

非线性混叠信号的可分离性及分离方法研究¹

刘 琚 聂开宝 何振亚*

(山东大学电子工程系 济南 250100)

*(东南大学无线电工程系 南京 210096)

摘 要 该文分析了非线性混叠信号的可分离性及分离条件, 指出现阶段非线性混叠信号盲分离的局限性。将 Edgeworth 展开代入信息后向传输算法中, 通过一种新的自适应累积量估计方法, 克服了原算法指出的 Edgeworth 展开在盲信号分离中的缺陷。计算机仿真结果表明了所提算法在特定非线性混叠模型信号分离的效果, 我们还对不同的方法进行了分析对比, 指出了累积量对不同算法的影响。

关键词 非线性, 盲源分离, 高阶累积量

中图分类号 TN911.23

1 引 言

盲源分离 (Blind Source Separation, BSS) 是指在不知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各个独立成分的过程。这一过程又称为独立分量分析 (Independent Component Analysis, ICA)。对这一问题的研究已成为近年来信号处理领域一个引人注目也是具有非常重要的实际意义的热点问题, 在语音分离, 雷达信号处理、移动通信和生物医学信号检测方面都具有非常好的应用前景。

较早进行盲源分离方法研究的是 Herelt 和 Jutten^[1], 之后许多高性能盲源分离算法^[2,3] 不断出现, 并得到成功应用。但在实际的环境里, 观测到的混叠信号可能是经过非线性混叠得到的, 而且这一问题要比线性混叠情况复杂得多。此时, 线性混叠信号盲分离的算法不再适用, 如果把非线性混叠模型仍假设为线性混叠, 并利用线性 ICA 方法求解, 可能导致完全错误的结果。因而, 作为更一般的混叠模型, 非线性混叠信号的盲分离问题的研究近来引起许多学者的注意^[4-8]。如 Burel^[4] 用一个两层感知器和基于误差后向传输思想的无监督训练算法, 通过梯度下降算法优化统计独立的测度函数, 得到一种盲分离算法, 可以用于非线性混叠信号的盲分离。由于非线性盲分离比线性情况的分离难度更大, 直到 1996 年 Parra^[5] 提出一类前向信息保持非线性结构映射网络, 通过最小化输出互信息, 减小输出各个分量间的剩余度, 从而可以得到非线性独立成分。Pajunen, Hyvarinen 和 Karhunen^[6] 用自组织映射 (Self-Organization Map, SOM) 网络从非线性混叠信号中恢复源信号, 该算法可以不考虑非线性混叠的形式, 但其网络复杂性呈指数增长且在分离连续源时存在严重的插值误差。Yang 和 Amari^[7] 利用两层感知器网络结构, 通过最大熵和最小互信息作为测度独立的代价函数, 提出了信息后向传输的训练方法。当合理选择非线性函数时该算法可以分离出一些特定非线性混叠的源信号。Taleb 和 Jutten^[8] 提出了一种非线性混叠信号盲分离算法, 可以对一种特定非线性混叠 (称为后非线性混叠) 的信号进行盲分离。

本文首先讨论了非线性混叠信号盲分离解的存在性问题, 指出该问题解的局限性; 然后将 Edgeworth 展开用于信息后向传输算法中, 通过正确的累积量估计方法, 克服了原算法指出的 Edgeworth 展开在盲信号分离中的缺陷。我们还通过计算机仿真对不同的累积量估计方法进行了分析对比, 指出了它们对不同算法的影响。最后对基于信息后向传输的两种算法进行比较, 并验证了本文提出的算法的有效性。

¹ 2001-07-12 收到, 2002-01-07 改回

国家自然科学基金 (30000041)、山东省自然科学基金 (y2000G12、G13) 和山东大学青年科学基金资助

2 一般的非线性混叠和解混叠模型

设有未知统计独立源信号矢量 $s(t) = [s_1(t), s_2(t), \dots, s_N(t)]^T \in \mathbf{R}^N$, 我们只能观测到瞬时混叠信号矢量 $x(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T \in \mathbf{R}^N$, 它是非线性瞬时混叠信号模型:

$$x(t) = f(s(t)) \quad (1)$$

的输出矢量. 式中 $f: \mathbf{R}^N \rightarrow \mathbf{R}^N$ 为未知的可逆非线性混合函数. 非线性盲源分离问题就是仅通过观测信号 $x(t)$ 辨识出映射 $f: \mathbf{R}^N \rightarrow \mathbf{R}^N$ 或求解一个映射 $g: \mathbf{R}^N \rightarrow \mathbf{R}^N$, 使得通过它可以恢复出源信号 $s(t)$. 分离系统输出 $y(t) = [y_1(t), y_2(t), \dots, y_N(t)]^T \in \mathbf{R}^N$ 为源信号的估计矢量, 可用数学模型表示为

$$y(t) = g(x(t)) = \hat{s}(t) \quad (2)$$

由于完全非线性混叠盲分离问题的复杂性, 现有的非线性混叠信号盲分离算法研究的都是如图 1 所示所谓的后非线性混叠 (Post-Nonlinear Mixture, PNL) 的情况, 即对源信号线性混叠后再加以非线性的情况. 分离系统的每一个通道先通过一个 $g_i(\cdot)$ 对后非线性求逆得到 $v_i(t)$, 然后通过分离矩阵 W 进行分离得到 $y_i(t)$. 如果 $g_i(\cdot)$ 和 W 恰好分别是 $f_i(\cdot)$ 和 A 的逆, 则源得以完全恢复, 有 $y(t) = s(t)$.




图 1 非线性混叠和分离系统框图

3 非线性混叠信号盲分离问题的可分离性及解的不唯一性

3.1 非线性混叠信号盲分离问题解的存在性

我们可以通过构造解的方式说明非线性盲源分离问题存在解. 如果能够构造出一个符合模型 (1) 和 (2) 式的解, 就说明解是存在的.

针对模型 (1) 和 (2) 式, 可以利用广义 Gram-Schmit 正交化方法构造解^[9]. 设已经有 m 个独立变量 y_1, y_2, \dots, y_m 和变量 x , 现在要构造新的变量 $y_{m+1} = g(y_1, y_2, \dots, y_m, x)$, 使得 y_1, y_2, \dots, y_{m+1} 相互独立.

假设 m 个独立随机变量 y_1, y_2, \dots, y_m 在 $[0, 1]^m$ 上遵从联合均匀分布 (假设 y_i 为均匀分布并不是一个限制, 这可从后面的递归直接得出). 为用 $x, a_1, a_2, \dots, a_m, b$ 以及一些非随机标量表示任意随机变量, 定义

$$\begin{aligned} g(a_1, a_2, \dots, a_m, b; p_{y,x}) &= p(x \leq b | y_1 = a_1, \dots, y_m = a_m) \\ &= \frac{\int_{-\infty}^b p_{y,x}(a_1, a_2, \dots, a_m, \zeta) d\zeta}{p_y(a_1, a_2, \dots, a_m)} \end{aligned} \quad (3)$$

其中 $p_y(\cdot)$ 和 $p_{y,x}(\cdot)$ 分别为 (y_1, y_2, \dots, y_m) 和 $(y_1, y_2, \dots, y_m, x)$ 的 (边缘) 概率密度, $p(\cdot)$ 表示条件概率密度. $p_{y,x}(\cdot)$ 在 $g(a_1, a_2, \dots, a_m, b; p_{y,x})$ 中表明了 g 与 (y_1, y_2, \dots, y_m) 和 x 的联合

概率密度有关, 当 $m = 0$ 时, g 只是 x 的积分分布函数. 下面的定理 1 表明, 以上定义的 g 给出了一个非线性分解.

定理 1^[9] 假设 y_1, y_2, \dots, y_m 为 m 个独立随机变量, 在 $[0, 1]^m$ 上遵从联合均匀分布. 设 x 为标量随机变量, g 的定义如式 (3). 令

$$y_{m+1} = g(y_1, y_2, \dots, y_m, x; p_{y,x}) \quad (4)$$

那么 y_{m+1} 与 y_1, y_2, \dots, y_m 都独立, 而且 y_1, y_2, \dots, y_{m+1} 都在 $[0, 1]^m$ 上服从均匀分布.

显然, 定理 1 可以用于从 n 个变量 x_1, x_2, \dots, x_n 分解出 n 个独立成分 y_1, y_2, \dots, y_n . 令 m 取值从 0 到 $n-1$, 用以上构造方法得到 y_{m+1} , 其中观测变量 x_{m+1} 的应用像 x 的应用一样. 即对 $m = 0, 1, \dots, n-1$, 令 $y_{m+1} = g(y_1, y_2, \dots, y_m, x_{m+1}; p_{y, x_{m+1}})$, 利用类似于 Gram-Schmit 递归, 可以得到相互独立的 y_1, y_2, \dots, y_n , 从而得到非线性盲源分离问题的一个解.

3.2 解的不唯一性

上面的定性分析在表明解存在的同时也表明这种分解不能保证解是唯一的. 这可以进一步地从以下 3 个方面粗略地进行分析. 首先, 在非线性和混叠模型 (1) 和 (2) 式中, 如果混叠函数 f 为可逆线性变换, 则模型就变为线性混叠情况, 可以得到唯一解 (但存在幅度和次序两个不确定性); 然而, 如果它为非线性函数, 则可能存在无数个具有独立成分的解. 例如, 设 u 和 v 为两个独立随机变量, $p(\cdot)$ 和 $q(\cdot)$ 为两个非线性函数, 那么 $p(u)$ 和 $q(v)$ 也相互统计独立, 这意味着仅仅通过统计独立的假设不可能完全恢复出最初的源信号本身, 而可能是一些它们的非线性函数. 进一步地, 对模型 (1) 和 (2) 式, 假设具有两个源 ($N = 2$) 且为连续变量的情况. 通过一任意可逆非线性变换 h 引入辅助随机变量 $z(t) = [z_1(t), z_2(t)]^T$, 使得 $z(t) = h(x(t))$. 定义 $y_1(t) = z_1(t)$, 一般地, 变量 $y_1(t)$ 和 $z_2(t)$ 将不会相互独立, 因此条件积分分布 $P(z_2(t)|y_1(t))$ 会与 $y_1(t)$ 有关; 但如果定义 $y_2(t) = P(z_2(t)|y_1(t))$, 则 $y_2(t)$ 在 $[0, 1]$ 之间有均匀分布且与 $y_1(t)$ 无关, 因此 $y_1(t)$ 和 $y_2(t)$ 相互独立. 因为 h 的选择是任意的, 所以这种解有无限多个^[10]. 最后明显地, 可以先对观测矢量 $x(t)$ 进行线性变换得到矢量 $x'(t) = Mx(t)$, 然后计算 $y'(t) = g'(x'(t))$. 其中的 $g'(\cdot)$ 为通过 (3) 式的程序确定, $x(t)$ 用 $x'(t)$ 代替. 这样就得到将 $x(t)$ 分解为独立分量的另一个解. 一般说来, 这一解 $y'(t)$ 为与 $y(t)$ 不同的解, 也没有办法仅通过简单的变换将它直接变换为 $y(t)$.

通过以上分析可以看出, 非线性混叠信号的盲分离是一个较为复杂的问题, 仅仅通过源信号独立的约束不足以使问题求解或给出唯一解; 如果不对解混叠的非线性函数加任何限制, 则这一非线性函数除了给出相互独立的输出外不能保证给出有关源信号的任何信息, 因为任何具有连续分布的随机变量都可变换为均匀分布的独立随机变量, 而且多个均匀分布的随机变量通常是相互独立的; 而如果限制解混叠函数的类型, 事实上也就相当于提供了混叠非线性函数的有关信息.

4 基于多层感知器的信息后向传播算法

4.1 信息后向传播

设后非线性混叠的模型中的非线性函数 $f(\cdot)$ 为可逆的. 利用两层感知器对后非线性混叠的模型在非线性和混叠的模型中再进行一次线性混叠, 使分离模型变为

$$y(t) = f^{-1}(x(t)) = Cg(Bx(t)) \quad (5)$$




图 2 信息后向传输法分离过程示意图

其中 $g(u) = [g(u_1), g(u_2), \dots, g(u_n)]^T$, $g(u)$ 为 sigmoid 函数, 如双曲函数. 令 $W_1 = A^{-1}C$ 和 $W_2 = B$, 则输出

$$\begin{aligned} y(t) &= W_1 g(W_2 x(t)) = A^{-1} C g(B(x(t))) \\ &= A^{-1} f^{-1}(x(t)) = A^{-1} A s(t) = s(t) \end{aligned}$$

类似于线性的情况, 考虑到不确定性, 如果存在对角阵 D 和置换阵 P 使得 $W_1 = DPA^{-1}C$, 则有

$$y(t) = W_1 g(W_2 x(t)) = DPs(t) \quad (6)$$

后非线性混叠和分离过程示意图如图 2.

根据信息理论, 很容易地得到用分离参数表示的输出互信息表示式^[7]:

$$MI(y; W_1, W_2) = \sum_{i=1}^N H(y_i) - \log |\det(W_1)| - H(v) \quad (7)$$

利用关系 $v = [g_1(u_1), g_2(u_2), \dots, g_N(u_N)]^T$ 和 $u = W_2 x$, 可以得出熵关系:

$$H(v) = \sum_{i=1}^N E[\log g'_i(u_i) + \log |\det(W_2)|] + H(x) \quad (8)$$

从图 2 的分离框图可以看出, 分离网络就是一个两层前向网络, 由于没有期望信号, 不能应用误差后向传播算法进行训练. 考虑到我们的目标是使输出相互独立, 此时输出互信息应该为零, 所以可以用 (7) 式代替误差后向传播学习算法中的误差作为准则函数进行训练, Yang 等称之为信息后向传播 (Information back-propagation)^[7], 他们基于概率密度 Gram-Charlier 展开给出了一种信息后向传播算法, 并且指出, 在信息后向传播非线性盲分离算法中, Edgeworth 展开性能较差或不能直接应用, 需加入一个四阶累积量的三次项, 使得和 Gram-Charlier 展开相逼近. 但 Kendall 和 Stuart^[11] 指出, Gram-Charlier 展开的项数排列顺序是不规则的, 而对 Gram-Charlier 展开, 由于各项排列不规则, 增加项数未必导致更精确的逼近. 文献 [11] 还给出了关于展开逼近的有效项数的详细讨论, 并指出, 高于四阶的展开项将会引起分布尾部的过渡波动, 可能导致负值. 而 Edgeworth 展开的每一项按其对应函数贡献递减和按渐近收敛性顺序排列, 密度逼近的精度直接取决于所取的展开式的项数.

4.2 基于 Edgeworth 展开的分离算法

当利用 Edgeworth 展开逼近 $y(t)$ 的概率密度, 则每个分量的熵 $H(y_i)$ 可以用 $y_i(t)$ 及其三

阶 $\text{cum}_3(y_i^3)$ 和四阶累积量 $\text{cum}_4(y_i^4)$ 表示为^[4]

$$H(y_i) \cong \frac{1}{2} \log(2\pi e) - \frac{1}{12} \text{cum}_3^2(y_i^3) - \frac{1}{48} \text{cum}_4^2(y_i^4) - \frac{7}{48} \text{cum}_3^4(y_i^3) + \frac{1}{8} \text{cum}_3^2(y_i^3) \text{cum}_4(y_i^4) \quad (9)$$

将 (8) 和 (9) 式代入 (7) 式, 略去与求导参数无关的项, 得到待优化的目标函数:

$$\begin{aligned} \phi_{NMI}(\mathbf{y}; \mathbf{W}_1, \mathbf{W}_2) \cong & -\log |\det(\mathbf{W}_1)| - \log |\det(\mathbf{W}_2)| - \sum_{i=1}^N E[\log g'_i(u_i)] \\ & - \sum_{i=1}^N \left[\frac{1}{12} \text{cum}_3^2(y_i^3) + \frac{1}{48} \text{cum}_4^2(y_i^4) + \frac{7}{48} \text{cum}_3^4(y_i^3) - \frac{1}{8} \text{cum}_3^2(y_i^3) \text{cum}_4(y_i^4) \right] \end{aligned} \quad (10)$$

式中各项对参变量 \mathbf{W}_1 和 \mathbf{W}_2 求偏导数, $\partial \phi_{NMI}(\mathbf{y}; \mathbf{W}_1, \mathbf{W}_2) / \partial \mathbf{W}_1$ 和 $\partial \phi_{NMI}(\mathbf{y}; \mathbf{W}_1, \mathbf{W}_2) / \partial \mathbf{W}_2$, 为求 $\partial \phi_{NMI}(\mathbf{y}; \mathbf{W}_1, \mathbf{W}_2) / \partial \mathbf{W}_1$ 需利用求偏导数的链规则, 关系 $\mathbf{y}(t) = \mathbf{W}_1 \mathbf{g}(\mathbf{W}_2 \mathbf{x}(t))$ 及其分量形式 $y_i(t) = \sum_{k=1}^N w_{ik}^1 g_k(\sum_{l=1}^N w_{kl}^2 x_l(t))$, 可得 $\partial y_i(t) / \partial w_{kl}^2 = w_{ik}^1 g'_k(u_k) x_l$.

利用随机自然梯度下降法, 得出更新分离参数矩阵的叠代公式:

$$\mathbf{W}_1(t+1) = \mathbf{W}_1(t) + [\mathbf{I} - O(\mathbf{y}(t)) \mathbf{y}^T(t)] \mathbf{W}_1(t) \quad (11)$$

$$\mathbf{W}_2(t+1) = \mathbf{W}_2(t) + [\mathbf{I} - Q(\mathbf{u}(t)) \mathbf{u}^T - D(\mathbf{u}(t)) \mathbf{W}_1^T P(\mathbf{y}(t)) \mathbf{u}^T] \mathbf{W}_2(t) \quad (12)$$

其中 $O(\mathbf{y}(t)) = [O(y_1(t)), O(y_2(t)), \dots, O(y_N(t))]^T$,

$$\begin{aligned} O(y_i(t)) = & \left[\frac{1}{2} \text{cum}_3^2(y_i^3(t)) - \frac{1}{6} \text{cum}_4(y_i^4(t)) \right] y_i^3(t) \\ & + \left[\frac{3}{4} \text{cum}_3(y_i^3(t)) \text{cum}_4(y_i^4(t)) - \frac{1}{2} \text{cum}_3(y_i^3(t)) - \frac{7}{4} \text{cum}_3^3(y_i^3(t)) \right] y_i^2(t) \end{aligned} \quad (13)$$

$$Q(\mathbf{u}(t)) = - \left[\frac{g''_1(u_1(t))}{g'_1(u_1(t))}, \frac{g''_2(u_2(t))}{g'_2(u_2(t))}, \dots, \frac{g''_N(u_N(t))}{g'_N(u_N(t))} \right]^T \quad (14)$$

$$D(\mathbf{u}(t)) = \text{diag}[g'_1(u_1(t)), g'_2(u_2(t)), \dots, g'_N(u_N(t))]^T \quad (15)$$

为了得到较为准确的分离效果, 我们采用如下累积量估计方法^[12]:

$$\text{cum}_3(y_i^3(t+1)) = \text{cum}_3(y_i^3(t)) + \mu(t)(y_i^3(t) - \text{cum}_3(y_i^3(t))) \quad (16)$$

$$\text{cum}_4(y_i^4(t+1)) = \text{cum}_4(y_i^4(t)) + \mu(t)(y_i^4(t) - y_i^2(t)y_i^2(t-1) - \text{cum}_4(y_i^4(t))) \quad (17)$$

5 计算机仿真比较和性能分析

实例 取 3 个未知源信号 $\mathbf{s}(t) = [s_1(t), s_2(t), s_3(t)]^T$ 的分量数据分别为: $s_1(t)$ 为零均值 $[-1, 1]$ 之间均匀分布的白噪声, $s_2(t) = 2 \sin(\pi t/10)$ 和 $s_3(t) = \text{sign}(\sin(500t + 9 \cos(40t)))$. 我们取 10000 点时间点数据. 经非线性关系 $\mathbf{x}(t) = \mathbf{A}_2 \tanh(\mathbf{A}_2 \mathbf{s}(t))$ 混叠, 其中混叠矩阵的

元素为选自 $[-1, +1]$ 之间均匀分布的随机数 $\mathbf{A}_1 = \begin{bmatrix} -0.4814 & 0.2277 & 0.0145 \\ 0.3723 & -0.3576 & -0.4614 \\ -0.1201 & 0.1922 & -0.1618 \end{bmatrix}$, $\mathbf{A}_2 =$

$$\begin{bmatrix} 0.6685 & -0.4258 & -0.5779 \\ -0.7075 & -0.9154 & -0.1562 \\ 0.3323 & 0.0904 & 0.7419 \end{bmatrix}$$
 . 源信号和混叠信号的 500 时间点的波形图分别如图 3(a) 和 3(b) 所示. 分离结果如图 3(c).

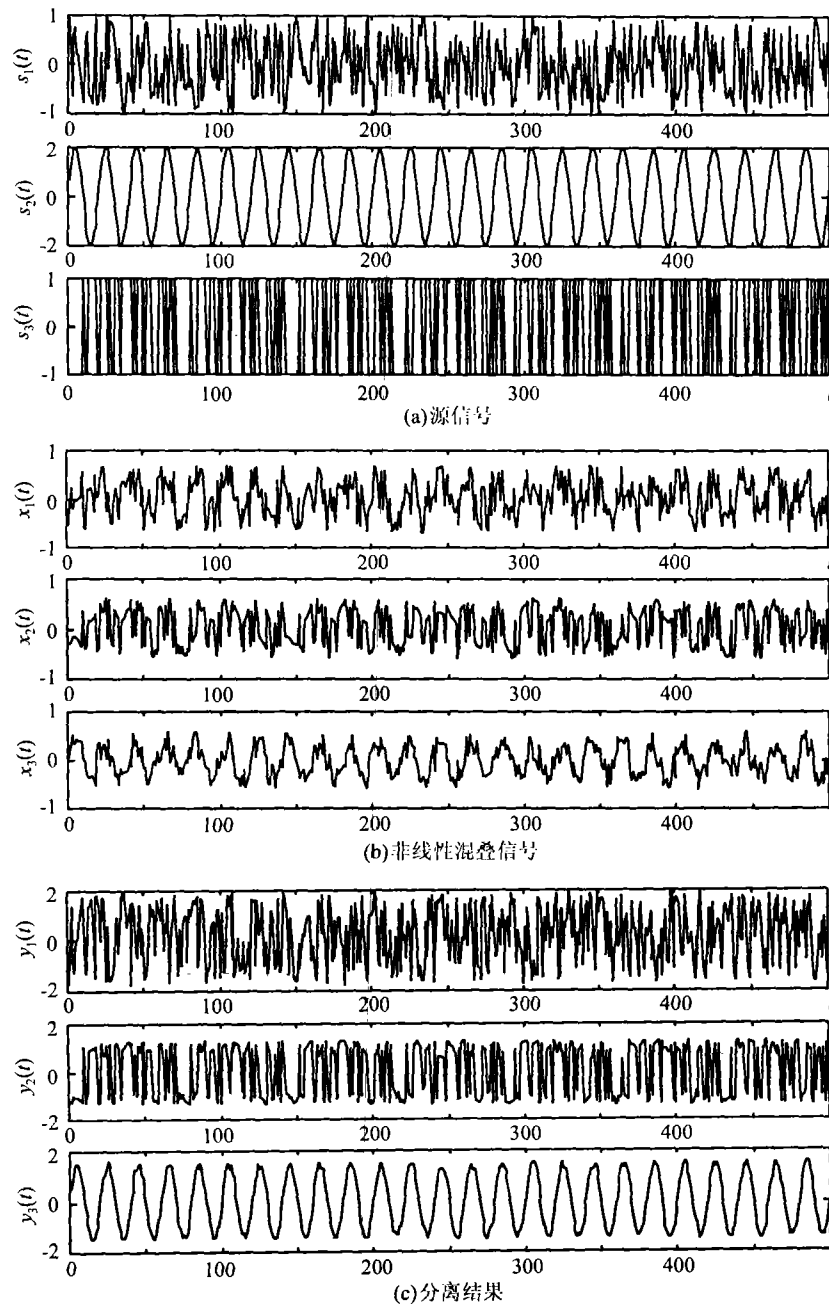


图 3 源信号、混叠信号和分离结果的 500 点波形图

仿真过程和结果表明,分离的性能实际上取决于四阶累积量的估计。如果仅用对所给出的非线性混叠信号,如果用文献 [7] 的累积量估计算法,则确实只有基于 Gram-Charlier 展开的算法可以分离,而用基于 Edgeworth 展开的算法训练时发散,但这不是 Edgeworth 展开式本身的问题,而是在于四阶累积量估计的是否准确。因为如果利用四阶累积量的估计 (17) 式,则两种算法都可以分离,并且两种方法的分离结果没有明显的差别。为了比较算法的性能,我们分别用两种方法得到的互信息作为性能测度进行了比较,结果如图 4。显然,在正确的累积量估计下,两种展开的互信息测度同样没有明显差别。

为进一步说明,我们分别自适应地计算了两种累积量估计,并和大样本集平均估计进行了比较,限于篇幅,图形从略。仿真结论表明自适应累积量估计 (17) 式可以更精确地估计四阶累积量,因而用于两种展开的算法都能得到好的分离结果。




图 4 分离过程互信息的变化曲线 (上图为 Edgeworth 展开, 下图为 Gram-Charlier 展开)

6 结 论

本文首先讨论了非线性混叠信号盲分离解的存在性问题,指出该问题解的局限性;然后将 Edgeworth 展开代入 Yang 等人提出的信息后向传输算法中,通过正确的累积量估计方法,克服了原算法指出 Edgeworth 展开在盲信号分离中的缺陷。通过计算机仿真对基于信息后向传输的两种算法进行比较,并验证了本文提出的算法的有效性。

参 考 文 献

- [1] C. Jutten, J. Herault, Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic, *Signal Processing*, 1991, 24(1), 1-10.
- [2] A. J. Bell, T. J. Sejnowski, An information-maximization approach to blind separation and blind deconvolution, *Neural Computation*, 1995, 7(6), 1129-1159.
- [3] S. Amari, A. Cichocki, H. H. Yang, A new learning algorithm for blind signal separation, *Advances in Neural Information Processing Systems*, Cambridge, MA: MIT Press, 1996, 8, 657-663.
- [4] G. Burel, Blind separation of sources: A nonlinear neural algorithm, *Neural Networks*, 1992, 5(6), 937-947.

- [5] L. C. Parra, Symplectic nonlinear component analysis, *Advances in Neural Information Processing Systems*, MA: MIT Press, 1996, 8, 437-443.
- [6] P. Pajunen, A. Hyvarinen, J. Karhunen, Nonlinear blind source separation by self-organization maps, in *Progress in Neural Information Processing*, Berlin, Springer, 1996, 2, 1207-1210.
- [7] H. H. Yang, S. Amari, A. Cichocki, Information back-propagation for blind separation of sources from non-linear mixture, in *Proc. ICNN*, Houston, 1997, 2141-2146.
- [8] A. Taleb, C. Jutten, Source separation in post nonlinear mixtures: An entropy-based algorithm, in *Proc. of ICASSP*, Seattle, Washington, 1998, 2089-2092.
- [9] A. Hyvarinen, P. Pajunen, On existence and uniqueness of solutions in non-linear independent component analysis, in *Proc. of IJCNN*, Anchorage, Alaska, 1998, 1350-1355.
- [10] C. Goncalo, L. B. Almeida, Separation of nonlinear mixtures using pattern repulsion, in *Proc. of the First International Workshop on Independent Component Analysis and Signal Separation*, Aussois, France, 1999, 277-282.
- [11] S. M. Kendall, A. Stuart, *The Advanced Theory of Statistics*, London, Charles Griffin Company Limited, 1977, Chapt. 6.
- [12] O. Amblard, J. M. Brossier, Adaptive estimation of the fourth-order cumulant of a white stochastic process, *Signal Processing*, 1995, 42(1), 37-42.

ON SEPARABILITY AND SEPARATING METHOD OF NONLINEAR MIXED SIGNALS

Liu Ju Nie Kaibao He Zhenya*

(Dept. of Electronic Engineering, Shandong Univeristy, Jinan 250100, China)

**(Dept. of Radio Eng., Southeast University, Nanjing 210096, China)*

Abstract The separability and separating conditions for mixed signals are analyzed in this paper. The limitation of nonlinear blind source separation methods is proposed. A new nonlinear BSS approach is developed by applying Edgeworth expansion and adaptive cumulant estimation into information back propagation algorithm. Computer simulation shows the validity of the proposed algorithm in some ad hoc model. A comparison with the Gram-Charlier expansion method is given.

Key words Nonlinear, Blind source separation, Higher order cumulants

刘 璐: 男, 1965 年生, 教授, 博士生导师, 研究方向为盲信号处理, 神经网络信息处理和多媒体通信等。
聂开宝: 男, 1966 年生, 博士, 副教授, 研究方向为生物医学工程。
何振亚: 男, 1923 年生, 教授, 博士生导师, 研究领域自适应信号处理、人工神经网络和混沌信号处理等。