

独立子波函数和小波分析在单路含噪信号盲分离中的应用研究:模型与关键技术

成谢锋^{1,3},陶冶薇^{2,3},张少白²,张学军¹,刘 璐⁴

(1. 南京邮电大学电子科学与工程学院,江苏南京 210001; 2. 南京邮电大学,江苏南京 210001;
3. 济南大学,山东济南 250022; 4. 山东大学信息科学与工程学院,山东济南 250001)

摘 要: 本文提出了一种基于独立子波函数和小波分析的单路含噪混合信号的盲源分离新方法. 首先分析了独立子波函数的组成原理,以及获得独立子波函数的方法;然后通过结合独立子波函数进入单路混合信号,使单路混合信号由一维向量转化成为多维向量;其次讨论了利用小波进行二次去噪和解决数据段顺序不确定性的问题,并且文中还给出了独立子波函数个数判定方法和相似相图;最后通过消除瞬态诱发耳声发射中伪迹的实验,验证了本方法的有效性和可行性.

关键词: 盲源信号分离;独立子波函数;单路含噪信号;小波;独立分量分析;瞬态诱发耳声发射

中图分类号: TN911.7 **文献标识码:** A **文章编号:** 0372-2112 (2009) 07-1522-07

Applications of Independent Sub-Band Functions and Wavelet Analysis in Single-Channel Noisy Signal BSS: Model and Crucial Technique

CHENG Xie-feng^{1,3}, TAO Ye-wei^{2,3}, ZHANG Shao-bai², ZHANG Xue-jun¹, LIU Ju⁴

(1. School of electron Science and Engineering, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China;
2. Nanjing University of Posts And Telecommunication, Nanjing, Jiangsu 210003, China; 3. University of Jinan, Jinan, Shandong 250022, China;
4. School of Information Science and Engineering, Shandong University, Jinan, Shandong 250001, China)

Abstract: Based on independent sub-band functions and wavelet analysis, the paper presents a new technique of signal processing to accomplish blind source separation when a single-channel mixture signal in noise is given. Firstly we analyzed the compositional principle of independent sub-band function and the method how to get independent sub-band function. And combining independent sub-band function into the single mixture signal, a single mixture signal can be transformed into a multi-dimensional vector from one-dimensional. Then we discuss the problems of second de-noising with wavelet and the order's uncertainty of data segments. The paper also presents a determine method of the number of independent sub-band function and the similar phase diagram. Through an experiment of eliminating the artifact of transient evoked otoacoustic emissions, the feasibility and effectiveness of this method have been proven.

Key words: blind signal separation; independent sub-band function; noise; wavelet; independent component analysis; transient evoked otoacoustic emissions

1 引言

盲源信号分离(Blind Signal Separation)是近年出现的一种新的信号处理方法,其作用是将满足某些条件诸如相互统计独立的源信号从未知的混合信号中分离出来.在语音处理、生物医学信号处理、电子通讯等方面都有着非常广泛的应用.但单路含噪混合信号的盲分离是困难的,因为太多的未知因素^[1~6],是一个病态问题.

可是,单路含噪混合信号又普遍存在于我们生活之中,近年来已有一些学者开始了这方面的研究,文献[9]就是一种有代表性的方法.本论文提出了另一种基于独立子波函数和小波分析的单路含噪混合信号的盲源分离新方法,对独立子波函数的模型及相关技术进行了深入研究.在本文中,首先分析了独立子波函数的组成原理,以及获得独立子波函数的方法;然后通过结合独立子波函数进入单路混合信号,使单路混合信号由一维向量转

收稿日期:2008-05-15;修回日期:2008-09-15

基金项目:山东省自然科学基金(No. Y2006G03, No. Y2007G14, No. Y2007G04, No. 2006CG3204005);国家自然科学基金(No. 60872024);南京邮电大学引进人才基金(No. NY207139)

化为多维向量从而构成了一种新的盲源分离方法;其次讨论了利用小波进行二次去噪和解决数据段顺序不确定性的问题,并且文中还给出了独立变量个数的判定方法和相似相图;最后通过消除瞬态诱发耳声发射中的伪迹实验,验证了本方法的有效性和可行性.

2 单路含噪信号盲分离的描述

设某个混合系统由 m 个传感器和 k 个信号源组成, $s = [s_1(t), s_2(t), \dots, s_k(t)]^T$, $x = [x_1(t), x_2(t), \dots, x_m(t)]^T$, 其混合模型可以表述如下^[3]:

$$x(t) = As(t) \quad (1)$$

其中 A 是非奇异混合矩阵. 令 $E[s_i(t_1), s_j(t_2)] = 0$, $i \neq j (i, j = 1, 2, \dots, k)$, $\forall t_1, t_2$, $E[s_i(t)] = 0$ 和 $y = [y_1(t), y_2(t), \dots, y_k(t)]^T$, W 是分离矩阵, 则分离模式如下:

$$y(t) = Wx(t) = WAs(t) = Cs(t) \quad (2)$$

式中 $C = WA$ 称为混合-分离复合矩阵, 等于一个排列矩阵和一个满秩对角矩阵的乘积. 独立成分分析就是要寻找一个 W , 使新向量 $y(t)$ 的各分量之间相互统计独立, 可见盲分离问题实际上是一个多解问题. 又设 D 为一可逆对角阵, 其对角元素为 $\{d_{ii} \mid R, i = 1, 2, \dots, k\}$; P 为置换阵, 它的每一行每一列仅有一个元素为 1, 其它元素为零. 令 $W = DA^{-1}$, 且 $y(t)$ 各成分统计独立, 则 $Py(t)$ 也满足各成分统计独立, 式(2)可表示为:

$$y(t) = Cs(t) = PDs(t) \quad (3)$$

显然盲分离存在不确定性. 因为 $y(t) = PDs(t)$, D 和 P 为任意不确定参数, D 对应了幅值的不确定性, P 对应了排列次序的不确定性. 通常情况下, 只要找出分离矩阵 W , 源信号就能被分离, 这两个不确定性是可以接受的. 但我们的目标是在提供单路含噪混合信号中复原出所有的源信号 $s_i(t)$. 设 $N = [N_1(t), N_2(t), \dots, N_m(t)]$ 为输出信号中的噪声集合, $N \in R^m$, 那么有:

$$x = As + N \quad (4)$$

(1) 当 $m = k$, $N = 0$ 时, 为多路输入多路输出的含噪混合系统, 有

$$x = As + N = \begin{bmatrix} A_x & A_N \end{bmatrix} \begin{bmatrix} s + N_1 \\ N_2 \end{bmatrix} \quad (5)$$

其中 $\begin{bmatrix} A_x & A_N \end{bmatrix}$ 为混合矩阵, $\begin{bmatrix} s + N_1 \\ N_2 \end{bmatrix}$ 为含噪信源的统计独立变量, 这种噪声意味着观测数据和源信号之间存在非线性, N_2 为纯噪声分量.

(2) 当 $m = 1, k > 1, N = 0$ 时, 为多路输入单路输出的含噪信号模型^[9,10]. 显然要利用单路含噪混合信号去复原 k 个源信号, 在数学处理中是病态解 (ill-conditioned). 因为已知单路信号却有 $2k$ 个以上的未知变量. 因此希望有某些预知的、相关的信号用于做训练信号,

作为先验知识.

3 独立子波函数

3.1 独立子波函数的模型

我们认为^[4], 一个信号是能够由一系列加权的时域独立子波函数的线性叠加所构成. 一个信源的独立子波函数可以通过一组训练数据的学习而获得, 而这些独立子波函数能被用来分离未知的信号. 比如一组军号信号, 可将其中的每一个信号分成 p 段, 然后采用最大似然估计等方法去提取独立子波函数, 再通过训练产生一组基本的独立子波函数簇, 由此所有的发生音调高低变化、强度大小变换、速度快慢变化的军号信号段均可由该基本独立子波函数簇的线性加权合成^[16].

为方便研究信源的独立子波函数, 假定式(1)中的 $k = 2$, 其中一路源信号 $s_1(t)$ 被显示在图 1(a) 中. 对于 $s_1(t)$, 我们将其分解为等长的短的数据段 $s_1^p(t)$, ($p = 1, 2, \dots, P$), 如图 1(b) 所示. 对于 $s_1(t) \in R^m$ 分成 P 段的后的信号进行独立成分分析, 这种独立性使用负熵最大判据或信息损失函数, 例如最小 Kullback-Leibler 发散度来评价, 通过寻找一个满秩分离矩阵, 从而定义输出信号 $[b^1, b^2, \dots, b^Q]$ 中包括了尽可能独立的源信号 $s_1(t)$ 的信息. 选择与 $s_1(t)$ 同性质的一组信号作训练数据, 通过同样的方法可以获得一组在时域相互统计独立的函数簇, 我们称之为独立子波函数. 如图 1(c) 所示.




图1 独立子波函数的组成原理示意图

并且 $s_1(t)$ 的各段信号能够由 $b_1^q (q = 1, 2, \dots, Q)$ 的线性加权而获得, 例如在图 1(d) 所示的 s_1^2 . 其中 Q 是独立子波函数的总个数, C_{pq} 是信号 $s_1(t)$ 第 p 个段的第 q 个独立子波函数的系数. 当 $P = Q$, 有:

$$\begin{bmatrix} s_1^1 \\ s_1^2 \\ \dots \\ s_1^P \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1Q} \\ c_{21} & c_{22} & \dots & c_{2Q} \\ \dots & \dots & \dots & \dots \\ c_{P1} & c_{P2} & \dots & c_{PQ} \end{bmatrix} \begin{bmatrix} b_1^1 \\ b_1^2 \\ \dots \\ b_1^Q \end{bmatrix} \quad (6)$$

当 C 是满秩, 则 s_1^p 和 b_1^q 的转换是可逆的. 如果独立子波函数簇 b_1^q 和 c_{pq} 能够预先获得, 那它们就能被用

来作为单通道混合信号盲分离的先验信息. 若 C 的逆矩阵是 $W = C^{-1}$, 正如公式(2)所示, 对于训练数据 s_1^p , 采用负熵最大判据进行迭代处理^[5], 其迭代公式为

$$W_i(j+1) = E \left[x_i g \left(W_i^T(j) x_j \right) \right] - E \left[g \left(W_i^T(j) x_j \right) \mid W_i(y) \right] \quad (7)$$

式中 g, g' 分别为函数 $G = \frac{1}{a} \lg \cos(ay)$ 的一阶和二阶导数, 其中 $1 \leq a \leq 2$. $W_i(j)$ 为迭代 j 次后的 W 矩阵中的第 i 个信号源相对应的某一行向量, 逐个求出 W_1, W_2, \dots, W_Q , 从而得到各个独立子波函数.

3.2 独立子波函数个数 Q 的判定方法

独立子波函数个数 Q 的确定, 不仅影响到式(6)描述的准确性, 而且直接影响到分离结果的好坏^[7,8,13]. 目前还没有较好的判定独立子波函数数目的方法. 本文提出了一种通过外加已知信号, 用实验分析法判定独立子波函数数目的方法.

对式(4), 外加一个确定的已知信号 e_0 , 有

$$x = As + N + e_0 \quad (8)$$

如果 e_0 与 $(As + N)$ 之间满足相互统计独立, 即 N 为非高斯噪声, 并且 e_0 的信号强度大于 N 的信号强度. 根据 ICA 的相关理论^[5,10,14], 当估计的独立子波函数的数目与真实的独立子波函数数目一致时, 可获得最佳的盲分离效果, 有分离结果 \hat{e}_0 与输入信号 e_0 的均方差最小.

具体方法如下:

(1) 对式(4)所示的样本信号, 先进行小波变换分解, 用第一层细节系数的标准差作为样本信号的噪声强度的估计;

(2) 添加白噪声 e_0 , 且 e_0 的信号强度略大于样本信号的噪声强度;

(3) 令 $i = 1, p = i + 1$, 将样本信号分成 p 段, 用 ICA 方法对它进行盲分离;

(4) 将分离结果与 e_0 比较, 若 $|e_0 - \hat{e}_0^i| > \epsilon$, 则 $i + 1$, 重复第(3)步, 否则执行第(5)步. 其中 ϵ 为给定的误差阈值.

(5) 结束计算. 此时所获得的 p 值就是我们估计的独立子波函数的数目 Q .

4 单路含噪信号盲分离的关键技术

4.1 扩大单通道信号源维数的方法

基于公式(1), 当 $m = 1, k = 2$, 有

$$x = a_1 s_1 + a_2 s_2 \quad (9)$$

其中 $s_1(t), s_2(t)$ 是相互统计独立的源信号, 将它分解为等长的数据段 P 段, 我们有:

$$x^p = \sum_{p=1}^P a_1 s_1^p + \sum_{p=1}^P a_2 s_2^p \quad (10)$$

令 x^p 的长度和独立子波函数的长度相同. 通过加入 s_1 源信号的独立子波函数进入 x^p , 一维混合信号就被转化成多维信号, 它可以表示为:

$$\begin{bmatrix} x^p \\ s_{11}^p \\ s_{12}^p \\ \dots \\ s_{1Q}^p \end{bmatrix} = \begin{bmatrix} a_2 s_2^p + a_1 s_1^p \\ s_{11}^p \\ s_{12}^p \\ \dots \\ s_{1Q}^p \end{bmatrix} = \begin{bmatrix} a_2 & a_1 c_{p1} & \dots & a_1 c_{pQ} \\ 0 & c_{p1} & 0 & 0 \\ 0 & 0 & c_{p2} & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & c_{pQ} \end{bmatrix} \begin{bmatrix} s_2^p \\ b_1^p \\ b_2^p \\ \dots \\ b_Q^p \end{bmatrix} \quad (11)$$

其中 x^p 是第 p 段的混合信号, $s_{1q}^p = c_{pq} b_1^q$ 是由式(6)预先获得的独立子波函数和对应的系数. 式(11)可认为是一种传感器个数大于源信号个数的情况, $s_1(t)$ 的独立子波函数保留了该源信号的信息, 且是相互统计独立, 加之 $s_1(t)$ 和 $s_2(t)$ 又相互统计独立的, 所以它们其中的一段之间也具备相互统计独立, 这满足 ICA 的所有假设, 所以我们可以利用 ICA 方法获得一个 \hat{s}_2^p 的盲分离结果.

用 ICA 算法获得 \hat{s}_2^p 有直接方法和间接方法两种.

直接方法属于盲提取, 是要估计一个具有特殊统计特征或性质的 \hat{s}_2^p 源信号, 而舍弃其它不感兴趣的源信号. 在许多应用中, 如生物医学中, 一些和源信号有关的参考信号显然是可以清楚得到的, 这种情况下, 通常希望提取与参考信号 $r(t - \tau)$ 相关程度尽可能高的独立源信号, 其中 τ 是适当选择的时滞. 所以可以将盲分离算法中的代价函数加上一个强制项 $E\{r^2(t - \tau) y^2(t)\}$. 例如利用线性预测器的盲提取算法的代价函数可以更改为^[13,14]:

$$J(w) = \frac{1}{2} E\{y^2\} + \frac{1}{4} (c - E\{y^2(t) r^2(t - \tau)\})^2 \quad (12)$$

其中 $y(t) = y(t) - \sum_{k=1}^L b_k y(t - k)$, L 是强制因子, c 是适当选择的正常数, 通常取 $c = 1$, b_k 是 FIR 滤波器的传递系数. 根据标准梯度下降法求式(12)的最小值就可导出所需的分离规则. 这样可直接分离出 \hat{s}_2^p .

间接方法是基于式(11)用 ICA 方法先获得 \hat{s}_1^p , 然后将 $x^p - \hat{s}_1^p$ 和 x^p 结合起来就成了一个新的二维矢量, 根据式(2)有:

$$\begin{bmatrix} (\hat{s}_1^p)^p \\ (x^p - \hat{s}_1^p)^p \end{bmatrix} = W \begin{bmatrix} x^p \\ x^p - \hat{s}_1^p \end{bmatrix} \quad (13)$$

再进行一次盲分离, 就可获得预期的结果.

4.2 基于小波断点检测解决数据段顺序不确定性问题

由于在 BSS 中存在着分离结果的顺序和幅值的不确定性, 本文采用分段处理方法, 其输出结果在排序上

的不确定性, 使各数据段的分离结果之间没有统一的对应关系, 常用“试听”“试看”等方法才能完成各数据段分离结果的前后连接。这一项工作比较繁琐, 尤其在信源比较多的情况下, 工作量非常大。

设经 ICA 分离后的两类数据段为 $f_j(i), f_{j+1}(i)$ 将二者连接时有:

$$f(i) = f_j(i) u(-i + i_g) + f_{j+1}(i) u(i - i_g) \\ = \begin{cases} f_j(i), & i < i_g \\ f_{j+1}(i), & i > i_g \end{cases} \quad (14)$$

其中 i_g 为连接点, $u(i)$ 为阶跃函数。

(a) 如果 $f_{j+1}(i)$ 是 $f_j(i)$ 同信号源连续段分离的结果, 且是无相位差连接, 那么 $f_{j+1}(i)$ 和 $f_j(i)$ 之间不存在不连续间断点。

(b) 如果 $f_{j+1}(i)$ 不是 $f_j(i)$ 同信号源连续段分离的结果, 那 $f_{j+1}(i)$ 和 $f_j(i)$ 之间存在不连续间断点。

(c) 如果 $f_{j+1}(i)$ 是 $f_j(i)$ 同信号源连续段分离的结果, 但是存在 180 的相位差, 那么 $f_{j+1}(i)$ 和 $f_j(i)$ 之间存在不连续间断点。

因此, 可以基于小波变换所具有的空间局部化性质, 利用小波变换来检测 $y_j(i), y_{j+1}(i)$ 的连接处是否存在间断点。选用消失矩大于 2, 支集长度最短的小波, 比如 dB3、Coif1, 通常可取小波分解的第一层细节系数判断, 在间断点位置, 系数有很大的幅值, 其判断域值可取等于 2 倍均值。当对 \hat{s}_j^2 和 \hat{s}_{j+1}^2 进行连接处理时, 用小波检测如出现大于判断域值现象, 可认为是 (c) 类情况, 将 \hat{s}_{j+1}^2 反转 180 再连接, 使之成为 (a) 类情况, 否则是 (b) 类情况, 更换之。这样就能实现各数据段分离结果的快速判断和正确连接。

4.3 基于矢量归一法解决幅值不确定性问题

由于 ICA 方法中存在幅值不确定问题, 这使每段分离结果的能量变化较大, 因此需要对幅值进行整理。我们采用矢量归一法进行幅值调整。即令 ICA 分离出的信号 \hat{s}_k 为^[15]:

$$\hat{s}_k = \frac{\hat{s}_k}{\|\hat{s}_k\|}, \quad (k=1, 2 \dots K) \quad (15)$$

4.4 将分离矩阵 W_j 近似为常系数矩阵处理, 以提高 ICA 运算的速度

对每一段数据都采用 ICA 方法进行处理是非常耗时的。在信号均匀分段处理中, 如果式(1)中的混合矩阵 A 是非时变的, 那么 A 是常系数矩阵。因此我们可以将第一段混合信号进行 ICA 处理所获得的分离矩阵 W_1 视为常系数矩阵, 它对全部观测数据均适用。但实际上矩阵 A 往往不是常系数矩阵, 通常具有一定的时变性, 为了提高分段混合信号进行 ICA 处理的速度, 本文的方法是选择其中具有代表性的一段信号, 比如第

一段信号, 优选适当的参数, 用 ICA 多次计数, 可获得该段混合信号的最佳源信号 \hat{s}_k^1 , 同时还获得起始分解矩阵 W_1^1 。然后将 W_1^1 作为第二段信号进行 ICA 的分解矩阵 W_1^2 的初值, 从该段起重新进行 ICA 分析, 用新的分解矩阵和信源特征代替原始值重复上述过程, 直到各段数据全部被正确分离。

4.5 小波去噪分析

利用滤波器和 BSS 方法可以消除噪声。比如 ICA 可以通过互信息冗余对系统进行去噪^[8,14], 能消除式(5)中的 N_2 , 同时分离出系统的统计独立状态变量。但 ICA 无法消去包含在统计独立状态变量中的噪声 N_1 。换句话说, 对于统计独立状态变量中具有自相关信息的噪声是不可能用 ICA 去除的。因此我们考虑用小波变换对独立状态变量中的噪声进行去噪。

由小波理论^[6], 式(4)可对应表示为

$$\tilde{x}(t) = A_J(t) + \sum_{j=1}^J [D_j(t) + N_1^j] \quad (16)$$

式中, A_J 为低频分量, D_j 为高频分量, J 为分解级数。在物理信号中, 低频信号表征信号本身特征, 而高频信号则表征信号的细微差别。在语音信号中, 噪声 N_1^j 是在高频段, 所以可以用式(16)去噪。

根据上述分析, 我们找出了一种基于独立子波函数和小波分析的单路含噪信号的盲分离方法。

第一步, 根据源信号类型构造训练集, 建立该类信号的一组独立子波函数。

第二步, 利用带通滤波器对单路含噪信号进行消噪, 消除背景噪声 N_2 , 得到尽可能“纯净”的混叠信号 $x(t)$ 。

第三步, 对 $x(t)$ 均匀分段, 对每一段加入独立子波函数 b_j^i , 按照式(11)将每一段一维信号 $x(t)$ 扩展成一个多维向量。

第四步, 对 $x(t)$ 的每段扩展向量进行第一次 ICA 处理, 可获得分段的分离结果 $\hat{s}_1^1, \hat{s}_1^2, \dots, \hat{s}_1^p$, 然后按照式(13)的方法进行第二次 ICA 处理获得 $\hat{s}_2^1, \hat{s}_2^2, \dots, \hat{s}_2^p$ 。或者采用式(12)所述方法一次性获得 $\hat{s}_2^1, \hat{s}_2^2, \dots, \hat{s}_2^p$ 。

第五步, 采用 4.2 节的小波断点检测方法并结合第 6 节的相似相图, 对经幅值调整后的 $\hat{s}_2^1, \hat{s}_2^2, \dots, \hat{s}_2^p$ 进行正确连接, 以获得一个完整的源信号估计 \hat{s}_2 。

第六步, 由于盲分离后的 \hat{s}_2 中还会存在一些残留噪声 N_2 , 针对这种情况, 用小波变换对 \hat{s}_2 再作一次消噪处理, 最终获得更加“纯净”的估计信号 \hat{s}_2 。

5 a_1 和 a_2 的估计

由以上分析可知, a_1 的值可以很容易的由式(11)估计出, 因为它是每一成分的公共系数。但是 a_2 的值

是很难直接获得,因此我们需要单独考虑 a_2 . 假定给出了 w 和当前的 s_{21}, s_{22} , 根据式(2)有:

$$s = Wx \tag{17}$$

$$x = W^{-1}s = Ds \tag{18}$$

根据式(9)有:

$$x = a_1 s_1 + a_2 s_2 \tag{19}$$

那么有:

$$(d_{11}s_1 + d_{21}s_1)/2 + (d_{12}s_2 + d_{22}s_2)/2 = a_1 s_1 + a_2 s_2 \tag{21}$$

我们可以得到:

$$a_2 = \frac{1}{2} \frac{\sum_{i=1}^N d_{ij}s_i}{\sum_{i=1}^N s_i^2} - \frac{\sum_{i=1}^N d_{i1}s_i}{\sum_{i=1}^N s_i^2} a_1 \tag{22}$$

6 相似相图

ICA 是信息处理领域的一个前沿研究课题. 为了评价分离效果, 目前普遍采用相似系数作为检验指标. 设分离后的信号为 $y(n)$, 原信号为 $s(n)$, 定义相似系数为:

$$(y_i(n), s_j(n)) = \frac{|\sum_{n=1}^N y_i(n) s_j(n)|}{\sqrt{\sum_{n=1}^N y_i^2(n) \sum_{n=1}^N s_j^2(n)}} \tag{23}$$

由于相似系数在 $y(n) = ks(n)$ 时, $= 1$, 其中 k 为常数, 可见这与式(3)有相同的结论, 相似系数允许盲分离的结果存在幅值上的差异, 换句话说, 相似系数不能反映出 $y_i(n)$ 与 $s_j(n)$ 的幅值差异, 也不能反应出 $y_i(n)$ 与 $s_j(n)$ 的相位差异. 为此我们引入相似相图这种新的评价方式. 这种方式虽然不能定量反应出相似程度, 但能形象直观的表明幅值差异和相位差异, 与相似系数 配合起来使用, 能较全面的对分离结果进行分析和评价. 特别对分段分离的结果进行评价和依序连接特别有用. 相似相图的判断规则是:

设有两信号 f_1, f_2, f_1 的幅值为 A_1 , 频率 ω_1 , 相角为 ϕ_1, f_2 的幅值为 A_2 , 频率 ω_2 , 相角为 ϕ_2 .

规则 1 如果 $A_1 = A_2, \phi_1 = \phi_2, \omega_1 = \omega_2$, 则相似相图是夹角为 45 度的斜线, 此时 $= 1$, 如图 2(a) 所示.

规则 2 如果 $A_1 = kA_2, \phi_1 = \phi_2, \omega_1 = \omega_2$, 则相似相图是夹角为 45 度的具有宽度为 d 的粗斜线, 并且有 $d \propto k$, 此时 < 1 , 如图 2(b) 所示.

规则 3 如果 $A_1 = A_2, \phi_1 = \phi_2, \omega_1 \neq \omega_2$, 则细斜线的夹角不再是 45 度, 而是随 $\Delta\phi$ 的变化左右倾斜, 当 $\Delta\phi = 180^\circ, = 1$ 时, 相似相图如图 2(c) 所示. 此时若是做的图像分离, 其分离结果为一张全黑图.

规则 4 如图 $A_1 \neq kA_2, \phi_1 \neq \phi_2, \omega_1 \neq \omega_2$, 则出现 n 个闭合圈的杂乱图形, 并且图形填充画面的面积与 $f_1、$

f_2 的不相关性成正比. 当充满整个画面时, $= 0, f_1, f_2$ 互不相关. 相似相图如图 2(d) 所示. 由于盲分离结果排列的不确定性, 当第 i 路的输入信号经 ICA 后的结果不是对应的第 i 路的输出时就会出现这种情况.

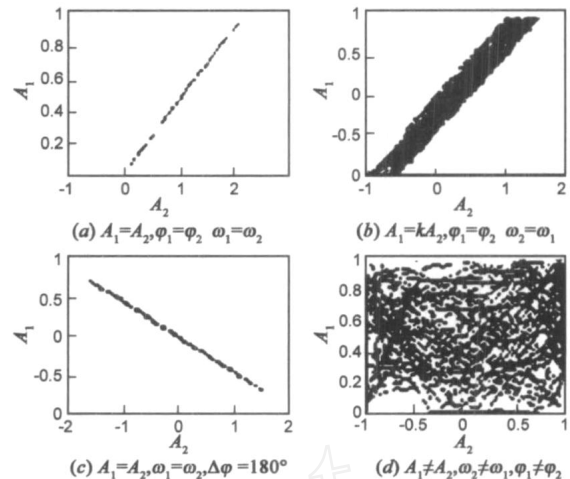


图2 相似相图的判断示例

7 瞬态诱发耳声发射信号的分离实验

耳声发射 (Otoacoustic Emissions, OAEs)^[11] 是当受到声音激励, 从耳蜗产生的经听骨链及鼓膜传导释放入外耳道的一种音频能量. 这个声音能够用一个小的探针传感器测量. 正常人的耳声发射检出率为 100%, 听力低于 25 - 30 dB 的病人是没有耳声发射的, 这意味着出现了外毛细胞的损伤或耳蜗功能的异常. 所以, 检验耳声发射的有无, 可以作为病人、特别是初生婴儿听觉系统的客观、无损检测手段. 瞬态诱发耳声发射 (Transient Evoked OAEs, TEOAEs)^[12] 是用很短的刺激声诱发出来的耳声发射, 其所需的检测时间短, 准确率高, 在生理学研究 and 临床上得到了广泛应用. 伪迹是刺激声在耳道内的直接反射, 主要存在于瞬态诱发耳声发射测量周期的前期, 与耳声发射在时域及频域都有重叠. 伪迹的存在降低了 TEOAEs 的信噪比, 且往往使 TEOAEs 前期的有用信号淹没在伪迹之中, 因此如何去伪迹是瞬态诱发耳声发射检测中的一个关键问题. 目前普遍采用的去除伪迹方法是导出非线性响应方法 (Derived Nonlinear Response, DNLR)^[12], 其依据原理是伪迹的幅度与刺激声的幅度成正比, 而耳声发射的幅度在刺激声较强时会趋于饱和. 但当刺激声较弱时, 由于耳声发射并未完全饱和, 使用 DNLR 法必然会损失一部分有用信号, 从而降低了信噪比. 另外, DNLR 法需要两组不同刺激强度的结果相减, 如果只考察一路 TEOAEs 在某一特定刺激强度下的情况, 此方法显然是不适用的.

瞬态诱发耳声发射信号可以由我们实验室制作的

耳声发射探测系统获得. 该探测系统利用 WINDOWS 的 API 函数控制声卡的输入输出, 系统选择了两种滤波器, 一个是输入端的滤波器, 带通频率是 300 ~ 8000Hz, 另一个是 MATLAB 中的数字滤波器, 带通频率是 600 ~ 6000Hz, 这样能有效消除一些噪音. 在耳道里, 发出一个 63.5 dB 的瞬态诱发信号, 一个由 TEOAEs 和回波组成的混合信号将被纪录到, 如图 3(a) 所示. 由于回波信号是随着激励信号增加而线性增加的, 而 TEOAEs 是随着激励信号的增加而非线性变化, 是逐渐转为饱和的, 因此, 从统计学来看, 它们之间是满足统计独立, 可以由式(9)表示出来. 其中 $s_1(t)$ 是回波信号及噪声, $s_2(t)$ 是 TEOAEs, $s(t)$ 是它们的混合信号. TEOAEs 如图 3(b) 所示, 回波信号及噪声如图 3(c) 所示. TEOAEs 和回波信号的频谱图如图 3(d) (1) 和 (2), 它们在时域和频域均发生重叠.




图3 耳声发射的探测信号

我们采用了一系列耳声发射中的回波信号来分析它们的独立子波函数簇. 在我们收集选定形式的回波噪声数据库中, 训练组被设计成从其中任选 10 个信号, 按照第 2 节的所述方法对每个样品的反复训练, 能形成 3 个独立子波函数簇, 如图 4(a).

首先将通过滤波器获得的单路含噪耳声信号 x 均匀分为三段, 加入独立子波函数 $b_i^q (q=1, 2, 3)$, 按照式(11)将一维信号 $x(t)$ 扩展成一个四维向量, 然后按照 4.1 节所述方法进行 ICA 处理, 获得分段的分离结果 $\hat{s}_1^1, \hat{s}_2^1, \hat{s}_3^1$, 最后根据式(15)进行幅值调整并按照小波断点检测方法依序正确连接各段信号就获得 \hat{s}_2 . 对 \hat{s}_2 中还会存在一些残留噪声, 用小波变换再作一次消噪处理, 最终获得更加“纯净”的估计信号 \hat{s}_2 , 如图 4(b) 所示. 下面用相似相图直观验证实验结果. 将如图 3(b) 所示的用 CNLR 的方法所得到的结果令它为 $s_2(t)$. 根据式(22), \hat{s}_2 和 s_2 及 $\hat{s}_1^1, \hat{s}_2^1, \hat{s}_3^1$ 和 s_1^1, s_2^1, s_3^1 对应各段的相似系数和相似相图如图 4(d) 所示. 从图 4(d) (2) 的 \hat{s}_2 和 s_2 的相似相图可见, 它们不仅存在幅值上的差异, 而

且存在相位上的差异, 并且相差 $= 180^\circ$. 如果 \hat{s}_2 是由此结果直接相加合成, 它的相似系数是 0.3849, 相似相图是一个 X 型. 在 \hat{s}_2 反转 180° , 相位被纠正后, \hat{s}_2 的相似系数是 0.9496, \hat{s}_2 和 s_2 是同相位的, 其结果显示在图 4(d) (4), 可见我们的方法是有效的, 能实现信号快速连续的处理. (除图 3(d)、图 4(d) 外, 其它各图纵轴是幅值, 横轴是采样点.)




图4 TEOAEs分离结果

8 结果分析

综上所述, 我们提出的基于独立子波函数和小波分析的单路含噪混合信号的盲分离方法与传统的 DNLR 方法相比, 本方法只需要一个 TEOAEs 信号, 而 DNLR 方法至少需要二个 TEOAEs 信号, 所以本方法可以基于一个固定强度的激励信号去有效地检测所有新生儿的听力, 并且实验结果的相似系数接近 1, 这意味着分离是成功的, 这也可从相似相图直观看出这一点. 显然本方法具有连续可操作性、直观性和实用性, 并在语音信号与心声信号处理方面也有较好的效果, 这些内容将另文论述.

参考文献:

- [1] Nishimori, Yasunori, Plumbley, Mark D. Flag manifolds for subspace ICA problems[A]. Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing [C]. Hawaii, USA: CPS Press, 2007. 1417 - 1420.
- [2] Vigliano D, et al. An information theoretic approach to a novel nonlinear independent component analysis paradigm[J]. Signal Processing, 2005, 85(5): 997 - 1028.
- [3] Cardoso J. F. Blind beam forming for non-gaussian signals[J]. IEEE Proceedings, 1993, 18(3): 362 - 370.
- [4] Cheng Xie-feng, et al. Independent sub-band functions: model and applications [A]. Proceedings of IEEE International Joint Conference on Neural Networks [C]. Orlando, USA: INNS Press, 2007. 1110 - 1114.
- [5] Qin H, Xie S. Blind separation algorithm based on covariance

- matrix[J]. Computer Engineering, 2003, 26(10) :36 - 38.
- [6] Chang S G, Yu B, Vetterli M. Adaptive wavelet threshold for image de-noising and compression[J]. IEEE Transactions on Image Processing, 2002, 32(9) :1532 - 1564.
- [7] Wold Scors. Validatory estimation of the number of components in factor and principal component analysis [J]. Technometrics, 1978, 20(4) :379 - 406.
- [8] Kundu D. Estimating the number of signals in the presence of white noise [J]. Journal of statistical planning and inference, 2000, 90(5) :57 - 68.
- [9] Jang Gil-Jin, Lee Te-Won. A maximum likelihood approach to single-channel source separation[J]. Journal of Machine Learning Research, 2004, 28(7 - 8) :1365 - 1392.
- [10] Jang Gil-Jin; Lee Te-Won. Single-channel signal separation using time-domain basis functions[J]. IEEE signal processing letters, 2003, 10(6) :168 - 171.
- [11] Whitehead M L. Measurement of otoacoustic emissions for hearing assessment [J]. IEEE Engineering in Medicine and Bioogy, 1994, 16(9) :210 - 226.
- [12] P RavazTni. Evoked otoacoustic emissions nonlinearities and response interpretation[J]. IEEE Transactions on Biomedical Engineering, 1993, 11(2) :500 - 504.
- [13] A Salazar, J Igual. Learning hierarchies from ICA mixtures [A]. Proceedings of IEEE International Joint Conference on Neural Networks[C]. Orlando, USA :INNS press, 2007. 12 - 17.
- [14] 刘璐, 何振亚. 盲分离与盲卷积[J]. 电子学报, 2002, 4(30) :570 - 576.
- Liu Ju, He Zhen-ya. A survey of blind source separation and blind deconvolution[J]. Acta Electronica Sinica, 2002, 4(30) :570 - 576. (in Chinese)
- [15] Liu J, Iserte A P, Lagunas M A. Blind separation of OSTBC signals using ICA neural networks [J]. IEEE International Symposium on Signal Processing and Information Technology, 2003, 23(12) :14 - 17.
- [16] Cheng X F, Tao Y W. A single channel mix signal separation technique[A]. Proceedings of IEEE International Conference on Bioinformatics and Biomedical Engineering[C]. Wuhan, China :IEEE Operations Center Press, 2007. 962 - 709.

作者简介:



成谢锋 男, 1956年6月出生于四川资阳。在山东大学获得硕士学位。教授、硕士生导师。先后主持过省级研究项目6项, 其中获得省级优秀教学成果奖2项, 获省科技进步奖、省自然科学奖2项。主编教材二部, 发表论文40余篇。主要从事智能信息处理、智能仪器方面的研究工作。
E-mail :chengxf @njupt. edu. cn



陶冶薇 女, 1958年8月出生于山东菏泽。副教授。长期从事理论物理、物理实验、应用电子等方面的教学、科研工作。发表论文20余篇。
E-mail :taoyw @njupt. edu. cn