基于 FSS-kernel BSS 方法的机械故障诊断

杨彦龙 程 伟 常洪振

(北京航空航天大学 航空科学与工程学院, 北京 100191)

摘 要: 机械设备发生故障时,故障特征的提取是很重要的. 为了从观测信号中分离出不同的故障特征源信号,并根据分离信号准确地进行故障诊断,从观测信号样本出发,提出了基于有限支持样本核函数的盲源分离(FSS-kernel BSS)方法. 此方法利用有限的观测样本估计信号的概率分布,得到了评价函数,具有很好的自适应能力. 仿真试验结果表明:此方法能成功地分离超、亚高斯混合信号,与其他盲源分离方法相比,此方法具有更好的分离性能. 将该方法用于转子不平衡和支座松动的复合故障信号的盲分离,分离出了各复合故障的主要频谱. 分离结果表明:此方法应用于机械设备复合故障诊断中是可行的.

关 键 词: 故障诊断; 盲源分离; 有限支持样本; 核函数

中图分类号: TN 911

文献标识码: A **文 章 编 号**: 1001-5965(2012)11-1557-05

Fault diagnosis based on blind source separation using kernel function with finite support samples

Yang Yanlong Cheng Wei Chang Hongzhen

(School of Aeronautic Science and Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: It is important to extract fault features when machine would be in fault state. In order to separate different fault vibration signals from measured mixtures and diagnose the fault features of the machine effectively according to the separated signals, a blind source separation (BSS) method using kernel function based on finite support samples was proposed. The method is stronger adaptability for the score functions estimated according to finite support observed signal samples. The simulation results prove that the proposed BSS algorithm is able to separate hybrid mixtures that contain both sub-gaussian and super-gaussian sources. It is shown that the algorithm has better separation performance when compared with other BSS ones. The results of an experiment under the motor's composite fault states with pedestal looseness fault and rotor unbalance fault show that this method is feasible for fault diagnosis.

Key words: fault diagnose; blind source separation; finite support samples; kernel function

机械设备的振动信号是故障特征识别和诊断的重要信息来源. 故障信号主要是由轴承支撑刚度、碰摩、支座松动、转轴裂纹、转子不对中、不平衡及油膜振荡等引起的. 传感器实际采集到的信号往往是多种故障共同作用的结果,这种信号的混叠降低了信噪比,给设备运行状态的评价和分析带来较大困难. 如何将不同的故障特征提取出来,提高故障诊断的准确率是一件困难的事情. 盲源分离(BSS,Blind Source Separation)的出现为振动信号的分离与故障特征识别提供了一种新的研究思路[1-5].

BSS[6]是指在源信号及传输通道特性未知的情况下,仅仅依靠源信号的一些基本统计特征,从观测信号恢复出原始信号的方法. 从 20 世纪 80 年代中期,Herault J 等对 BSS 开始研究至今,已出现许多算法[6-10],并取得了一定的效果. 然而,这

收稿日期: 2011-07-28; **网络出版时间**: 2012-11-09 17:21

网络出版地址: www.cnki.net/kcms/detail/11.2625.V.20121109.1721.016.html

作者简介: 杨彦龙(1981-),男,河北石家庄人,博士生,dragon-yan@163.com.

些算法的评价函数大多面临非线性函数的选择问题,源信号分离效果的好坏在很大程度上取决于非线性函数选取得是否适当. 当观测信号由杂系信号混合而成时,单一的非线性函数又难以满足要求. 为解决这个问题,本文从观测信号样本出发,利用有限的支持样本核函数方法估计概率密度函数,得到非线性函数,用此非线性函数实现分离信号的互信息最小化,进而完成超高斯和亚高斯混合信号的盲分离. 与其他常用 BSS 方法相比,本文方法具有很好的自适应性和更好的分离效果. 最后用此方法成功实现了机械设备复合故障信号的盲分离.

1 盲源分离基本原理及分离准则

1.1 盲源分离基本原理

假设 M 个传感器通道获得的观测信号为 $\boldsymbol{X}=[x_1,x_2,\cdots,x_M]^{\mathrm{T}}$. 每个观测信号 x_i 是 N 个统计独立的源信号 $s_j(j=1,2,\cdots,N)$ 的线性混合($M\geqslant N$). 不考虑噪声情况下,观测信号的数学模型为

$$\boldsymbol{X}=\boldsymbol{AS} \tag{1}$$

式中,$\boldsymbol{S}$ 为源信号矢量,$\boldsymbol{S}=[s_1,s_2,\cdots,s_N]^{\mathrm{T}}$;$\boldsymbol{A}$ 为 $M\times N$ 维列满秩未知混合矩阵.

盲源分离即在源信号 $\boldsymbol{S}$ 和线性组合方式 $\boldsymbol{A}$ 均未知的条件下,仅依据观测信号 $\boldsymbol{X}$,寻找一个 $N\times M$ 维分离矩阵 $\boldsymbol{W}$,从而实现对源信号的估计:

$$\boldsymbol{Y}=\boldsymbol{WX}=\boldsymbol{WAS} \tag{2}$$

式中,$\boldsymbol{Y}=[y_1,y_2,\cdots,y_N]^{\mathrm{T}}$ 是估计得到的源信号矢量.

1.2 盲源分离准则

盲源分离的基本假设条件为源信号相互独立. 当分离信号的互信息取最小值时,即实现了混合信号的分离. 基于分离出的各个分量的最小互信息准则[11]为

$$\hat{\boldsymbol{W}}=\arg\min_{\boldsymbol{W}}D(y_1,y_2,\cdots,y_N) \tag{3}$$

互信息可以表示为边际熵与联合熵的函数:

$$D(y_1,y_2,\cdots,y_N)=\sum_{i=1}^{N}H(y_i)-H(y_1,y_2,\cdots,y_N)=\sum_{i=1}^{N}H(y_i)-H(x_1,x_2,\cdots,x_N)-\lg(|\boldsymbol{W}|) \tag{4}$$

式中,$H(y)$ 为多维随机变量 y 的二阶 Renyi 熵:

$$H(y)=-\lg\int p^2(y)\mathrm{d}y=-\lg E[p(y)] \tag{5}$$

在对混合信号 x 进行预白化处理的前提下,分离矩阵 $\boldsymbol{W}$ 可以看作雅克比旋转矩阵[2],此时 $\lg(|\boldsymbol{W}|)=0$,$H(x)$ 相对于 $\boldsymbol{W}$ 为不变常量,因此目标函数式(3)变为

$$\hat{\boldsymbol{W}}=\arg\min_{\boldsymbol{W}}\{H(y_1)+H(y_2)\cdots+H(y_N)\} \tag{6}$$

2 有限样本核函数的盲源分离方法

根据式(6)及式(5),为了从混合信号中分离出源信号,需要知道准确的概率密度函数 $p(y)$. 传统的 BSS 方法利用某些特定的非线性函数代替 $p(y)$,然而,在源信号未知的情况下,这个非线性函数很难完全符合所有源信号的统计特性,恢复出的源信号可能不理想,甚至无法实现分离.

为了解决这个问题,本文基于核函数方法,从观测信号本身出发,每个窗函数仅用到 N 个观测样本中的 m 个有限支持样本对概率密度函数进行估计. 将得到的概率密度函数用于最小互信息准则,从而实现混合信号的盲分离.

首先将样本 y_i 以非递减顺序进行排序,得到 $\{y_1<y_2<\cdots<y_N\}$,有限支持样本核函数的概率密度函数估计[12]为

$$\hat{p}(y_j)=\frac{1}{N-m}\sum_{i=1}^{N-m}\phi(y_j-\hat{y}_i) \tag{7}$$

式中,$\hat{y}_i=(y_i+y_{i+m})/2$,为 m 个有限支持样本 $\{y_i,y_{i+1},\cdots,y_{i+m}\}$ 核函数的中心;m 为窗宽.

本文采用“留一法交叉验证”技术[9],确定 m 的最佳值为 $\sqrt{N}$. 核函数 $\phi(y)$ 的选择应满足有限支持样本边界条件及概率密度函数的基本条件:①当 $y\leqslant y_i$ 或 $y\geqslant y_{i+m}$,$\phi(y)=0$;②核函数 $\phi(y)$ 对边界点 y_i 及 y_{i+m} 微分为 0;③核函数 $\phi(y)$ 在整个定义域 $y_i\leqslant y\leqslant y_{i+m}$ 上的积分为 1;④核函数具有连续可微性. 满足上述条件的最低阶核函数为

$$\phi(y)=\begin{cases}C_i(y-\mu_i)^2(y+\mu_i)^2 & y\in[-\mu_i,\mu_i]\\ 0 & \text{其他}\end{cases} \tag{8}$$

式中,$\mu_i=(y_{i+m}-y_i)/2$,根据条件③得到 $C_i=15\mu_i^{-5}/16$.

将 $\hat{y}_i,\mu_i,C_i$,式(7)及式(8)代入式(5),得

$$H(y)\approx-\lg\sum_{i=1}^{N-m}\sum_{j=i+1}^{i+m-1}\frac{30(y_j-y_{i+m})^2(y_j-y_i)^2}{N(N-m)(y_{i+m}-y_i)^5} \tag{9}$$

将式(2)及式(9)代入式(6),得到关于变量 $\boldsymbol{W}$ 的互信息表达式,通过求解互信息关于分离矩阵 $\boldsymbol{W}$ 的最小值实现混合信号的盲分离.

根据 1.2 节所述,分离矩阵 $\boldsymbol{W}$ 可以用雅克比

旋转矩阵表示. 优化的基本思想是:每次同时,对变量 $\boldsymbol{X}'$ 任意两列进行雅克比旋转. 同时对变量 $\boldsymbol{X}'$ 的 p 列和 q 列进行旋转的矩阵 $\boldsymbol{W}$ 关于旋转角度 θ 的定义为

$$\boldsymbol{W}(p,q,\theta)=\begin{bmatrix} 1 & \cdots & 0 & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \boldsymbol{D} & & \vdots & & \vdots \\ 0 & \cdots & \cos(\theta) & \cdots & -\sin(\theta) & \cdots & 0 \\ \vdots & & \vdots & \ddots & \vdots & & \vdots \\ 0 & \cdots & \sin(\theta) & \cdots & \cos(\theta) & \cdots & 0 \\ \vdots & & \vdots & & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & 0 & \cdots & 1 \end{bmatrix}$$

$$\theta \in \left[-\frac{\pi}{4},\frac{\pi}{4}\right]$$

可以看出 $\boldsymbol{W}(\theta)$ 为单一变量 θ 的函数. 因此,可以在 $-\frac{\pi}{4}\leqslant\theta\leqslant\frac{\pi}{4}$ 取均匀分布的 K 个值,进行穷举搜索方法寻找式(6)的最小值,K 越大分离效果越好. 通过 100 次 Monte Carlo 仿真表明,$K=150$ 时,混合信号已被很好分离,进行 N 次旋转即可得到很好的分离效果.

本文提出的基于有限支持样本核函数的盲源分离(FSS-Kernel BSS)方法的优势在于:不用选择非线性函数,采用核函数的窗函数仅用少数的样本,从实测信号本身出发估计概率密度函数,从而实现混合信号的盲恢复,此方法具有很好的自适应性.

3　仿真试验与性能分析

为了说明此算法应用的广泛性,即与信号的超高斯性、亚高斯性无关,选取不同峭度的 3 个亚高斯信号和 3 个超高斯信号作为源信号,3 个亚高斯信号分别为

$$s_1=\sin(1\,600\pi\eta t)$$

$$s_2=\sin(600\pi\eta t+6\cos(120\pi\eta t))$$

$$s_3=\sin(180\pi\eta t)$$

3 个超高斯信号分别为

$$s_4=[(\mathrm{mod}(t,23)-11)/9]^5+3$$

$$s_5=\mathrm{sign}(\mathrm{rand}(1,N)-0.5)\times\lg(\mathrm{rand}(1,N))+1.4$$

$$s_6=\cos(300\pi\eta t)\sin(200\pi\eta t)^7$$

式中,$\eta=2\times10^{-4}$,N 为样本点数. 这里,信号的样本点数为 1 000. 为了更清晰地观察信号,仅画出 500 样本点. 源信号的时域波形如图 1 所示,以 6×6 的随机矩阵对源信号进行混合,得到 6 个混合信号的波形如图 2 所示. 用文中方法对混合信号进行分离,得到的源信号的估计信号见图 3.

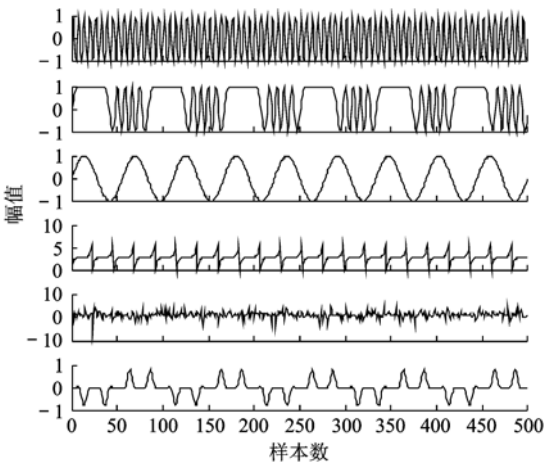

图 1　源信号

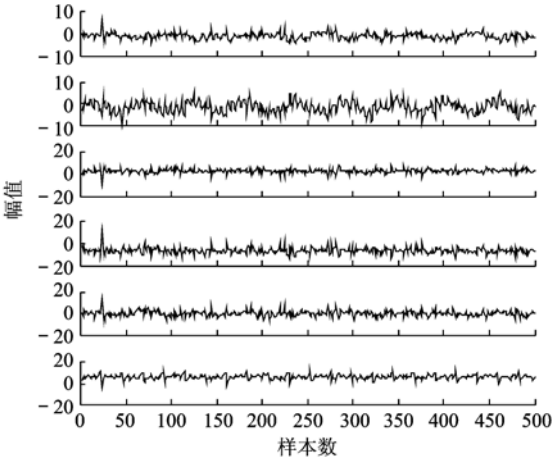

图 2　混合信号

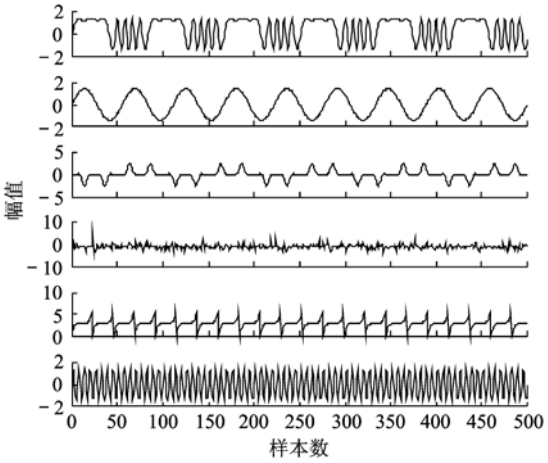

图 3　分离信号

从图 3 中可以直观地看出,本文方法很好地实现了超、亚高斯混合信号的盲分离,分离效果比较理想.

为了定量研究本文提出的方法的分离性能,将此算法与 FastICA 算法[7],Jade 算法[8],Pearson ICA 算法[12],Kernel-ICA 中的 KCCA 算法及 KGV 算法[13]的分离结果进行比较. 仿真试验采用不同的样本点数. 分离性能的评估标准为信号的干扰

比 SIR,公式如下[14]:

$$\text{SIR 值} = 10\lg \frac{\sum_{i=1}^{N}\sum_{j=1}^{N} s_i^2(j)}{\sum_{i=1}^{N}\sum_{j=1}^{N} (\hat{s}_i(j) - s_i(j))^2} \quad (10)$$

式中,$\hat{s}$ 代表分离出的源信号的估计信号,s 代表源信号,单位为 dB. 从定义可以看出 SIR 越大,说明分离性能越好. 一般情况下,当 SIR 小于 8 ~ 10 dB时,说明未能有效分离出源信号. 这里采用进行 50 次仿真,求平均值的方法. 各种算法的 SIR 性能如图 4 所示.

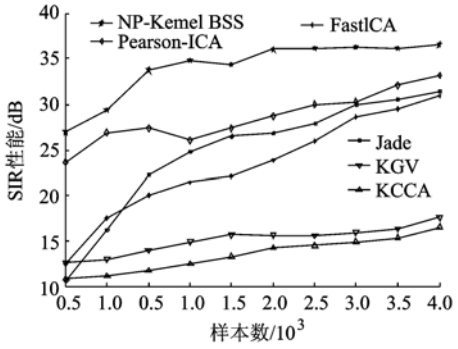

图 4 各种算法性能比较

从图 4 中可以看出,上述各种方法在样本点 500 点以上均能实现混合信号的盲分离,且随着样本点数的增加,分离性能逐渐提高. 其中 Kernel-ICA 中的 KCCA 算法及 KGV 算法的分离性能最差,FastICA 算法及 Jade 算法随着样本点数的增加,分离性能有较大的提高. 在所有方法中,本文提出的方法分离效果最佳.

4 在机械故障诊断中的应用

机械设备发生故障时,难以预先知道故障信号的超、亚高斯性,因此本文方法更适合实测信号的盲分离. 将此方法应用于小型转子试验台的复合故障诊断. 试验台示意图如图 5 所示,试验设备组成主要包括图中所示以及 LMS 信号采集系统(未画出).

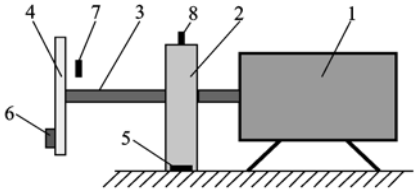

1—小型电机,2—轴承座,3—转轴, 4—法兰盘, 5—轴承座紧固螺栓,6—质量块,7—电涡流传感器,8—加速度传感器.

图 5 试验台示意图

为了模拟转子基础松动情况,人为地将轴承座的紧固螺栓松开一定程度,并对其进行轴向限位. 在与电机转轴相连的法兰上安装可调偏心重块,模拟转子不平衡. 针对此试验系统设置 2 个传感器:在轴承座垂直方向安装一个加速度传感器,在法兰盘端面的垂直方向安装一个非接触式电涡流传感器,尽量保证传感器之间不受影响. 通过信号采集系统记录传感器测量的振动信号.

已知电机的转速为 2 760 r/min,工作频率为 46 Hz,试验采样频率为 1 000 Hz. 在此转速下采集得到的信号的功率谱特征如图 6 所示.

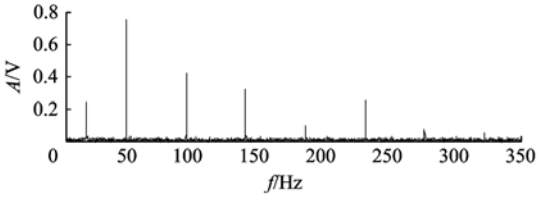

a 电涡流传感器采集信号的功率谱

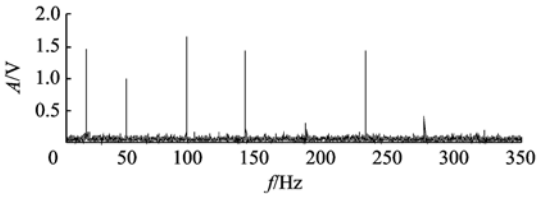

b 加速度传感器采集信号的功率谱

图 6 测量振动信号功率谱

图 6 中,由于故障特征频率在每一个功率谱图上相互混叠,难以确定故障类型的存在,不易准确进行故障诊断. 考虑本文系统为一个刚度很大的结构,振动延迟可以忽略不计,一个瞬时模型是可以保持的[15]. 因此,运用本文提出 FSS-kernel BSS 方法对故障信号进行分离,得到的分离信号的功率谱特征如图 7 所示.

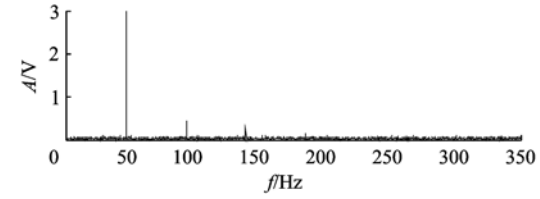

a 分离信号 Y_1

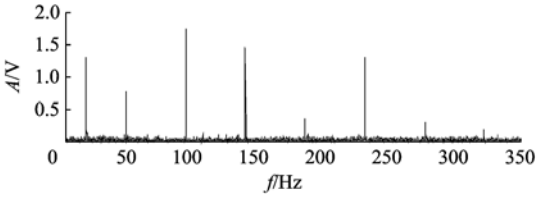

b 分离信号 Y_2

图 7 本文方法分离后振动信号功率谱

从图 7 中可以看出,分离后,每一个信号的功率谱图中基本只显示一种故障特征:分离信号 Y_1 的能量主要集中在基频 46 Hz,其他频率成分的能量很小,这正是转子不平衡故障的表现特征;分离

信号 $Y2$ 的频率成分包括:15.3,46,92,138 及 230 Hz,分别为 1/3 倍频,基频,二倍频,三倍频和五倍频,此特征对应支座松动的故障特征. 同时,采用最为广泛应用的 FastICA 方法对测量信号进行分离,分离结果见图 8. 从图 8 中可以看出,分离信号 Y_1 及 Y_2 中均包括两种故障频率,即 FastICA 方法对混合故障信号的盲分离效果不理想.

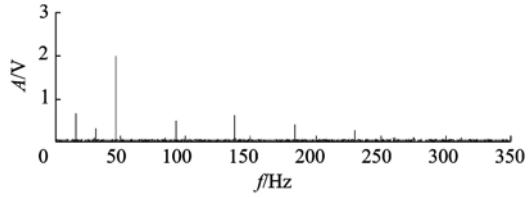

a　分离信号 Y_1

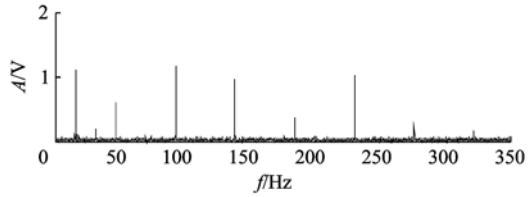

b　分离信号 Y_2

图 8　FastICA 分离后振动信号功率谱

以上复合故障分离结果表明,本文提出的方法很好地将转子不平衡故障和支座松动故障分离,提高了机械设备故障诊断的准确率. 因此,将本文方法用于机械设备故障诊断方面是可行的.

5　结 束 语

1) 本文提出的基于 FSS-Kernel BSS 方法,具有复杂度低,自适应好的优点;

2) 仿真结果表明,此方法能够分离超、亚高斯信号组成的混合信号,与其他盲源分离算法相比,具有更好的分离性能;

3) 运用 FSS-kernel BSS 方法对采集到的实际转子的复合故障振动信号进行盲分离,结果表明本文方法能够很好的将不同的故障信号分离开来,为提高故障诊断的准确率提供了一种新方法.

参考文献 (References)

[1] 李良敏,温广瑞,王生昌,等. 机械故障诊断的遗传-独立分量分析算法[J]. 农业机械学报,2008,39(11):197-202
Li Liangmin, Wen Guangrui, Wang Shengchang, et al. Genetic algorithm based independent component analysis method in machine fault diagnosis[J]. Transactions of the Chinese Society for Agricultural Machinery, 2008, 39(11): 197-202(in Chinese)

[2] 艾延廷,费成巍,张凤玲,等. ICA 在航空发动机振动信号盲源分离中的应用[J]. 振动、测试与诊断,2010,30(6):671-674,711
Ai Yanting, Fei Chengwei, Zhang Fengling, et al. Blind source separation for aero-engines vibration signal by independent component analysis[J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(6): 671-674, 711(in Chinese)

[3] 胥永刚,李强,王正英,等. 基于独立分量分析的机械故障信息提取[J]. 天津大学学报,2006,39(9):1066-1071
Xu Yonggang, Li Qiang, Wang Zhengying, et al. Fault information extraction of mechanical equipment based on independent component analysis[J]. Journal of Tianjin University, 2006, 39(9): 1066-1071(in Chinese)

[4] 李良敏. 基于遗传算法的盲源分离及其在轴承诊断中的应用[J]. 轴承,2005(9):31-34
Li Liangmin. Application of blind source separation method based genetic algorithm in bearing diagnosis[J]. Bearing, 2005(9): 31-34 (in Chinese)

[5] 吴作伦,杨世锡,冯海涛. 基于最小互信息原理的机械振动源分离研究[J]. 机电工程,2003,20(5):44-46
Wu Zuolun, YangShixi, Feng Haitao. Study on separation of mechanical vibration based on the principle of the minimum mutual information[J]. Mechanical & Electrical Engineering Magazine, 2003, 20(5): 44-46(in Chinese)

[6] 张洪渊,史习智. 一种任意信号源盲分离的高效算法[J]. 电子学报,2001,29(10):1392-1396
Zhang Hongyuan, Shi Xizhi. An effective algorithm for blind separation of arbitrary source signals[J]. Acta Electronica Sinica 2001, 29(10): 1392-1396(in Chinese)

[7] Hyvarinen A, Oja E. A fast fixed point algorithm for independent component analysis[J]. Neural Computation, 1997, 9(7): 1483-1492

[8] Cardoso J F. High-order contrasts for independent component analysis[J]. Neural Computation, 1999, 11(1): 157-192

[9] Duda R O, Hart P E, Strok D G. 模式分类[M]. 李宏东,等译. 2 版. 北京:机械工业出版社,2009:389-390
Duda R O, Hart P E, Strok D G. Pattern classification[M]. Translated by Li Hongdong, et al. 2nd ed. Beijing: China Machine Press Edition, 2009: 389-390(in Chinese)

[10] Karvanen J, Eriksson J, Koivunen V. Pearson system based method for blind separation[C]//Proceedings of 2nd International Workshop on Independent Component Analysis and Blind Signal Separation. Helsinki: IEEE, 2000: 585-590

[11] Barlow H. Unsupervised learning[J]. Neural Computation, 1989(1): 295-311

[12] Ozertem U, Uysal I, Erdogmus D. Continuously differentiable sample-spacing entropy estimation[J]. IEEE Trans Neural Networks, 2008, 19(11): 1978-1984

[13] Bach F, Jordan M. Kernel independent component analysis[J]. Journal of Machine Learning Research, 2002(3): 1-48

[14] 成孝刚,姜华,刘国庆,等. 基于参数 Parzen 窗估计的独立分量分析[J]. 信号处理,2009,25(3):485-488
Cheng Xiaogang, Jiang Hua, Liu Guoqing, et al. Independent component analysis based on parametric parzen window estimstion[J]. Signal Processing, 2009, 25(3): 485-488(in Chinese)

[15] Ypma A, Leshem A. Blind separation of machine vibration with bilinear forms[C]//Proceedings of 2nd International Workshop on Independent Component Analysis and Blind Signal Separation. Helsinki: IEEE, 2000: 109-114

(编　辑:李　晶)