

一类基于多变量密度估计的盲源分离方法¹

何振亚 杨绿溪 刘 璐 鲁子奕 何 晨*

(东南大学无线电工程系 南京 210096)

*(上海交通大学电子工程系 上海 200030)

摘 要 该文给出了一类独立源信号盲分离的训练算法。该类算法都以测度概率密度函数的 Kullback-Leibler 距离作为目标函数,用来衡量源信号各分量的独立性。该文利用多变量概率密度估计技术和自然梯度优化算法,使目标函数最小化,得出了两种分离算法。计算机仿真结果表明了算法的有效性。并与 Infomax 算法比较,性能较优。

关键词 盲源分离,多变量密度估计,互信息,统计独立

中图分类号 TN911.72

1 引 言

盲源分离 (Blind Source Separation, BSS), 由于其在通信、生物医学工程、雷达和语音等方面的应用, 正引起越来越多的关注^[1-7]。盲源分离又称为独立分量分析 (Independent Component Analysis, ICA) 是指在未知系统参数的情况下, 仅用多通道观测输出, 恢复出输入源信号各个独立成分。设有 N 个传感器记录的观测序列为 $X(t) = [X_1(t), X_2(t), \dots, X_N(t)]$, 其中的每一个分量 $X_i(t)$ 都为 M 个源信号 $S(t) = [S_1(t), S_2(t), \dots, S_M(t)]$ 的线性混叠, 即 $X(t) = AS(t)$, A 为 $N \times M$ 混合矩阵。

由于是在“盲”的情况下处理, 没有任何可以利用的先验信息, 根据问题的复杂性, 现在大多进行无噪声、线性混叠信号的分离, 而且假设: (1) A 为非奇异阵, 且观测信号的维数 N 不小于源信号维数 M 。这里我们设 $M = N$; (2) 在任一时间点, 源信号各分量 $S_k(t), k = 1, 2, \dots, M$ 相互统计独立; (3) 每一个源信号 $S_k(t)$ 为零均值平稳随机过程。由于高斯信号的线性相加仍为高斯的, 不可能被分开, 所以设至多有一个源为高斯分布。

Jutten 和 Herault^[1] 较早提出盲源分离问题。由于他们的类神经算法简单并较容易硬件实现而引起广泛注意。但该方法只能分离不多于两个混叠源信号。盲源分离中一个重要的问题就是如何选取合适的用来优化的目标函数^[2]。文献 [3, 4] 提出了基于信息理论判据的神经网络分离算法, 但该类算法给出的对分离性能起重要作用的边缘密度函数的选取有一定的限制, 并只能分离具有某种特性的信号。Bell 和 Sejnowski^[5] 提出一种最大化神经网络非线性单元中信息传输 (Infomax) 的分离算法。Obradovic 和 Decol^[6] 指出 Infomax 算法事实上也是基于 Kullback-Leibler 距离的, 并且只能分离具有正峭度 (超高斯) 的源信号。

本文给出了一类独立源信号盲分离的训练算法。该类算法也选用 Kullback-Leibler 距离作为目标函数来衡量源信号各分量的独立性, 但利用多变量概率密度估计技术和新出现的自然梯度优化算法, 最小化该目标函数, 得出了两种分离算法。计算机仿真结果表明, 该算法既可以分离具有正峭度的混叠语音信号, 也可有效地分离具有负峭度的混叠图象信号。仿真中还对所提出的两种算法进行了比较。

¹ 1999-04-14 收到, 1999-10-13 定稿
国家自然科学基金资助课题

2 Kullback-Leibler 目标函数和训练算法

由前所述盲源分离的目标就是寻找一个 $M \times M$ 矩阵 W ，使得仅利用观测信号 $X_i(t)$ ， $i = 1, 2, \dots, M$ 通过 $Y(t) = WX(t)$ 恢复的源尽可能逼近源信号 $S(t)$ 。由于没有关于混叠过程的先验信息可以利用，我们只能根据源信号统计独立的假设来构造目标函数。我们已知，当 Y 的各个分量相互独立时，有 $P(Y) = P_{Y_1}(y_1)P_{Y_2}(y_2) \cdots P_{Y_M}(y_M)$ ，其中 $P(Y)$ 为 Y 的联合概率密度函数， $P_{Y_i}(y_i)$ 为边缘概率密度函数。为比较联合概率密度函数和边缘概率密度函数，我们采用 Kullback-Leibler 距离：

$$K = \int P_Y(y) \ln \frac{P_Y(y)}{\prod_{i=1}^M P_{Y_i}(y_i)} dy \quad (1)$$

显然， K 为非负的且仅当 Y 的各成分相互独立时为零。因此，盲源分离就是求取分离矩阵 W ，以使 K 达到最小。 $K(W)$ 也因此被定义为被优化的目标函数。这一目标函数是由 Comon^[2] 定义的，由于对 W 的限制少而广泛使用。

为获得更新 W 的训练规则，要对目标函数 $K(W)$ 进行优化，需求它对 W 的梯度。我们引入如下定理：

定理 1 目标函数 $K(W)$ 的梯度可表示为^[7]

$$\frac{\partial K(W)}{\partial W} = -[W^T]^{-1} - \left[E_x \left\{ \frac{P_{Y_1}(y_1)}{P_{Y_1}(y_1)} \right\} \cdots E_x \left\{ \frac{P_{Y_M}(y_M)}{P_{Y_M}(y_M)} \right\} \right]^T (x_1 \cdots x_M) \quad (2)$$

其中，符号 T 表示转置， $E_x[f(y)] = \int P_X(x)f(y)dx$ 和 $P'(s) = \partial P(s)/\partial s$ 。将上式表示的梯度两边各后乘以 $W^T W$ ，我们得到更新 W 的训练规则：

$$\Delta W \propto -\frac{\partial K(W)}{\partial W} W^T W = \left\{ I + \left[E_x \left\{ \frac{P_{Y_1}(y_1)}{P_{Y_1}(y_1)} \right\} \cdots E_x \left\{ \frac{P_{Y_M}(y_M)}{P_{Y_M}(y_M)} \right\} \right]^T (y_1 \cdots y_M) \right\} W \quad (3)$$

由于 $W^T W$ 为正定阵，它不影响随机梯度下降算法的收敛；相反地，它使算法收敛性更好，由于避免了矩阵求逆，使算法计算效率更高。(3) 式称为随机自然梯度下降法^[4]，或称相对梯度法^[7]。

从 (3) 式可以看出，正确得出分离阵 W 的关键在于如何求边缘概率密度函数 $P_{Y_i}(y_i)$ ， $i = 1, 2, \dots, M$ 。下面我们给出两种多变量密度估计方法，从而得到两种更新 W 的训练算法。

3 多变量密度估计

由于只有观测样本 $X(1), X(2), \dots, X(T)$ 可以利用。由 $Y = WX$ ，我们可以得到 $Y(1), Y(2), \dots, Y(T)$ 。所以估计 $P_{Y_i}(y_i)$ 的途径有两种：一是利用 $X(1), X(2), \dots, X(T)$ 先估计 X 概率密度 $P_X(x)$ ，由 $Y = WX$ ，可得 $P_Y(y) = P_X(W^{-1}Y)/|\det W|$ ，进而求 $P_{Y_i}(y_i)$ 。再者是直接从恢复出的源信号 $Y(1), Y(2), \dots, Y(T)$ 来估计 $P_{Y_i}(y_i)$ 。基于以上设想，下面分别给出两种多变量估计方法，并指出，第二种方法其实是 Infomax 法的推广。

3.1 从 $X(1), X(2), \dots, X(T)$ 估计 $P_{Y_i}(y_i)$

我们选择核函数法估计 X 的概率密度 $P_X(x)$ 。以统计的观点看, 从观测数据利用核函数法估计概率密度可分为固定宽度核密度估计和自适应核密度估计^[8], 两种方法都存在计算量大的问题。为此我们引入基于径向基函数 (RBF) 的核函数密度估计方法^[9]。该方法通过聚类, 减少了核函数的个数, 从而减少了待估计参数。

设给定 N 组训练数据 $\{x_t, t = 1, \dots, N\}$, 多变量密度估计方法可表示为

$$P_X(x) = \frac{1}{Nh^M} \sum_{t=1}^N \phi\left(\frac{x - x_t}{h}\right) \quad (4)$$

其中核函数 ϕ 的选择应满足

$$\phi(x) \geq 0, \quad \int \phi(x) dx = 1 \quad (5)$$

通常选择 ϕ 为高斯核函数

$$\phi(x) = (2\pi)^{-M/2} \exp\left(-\frac{1}{2}x^T x\right) \quad (6)$$

3.1.1 数据规整和去相关 通常, 观测数据在各个方向的展开并不相同, 而且外围数据很少, 他们对概率密度提供非常少的信息。另外, 在聚类之前进行数据预白化 (去相关) 可以简化数据的相关结构, 从而使聚类算法中的距离测度变得简单。因为没有去相关的数据在不同的维上具有不同的比例。主元分析 (PCA) 可以完成这一过程, 它通过线性变换 $V = UX$ 产生零均值单位方差的规整的数据。这一过程在大多数的盲分离算法中经常使用^[2,7]。

给定一组 M 维观测数据 $\{X\}$, 我们定义 $\{X\}$ 的预白化的数据 $\{V\}$ 为

$$V = U(X - E[X]) \quad (7)$$

其中 $UU^T = E[(X - E[X])(X - E[X])^T] = D\Lambda D^T$, 即 $U = D\Lambda^{\frac{1}{2}}$; D 为一正交阵, Λ 为角阵。预白化后的数据有

$$E[V] = 0, \quad E[VV^T] = I \quad (8)$$

至此, 我们只需估计去相关后的数据 $\{V\}$ 的概率密度函数 $P_V(V)$ 。

3.1.2 通过聚类估计去相关数据的概率密度 通过去相关, 数据的协差阵为对角阵; 如果再通过聚类, 则每个数据类的方差可以独立求出。此时, $Y(t) = WV(t)$ 。我们只需估计去相关数据的概率密度, 因而, 根据 (4) 式, 我们构造基于 RBF 的具有 N 个核的密度估计器来逼近去相关数据的概率密度

$$P_V(\nu) = \sum_{t=1}^N c_t \phi_t(\nu, \mu_t, \sigma_t) \quad (9)$$

其中

$$\phi_t(\nu, \mu_t, \sigma_t) = \frac{1}{(\sqrt{2\pi})^M \prod_{k=1}^M \sigma_{tk}} \exp\left\{-\frac{1}{2} \sum_{k=1}^M \frac{(\nu_k - \mu_{tk})^2}{\sigma_{tk}^2}\right\} \quad (10)$$

$\mu_t = (\mu_{t1}, \mu_{t2}, \dots, \mu_{tM})^T$, $t = 1, 2, \dots, N$ 表示 N 个聚类中心。我们选用 LBG 聚类算法^[10] 以获得比 K 均值法性能更好的聚类效果; $c = (c_1, c_2, \dots, c_N)^T$ 表示 N 个核函数的高度矢量。设 t 类样本个数为 m_t , 则 $c_t = m_t / \sum m_t = m_t / K$; $\sigma_t = (\sigma_{t1}, \sigma_{t2}, \dots, \sigma_{tM})^T$ 对每一类 t 有 m_t 个 M 维样本, σ_{ti} 为对应于每一维的方差。

3.1.3 估计恢复的各独立源信号的概率密度 有了估计概率密度函数 $P_V(V)$ 的各参数, 我们引入如下定理以估计恢复的各独立源信号的概率密度

定理 2 设矢量 V 的概率密度 $P_V(\nu)$ 如 (9) 式所示, 由 $Y(t) = WV(t)$, 则矢量 Y 的各成分 Y_i 概率密度由下式给出:

$$P_{Y_i}(y_i) = \sum_{t=1}^N c_t \frac{1}{\sqrt{2\pi \sum_{j=1}^M \sigma_{tj}^2 w_{ij}^2}} \exp \left\{ -\frac{(y_i - y_{it})^2}{2 \sum_{j=1}^M \sigma_{tj}^2 w_{ij}^2} \right\} \quad (11)$$

其中 $y_{it} = (W\mu_t)_i$ 。

证明 我们将 (10) 式重新表示为

$$\phi_t(\nu, \mu_t, \Gamma) = \frac{1}{(\sqrt{2\pi})^M (\det \Gamma)^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (\nu - \mu_t) \Gamma^{-1} (\nu - \mu_t) \right\} \quad (12)$$

其中 $\Gamma = \text{diag}(\sigma_{t1}^2, \sigma_{t2}^2, \dots, \sigma_{tM}^2)$ 。

明显地, 如果 $\nu \sim \phi_t(\nu, \mu_t, \Gamma)$, 则

$$(W\nu)_i \sim \phi_t((W\nu)_i, (W\mu_t)_i, (W\Gamma W')_{ii}) \quad (13)$$

从 (9) 式可得

$$\begin{aligned} P_{Y_i}(y_i) &= \sum_{t=1}^N c_t \phi_t((W\nu)_i, (W\mu_t)_i, (W\Gamma W')_{ii}) \\ &= \sum_{t=1}^N c_t \frac{1}{\sqrt{2\pi \sum_{j=1}^M \sigma_{tj}^2 w_{ij}^2}} \exp \left\{ -\frac{(y_i - y_{it})^2}{2 \sum_{j=1}^M \sigma_{tj}^2 w_{ij}^2} \right\} \end{aligned}$$

这样我们得到从去相关数据 V 恢复的各独立源信号的概率密度 $P_{Y_i}(y_i)$, 代入 (3) 式可得更新分离阵 W 的训练规则。 证毕

3.2 直接从 $Y(1), Y(2), \dots, Y(T)$ 估计 $P_{Y_i}(y_i)$

我们仍然选择核函数法估计 $P_{Y_i}(y_i)$, 即

$$P_{Y_i}(y_i) = \sum_{t=1}^N \frac{c_{it}}{\sigma_{it}} \phi\left(\frac{y_i - m_{it}}{\sigma_{it}}\right) \quad (14)$$

但这里的参数 $c_{it}, \sigma_{it}, m_{it}$, $i = 1, \dots, M, t = 1, \dots, N$ 要和分离阵 W 一起训练更新。我们称为自适应多变量密度估计。它与 (11) 式的主要区别在于 (11) 式的所有参数如 $c_{it}, \sigma_{it}, \mu_{it}$ 均在训练 W 前已通过聚类确定而训练过程中不必修改。我们称前一种方法为固定宽度多变量密度估计。

除了 W 的训练仍同 (3) 式, (14) 式中其他参数可通过求 (1) 式对各参数的梯度 $K(W, c, \sigma, m)$ 得到训练公式:

$$\begin{aligned} \frac{\partial K}{\partial c_{it}} &= \frac{\partial}{\partial c_{it}} \left\{ - \int P_X(x) \sum_{i=1}^M P_{Y_i}(y_i) dx \right\} = \frac{\partial}{\partial c_{it}} \{ -E_x [P_{Y_i}(y_i)] \} \\ &= -E_x \left\{ \phi \left(\frac{y_i - m_{it}}{\sigma_{it}} \right) \frac{1}{P_{Y_i}(y_i) \sigma_{it}} \right\} \end{aligned} \quad (15)$$

$$\begin{aligned} \frac{\partial K}{\partial \sigma_{it}} &= -E_x \left\{ \frac{1}{P_{Y_i}(y_i)} \frac{\partial P_{Y_i}(y_i)}{\partial \sigma_{it}} \right\} \\ &= E_x \left\{ \frac{c_{it} \phi \left(\frac{y_i - m_{it}}{\sigma_{it}} \right)}{P_{Y_i}(y_i) \sigma_{it}^2} + \frac{c_{it} \phi' \left(\frac{y_i - m_{it}}{\sigma_{it}} \right) (y_i - m_{it})}{P_{Y_i}(y_i) \sigma_{it}^3} \right\} \end{aligned} \quad (16)$$

$$\frac{\partial K}{\partial m_{it}} = -E_x \left\{ \frac{1}{P_{Y_i}(y_i)} \frac{\partial P_{Y_i}(y_i)}{\partial m_{it}} \right\} = E_x \left\{ \frac{c_{it}}{P_{Y_i}(y_i) \sigma_{it}^2} \phi' \left(\frac{y_i - m_{it}}{\sigma_{it}} \right) \right\} \quad (17)$$

其中 $\phi'(s) = \partial \phi(s) / \partial s$ 。由于混迭信号 X 中存在 M 个独立源信号, 所以, 仅当将每个 Y_i 表示一个 S_j 时目标函数 (1) 式达到最小, 此时只有估计的边缘密度为源信号密度充分接近, 而且 W 为分离阵。

这些参数的更新, 连同 (14) 式和 (3) 式构成了又一分离算法。

关于核函数 ϕ 的选取, 我们可以选高斯核, 即 $\phi(s) = (1/\sqrt{2\pi}) \exp(-s^2/2)$, 也可以为一 sigmoid 函数的导数。令 $f(x) = 1/(1 + \exp(-x))$ 表示 sigmoid 函数, $g(x) = f(x)(1 - f(x))$ 表示 $f(x)$ 的导数, 则显然, $g(x)$ 为 x 的密度, 满足条件:

$$g(x) \geq 0, \quad \int g(x) dx = 1 \quad (18)$$

特别指出的是, 用 $g(x)$ 作为核函数, 则算法成为 Bell 的 Infomax 算法^[5]的推广。Infomax 网络中, 假设输入矢量 X , 输入的线性组合为 $R = WX$, 则网络输出为 $Y_i = f_i(r_i)$, 其中 $f_i(\cdot)$ 为非线性传输函数。输出熵:

$$\begin{aligned} H(y) &= - \int P_Y(y) \ln P_Y(y) dy = - \int P_R(R) \ln \frac{P_R(R)}{\prod_{i=1}^M f_i(r_i)} dR \\ &= K \left(P_R(R), \prod_{i=1}^M f_i'(r_i) \right) \end{aligned} \quad (19)$$

其中 $K(P_R(R), \prod_{i=1}^M f_i'(r_i))$ 表示两个密度函数 $P_R(R)$ 和 $\prod_{i=1}^M f_i'(r_i)$ 之间的 Kullback-Leibler 距离。

比较 (19) 式和 (1) 式很容易可以看出, 如果我们选择非线性传输函数的导数作为独立源信号的概率密度, 则当输出熵 $H(y)$ 达最大时信号得以分离。Bell^[5] 选择固定 $f(x)$ 为非线性传输函数, 我们算法中选择可调整的 sigmoid 函数的组合, 增加了算法的鲁棒性。当 (14) 式中取 $N = 1$, 我们可得 Infomax 算法, 因此, 我们研究的算法是 Infomax 算法的推广。

4 计算机仿真实例

为验证本文所提算法的性能，我们分别以语音和图像作源信号进行了盲分离仿真。

4.1 混叠语音信号盲分离

图 1 表示以 11kHz 采样的四个说话者说话，时间为 10s，语音数据 $S = [s_1, s_2, s_3, s_4]^T$ 作为源信号，通过 $X = AS$ 与一随机产生的常数矩阵 A 混叠，得到观测数据 $X = [x_1, x_2, x_3, x_4]^T$ 如图 2 所示。图 3 为利用 3.1 节的分离算法取 $N=8$ 时所得分离后的信号 $Y = [y_1, y_2, y_3, y_4]$ 。图 4 为利用 3.2 节的分离算法时，取 $N = 6$ 所得分离后的信号，其中 (14) 式的核函数取 sigmoid 函数的导数，且 $N=4$ 。从图 3 和图 4 可以看出，两种算法都成功地恢复了源语音信号。为衡量算法的性能，我们定义信噪比 $SNR(y_i) = 10 \log\{E[|s_i|^2]/E[|y_i - S_i|^2]\}$ (dB)，我们计算的两种算法分离后的各个源的信噪比 (dB) 分别为

3.1 节算法： $SNR(y_1)=41.74, SNR(y_2)=38.0, SNR(y_3)=27.84, SNR(y_4)=24.26$ 。

3.2 节算法： $SNR(y_1)=33.94, SNR(y_2)=30.22, SNR(y_3)=45.60, SNR(y_4)=41.20$ 。

算法的性能还可通过 $G = WUA$ 来衡量。针对两种算法得到的 $G_{3.1}$ 和 $G_{3.2}$ 分别为

$$G_{3.1} = \begin{bmatrix} \underline{0.0389} & -0.0001 & 0.001 & 0.0001 \\ 0.0002 & 0.0001 & \underline{-0.0408} & 0.0004 \\ -0.0015 & -0.0002 & 0.0005 & \underline{0.0420} \\ -0.0006 & \underline{0.0198} & 0.0007 & 0.0001 \end{bmatrix}, G_{3.2} = \begin{bmatrix} \underline{0.2932} & 0.0007 & -0.0030 & -0.0048 \\ -0.0036 & 0.0015 & \underline{-0.2774} & 0.0060 \\ 0.0014 & 0.0000 & 0.0003 & \underline{0.2667} \\ -0.0011 & \underline{0.1147} & -0.0012 & -0.0018 \end{bmatrix}$$

可以看出，他们的每一行和每一列仅有一个元素远大于其他，因而能较好地恢复源信号，但由于 $G_{3.1}$ 和 $G_{3.2}$ 都非单位阵，图 3 和图 4 分离出的源信号的幅度和排列顺序都发生了变化，这在盲分离过程为幅度和次序的不确定 [2]，而 $G = WUA$ 被称为广义置换阵。

4.2 混叠图像信号盲分离

我们也用图像作为源信号进行了仿真。由于版面的限制，图像不再列出，仅给出能表明分离性能的有关数据。

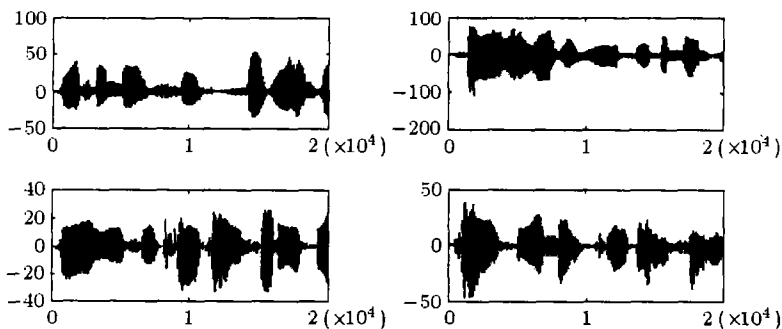





图 1 源语音信号 $s_i, i = 1, 2, 3, 4$

图 2 混叠语音信号 $x_i, i = 1, 2, 3, 4$ 图 3 分离后的语音信号 $y_i, i = 1, 2, 3, 4$ (3.1 节算法)图 4 分离后的语音信号 $y_i, i = 1, 2, 3, 4$ (3.2 节算法)

源信号为四幅标准的 256×256 图像, 通过 $X = AS$ 与一随机产生的常数矩阵 A 混叠。两种算法下分离出了源图像(3.1 节算法取 $N=8$, 3.2 节算法用高斯核函数且 $N=6$)。同样地, 我们定义图像的信噪比 $\text{SNR}(y_i) = 10 \log[255^2/\text{MSE}]$, MSE 为图像误差 $\delta_i = y_i - s_i$ 的平均能量。我们计算的两种算法分离后的各个源图像的信噪比分别为

3.1 节算法: $\text{SNR}(y_1)=23\text{dB}, \text{SNR}(y_2)=32\text{dB}, \text{SNR}(y_3)=27\text{dB}, \text{SNR}(y_4)=27\text{dB}$ 。

3.2 节算法: $\text{SNR}(y_1)=25\text{dB}, \text{SNR}(y_2)=35\text{dB}, \text{SNR}(y_3)=22\text{dB}, \text{SNR}(y_4)=26\text{dB}$ 。

两种算法均较好地恢复了源图像。

Infomax 算法只对正峭度信号^[5]且峭度大于某值时分离效果才相对较好。仿真结果表明, 本文的算法可以有效分离具有负峭度的图象信号。为了对算法性能进行比较, 我们还引

入常用的用来衡量算法分离性能的指标^[4]:

$$PI(G) = \sum_{i=1}^N \left[\sum_{j=1}^N \frac{|g_{ij}|}{\max_k |g_{ik}|} - 1 \right] + \sum_{j=1}^N \left[\sum_{i=1}^N \frac{|g_{ij}|}{\max_k |g_{kj}|} - 1 \right] \quad (20)$$

式中的 g_{ij} 为第 (i, j) 个元素。当信号完全分离后, 上式应该为零。一般它为较小的值。本文中的两个算法和 Infomax 算法在分离具有正峭度的混叠语音信号时性能比较如图 5 所示。




图 5 算法性能分离比较

图中曲线 P_1 为 Infomax 算法, P_2 和 P_3 分别为本文的 3.1 节算法和 3.2 节算法。可以看出本文算法比 Infomax 算法分离效果更好, 这是因为 Infomax 用了固定的非线性函数来代替源信号概率分布, 而本文算法用自适应算法估计的概率密度, 更逼近源信号的真实密度。

关于算法的稳定性我们进行如下简要分析。当算法收敛时, 收敛的平衡点应该为 $E[I - f(Y)Y^T] = 0$, 此时矩阵 W 即为分离阵, 当 $i \neq j$ 时 $E[f_i(y_i)g_j(y_j)] = E[f_i(y_i)]E[g_j(y_j)]$ 为零, 而当 $i = j$ 时它为一标量值, 恰好满足统计独立的假设。

4 结 论

我们得出一类盲源分离算法。算法将 Kullback-Leibler 距离作为优化的目标函数。利用了多变量密度估计技术来逼近独立源信号的概率密度函数, 为盲分离算法中非线性函数的选取提供了一种新的途径。通过把语音和图像作为源信号进行了计算机仿真, 结果表明了算法的良好性能。

参 考 文 献

- [1] C. Jutten, J. Herault, Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic structure, *Signal Processing*, 1991, 24(1), 1-10.
- [2] P. Comon, Independent component analysis, A new concept? *Signal Processing*, 1994, 36(3), 287-314.
- [3] 刘磊, 鲁子奕, 何振亚等, 基于信息理论准则的盲源分离方法, *应用科学学报*, 1999, 17(2), 156-162.
- [4] H. H. Yang, S. Amari, Adaptive online learning algorithms for blind separation: Maximum entropy and minimum mutual information, *Neural Computation*, 1997, 9(7), 1457-1482.
- [5] A. J. Bell, T. J. Sejnowski, An information-maximization approach to blind separation and blind deconvolution, *Neural Computation*, 1995, 7(6), 1129-1159.

- [6] D. Obradovic, G. Deco, Information maximization and independent component analysis, is there a difference? *Neural Computation*, 1998, 10(8), 2085–2101.
- [7] J. F. Cardoso, B. Laheld, Equivariant adaptive source separation, *IEEE Trans. on Signal Processing*, 1996, 44(12), 3017–3030.
- [8] J. N. Hwang, S. R. Lay, A. Lippman, Nonparametric multivariate density estimation, A comparative study. *IEEE Trans. on Signal Processing*, 1994, 42(10), 2795–2810.
- [9] J. N. Hwang, S. R. Lay, A. Lippman, Unsupervised learning for multivariate probability density estimation, Radial basis and projection pursuit, *IEEE Int. Conf. Neural Networks*, 1993, San Francisco, CA, 1486–1491.
- [10] B. A. Linde, R. M. Gray, An algorithm for vector quantizer design, *IEEE Trans. on Commun.*, 1980, 28(1), 84–95.

A CLASS OF APPROACHES FOR BLIND SOURCE SEPARATION BASED ON MULTIVARIATE DENSITY ESTIMATION

He Zhenya Yang Luxi Liu Ju Lu Ziyi He Chen*

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

(**Electronic Eng. Dept., Shanghai Jiaotong University, Shanghai 200030, China*)

Abstract A class of learning algorithms is derived for blind separation of independent source signals in this paper. These algorithms are based on minimizing a contrast function defined in terms of the Kullback-Leibler distance. By utilizing the technique of multivariate density estimation, two types of separating algorithms are obtained. Simulations illustrate the effectiveness of the algorithms.

Key words Blind sources separation, Multivariate density estimation, Mutual information, Statistical independent

何振亚: 男, 1923 年生, 教授, 博士生导师, IEEE Fellow, 国家攀登计划首席科学家, 研究领域为自适应信号处理, 多维信号处理和神经计算科学等.

杨绿溪: 男, 1964 年生, 博士, 副教授, 主要研究方向为信号 / 图像处理, 神经网络等.

刘 璐: 男, 1965 年生, 副教授, 主要研究方向为盲信号处理, 神经网络信息处理等.

鲁子奕: 男, 1972 年生, 博士, 主要研究方向为神经网络.

何 晨: 男, 1952 年生, 教授, 主要研究方向为通信, 信号处理等.