

联合非高斯性和非线性自相关的有噪盲源分离算法

陈寿齐 沈越泓 许魁

(解放军理工大学通信工程学院, 南京 210007)

摘要: 现有的盲源分离算法往往利用信号某一方面的统计特性来分离信号, 例如: 利用信号的非高斯特性, 或者利用信号的时序特性。在实际应用中, 信号往往是具有这两种特性信号的混合, 采用信号某一方面的特性往往不能够成功的分离出信号。现有的盲源分离算法往往不考虑噪声的影响, 但在实际应用中, 噪声的影响是不可避免的。当源信号具有非高斯性和非线性自相关特性时, 提出了联合非高斯性和非线性自相关特性的有噪盲源分离算法。计算机仿真表明了提出算法的有效性, 和现有的基于非高斯性和非线性自相关特性的有噪盲源分离算法相比, 提出算法具有更好的信号分离性能。

关键词: 盲源分离; 非高斯性; 非线性自相关; 高斯矩

中图分类号: TN911.7 文献标识码: A 文章编号: 1003-0530(2010)01-0141-05

Blind source separation for noisy mixtures with non-Gaussianity and nonlinear autocorrelation

CHEN Shou-qi SHEN Yue-hong XU Kui

(Institute of Communications Engineering, PLA University of Science and Technology, Nanjing 210007, China)

Abstract: One often solve the BSS problem by using the statistical properties of original sources, e.g., non-Gaussianity or time-structure information. Nevertheless, real-life mixtures are likely to contain both non-Gaussianity and time-structure information, rendering the algorithm using only one statistical property fail. The BSS algorithms are often limited to noise-free mixtures, which are not realistic. Therefore, this paper address the separation of the noisy model based on non-Gaussianity and nonlinear autocorrelation of sources. An objective function which based on the two statistical characteristics of sources is proposed. Maximizing this objective function, we present a blind source separation algorithm for noisy mixtures. The validity of the proposed algorithm is demonstrated by computer simulation. Moreover, comparisons with the existing algorithm for noisy mixtures based on non-Gaussianity and nonlinear autocorrelation indicate the better performance.

Key words: Blind source separation; Non-Gaussianity; Nonlinear autocorrelation; Gaussian moments

1 引言

盲源分离是指在不知道源信号和传输通道参数的情况下, 根据输入源信号的统计特性, 仅由观测信号恢复出源信号的过程^[1]。作为一种新兴的信号处理技术, 盲源分离在生物医学信号处理、语音信号处理、图像处理、数据挖掘模式识别和通讯信号处理等^[2]领域引起了人们的广泛关注。

根据源信号的统计特性, 人们提出了大量的盲源分离算法。例如: 利用信号的非高斯特性^[3-8]分离信号, 利用信号的时序特性^[9-14]分离信号等等。但是现有的盲源分离算法往往利用信号某一方面的统计特性来

分离信号, 例如: 仅利用信号的非高斯特性, 或者仅利用信号的时序特性来分离信号。在实际应用中, 混合的信号往往是具有非高斯特性信号和时序结构特性信号的混合, 利用信号某一方面的统计特性往往不能够成功分离出这样的信号。

现有的盲源分离算法往往不考虑噪声的影响, 或者认为噪声的影响可以忽略不计, 但在实际应用中, 噪声的影响是不可避免的。因此, 在设计盲源分离算法时, 必须要考虑到噪声的影响。

当源信号是具有非高斯特性和非线性自相关特性信号混合时, 提出了基于高斯矩的联合信号的非高斯性和非线性自相关性的目标函数, 最大化这个目标函

数,提出了梯度上升的盲源分离算法。计算机仿真表明了提出算法的有效性,和现有的基于非高斯性和非线性自相关特性的有噪盲源分离算法相比,提出算法具有更好的信号分离性能。

文章共分为四个部分:第一部分为引言,简单介绍了盲源分离的现状,并引出了相应的联合非高斯性和非线性自相关特性的有噪盲源分离算法;第二部分提出了基于高斯矩的联合非高斯性和非线性自相关的目标函数,并推导了相应的梯度算法;第三部分介绍了计算机仿真;文章最后给出了结论。

2 提出算法

2.1 准白化

假设观测信号 $\mathbf{x}(t) = [x_1(t), \dots, x_n(t)]^T$ 用矩阵方程描述为:

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

其中, \mathbf{A} 是 $n \times n$ 维的未知混合矩阵, $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ 是未知的具有时序结构特性的源信号矢量。 $\mathbf{n}(t) = [n_1(t), \dots, n_n(t)]^T$ 是加性高斯白噪声。高斯噪声 $\mathbf{n}(t)$ 和源信号 $\mathbf{s}(t)$ 是相互统计独立的, $\mathbf{n}(t)$ 的协方差矩阵被定义为: $\Sigma = E\{\mathbf{n}(t)\mathbf{n}(t)^T\}$ 。

在噪声存在的情况下,对观测信号 $\mathbf{x}(t)$ 的白化预处理就必须要考虑到噪声的影响,如果噪声的方差已知或者可以估计的情况下,这样的方法是简单的。假设观测信号 $\mathbf{x}(t)$ 的协方差矩阵为: $\mathbf{C} = E\{\mathbf{x}(t)\mathbf{x}(t)^T\}$ 。正常的白化方法就要变成为下面的准白化,也就是, $\tilde{\mathbf{x}}(t) = (\mathbf{C} - \Sigma)^{-1/2}\mathbf{x}(t)$ 。准白化的数据 $\tilde{\mathbf{x}}(t)$ 满足有噪的盲源分离的模型:

$$\tilde{\mathbf{x}}(t) = \mathbf{B}\mathbf{s}(t) + \tilde{\mathbf{n}}(t) \quad (2)$$

其中, $\mathbf{B} = (\mathbf{C} - \Sigma)^{-1/2}\mathbf{A}$ 是一个正交的混合矩阵。噪声 $\tilde{\mathbf{n}}(t)$ 是源噪声信号 $\mathbf{n}(t)$ 的线性变换,它的协方差矩阵有如下的形式:

$$\tilde{\Sigma} = E\{\tilde{\mathbf{n}}(t)\tilde{\mathbf{n}}(t)^T\} = (\mathbf{C} - \Sigma)^{-1/2}\Sigma(\mathbf{C} - \Sigma)^{-1/2} \quad (3)$$

2.2 非线性自相关

考虑到无噪情况下的数据模型: $\mathbf{y}(t) = \mathbf{B}\mathbf{s}(t)$ 。假设源信号具有时序结构和不同的自相关函数。

为了提取期望信号,有下面的一单元处理公式:

$$\begin{cases} \mathbf{z}(t) = \mathbf{w}^T \mathbf{y}(t) \\ \mathbf{z}(t-\tau) = \mathbf{w}^T \mathbf{y}(t-\tau) \end{cases} \quad (4)$$

其中, $\mathbf{w} = (w_1, \dots, w_n)^T$ 是解混矢量, $\mathbf{z}(t)$ 和 $\mathbf{z}(t-\tau)$ 分别代表 t 和 $t-\tau$ 时刻提取出来的期望信号, τ 为时间延迟。公式(5)给出了期望提取信号 $\mathbf{z}(t)$ 的具有非线性自相关特性的表达式:

$$\Psi(\mathbf{w}) = E\{G(z(t))G(z(t-\tau))\} \quad (5)$$

这里的 $G(\cdot)$ 是可微分的函数,它用来衡量期望提取信号的自相关程度。在 $\mathbf{w}\mathbf{w}^T = 1$ 的约束条件下,最大化公式(5)可以获得如下的 FixNA 算法^[11]。

$$\begin{aligned} \mathbf{w} &\leftarrow E\left\{g(z(t))G(z(t-\tau))\mathbf{y}(t) + G(z(t))\right. \\ &\quad \left.g(z(t-\tau))\mathbf{y}(t-\tau)\right\} \\ \mathbf{w} &\leftarrow \mathbf{w} / \|\mathbf{w}\| \end{aligned} \quad (6)$$

其中,函数 $g(\cdot)$ 是函数 $G(\cdot)$ 的导函数。

2.3 高斯矩

上述的非线性自相关的不动点算法,没有考虑到噪声对算法性能的影响,如果能从带噪的观测数据中估计出无噪模型的代价函数,该方法就能够应用到有噪的盲源分离模型中去。

定义协方差为 c^2 的高斯密度函数:

$$\varphi_c(x) = \frac{1}{c} \varphi\left(\frac{x}{c}\right) = \frac{1}{\sqrt{2\pi c}} \exp\left(-\frac{x^2}{2c^2}\right) \quad (7)$$

用 $\varphi_c^{(l)}(x)$ 来表示函数 $\varphi_c(x)$ 的 l ($l > 0$) 阶导数,用 $\varphi_c^{(-l)}(x)$ 表示函数 $\varphi_c(x)$ 的 l 阶积分,具体的表达式为: $\varphi_c^{(-l)}(x) = \int_0^x \varphi_c^{(-l+1)}(\xi) d\xi$, 这里 $\varphi_c^{(0)}(x) = \varphi_c(x)$ 。

那么有下面的定理^{[7][8]}:

定理 1: 对于任意的非高斯随机变量 v , n 表示方差为 σ^2 的独立的高斯噪声变量, 定义高斯函数如公式(7), 那么对于任意的 $c > \sigma^2$ 有下面的表达式成立:

$$E\{\varphi_c(v)\} = E\{\varphi_d(v+n)\} \quad (8)$$

其中, $d = \sqrt{c^2 - \sigma^2}$ 。 k 为任意的整数,当 φ 被 $\varphi^{(k)}$ 代替时,上述公式依然成立。

此定理说明可以通过最大化目标函数(5)来从有噪的观测数据中估计出源信号分量。可以通过选取 $G(u) = \varphi_c^{(k)}(u)$ 估计统计量 $E\{G(z(t))\}$, 这里具有 $E\{\varphi_c^{(k)}(\mathbf{w}^T \mathbf{y}(t))\}$ 形式的统计量叫高斯矩。

2.4 目标函数

当源信号是具有非高斯性和非线性自相关特性的信号混合时,给出如下的基于非高斯性和非线性自相关特性的目标函数:

$$\max_{\|\mathbf{w}\|} \Phi(\mathbf{w}) = \lambda E\{G(z(t))\} + (1 - \lambda) E\{G(z(t))G(z(t-\tau))\} \quad (9)$$

上述目标函数利用了期望提取信号所具有的非高斯性和非线性自相关的特性。其中, $G(\cdot)$ 是一个可微分的函数,表示衡量信号的非高斯性和非线性自相关特性的程度,在 ICA 领域,众所周知,有关高阶统计的非二次函数并不是十分重要的。因此,可以假设函数 $G(\cdot)$ 的准确形式并不是十分重要的,只要具有一定的相似程度就可以了。考

虑到采用 $G(u) = -\log \cosh(u)$ 具有好的性能和对野值具有很好的健壮性,因此,在文章中采用 $G(u) = -\log \cosh(u)$ 。 $\lambda(0 \leq \lambda \leq 1)$ 表示衡量信号非高斯特性的相对权重, $(1 - \lambda)$ 表示衡量信号非线性自相关特性的相对权重。上述的目标函数(9)没有考虑到噪声的影响,根据定理1,可知,由高斯矩可以从有噪的观测数据中估计出源信号分量,由公式(8,9)就能够通过最大化公式(10)估计有噪的盲源分离模型。

$$\begin{cases} \max \Phi(\mathbf{w}) = \lambda E \left\{ \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \right\} + (1 - \lambda) \\ \quad E \left\{ \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t - \tau)) \right\} \\ \text{s. t. } \mathbf{w}\mathbf{w}^T = 1 \end{cases} \quad (10)$$

其中, $d(\mathbf{w}) = \sqrt{c^2 - \mathbf{w}^T \tilde{\Sigma} \mathbf{w}}$, $\tilde{y}(t) = \mathbf{w}^T \tilde{\mathbf{x}}(t)$, $\tilde{y}(t - \tau) = \mathbf{w}^T \tilde{\mathbf{x}}(t - \tau)$ 。

2.5 学习算法

在推导算法之前,注意到 $\varphi_c^{(k)}(x) = \varphi^{(k)}\left(\frac{x}{c}\right)c^{(-k-1)}$, 并

且 $d(\mathbf{w}) = \sqrt{c^2 - \mathbf{w}^T \tilde{\Sigma} \mathbf{w}}$ 。

那么, $\varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t))$ 的关于 \mathbf{w} 的梯度为:

$$\begin{aligned} \nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) &= \varphi_{d(\mathbf{w})}^{(k+1)}(\tilde{y}(t)) \tilde{\mathbf{x}}(t) + d^{-2}(\mathbf{w}) \\ &\quad \tilde{y}(t) \varphi_{d(\mathbf{w})}^{(k+1)}(\tilde{y}(t)) \tilde{\Sigma} \mathbf{w} \\ &\quad + d^{-2}(\mathbf{w})(k+1) \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \tilde{\Sigma} \mathbf{w} \end{aligned} \quad (11)$$

由文献^[8]中的引理,可得到:

$$\begin{aligned} d^{-2}(\mathbf{w}) \tilde{y}(t) \varphi_{d(\mathbf{w})}^{(k+1)}(\tilde{y}(t)) + d^{-2}(\mathbf{w})(k+1) \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \\ = -\varphi_{d(\mathbf{w})}^{(k+2)}(\tilde{y}(t)) \end{aligned} \quad (12)$$

这就意味着公式(11)可表示为:

$$\nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) = \varphi_{d(\mathbf{w})}^{(k+1)}(\tilde{y}(t)) \tilde{\mathbf{x}}(t) - \varphi_{d(\mathbf{w})}^{(k+2)}(\tilde{y}(t)) \tilde{\Sigma} \mathbf{w} \quad (13)$$

同样可以得到, $\varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t - \tau))$ 的关于 \mathbf{w} 的梯度为:

$$\begin{aligned} \nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t - \tau)) &= \varphi_{d(\mathbf{w})}^{(k+1)}(\tilde{y}(t - \tau)) \tilde{\mathbf{x}}(t - \tau) - \\ &\quad \varphi_{d(\mathbf{w})}^{(k+2)}(\tilde{y}(t - \tau)) \tilde{\Sigma} \mathbf{w} \end{aligned} \quad (14)$$

那么,目标函数(10)的关于 \mathbf{w} 的梯度为:

$$\begin{aligned} \nabla_{\mathbf{w}} \Phi(\mathbf{w}) &= \lambda E \left\{ \nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \right\} + (1 - \lambda) \\ &\quad E \left\{ \nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t - \tau)) + \nabla_{\mathbf{w}} \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t - \tau)) \right. \\ &\quad \left. \varphi_{d(\mathbf{w})}^{(k)}(\tilde{y}(t)) \right\} \end{aligned} \quad (15)$$

选择 $G(u) = \varphi^{(k)}(u)$, 可获得对于准白化数据的最终形式的梯度为:

$$\begin{aligned} \nabla_{\mathbf{w}} \Phi(\mathbf{w}) &= \lambda E \left\{ g(\tilde{y}(t)) \tilde{\mathbf{x}}(t) - g'(\tilde{y}(t)) \tilde{\Sigma} \mathbf{w} \right\} \\ &\quad + (1 - \lambda) E \left\{ \left(g(\tilde{y}(t)) \tilde{\mathbf{x}}(t) - g'(\tilde{y}(t)) \tilde{\Sigma} \mathbf{w} \right) G(\tilde{y}(t - \tau)) \right. \\ &\quad \left. + \left(g(\tilde{y}(t - \tau)) \tilde{\mathbf{x}}(t - \tau) - g'(\tilde{y}(t - \tau)) \tilde{\Sigma} \mathbf{w} \right) G(\tilde{y}(t)) \right\} \end{aligned} \quad (16)$$

其中, $\tilde{\Sigma}$ 由公式(3)给出, 函数 $g(\cdot)$ 是函数 $G(\cdot)$ 的导函数, 函数 $g'(\cdot)$ 是函数 $g(\cdot)$ 的导函数。

综上所述,可获得联合信号的非高斯性和非线性自相关特性的有噪盲源分离算法的过程如下:

1. 中心化观测数据 $\mathbf{x}(t)$,使得它的均值为0,并计算观测信号 $\mathbf{x}(t)$ 的协方差矩阵 $\mathbf{C} = E\{\mathbf{x}(t)\mathbf{x}(t)^T\}$ 。
2. 对观测信号 $\mathbf{x}(t)$ 进行准白化预处理,得到新的观测值 $\tilde{\mathbf{x}}(t) = (\mathbf{C} - \Sigma)^{-1/2} \mathbf{x}(t)$ 。
3. 随机选择一个矩阵 $\mathbf{W} = [\mathbf{w}_1 \cdots \mathbf{w}_n]^T$ 作为迭代的初始点。
4. 计算 $\tilde{y}_i(t) = \mathbf{w}_i^T \tilde{\mathbf{x}}(t), (i = 1, 2, \dots, n)$ 。
5. 根据公式(13)做 $\Phi(\mathbf{w})$ 的关于 \mathbf{w} 的梯度 $\nabla_{\mathbf{w}} \Phi(\mathbf{w})$, 并选择合适的 $G(\cdot)$ 函数。
6. 用表达式 $\mathbf{W} \leftarrow \mathbf{W} + \mu \nabla_{\mathbf{w}} \Phi(\mathbf{w})$ 来更新分离矩阵 \mathbf{W} , μ 是学习步长。
7. 用表达式 $\mathbf{W} \leftarrow (\mathbf{W} \mathbf{W}^T)^{(-1/2)} \mathbf{W}$ 来做矩阵 \mathbf{W} 的对称正交化。
8. 如不满足终止条件,返回步骤4。

算法的终止条件为:迭代前的 \mathbf{w}_i 和迭代后的 \mathbf{w}_i 同指一个方向,也就是,它们的内积等于或接近于1($i = 1, 2, \dots, n$)。

3 计算机仿真

生成具有非高斯性和非线性自相关特性的20路信号用于仿真,10路(ACvsparse10.mat)非高斯信号,取至于 <http://www.bsp.brain.riken.jp/ICALAB/ICALABSignalProc/benchmarks/>。10路具有非线性自相关特性的信号采用下述方法产生:首先,生成10路具有AR(1)模型的信号,这些信号是由高斯更新生成的;所有的信号都具有单位方差和相同的自回归系数(0.9),这10路信号被等概取得±符号的信号随机相乘,信号的样点数为1000,具体的20路信号如图1所示。

这20路源信号被 20×20 维的随机产生的矩阵混合,加性高斯白噪声的方差为0.25I,混合后的信号如图2所示。

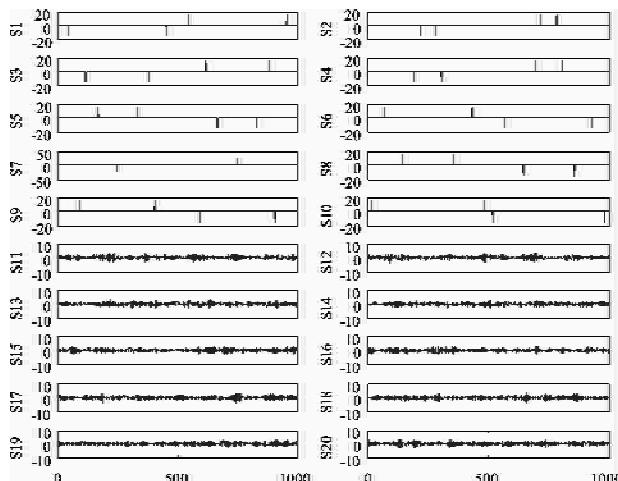


图 1 源信号

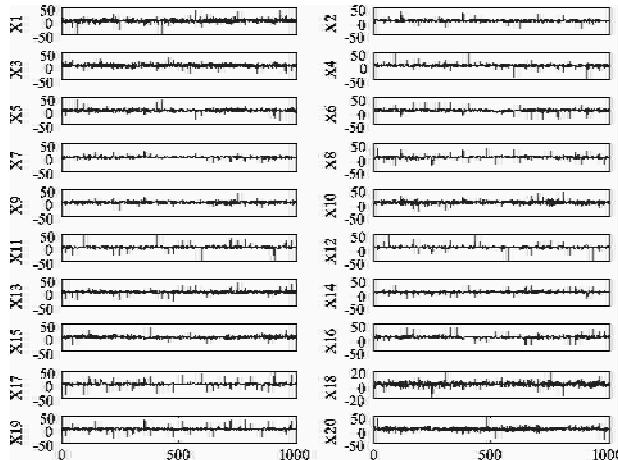


图 2 混和后的信号

采用 PI 性能指数来评价算法分离信号的性能, 具体的定义如下:

$$PI = \frac{1}{N^2} \left\{ \sum_{i=1}^N \left(\sum_{j=1}^N \frac{|p_{ij}|}{\max_k |p_{ik}|} - 1 \right) + \sum_{j=1}^N \left(\sum_{i=1}^N \frac{|p_{ij}|}{\max_k |p_{kj}|} - 1 \right) \right\} \quad (17)$$

其中, p_{ij} 是 $N \times N$ 维全局矩阵 $\mathbf{P} = \mathbf{WA}$ 的第 i 行和第 j 列的元素, PI 值越小, 对混合信号的分离性能越好。

采用公式(17)所采用的性能指数定义评价提出算法分离信号的性能, 算法迭代到固定的迭代次数 N 时停止, 迭代次数 N 由 1 变化到 200。对于每一个固定的迭代次数 N , 算法独立运算 100 次, 每次信号都用随机生成的混合矩阵来混合, 并计算每一次的性能指数, 最后的性能指数是这 100 次性能指数的平均。

采用下面的两组条件来比较本文提出的算法:

- 对算法采用不同学习步长的方法来分离信号, 学习步长 μ 选择依次为: 1、0.9、0.8、0.7、0.6 和 0.5。(时间延迟为 $\tau=1$, 相对权重为 $\lambda=0.5$)
- 对算法采用固定学习步长的方法来分离信号, 时间

延迟选择为 1 到 6, 相对权重取值从 0 到 1, 间隔为 0.05。

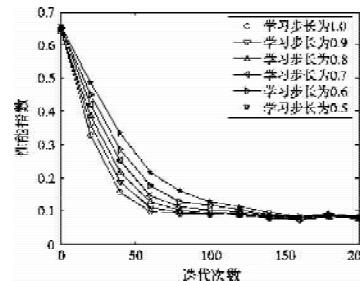


图 3 采用不同学习步长的性能指数曲线

图 3 给出了条件 1 情况下分离混合信号的平均性能曲线图, 可以看出, 采用不同的学习步长对算法的收敛速度有一定的影响, 但是不影响算法对混合信号的分离性能, 也就是, 当算法收敛后, 采用不同的学习步长得到的性能指数值趋于一致。

针对条件 2, 采用固定的学习步长为 1 时, 针对不同的时间延迟和不同的相对权重对混合信号进行分离仿真, 算法的最大迭代次数为 200。

图 4 给出了条件 2 情况下采用不同的时间延迟和相对权重的性能指数曲线, 可以看出, 当采用时间延迟 τ 为 1 时, 所得到的性能指数曲线为几组性能指数曲线中最好的曲线, 这验证了源信号具有一阶自回归特性的实际。当时间延迟 τ 为 1 和相对权重 λ 为 0.7 时, 在六组性能指数曲线中, 可取得最小的性能指数值, 可见当时间延迟 τ 为 1 和相对权重 λ 为 0.7 时, 提出算法对混合信号的分离性能最好。

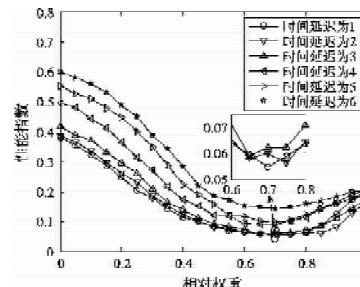


图 4 采用不同时间延迟和相对权重的性能指数曲线

通过上述两组条件的分离仿真, 可以看出对于本文提出算法在采用学习步长 μ 、时间延迟 τ 和相对权重 λ 的选择依次为: 1、1 和 0.7 时对混合信号的分离性能最好。

上述的 20 路混

合信号是不能够被传统的基于信号的非高斯性的算法和具有非线性自相关特性的有噪盲源分离算法分离。采用文献[8]算法(记为 FastNoisyICA 算法)、文献[14]算法(记为 FixNANOISy 算法)和本文提出算法对 20 路混合信号进行分离仿真。

具体的仿真参数设置为: FastNoisyICA 算法中的 $G(\cdot)$ 函数选择为 $G(u) = \log(\cosh(u))$; FixNANOISy 算法中的 $G(\cdot)$ 函数选择 $G(u) = \log(\cosh(u))$, 因为 FixNANOISy 算法是盲提取算法, 在本文中需对分离矩阵采取对称正交化的处理, 这两个算法都是不动点算法不需要选择学习步长; 对于本文提出算法中的 $G(\cdot)$ 函数选择为 $G(u) = -\log(\cosh(u))$, 学习步长 μ 、时间延迟 τ 和相对权重 λ 的选择依次为: 1、1 和 0.7。

图5给出了本文提出算法分离出来的信号,可以看出本文提出算法成功实现了对这20路混合信号的分离。

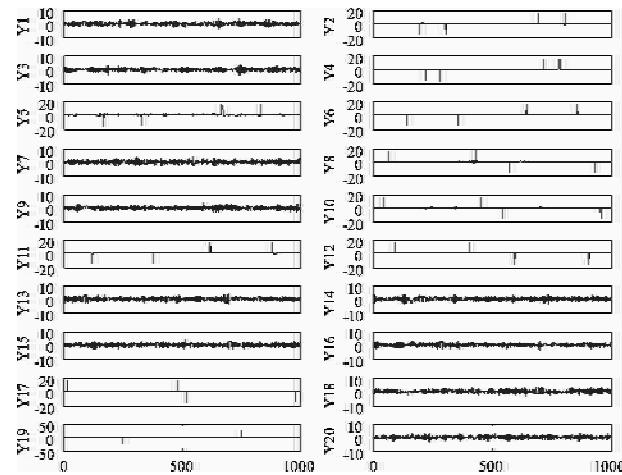


图5 本文算法分离出的信号

图6给出了三种算法分离混合信号的平均性能曲线图,可以看出,本文提出算法对这些源信号的分离效果最好, FastNoisyICA 算法次之,而 FixNA-Noisy 算法的分离效果最差。

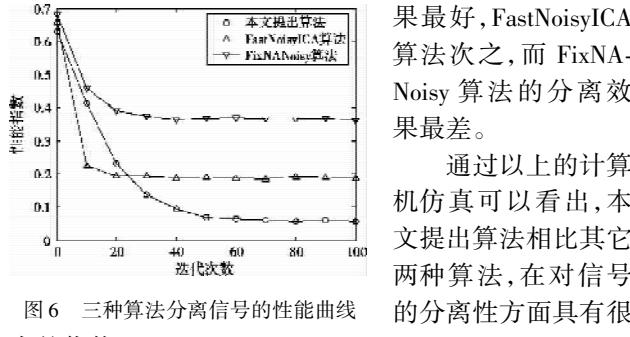


图6 三种算法分离信号的性能曲线图

4 结论

在实际应用中,混合的信号往往是具有非高斯特性信号和时序结构特性信号的混合,利用信号某一方面的统计特性往往不能够成功分离出这样的混合信号。当源信号是具有非高斯特性和非线性自相关特性信号混合时,提出了基于高斯矩的联合信号的非高斯性和非线性自相关性的目标函数,最大化这个目标函数,提出了一个梯度上升的有噪盲源分离算法。该算法解决了利用信号某一方面的统计特性不能够成功分离这类混合信号的问题,提供了解决这类信号盲分离的新的方法。

计算机仿真表明了提出算法的有效性,和现有的基于非高斯性和非线性自相关特性的有噪盲源分离算法相比,提出算法具有更好的信号分离性能。

参考文献

- [1] A. Cichocki, S. Amari. Adaptive Blind Signal and Image Processing [M]. John Wiley & Sons Ltd, England, 2002.
- [2] A. Hyvärinen, J. Karhunen, E. Oja. Independent Component Analysis [M]. John Wiley & Sons Ltd, New York, 2001.
- [3] A. Bell, T. Sejnowski. An information-maximization approach to blind separation and blind deconvolution [J]. Neural Computation, 1995, 7(6):1129-1159.
- [4] J.-F. Cardoso, B. H. Laheld. Equivariant adaptive source separation [J]. IEEE Transactions on Signal Processing, 1996, 44(12):3017-3030.
- [5] A. Hyvärinen. Fast and robust fixed-point algorithm for independent component analysis [J]. IEEE Transaction on Neural Networks, 1999, 10(3):626-634.
- [6] Z. Shi, H. Tang, Y. Tang. A new fixed-point algorithm for independent component analysis [J]. Neurocomputing, 2004, 56:467-473.
- [7] A. Hyvärinen. FastICA for noisy data using Gaussian moments [C]. Proceeding of the International Symposium on Circuits and Systems, Orlando, FL, 1999, 57-61.
- [8] A. Hyvärinen. Gaussian moments for noisy independent component analysis [J]. IEEE Signal Process Lett, 1999, 6(6):145-147.
- [9] A. Hyvärinen. Complexity pursuit: separating interesting components from time-series [J]. Neural Computation, 2001, 13(4):883-898.
- [10] Z. Shi, H. Tang, Y. Tang. A new fixed-point algorithm for complexity pursuit [J]. Neurocomputing, 2004, 61:461-469.
- [11] Z. Shi, C. Zhang. Gaussian moments for noisy complexity pursuit [J]. Neurocomputing, 2006, 69:917-921.
- [12] Z. Shi, C. Zhang. Nonlinear innovation to blind source separation [J]. Neurocomputing, 2007, 71:406-410.
- [13] Z. Shi, Z. Jiang, F. Zhou. A fixed-pointed algorithm for blind source separation with nonlinear autocorrelation [J]. Journal of Computational and Applied Mathematics, 2008, doi:10.1016/j.cam.2008.03009.
- [14] H. Zhang, Z. Shi, C. Guo. Blind source extraction for noisy mixtures by combining Gaussian Moments and generalized autocorrelations [J]. Neural Process Lett, 2008, 28:209-225.

作者简介



陈寿齐,男,1975年4月出生于江苏省建湖县,现为解放军理工大学通信工程学院博士生。从事盲信号处理、通信抗干扰等方面的研究工作。

E-mail:jschenshouqi@163.com

沈越泓,男,1959年12月出生于湖北省武汉市,现为解放军理工大学通信工程学院教授、博士生导师,中国电子学会高级会员。从事数字通信、软件无线电、多载波通信系统等方面的研究工作。获多项军队、省市科技进步奖。在国内外发表学术论文60余篇,出版著作1部。

许魁,男,1982年11月出生于安徽省蚌埠市。现为解放军理工大学通信工程学院博士生。从事软件无线电、多载波通信系统中同步技术方面的研究工作。