

用慢特征分析算法实现水声信号盲分离

何会会, 李钢虎, 要庆生, 贺晓凯, 石超雄

(西北工业大学航海学院, 陕西西安 710072)

摘要: 在常规的水声信号盲处理研究中, 通常都是用独立成分分析算法分离线性混合信号, 而对于较复杂的非线性混合信号, 独立成分分析算法无能为力。针对这种情况, 提出将慢特征分析(Slow Feature Analysis, SFA)算法应用于水声信号非线性盲源分离领域。一般而言, 对源信号做非线性混合变换后输出混合信号较源信号变化较快, 而采用 SFA 算法可以从复杂的非线性混合信号中提取出变化缓慢的信号, 通过仿真实验, 分别对简单信号和复杂水声信号的非线性混合信号进行分离, 通过将源信号与分离信号对比, 发现 SFA 算法输出信号与源信号高度相似, 验证了 SFA 算法在非线性的盲源分离领域应用的有效性和可行性。

关键词: 信号处理; 盲源分离; 慢特征分析

中图分类号: TB566

文献标识码: A

文章编号: 1000-3630(2014)-03-0270-05

DOI 编码: 10.3969/j.issn1000-3630.2014.03.017

Blind source separation of underwater acoustic signals by using slowness feature analysis

HE Hui-hui, LI Gang-hu, YAO Qing-sheng, HE Xiao-kai, SHI Chao-xiong

(Institute of Acoustic Engineering, Northwestern Polytechnical University, Xi'an 710072, Shaanxi, China)

Abstract: In conventional blind underwater acoustic signal processing, the independent component analysis algorithm is often used to separate linear mixed signals. However, for the more complex nonlinear mixed signal, the independent component analysis algorithm is helpless. To solve this problem, this article applies slow feature analysis to blind underwater acoustic signal processing. In general, the nonlinear mixed signal varies faster than the source signal does, and SFA algorithm can extract slowly varying features from complex nonlinear signals. Through simulation experiment, the nonlinear mixed signals of simple signals and complex underwater acoustic signals are separated. By comparing the source signals and the separated signals, it is found that the output signals of SFA correlate to the source signal highly. It proves that SFA is effective and practicable in the field of nonlinear blind source separation application.

Key words: signal processing; blind source separation; slowness feature analysis

0 引言

盲源分离是盲信号处理领域中的一个重要分支, 自 1986 年 Herault J 和 Jutten C^[1]首次提出盲源分离的概念, 盲源分离经过近 30 年的发展, 已经成为比较成熟的一门学科分支。盲源分离在雷达、通信、医学分析、图象处理、语音信号识别、阵列信号处理以及通信信号分析等众多领域有着广泛应用, 得到了许多突破性成果, 引起了相关学者的极大关注。

盲源分离是指在信号模型和传输通道参数未知或已知的信息非常少的情况下, 仅从观测信号中

分离出源信号的方法。当前多数盲源分离算法都假设源信号是统计独立的并且是线性混合的, 这时我们用独立成分分析(Independent Component Analysis, ICA)方法分析, 在这个问题上众多学者已经取得了丰硕的成果^[2]。ICA 的基本思想为: 在线性混合的情况下, $\mathbf{X}(t)=\mathbf{A}\mathbf{S}(t)$, 其中 $\mathbf{S}(t)$ 为源信号, $\mathbf{X}(t)$ 为观测混和信号, \mathbf{A} 为未知的混合矩阵, 输出为 $\mathbf{Y}(t)=\mathbf{W}\mathbf{X}(t)$, 其中 \mathbf{W} 为权矩阵, 也是所要求的矩阵, \mathbf{W} 需满足使得输出信号和源信号具有相同的形状, 但不要求幅度和顺序的一致性, 通常 $\mathbf{W}=\mathbf{P}\mathbf{D}\mathbf{A}^{-1}$, 其中 \mathbf{P} 为置换矩阵, \mathbf{D} 为对角矩阵^[3]。

众所周知, 水下通信系统是相当复杂的, 有行船、地震波、海面波浪以及海洋湍流等噪声, 因此当观察声呐接收到信号时, 通常目标信号被海洋环境噪声扰乱甚至淹没, 这严重阻碍了提取有用的信息。这时观测信号发生了非线性混合畸变, 显然线性混合信号分离算法已不再适用, 若把非线性混和

收稿日期: 2012-12-24; 修回日期: 2013-03-19

作者简介: 何会会(1990—), 女, 陕西榆林人, 硕士研究生, 研究方向为水声信号与信息处理。

通讯作者: 何会会, E-mail: hehuihui15@163.com

模型仍视为线性混和的情况并利用线性 ICA 方法分离信号, 可能导致错误的结果。因此, 需要能更逼真地模拟海洋环境的假设模型, 即非线性或者弱非线性模型。在非线性和混合模型中进行信号的盲分离, 在盲源分离领域称之为非线性盲源分离, 慢特征分析(Slowness Feature Analysis, SFA)算法是盲源分离新近发展起来的算法, 基于其特性, 本文将这种算法用于水声信号分离, 通过仿真研究, 发现慢特征分析算法非常实用。

1 慢特征分析

1.1 慢特征

慢特征是表征信号所固有的性质, 因而对于信号分离具有至关重要的作用, 等同于模式识别中的不变量, 慢特征指的是信号中所隐含的变化最缓慢的成分, 是从混和信号中提取出来的源信号的高级表示, 表征信号发生源的固有属性。

1.2 慢特征分析算法概述

慢特征分析就是从快变的复杂信号中提取慢特征的一种算法, 该算法已经取得了很多的应用, 例如在生物视觉中的应用, 通过模拟在生物视觉中大脑是如何从观感信号中提炼出平移、旋转等慢特征的^[4]。SFA 在生物视觉系统中的成功应用启发我们将 SFA 应用于听觉系统, 由此我们尝试在海洋声学环境中通过 SFA 的方法达到非线性盲源分离的效果。

SFA 算法的目标是提取输入时序数据中所隐含的缓慢变化的成分, 即除了常值信号外, 变化最缓慢的成分, 其算法基本思想是相关矩阵的特征值分解, 其本质是在经过非线性扩展的特征空间对目标函数进行优化, 寻找最优解的线性组合。它的非线性是通过增加输入变量的高阶多项式来引入的。多项式的阶数体现特征空间的复杂程度, 算法的输出 $y(t)$ 包含信号本身所固有的不变量信息的程度, 取决于其输入变量非线性扩展的程度^[4]。

1.3 SFA 算法基本原理

慢特征分析是独立成分分析算法^[5]的发展, 它是从快速变化信号中提取慢信号特征的算法。SFA 可以得到变化速率从小到大排列的一系列特征。

设多维输入信号 $\mathbf{x}(t)=[x_1(t), x_2(t), \dots, x_n(t)]$, 需要求得多维函数 $g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_n(\mathbf{x})$ 作为传输函数, 使得输出信号 $y_j(t)=g_j(\mathbf{x}(t))$ 的各分量变化尽可能的慢, 我们选择用信号的一阶导数的均方值

来度量变化速率。此时问题将转化为最佳优化问题, 目标函数为

$$\min_{y_j} \Delta(y_j) = \langle \dot{y}_j(t) \rangle^2 \quad (1)$$

满足约束条件:

$$\langle y_j(t) \rangle = 0 \quad (2)$$

$$\langle (y_j(t))^2 \rangle = 1 \quad (3)$$

$$\langle y_i(t)y_j(t) \rangle = 0, \quad \forall i < j \quad (4)$$

其中: $\dot{y}_j(t)$ 为 $y_j(t)$ 的一阶导数, $\langle \cdot \rangle$ 为时间平均, 约束条件(2)和(3)排除常值解, 约束条件(4)保证各分量间是互不相关的, 使得各分量承载的信息互不重叠。若经计算得最优解

$$\mathbf{y}^*(t) = [y_1^*(t), y_2^*(t), \dots, y_n^*(t)]$$

则 $y_1^*(t)$ 为变化最缓慢的成分, $y_2^*(t)$ 为变化速率除 $y_1^*(t)$ 以外最慢的成分, 且与 $y_2^*(t)$ 互不相关, 以此类推。

值得指出的是, 从输入到输出是瞬时的, 因此处理速度是非常快的, 但得到的却是信号的慢特征, 而这是低通滤波器所不能达到的效果, 因为低通滤波器处理信号是有延时的, 且滤波器会滤除高频成分, 而慢特征分析算法只是优先提取出变化缓慢的成分。

接下来分两种情况讨论:

(1) 线性

就线性情况而言, 设 $y_j(t) = g_j(\mathbf{x}(t)) = \mathbf{w}_j^T \mathbf{x}(t)$, $\mathbf{x}(t)$ 为输入的观测信号, \mathbf{w} 为权向量, 为简单起见在接下来的讨论中, 均假设 $\mathbf{x}(t)$ 的均值为 0, 则可将式(1)写为

$$\Delta(y_j) = \langle (\dot{y}_j)^2 \rangle = \langle (\mathbf{w}_j^T \dot{\mathbf{x}})^2 \rangle = \mathbf{w}_j^T \langle \dot{\mathbf{x}} \dot{\mathbf{x}}^T \rangle \mathbf{w}_j \quad (5)$$

则式(2)可写为

$$\langle (y_j)^2 \rangle = \langle (\mathbf{w}_j^T \mathbf{x})^2 \rangle = \mathbf{w}_j^T \langle \mathbf{x} \mathbf{x}^T \rangle \mathbf{w}_j = 1 \quad (6)$$

将式(5)和(6)结合可以得到

$$\Delta(y_j) = \frac{\mathbf{w}_j^T \langle \dot{\mathbf{x}} \dot{\mathbf{x}}^T \rangle \mathbf{w}_j}{\mathbf{w}_j^T \langle \mathbf{x} \mathbf{x}^T \rangle \mathbf{w}_j} = \frac{\mathbf{w}_j^T \mathbf{A} \mathbf{w}_j}{\mathbf{w}_j^T \mathbf{B} \mathbf{w}_j} \quad (7)$$

其中 $\mathbf{A} = \langle \dot{\mathbf{x}} \dot{\mathbf{x}}^T \rangle$ $\mathbf{B} = \langle \mathbf{x} \mathbf{x}^T \rangle$

由矩阵论的知识可以知道, 使上式成立的权向量为式(8)的广义特征向量

$$\mathbf{A} \mathbf{W} = \mathbf{A} \mathbf{B} \mathbf{W} \quad (8)$$

其中 $\mathbf{W} = (\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N)$ 为特征向量构成的特征矩阵, \mathbf{A} 是由广义特征值 $\lambda_1, \dots, \lambda_N$ 构成的对角矩阵, 并将特征值排序使得 $\lambda_1 < \lambda_2 < \dots < \lambda_N$ 。则式(7)可化为

$$\Delta(y_j) = \lambda_j \quad (9)$$

根据矩阵论的知识, 式(7)的极小化问题为求

Rayleigh 商的极小值点, 则

$$\min_{y_j} \Delta(y_j) = \min \lambda_j \quad (10)$$

将特征向量标准正交化可得, 即 $w_j^T B w_j = \delta_{ij}$ 可以使输出满足约束条件(3)和(4), 由于假设 $x(t)$ 的均值为 0, 故也满足约束条件(1).

(2) 非线性

就非线性情况而言, 设一个有限维的函数空间 F , 基为 h_1, \dots, h_M , 例如 F 为多项式函数空间. 二阶多项式扩展如下:

$$\mathbf{x} = [x_1, x_2] \xrightarrow{\text{二阶扩展}} \mathbf{h}(\mathbf{x}) = [x_1, x_2, x_1 x_1, x_1 x_2, x_2 x_2]$$

设非线性扩展后为 $\mathbf{h}(\mathbf{x}) := (h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_M(\mathbf{x}))$, 对于任意函数 $g \in F$, 则有

$$g(\mathbf{x}) = \sum_{k=1}^M w_k h_k(\mathbf{x}) = \mathbf{W}^T \mathbf{h}(\mathbf{x}) \quad (11)$$

这样就将非线性情况转化为线性情况了, 同样这里需要把 $\mathbf{h}(\mathbf{x})$ 中心化^[6].

到此为止, 总结慢特征分析算法如下:

① 线性情况略去此步骤, 非线性情况, 对输入信号做非线性扩展 $\mathbf{h}(\mathbf{x}) := (h_1(\mathbf{x}), \dots, h_M(\mathbf{x}))$;

② 解广义特征值问题 $\mathbf{A}\mathbf{W} = \mathbf{A}\mathbf{B}\mathbf{W}$, 其中 $\mathbf{A} = \langle \dot{\mathbf{x}} \dot{\mathbf{x}}^T \rangle$, $\mathbf{B} = \langle \mathbf{x} \mathbf{x}^T \rangle$, 对于非线性情况, $\mathbf{h}(\mathbf{x})$ 替换式中 \mathbf{x} 即可, 其中时间导数通过 $\dot{\mathbf{x}}(t) = \mathbf{x}(t) - \mathbf{x}(t-dt)$ 实现, 解得 w_1, w_2, \dots, w_N 为对应于 $\lambda_1 < \lambda_2 < \dots < \lambda_N$ 的特征向量;

③ 求输出 $y_j(t) = g_j(\mathbf{x}(t)) = w_j^T \mathbf{h}(\mathbf{x})$.

1.4 SFA 应用于盲源分离

众所周知, 独立分量分析用于线性盲源分离, 而在非线性盲源分离中, 仅有独立性的约束已不能分离混合信号了, 将慢特征分析算法用于盲源分离是基于以下原因: 若对源信号做非线性混合, 混合后的信号要比源信号变化得更快, 最简单的例子就是对正弦波做平方运算可以得到频率加倍的信号, 变化更快. 由于慢特征分析算法可从复杂多变的信号中提取出慢变的信号, 所以考虑将其应用于盲源分离, 认为提取出的慢变信号即为源信号的近似.

2 仿真实验结果

仿真实验一: 采用的源信号是 Matlab 仿真的三角函数信号 s_1 和 s_2 , 信号频率分别为 20 Hz 和 60 Hz, 采样频率为 5 kHz, 取 1000 个采样点. 对源信号进行非线性混合, 此模型又称为线性非线性线性混合模型, 在实际应用中具有广泛的意义, 例如它表示信号首先经过一个线性无记忆信道, 然后经过传感器或前置放大器引入无记忆的非线性变换,

最后又产生交叉信道混合, 例如在传感器阵列处理、卫星和微波通信、以及生物医学领域存在无记忆非线性模型. 因此这个模型除可用于理论分析外, 对许多实际应用也很有价值. 公式可表示为

$$x_k = \sum_{i=1}^n b_{ki} f_i \left(\sum_{j=1}^n a_{ij} s_j \right)$$

矩阵形式为

$$\mathbf{X} = \mathbf{B} \mathbf{f}(\mathbf{A} \mathbf{S}) \quad (12)$$

在实验一中, \mathbf{A} 取二阶单位矩阵, 模拟较理想情况下的线性无记忆信道, 所以输出仍为 s_1 和 s_2 , 且作为非线性 $f(\cdot)$ 的输入, $f(\cdot)$ 混合形式如下:

$$\begin{cases} f_1 = s_1 + (s_2)^2 \\ f_2 = s_2 \end{cases} \quad (13)$$

交叉信道混合矩阵为随机产生, $\mathbf{B} = \begin{bmatrix} 0.5 & 0.7 \\ 0.9 & 0.3 \end{bmatrix}$,

则混合信号可以表示为

$$\begin{aligned} \mathbf{X} = \mathbf{B} \mathbf{f}(\mathbf{A} \mathbf{S}) = & \begin{bmatrix} 0.5 & 0.7 \\ 0.9 & 0.3 \end{bmatrix} \begin{bmatrix} s_1 + (s_2)^2 \\ s_2 \end{bmatrix} = \\ & \begin{bmatrix} 0.5s_1 + 0.5(s_2)^2 + 0.7s_2 \\ 0.9s_1 + 0.9s_2^2 + 0.3s_2 \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \end{aligned} \quad (14)$$

图 1 为两个源信号波形图, 图 2 为两个源信号经过上述线性非线性线性混合后的信号, 图 3 为将混合信号作为基于二阶多项式扩展的 SFA 算法的输入信号生成的前两个输出信号 y_1 和 y_2 , 在 1.4 节中提到过, SFA 用于盲源分离的原因在于其可以从复杂变换信号中提取慢特征, 认为提取出的慢特征即为源信号的近似估计. 本实验采用的源信号较简单是为了通过观察就可以将源信号与分离信号做对比. 图 3 与图 1 对比发现, SFA 算法可以成功地实现非线性盲源分离, 本实验属于理论研究, 对实际应用具有一定启示作用.

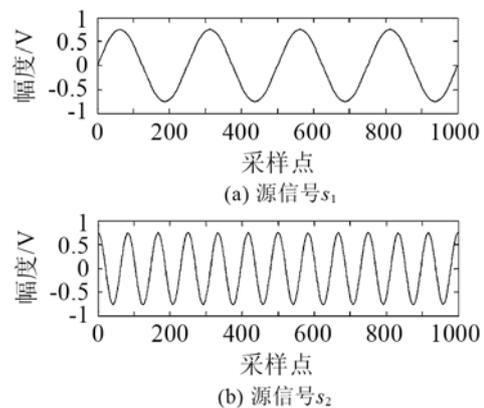


图 1 (a)源信号 s_1 (b)源信号 s_2
Fig.1 (a) Source signal s_1 ; (b) Source signal s_2

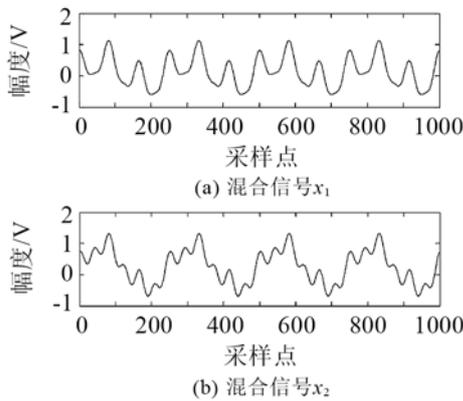


图 2 (a)混合信号 x_1 (b)混合信号 x_2
Fig.2 (a) Mixed signal x_1 ; (b) Mixed signal x_2

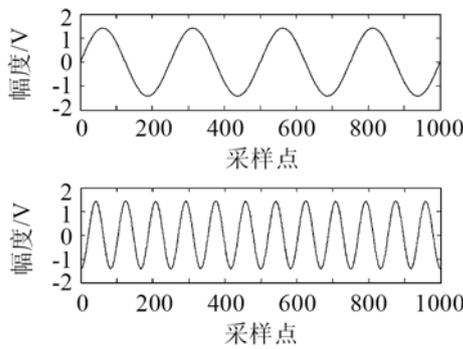


图 3 SFA 输出信号
Fig.3 Output signals of SFA corresponding to Fig.2

实验一中采用的是基于二阶多项式扩展的非线性情况下的 SFA 算法，由 1.3 节知，对于二维信号，SFA 输出为 5 个，这里只取与源信号数目 n 相同的前 n 个输出，这也说明了 SFA 适用于源信号数目已知盲源分离算法。除前 n 个输出外，其他为源信号的高阶非线性形式。

仿真实验二：源信号采用海狮和鲸鱼的叫声，信号采样频率为 44 100 Hz，采样点数取 5 000 个，混合模型同实验一所采用的模型相同。

图 4 为两个源信号 s_1 和 s_2 波形图，图 5 为经过非线性混合后的混合信号，图 6 为基于二阶多项式扩展的 SFA 前两个输出信号。对于复杂信号，通过直接观察源信号与分离信号的相似程度比较困难，所以在此采用散点图，散点图是由两个信号的对应采样点的幅度值构成坐标对，坐标对所对应的点显示在图中，图 7(a)为源信号 s_1 和 s_2 的散点图，图 7(b)为混合信号 x_1 和 x_2 构成的散点图，可以看出图 7(b)和图 7(a)相差很大，这说明实验中所采用的非线性混合模型对源信号的扭曲程度非常大。图 7(c)为 SFA 算法输出信号的散点图，可以看出图 7(c)和图 7(a)较相似，说明 SFA 算法输出信号和源信号较相似，图 7(d)为采用独立成分分析算法做盲源分离输

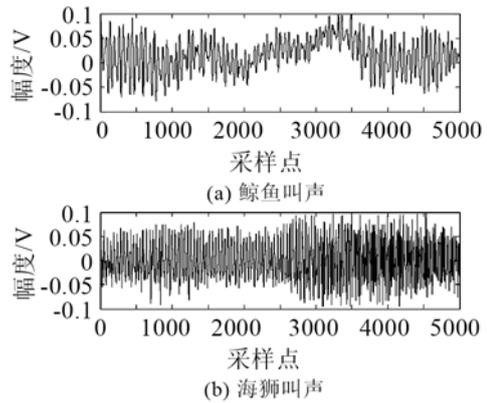


图 4 (a)鲸鱼叫声 (b)海狮叫声
Fig.4 (a) Whale call; (b) Sea lion call

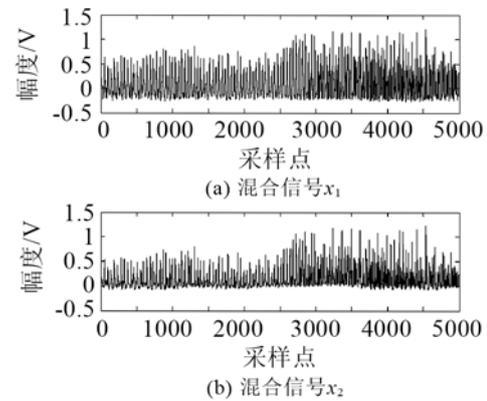


图 5 (a)混合信号 x_1 (b)混合信号 x_2
Fig.5 (a) Mixed signal x_1 ; (b) Mixed signal x_2

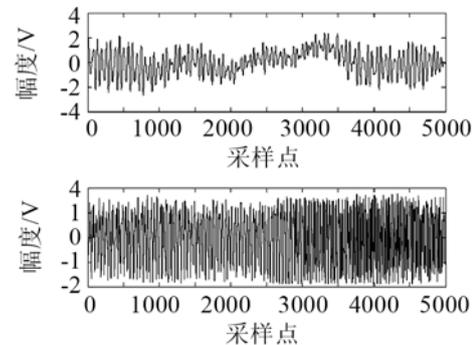


图 6 SFA 输出信号
Fig.6 Output signals of SFA corresponding to Fig.5

出信号的散点图，可以看出图 7(d)和图 7(a)相差较大，实际上图 7(d)只是图 7(b)旋转形式，说明独立成分分析算法对于非线性盲源分离的无能为力。

实验二和实验一采用不同的源信号、相同的混合模型，实验结果表明，SFA 算法不仅可以分离简单信号的非线性混合信号，也可以分离复杂信号的非线性混合，且分离信号与源信号相似度较高。分离简单信号的效果优于分离复杂信号的效果，说明 SFA 性能与源信号有关。从输出信号中也可以看出，SFA 输出信号按照信号变化快慢的程度排列，

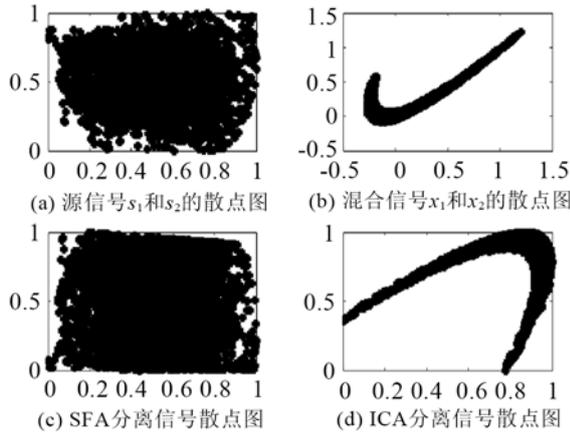


图7 (a) 源信号 s_1 和 s_2 的散点图 (b) 混合信号 x_1 和 x_2 散点图
(c) SFA 分离信号散点图 (d) ICA 分离信号散点图

Fig.7 Scatter plots of input signals s_1 and s_2 (a), nonlinear mixed signals x_1 and x_2 (b), separated signals by SFA (c), separated signals by ICA (d)

变化越慢的信号, 输出越靠前, 与 ICA 输出次序不确定相比的又一优点。

3 结 语

本文提出将慢特征分析算法应用于水声信号

盲处理中, 并取得了很好的效果, 通过仿真验证了算法的有效性和可行性。但是目前由于完全非线性混合盲分离问题的复杂性, 现有的非线性混合信号盲分离算法研究的都是较简单的非线性混合的情况, 对更一般的非线性混合信号的可分离性以及可分离的充要条件需作进一步的研究。

参 考 文 献

- [1] Jutten C, Herault J. Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic[J]. *Signal Processing*, 1991, **24**(1): 1-10.
- [2] 郑春厚. 独立分量分析算法及其应用研究[D]. 安徽: 中国科学技术大学博士学位论文, 2006.
- [3] Comon Pierre. Independent Component Analysis, A New Concept?[J]. *Signal Processing*, 1994, **36**(3), 287-314.
- [4] Wiskott L, Sejnowski T. Slow feature analysis: unsupervised learning of invariances[J]. *Neural Computation*, 2002, **14**(4): 715-770.
- [5] Blaschke T, Berkes P, Wiskott. What is the relationship between slow feature analysis and independent component analysis?[J]. *Neural Computation*, 2006, **18**(10): 2495-2508.
- [6] Blaschke T, Zito T, Wiskott L. Independent slow feature analysis and nonlinear blind source separation[J]. *Neural Computation*, 2007, **19**(4): 994-1021.