH165.3; TH17

引 言

滚动轴承运行状态直接关系到设备生产状况,对其振动信号进行故障诊断及模式识别显得尤其重要^[1]。滚动轴承的振动信号经常混有其他振源及噪声等干扰成分,对诊断轴承状态影响很大^[2]。盲源分离(blind source separation,简称 BSS)是一种无需源信号的特征及混合条件就能够从混合信号中通过逆变换分离出源信号的方法,要求待观测信号数应该大于或等于源信号数,但由于工况限制,实际检测的信号一般都是单通道的混合信号。因此,如何解决欠定盲分离问题一直是研究的热点。徐根厚等^[3]将构造虚拟通道与独立成分分析(independent component analysis,简称 ICA)相结合,应用于齿轮箱轴承的故障诊断。Zhen 等^[4]利用稀疏编码重组观测信号实现盲源分离。朱江涛^[5]利用相空间重构和奇异值分解构造虚拟观测信号,结合盲源分离实现了对柴油机滚动轴承的故障诊断。Deng 等^[6]将完整经验模式分解与 FastICA 相结合,应用于单通道电磁信号的盲源分离。李晓晖等^[7]应用总体经验模式分解重构信号矩阵,利用联合对角化算法实现盲源分离。以上研究大多是针对欠定盲分离问题直接进行原始信号重构,存在信源数估计方面的问题,

且由单个指标或单域指标作为重构基础存在评估能力不足的问题。

笔者提出一种基于流形学习的盲源分离方法。首先,应用 EMD 对模拟的混合信号进行分解,得到多通道观测信号,并构造其协方差矩阵,计算奇异值的下降速比来得到信号数目;其次,计算峭度等多个指标选择最优观测信号作为 KPCA 的输入,提取其流形成分;最后,通过 FastICA 分离出源信号。

1 理论基础

1.1 ICA 盲源分离算法

盲源分离是信号处理领域的前沿方法,其中独立成分分析^[8]方法尤为引人注目。ICA 方法最终分离出来的源信号是互相独立的。ICA 的线性模型如图 1 所示。

设 $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_M(t)]^T$ 为 M 个源信号, $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T$ 为 N 个观测信号。假设将 M 个 $\mathbf{s}(t)$ 信号进行混合,形成 N 个 $\mathbf{x}(t)$ 信号,其线性关系为

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (1)$$

其中: \mathbf{A} 为系数 $\{a_{ij}\}$ 的未知混合矩阵。

ICA 方法就是需要从 $\mathbf{x}(t)$ 中分离出独立源信

* 国家自然科学基金资助项目(51875075,51775257)

收稿日期:2018-04-16;修回日期:2018-07-31




图1 ICA线性模型
Fig. 1 ICA linear model

号 $s(t)$ 。设 ICA 方法还原出的信号为 $y(t) = [y_1(t), y_2(t), \dots, y_n(t)]^T$ ，其过程可描述为

$$y(t) = Wx(t) = WAs(t) \quad (2)$$

其中： $y(t)$ 为 $s(t)$ 的近似估计； $y_1(t), y_2(t), \dots, y_n(t)$ 间相互独立； W 为分离矩阵。

为了提高算法的收敛速率，笔者采用 FastICA 算法。该算法迭代步数较小，有较好的分离效果^[9]。

1.2 KPCA 流形学习算法

流形学习的基本思想是将高维特征空间中的样本分布群“平铺”至一个低维空间，同时能保存原高维空间中样本点之间的局部位置相关信息。局部切空间对齐方法 (local tangent space alignment, 简称 LTSA) 是一种流形学习算法，而 KPCA 算法是一种非线性特征提取算法^[10]。文献[11]论述了 KPCA 算法与 LTSA 算法在计算结果方面的一致性，尽管理论证明过程有差异，但本质上 KPCA 可以表示 LTSA 算法。KPCA 算法的具体步骤如下。

1) 引入非线性映射 φ ，将原空间 R 中的数据 x_i 映射到高维空间 F ，得到 x_i 像为 $\varphi(x_i)$ ，计算其协方差矩阵为

$$\bar{S}_T = \frac{1}{n} \sum_{k=1}^n \varphi(x_k) \varphi(x_k)^T \quad (3)$$

2) 对矩阵 \bar{S}_T 做特征值分解，得到 $\lambda_i \omega_i = \bar{S}_T \omega_i$ ，其中： λ_i 为特征值； ω_i 为特征向量。将 $\varphi(x_i)$ 与式(3)作内积，得到

$$\lambda_i [\varphi(x_k) \omega_k] = \varphi(x_k) \bar{S}_T \omega_i \quad (k=1, 2, \dots, n) \quad (4)$$

3) 用 $\varphi(x_i)$ 线性表示 ω_i 为 $\omega_i = \sum_{j=1}^n a_j \varphi(x_j)$ ，其中： a_j 为相关系数。将其代入式(4)得到

$$\frac{1}{n} \sum_{j=1}^n a_j [\varphi(x_k) \cdot \sum_{i=1}^n \varphi(x_i)] [\varphi(x_i) \cdot \varphi(x_j)] = \lambda_i \sum_{j=1}^n a_j [\varphi(x_k) \cdot \varphi(x_j)] \quad (5)$$

4) 定义矩阵 K ，令 $K_{ij} = [\varphi(x_i) \cdot \varphi(x_j)]$ ，选取高斯核函数 $k(x, y) = \exp\{-x - y^2/2\sigma^2\}$ ，取 $\sigma =$

0.5。式(5)可表示为 $n\lambda K a = K K a$ ，即 $n\lambda a = K a$ 。因此，可求出协方差矩阵的特征向量 ω_i 和特征值 λ_i 。依据信息论排列 λ_i ，当 $\eta = \sum_{i=1}^m \lambda_i / \sum_{i=1}^n \lambda_i > 90\%$ 时，将相空间沿此时的特征向量 $\omega = [\omega_1, \omega_2, \dots, \omega_m]$ 方向做投影，得到其核主成分分量 H_i 为

$$H_i = [\omega \cdot \varphi(x)] = \sum_{i=1}^n a_i [\varphi(x_i) \cdot \varphi(x)] \quad (6)$$

2 基于流形学习的盲源分离方法

在确定信源数目后，还需从重构信号中选出相同数目、独立性较好的信号作为最优观测信号。笔者选取峭度、稀疏度和互信息 3 类典型的参数作为选择标准。参数之间相互补充，以增强方法的可靠性。整体方法流程如图 2 所示。

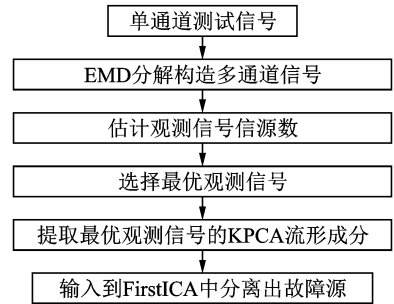


图2 基于流形学习的盲源分离方法流程图

Fig. 2 Flowchart of blind source separation method based on manifold learning

具体步骤为：

1) 对原混合信号 $x_1(t)$ 做 EMD 分解，并与得到的 IMF 分量组成信号集 $x = (x_1(t), x_2(t), \dots, x_n, r_n)^T$ ，其中： $x_2(t), \dots, x_n, r_n$ 为 $x_1(t)$ 的 IMF 分量； r_n 为 EMD 分解后得到的趋势项。同时通过计算其相关矩阵 $R_x = [x(t) \cdot x(t)^H]$ 的特征值最大下降速比，确定源信号的个数。

2) 在确定信源数后，利用峭度值等选择标准从得到的信号集 $x = (x_1(t), x_2(t), \dots, x_n, r_n)^T$ 中选出一组与信源数相等的最优观测信号。

3) 利用 KPCA 流形学习算法提取最优观测信号的流形成分。

4) 将提取的 KPCA 流形成分输入到 FastICA 中进行故障源的分离。

3 仿真与应用

由于齿轮箱的结构特性，其轴承外圈固定的齿

轮箱振动情况可表示为

$$s_b(t) = \sin(2\pi f_b t)[1 + \alpha \sin(2\pi f_r t)] \quad (7)$$

其中: f_b 为轴承滚动体通过内圈的特征频率; f_r 为转轴的转动频率。

为验证算法的有效性,模拟 3 个源信号为

$$\begin{cases} s_1(t) = \cos(2\pi f_1 t + 10) \\ s_2(t) = 0.5 \cos(2\pi f_2 t - 10) \\ s_3(t) = \sin(2\pi f_b t)(1 + \alpha \sin(2\pi f_r t)) \end{cases} \quad (8)$$

其中: $s_1(t)$ 为 $f_1 = 20$ Hz 的轴承故障引起的振动信号; $s_2(t)$ 为 $f_2 = 50$ Hz 的齿轮箱故障引起的振动信号; $s_3(t)$ 为齿轮箱正常振动信号; $f_r = 10$ Hz; $f_b = 100$ Hz; $\alpha = 1.6$; 采样长度 $N = 512$ 。

仿真信号的时域、频域波形如图 3 所示。为了模拟实际工况下的实测信号,将仿真信号添加随机噪声,选取任意一个 3×3 的矩阵对仿真信号进行混合,混合矩阵模型为 $\mathbf{x}(t) = \mathbf{B}\mathbf{s}(t)$ 。假定只获得单通道时频域信号,如图 4 所示。混合矩阵为

$$\mathbf{B} = \begin{bmatrix} -0.6816 & 0.9469 & -0.5718 \\ -0.9123 & 1.5598 & 0.1801 \\ -0.1551 & 0.4302 & -0.7712 \end{bmatrix} \quad (9)$$

利用 EMD 分解信号 $x_1(t)$,在舍弃不含有用信息的 IMF_8 之后,将 $x_1(t)$ 与其余 7 个 IMF 分量构成新的信号集 $\mathbf{x} = [x_1(t), \text{IMF}_1, \dots, \text{IMF}_7]^T$,计算 \mathbf{x} 的相关矩阵 $\mathbf{R}_x = [\mathbf{x}(t) \cdot \mathbf{x}(t)^H]$ 的特征值。由计算可得,当 $i = 3$ 时,下降速比达到峰值,所以确定源信号数目为 3 个。

在舍去含有大量噪声成分但不含振源信号的基本模式分量 IMF_1 之后,分别计算余下各 IMF 分量的峭度及稀疏度值,结果如表 1 所示。

计算任意两个 IMF 与 $x_1(t)$ 组合后的互信息值如表 2 所示。综合考虑 3 项指标,选取 $[x_1,$

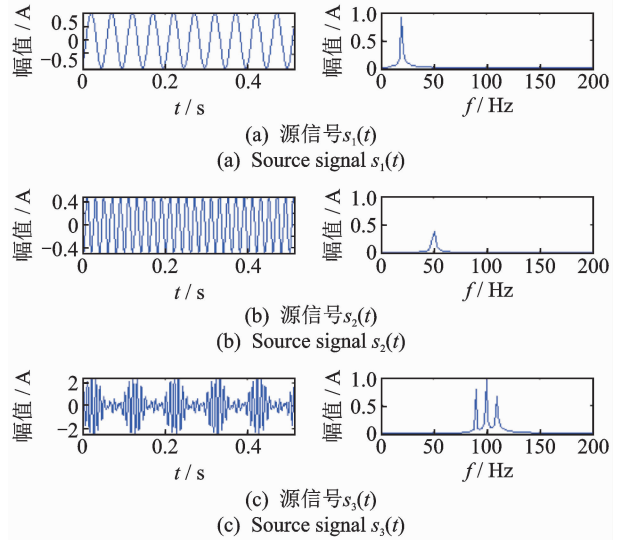


图 3 仿真信号时域、频域图

Fig. 3 Time domain and frequency domain diagram of simulation signal




图 4 添加噪声的单通道混合信号 $x_1(t)$

Fig. 4 Noisy single channel mixed signal $x_1(t)$

$\text{IMF}_2, \text{IMF}_3]^T$ 作为最优观测信号。

在选定最优观测信号后,需要确定延迟时间和嵌入维数来对其重构相空间^[12]。经计算可得延迟时间为 1,嵌入维数为 6,则重构 $x_1(t)$ 的相空间并利用 KPCA 流形学习算法提取信号的流形成分。最优观测信号 $[x_1, \text{IMF}_2, \text{IMF}_3]^T$ 的流形成分如图 5 所示。

表 1 各分量峭度、稀疏度

Tab. 1 The kurtosis and sparsity of each component

分量	IMF_2	IMF_3	IMF_4	IMF_5	IMF_6	IMF_7	IMF_8
峭度	2.867 6	2.249 8	1.645 3	2.033 2	1.633 2	1.677 8	1.596 3
稀疏度	1.310 4	1.192 5	1.121 8	1.151 3	1.122 3	1.097 7	1.003 2

表 2 互信息

Tab. 2 Mutual information

项目	IMF_2	IMF_3	IMF_4	IMF_5	IMF_6	IMF_7	IMF_8
IMF_2	0.443 2	0.131 0	0.165 1	0.096 8	0.096 8	0.096 7	0.097 3
IMF_3	0.131 0	0.318 7	0.102 9	0.036 1	0.034 6	0.034 3	0.037 4
IMF_4	0.165 1	0.102 9	0.387 5	0.069 6	0.071 4	0.069 1	0.070 6
IMF_5	0.096 8	0.036 1	0.069 6	0.250 2	0.011 0	0.001 5	0.000 6
IMF_6	0.096 8	0.034 6	0.071 4	0.011 0	0.250 4	0.021 3	0.009 0
IMF_7	0.096 7	0.034 3	0.069 1	0.001 5	0.021 3	0.250 0	0.005 3
IMF_8	0.097 3	0.037 4	0.070 6	0.000 6	0.009 0	0.005 3	0.250 5




图5 最优观测信号的流形成分

Fig. 5 Flow formation of optimal observation signal

将流形成分输入到 FirstICA 中,计算分离矩阵 W 并分离源信号,估计信号的时频图如图 6 所示。

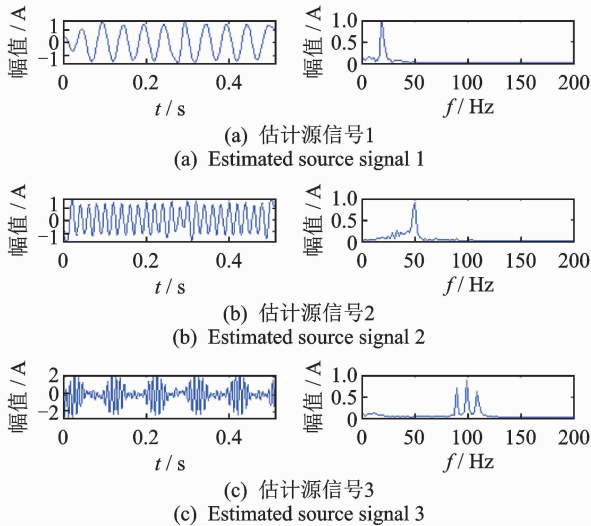


图6 最优测试信号流形成分盲源分离结果

Fig. 6 Blind source separation results of the best observed signal stream formation

比较图 6 与图 3 中的信号,当以观测信号 $[x_1, IMF_2, IMF_3]^T$ 的流形成分作为输入时,通过 FastICA 算法计算得到的信号图与仿真信号的时频图基本相同。若直接将观测信号 $[x_1, IMF_2, IMF_3]^T$ 输入 FastICA,得到的分离结果如图 7 所示。与图 3 所示的信号源相比,分离出的信号波形发生畸变,且蕴含其他成分,不能得到有效故障信息。因此,基于流形学习的盲源分离更有效,分离出的源信号具有更加准确的故障信息。

4 实例应用

为了验证本方法的有效性,对某公司混炼机减速箱输出轴端滚动轴承进行监测,测得的单通道信号时域波形如图 8 所示。轴承的型号为 NSK22338,输出轴转速约为 510r/min,齿轮啮合频率约为 387.5 Hz,采样频率为 12 800 Hz,采样长度为 8 192。计算得到轴承内环、外环、滚动体和保持架的特征频率依次为 68.75, 48.2, 21.58 和 3.44 Hz。利用 EMD 分解图 7 中的观测信号 x_1 ,在舍弃趋势项 IMF_7 后,将 x_1 与其余 IMF 分量构造信




图7 最优测试信号盲源分离结果

Fig. 7 Blind source separation results of optimal observation signals




图8 轴承故障信号时域波形

Fig. 8 Time waveform of bearing fault signal

号集 $\mathbf{x} = [x_1, IMF_1, \dots, IMF_6]^T$,并计算相关矩阵特征值下降速比最大值,确定系统的信源数为 3。

图 9 为轴承故障源分离结果。应用稀疏度、峭度和互信息指标确定最优观测信号 $[x_1, IMF_1, IMF_2]$,将其直接输入到 FirstICA 中,得到解混后的波形如图 9(a)所示,若将其流形成分作为输入时,分离结果如图 9(b)所示。可见,图 9(b)中故障特征显著,冲击成分更加突出。图 9(b)中第 1 行信号即 $y_1(t)$ 的希尔伯特-黄变换(Hilbert-Huang transform,简称 HHT)时频谱如图 10 所示。可见, $y_1(t)$ 存在 15 ms 的周期冲击,对应的冲击频率约为 66.75 Hz,接近内环故障频率,可判断轴承发生了内环故障。

5 结束语

对单通道观测信号进行分解,构造多通道观测

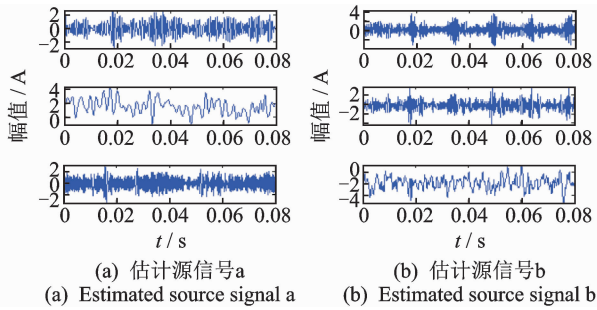



图9 轴承故障源分离结果

Fig. 9 Bearing fault source separation results

图10 $y_1(t)$ 的 HHT 时频图Fig. 10 HHT time-frequency spectrum of signal $y_1(t)$

信号,解决了实际工况中通常只能获得单通道混合信号的不足。提出最优观测信号的确定准则,克服了常规方法选取的最优观测信号独立性不强、分离效果不好的缺点。提取信号的流形成分作为 BSS 算法的输入,避免了直接将最优观测信号作为输入将会引起信号源时频域波形的畸变,可有效排除其他干扰信号。

参 考 文 献

- [1] ZHENG J, PAN H, CHENG J. Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines [J]. *Mechanical Systems & Signal Processing*, 2017, 85:746-759.
- [2] CHU D, HE Q, MAO X. Rolling bearing fault diagnosis by a novel fruit fly optimization algorithm optimized support vector machine [J]. *Journal of Vibration Engineering*, 2016, 18(1): 151-164.
- [3] 徐根厚, 曹伟青, 陈春俊. 基于单通道盲源分离的齿轮故障诊断研究 [J]. *现代制造工程*, 2017, 39(4): 138-141.
- XU Genhou, CAO Weiqing, CHEN Chunjun. Research of gear fault diagnosis based on the single channel blind source separation [J]. *Modern Manufacturing Engineering*, 2017, 39(4): 138-141. (in Chinese)
- [4] ZHEN L, PENG D, YI Z, et al. Underdetermined blind source separation using sparse coding [J]. *IEEE Trans Neural Netw Learn System*, 2017, 28(12):

- 3102-3108.
- [5] 朱江涛. 基于欠定盲源分离的柴油机曲轴轴承故障诊断方法研究 [J]. *车用发动机*, 2017(4): 36-42.
- ZHU Jiangtao. Fault diagnosis for crankshaft bearing of diesel engine based on underdetermined blind source separation [J]. *Vehicle Engine*, 2017(4):36-42. (in Chinese)
- [6] DENG X, PANG L, JIANG K, et al. Single-channel blind signal separation method for time-frequency overlapped signal based on CEEMD-FastICA [C] // *International Conference on Signal Processing*. [S. l.]: IEEE, 2017: 1440-1445.
- [7] 李晓晖, 傅攀. 基于一维盲源分离的滚动轴承故障诊断 [J]. *电子测量与仪器学报*, 2013, 27(6):535-542.
- LI Xiaohui, FU Pan. Rolling bearing fault diagnosis based on one-dimension blind source separation [J]. *Journal of Electronic Measurement & Instrument*, 2013, 27(6):535-542. (in Chinese)
- [8] MATTESON D S, TSAY R S. Independent component analysis via distance covariance [J]. *Journal of the American Statistical Association*, 2017, 30(2/3):113-118.
- [9] 赵洪山, 李浪, 王颖. 一种基于盲源分离和流形学习的风电机组轴承故障特征提取方法 [J]. *太阳能学报*, 2016, 37(2): 269-275.
- ZHAO Hongshan, LI Lang, WANG Ying. Fault feature extraction method of wind turbine bearing based on blind source separation and manifold learning [J]. *Acta Energetica Solaris Sinica*, 2016, 37(2): 269-275. (in Chinese)
- [10] 王奉涛, 陈旭涛, 柳晨曦, 等. 基于 KPCA 和 WPHM 的滚动轴承可靠性评估与寿命预测 [J]. *振动、测试与诊断*, 2017, 37(3): 476-483.
- WANG Fengtao, CHEN Xutao, LIU Chenxi, et al. Rolling bearing reliability assessment and life prediction based on KPCA and WPHM [J]. *Journal of Vibration, Measurement & Diagnosis*, 2017, 37(3): 476-483. (in Chinese)
- [11] 詹宇斌, 殷建平, 刘新旺. 局部切空间对齐算法的核主成分分析解释 [J]. *计算机工程与科学*, 2010, 32(6):158-161.
- ZHAN Yubin, YIN Jianping, LIU Xinwang. A kernel PCA view of the local tangent space alignment algorithm [J]. *Computer Engineering & Science*, 2010, 32(6):158-161. (in Chinese)
- [12] CAO L. Practical method for determining the minimum embedding dimension of a scalar time series [J]. *Physica D*, 1997, 9(110):43-45.



第一作者简介:王奉涛,男,1974年2月生,博士、教授。主要研究方向为设备状态监测与故障诊断、振动与噪声。曾发表《基于流形-奇异值熵的滚动轴承故障特征提取》(《振动、测试与诊断》2016年第36卷第2期)等论文。
E-mail: wangft@stu.edu.cn