

A Review on the Blind Source Separation Algorithm

Dandan He, Runjie Liu, Jinyuan Shen, Yuanyuan Chen

Schools of Information Engineering, Zhengzhou University, Zhengzhou

Email: dandanhebaby@163.com

Received: Sep. 10th, 2011; revised: Sep. 20th, 2011; accepted: Sep. 22nd, 2011.

Abstract: This paper studies the theory and application of Blind Source Separation (BSS). First, the background and the development prospects of BSS are described. Then, we briefly introduce and evaluate the definition of BSS, and summarize the classification of the algorithm; and finally, we discuss the application about the BSS algorithm in many different fields, in order BSS algorithm can be better applied in the future.

Keywords: Blind Source Separation; Separation Algorithm; Classification of the Algorithm; BSS Application

盲信号分离算法综述

何丹丹, 刘润杰, 申金媛, 陈圆圆

郑州大学信息工程学院, 郑州

Email: dandanhebaby@163.com

收稿日期: 2011年9月10日; 修回日期: 2011年9月20日; 录用日期: 2011年9月22日

摘要: 针对盲信号分离(BSS)方法的原理和应用进行了研究。首先, 对盲分离的产生背景和发展前景作出概要的叙述; 其次, 介绍和评述了盲分离的定义, 以及对算法的分类进行了归纳总结; 最后, 对 BSS 的算法在不同领域的实际应用进行了讨论, 以便 BSS 算法在未来可以得到更好的应用。

关键词: 盲信号分离; 分离算法; 算法分类; 盲分离应用

1. 引言

盲分离(BSS)算法最早就是从“鸡尾酒会”的问题引出来的。“鸡尾酒会”问题可以描述成为从许多混乱无章的谈话声音和噪声背景中获得所需要的某个或者几个谈话人的语音, 而 BSS 所要解决的问题就是从麦克风的阵列中记录到的混合语音信号中分离出每个说话者的声音信号, 进而识别出某个谈话者的声音。

盲信号分离是近几年才发展起来, 用于解决从多个混合观测信号中分离源信号的一门信号处理技术^[1]。通常观测信号来自于一族传感器的输出, 其中每一个传感器接收到的是多个源信号的一组混合, 然而, 一般情况下并不知道信号时怎样混合的, 因此只能利用观测的混合信号, 采用一定的算法对混合系统进行

求解, 从而实现盲信号的分离^[2]。本文将从算法原理入手, 研究分析盲信号分离的常用算法的优缺点, 如独立成分分析(ICA)法, 熵的最大化方法, 主成分分析(PCA)法^[3-5], 非线性主成分分析(非线性 PCA)法等。同时, 针对算法的分离结果进行分析评价, 并根据盲分离算法目前的发展状况, 指出未来的研究重点和发展方向。

2. 盲信号分离(BSS)基本理论

2.1. 数学模型

盲信号分离的处理过程是指从若干观测到的多个混合信号中分离或恢复出无法直接观测到的源信号。分离原理如图 1 所示, 其中, S 为源信号向量, A 为




Figure 1. Block diagram of blind signal separation
图 1. 盲信号分离原理框图

混合矩阵(即传输信道), \mathbf{x} 是观测信号向量, \mathbf{W} 为分离矩阵。

需要注意的是, 在使用该模型解决问题时需要以下几个假设条件^[6]:

- (1) 各源信号之间是相互统计独立的;
- (2) 所有的源信号间的混合方式是线性的;
- (3) 混合矩阵 \mathbf{A} 需要满足列满秩($N \leq M$)或者可逆的条件;
- (4) 在所有的源信号中最多只能有一个源信号服从高斯分布。

2.2. 原理描述

一般情况下, $x(t)$ 是通过 N 个传感器获得的 N 个观测信号 $x_i (i=1, 2, \dots, N)$, 而且每个观测信号 x_i 是 M 个独立源信号 $S_j (j=1, 2, \dots, M)$ 的线性混合。整个问题可以使用以下的混合方程来进行描述:

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

式中, $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T$ 为观测矢量; $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_M(t)]^T$ 为源信号矢量; \mathbf{A} 为 $N \times M$ 的未知混合矩阵; $\mathbf{n}(t)$ 为 $N \times 1$ 的噪声矢量。目前, 在研究盲信号分离问题时, 一般情况下不考虑观测噪声, 可以认为不存在噪声或噪声在进行盲分离之前已经通过其他方法降低到了可以忽略的程度。因此, 式(1)可以写为:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (2)$$

从观测到的信号矢量中分离出源信号的过程就称为解混合, 经过解混合之后的输出信号为:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \quad (3)$$

式中, \mathbf{W} 为 $M \times N$ 的分离矩阵, $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_M(t)]^T$ 为输出信号矢量。这里的输出 $\mathbf{y}(t)$ 可以看作是对源信号向量 $\mathbf{s}(t)$ 的拷贝或估计。因此, 可以知道, 在进行盲信号分离过程中, 最

核心的问题是要求解出分离矩阵 \mathbf{W} , 或是分离矩阵的学习算法。

3. 盲分离算法

在实际中, 运用盲分离算法解决问题时, 现已使用的算法有很多, 对现有的方法分类归纳如图 2 所示。

盲分离算法在现阶段, 对提到的算法一般分为三大类, 即独立分量分析(ICA)算法^[7-9], 熵的最大化法^[10], 以及非线性主分量分析(非线性 PCA)算法^[11]。一般情况下, 在使用 ICA 算法的时候, 对信号之间采用不同测度时, 所得到的最终的算法也是不一样的; 熵的最大化方法的要求是迫使输出尽可能的均匀散布在超立方体中; 而在使用非线性主分量分析算法解决问题的时候, 则要求在正交约束下来实现信号的分离。

在运用这些算法对信号进行处理的过程中, 前两种方法都是基于互信息和熵来进行分析的, 而在互信息和熵之间又存在如下的关系:

$$I(\mathbf{W}) = -H(\mathbf{y}; \mathbf{W}) + \sum_{i=1}^n H(y_i; \mathbf{W}) \quad (4)$$

式(4)中 $H(\mathbf{y}; \mathbf{W}) = -\int p(\mathbf{y}; \mathbf{W}) \log p(\mathbf{y}; \mathbf{W}) d\mathbf{y}$ 是输出向量 \mathbf{y} 各元素的联合熵, 这里的

$$H(y_i; \mathbf{W}) = -\int p(y_i; \mathbf{W}) \log p(y_i; \mathbf{W}) dy_i$$

表示的则是边缘熵。从以上式子中可以看出, 对于盲分离算法中, 可以将熵的最大化方法归结到独立分量分析(ICA)方法中。因此经常对盲信号分离算法分为两类: ICA 和非线性 PCA 算法。

在对分离矩阵 \mathbf{W} 进行求解时, 可用的算法形式很多, 但是具体的推导思想却是大同小异。盲信号处理

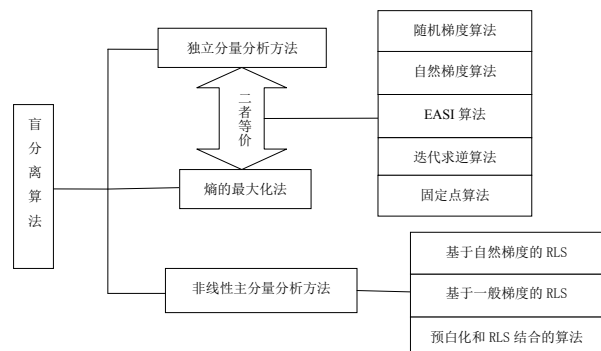


Figure 2. Classification of blind source separation algorithm
图 2. 盲分离算法分类

问题的基本框架是根据某种优化准则，首先去选择合适的对比函数，然后采用某种优化方法来求解出所需的分离矩阵。这个框架可以使用下面的等式来进行描述说明：

BSS 算法 = 对比函数 + 优化方法

因此，选用不同的对比函数的时候，相对应的得到的分离算法也是不同的。

3.1. 独立分量分析(ICA)

这里独立分量分析(ICA)方法采用最小互信息作为对比函数进行目标的分离。它的基本思想是选择变换矩阵 \mathbf{W} ，使最终输出 $y = \mathbf{W}x$ 各分量信号之间的相依性最小化。用输出 y 的联合概率密度函数

$p(y; \mathbf{W}) = p(y_1, \dots, y_n)$ 和边缘概率密度函数的乘积 $\tilde{p}(y; \mathbf{W}) = p(y_1) \dots p(y_n)$ 之间的 Kullback-Leibler 散度来表示输出 y 的相依性，即

$$I(\mathbf{W}) = D[p(y; \mathbf{W}) \| \tilde{p}(y; \mathbf{W})] \\ = \int p(y_1, \dots, y_n) \frac{p(y_1, \dots, y_n)}{p(y_1) \dots p(y_n)} dy_1 \dots dy_n \quad (5)$$

从上式可以看出，互信息是一个非负的值，即 $I(\mathbf{W}) \geq 0$ ，而且当且仅当输出 y 的各分量相互独立时，互信息的值才为零。因此， $I(\mathbf{W})$ 是独立分量分析方法的对比函数。根据对分离矩阵的不同的更新迭代方法，现介绍几种典型的算法。

(1) 随机梯度算法

这里对分离矩阵的迭代过程中使用瞬时或随机梯度进行计算，可以得到随机梯度算法，即

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta(t) (\mathbf{W}^{-T}(t) - \phi(y(t)) x^T(t)) \quad (6)$$

式中， $\eta(t)$ 是学习速率或步长。

但是此算法的缺点是收敛速度慢，而且在计算过程中涉及到分离矩阵的求逆运算，如果 $\mathbf{W}(t)$ 在更新过程中条件数变差的话，算法就可能会分散。

(2) 自然梯度算法

在随机梯度算法的基础上通过演变，用自然梯度来代替随机梯度，即可得到自然梯度算法如下所示：

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta(t) (I - \phi(y(t)) y^T(t)) \mathbf{W}(t) \quad (7)$$

其中，非线性变换函数为

$$\phi_i(y_i) = \alpha_i (k_3^i, k_4^i) y_i^2 + \beta_i (k_3^i, k_4^i) y_i^3$$

$$\text{这里,} \\ a_i(k_3^i, k_4^i) = -\frac{1}{2} k_3^i + \frac{9}{4} k_3^i k_4^i \\ \beta_i(k_3^i, k_4^i) = -\frac{1}{6} k_4^i + \frac{3}{2} (k_3^i)^2 + \frac{3}{4} (k_4^i)^2$$

其中的 $k_3^i = E\{y_{i,k}^3\}$ 及 $k_4^i = E\{y_{i,k}^4\} - 3$ 分别表示 y_i 偏度和峰度。偏度即是衡量一个信号的分布偏离对称分布的歪斜程度，而峰度不仅可以用来区分高斯和非高斯信号，还可以进一步的对亚高斯和超高斯信号进行区分。在对偏度和峰度进行更新的时候，采用下面公式进行：

$$k_{3,k+1}^i = k_{3,k}^i - u \cdot T \cdot (k_{3,k}^i - y_{i,k}^3) \\ k_{4,k+1}^i = k_{4,k}^i - u \cdot T \cdot (k_{4,k}^i - y_{i,k}^4 + 3)$$

自然梯度算法最早是由 Cichocki 等人提出来的，但是后来 Amari 也只是在理论上对该算法进行了证明，证实了它的有效性。

(3) EASI 算法

该算法是借助于独立性的等变化的一种自适应分离方法：

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta(t) [I - \phi(y(t)) y^T(t) \\ + y(t) \phi^T(y(t)) - y(t) y^T(t)] \mathbf{W}(t) \quad (8)$$

在这里，对分离矩阵的计算过程中引入的是相对梯度，一般的随机梯度在计算代价函数是相对于权矩阵的绝对变化量的，但该算法的不同之处在于计算权矩阵的相对变化量。

(4) 迭代求逆运算

与前面所提到的算法不同的是，如果取两个不同的非线性变换函数 $f(y) = [f_1(y_1), \dots, f_n(y_n)]^T$ 和 $g(y) = [g_1(y_1), \dots, g_n(y_n)]^T$ ，那么就有迭代求逆算法：

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta(t) [I - f(y(t)) g(y(t))^T] \mathbf{W}(t) \quad (9)$$

这里的非线性变换函数分别取为

$$f_i(y_i) = |y_i|^2 y_i \\ g_i(y_i) = \text{sgn}(\text{Re}(y_i)) + j \cdot \text{sgn}(\text{Im}(y_i))$$

其中 $\text{sgn}()$ 是符号函数。

上面提到的算法，都只适合于亚高斯和超高斯信

号单独存在的情况，如果两者同时存在的情况，可以使用广义的 ICA 自适应算法，但是一般情况下，这种算法都比较复杂。

3.2. 非线性 PCA

运用非线性 PCA 算法实现对非高斯信号的分离的基本思想是，需要首先对观测数据做非线性变换，引入高阶统计量，然后再进行主分量分析。由于引入的是高阶统计量，所以需要先对数据进行预处理，是对数据的一阶和二阶距标准化。

令 $X(t)$ 是原始观测数据，则使其各分量白化成单位方差的白噪声的步骤如下所示：

$$\begin{aligned}\overline{X(t)} &= X(t) - E\{X(t)\} \\ V(t) &= E\left\{\overline{X(t)}\overline{X^T(t)}\right\}^{-1/2} X(t)\end{aligned}$$

通过上面两个式子分别进行零均值化和协方差矩阵化为单位矩阵的过程。

对数据进行预白化处理以后，需要对分离矩阵进行自适应更新，将合适的非线性函数引入到标准 PCA 算法的准则函数中就可以得到非线性 PCA 的准则函数，即：

$$J(\mathbf{W}) = E\left\{\left\|V(t) - \mathbf{W}g(\mathbf{W}^T V(t))\right\|^2\right\} \quad (10)$$

其中 \mathbf{W} 是分离矩阵， $g(\cdot)$ 是非线性函数。然后就可以利用随机梯度型算法进行自适应更新。

非线性 PCA 算法经过多年的发展，形成了好多成熟的算法，主要是以经典的 RLS 算法为主，下面就简单介绍一下几种典型的算法。

(1) RLS 算法

在这个算法里，只要是引入了遗忘因子 λ ，它的作用是强化当前观测数据对参数估计的作用，削弱先前数据的影响，是一种渐消记忆的方法。因此该算法的准则函数为：

$$J(\mathbf{W}) = \sum_{i=1}^l \lambda^{l-i} \left\|V(i) - \mathbf{W}(i)g(\mathbf{W}^T(i-1)V(i))\right\|^2 \quad (11)$$

基于非线性 PCA 的最小二乘 RLS 算法相对于梯度型的 LMS 在收敛速度上有了很大的提高，而且稳定性更好。

(2) 非线性 PCA 子空间学习算法

这里提到的算法是从鲁棒 PCA 子空间学习算法中改进而来的，在其迭代算法中引入非线性函数 $g(\cdot)$ 就能够得到非线性 PCA 子空间分离矩阵迭代计算公式为：

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \mu(t)[V(t) - \mathbf{W}g(Y)]g(Y^T) \quad (12)$$

其中的分离矩阵 \mathbf{W} 的自适应更新过程需要满足正交。

在运用非线性 PCA 来解决问题的时候，还有一些是在 RLS 算法的基础上通过对遗忘因子进行更新，得到一种可变遗忘因子的非线性 PCA 算法^[12]。

4. 盲分离算法的应用与发展

盲信号分离算法在最近几年已经获得了很好的发展，在若干理论和方法方面都得到了改进和提高，如本文所提到的在优化准则，以及对比函数方面。随着盲信号分离算法的不断发展，它在很多方面都得到了十分广泛的应用。最初就是把盲分离应用在盲多用户检测问题中，需要使用盲分离算法的理论进行求解，从与多个发射器相对应的天线中所接收到的混合信号中，恢复出各个通信的源信号；在语音识别方面，接收的语音指令会不可避免的带有各种环境噪声，这就需要运用盲分离算法去解决这种“鸡尾酒会”的问题，去分离识别正确的语音信息；在生物医学信号处理方面，盲信号分离也应用的非常多，主要在脑电信号、脑磁信号、心电信号以及核磁共振成像信号等方面都有着广泛的应用，对信号的提取问题方面取得了非常好的效果^[13-15]。

除此以外，还在图像滤波、声纳问题、无线电频谱管理以及光纤通信方面都有应用。

5. 展望

目前为止，盲分离算法在很多领域都有了实际性的应用，但是也还有许多理论上的问题需要解决，例如可以通过研究使算法在全局收敛性上得到提高，令算法的收敛速度增快，以及对算法的稳定性以及鲁棒性方面都可以进行更加深层次的研究。未来在应用方面，可以尝试把盲分离算法应用在电磁信号的分离去噪方面，研究分析提取电磁辐射信号的效果。

6. 致谢

这篇论文的完成我要衷心感谢我的恩师申金媛老师和刘润杰老师, 从选定题目, 到指导修改论文, 老师们时刻关注着我的学术成长, 对我寄予了深深的厚望, 感谢老师! 还要感谢所参考和引用文献的作者, 你们的成果是我研究的基础, 没有你们的努力, 就没有我的成果。最后, 真心的感谢《光电子》期刊对本论文的认可及接纳。

参考文献 (References)

- [1] 张贤达, 保铮. 盲信号分离[J]. 电子学报, 2001, 29(12A): 1766-1771.
- [2] 夏冰. 基于非线性 PCA 的胎儿心电信号提取算法研究[D]. 郑州: 郑州大学, 2009.
- [3] 李文娟, 郭晓静, 吴小培. 结合 ICA 和 PCA 方法的胎儿心电提取[J]. 计算机技术与发展, 2007, 17(8): 223-225.
- [4] 周宗谭, 董国华, 胡德文等. 独立分量分析[M]. 北京: 电子工业出版社, 2007.
- [5] A. Weingessel, K. Homik Local PCA algorithms. IEEE Transaction on Neural Networks, 2000, 11: 1242-1250.
- [6] 李木森, 毛剑琴. 盲信号分离的现状和展望[J]. 信息与电子工程, 2003, 3(1): 69-79.
- [7] 胡学友. 盲信号分离技术及其应用研究[D]. 合肥: 合肥工业大学硕士学位论文, 2003.
- [8] A. Hyvarinen, E. Oja. Independent component analysis: Algorithms and applications. Finland Neyral Networks, 2000, 13(4-5): 411-430.
- [9] 杨竹青, 李勇, 胡德文. 独立成分分析方法综述[J]. 自动化学报, 2002, 28(5): 762-772.
- [10] 李小军, 朱孝龙, 张贤达. 盲信号分离研究分类与展望[J]. 西安电子科技大学学报(自然科学版), 2004, 31(3): 399-404.
- [11] 高鹰, 谢胜利. 基于非线性 PCA 准则的两个盲信号分离算法[J]. 计算机工程与应用, 2005, 22: 24-26.
- [12] X. L. Zhu, X. D. Zhang. Adaptive RLS algorithm for blind source separation using a natural gradient. IEEE Signal Processing. Letters, 2002, 9(12): 432-435.
- [13] D. H. Li, M. Diao, and X. F. Dai. Blind separation algorithm for audio signal based on genetic algorithm and neural network. Shanghai: IEEE Computer Society, 2008, 436-440.
- [14] 张承钰. 通信信号盲分离方法研究[D]. 合肥: 中国科学技术大学, 2009.
- [15] 刘清欣. 胎儿心电信号提取的算法研究[D]. 郑州: 郑州大学, 2007.