

非平稳信号的递推最小二乘盲分离

徐洪涛¹, 王跃钢¹, 陈霞²

(1. 第二炮兵工程学院 304 教研室, 陕西 西安 710025; 2. 第二炮兵工程学院 403 教研室, 陕西 西安 710025)

摘要: 针对非平稳信号盲分离问题提出了一种基于递推最小二乘(RLS)算法的非平稳信号盲分离新方法. 首先引入遗忘因子对常规代价函数进行指数加权修正, 得到一种新的具有递归结构的代价函数; 然后利用 RLS 算法最小化代价函数, 推导最优分离矩阵的自适应更新算法, 逐步实现信号分离. 该算法避免了最小二乘类算法关于学习速率选择困难的缺点, 具有收敛速度快、稳定性好等优点. 仿真实验验证了算法的有效性.

关键词: 盲分离; 非平稳信号; 递推最小二乘; 遗忘因子

中图分类号: TP911 **文献标识码:** A

Recursive least-squares algorithm for blind separation of nonstationary signals

XU Hong-tao¹, WANG Yue-gang¹, CHEN Xia²

(1. Staff Room 304, The Second Artillery Engineering College, Xi'an Shaanxi 710025, China;

2. Staff Room 403, The Second Artillery Engineering College, Xi'an Shaanxi 710025, China)

Abstract: For the blind separation of nonstationary signals, we propose a new method which is based on the recursive least-squares(RLS) algorithm. A forgetting factor is introduced to modify the normal cost-function by incorporating the exponential weighting-factors to obtain a new cost-function with a recursive structure. This new cost-function is minimized by using RLS algorithm. An adaptive updating algorithm is derived for the optimal separation matrix which is for gradually separating the signals. This algorithm alleviates the difficulty in selecting the learning speed in the least-mean-squares algorithms, and possesses excellent performances in convergence and stability. Simulations are carried out to verify the validity of the new algorithm.

Key words: blind source separation; nonstationary signal; recursive least-squares; forgetting factor

1 引言(Introduction)

盲信号分离理论是近 10 年来发展比较迅速的一种信号处理方法, 由于其所处理问题以及采用的方法的独特性和新颖性, 使得在语音信号处理, 通信信号处理, 生物、医学信号处理, 图像、图像信号处理以及经济、生活等各个领域都具有广泛的应用^[1,2]. 所谓盲信号分离(blind source separation, BSS), 是指在一个具有多输入源和多输出源的复杂环境中, 对于在源信号以及传输通道特性均未知的情况下, 采用一定的方法从仅有的观测信号中分离出源信号的一种信号处理方法^[1].

有效的在线盲信号分离方法有最速下降法(随机梯度法)^[3], 自然梯度法^[4]以及 EASI 算法^[5]等. 随机梯度法在每次迭代中均需要对矩阵进行求逆操作, 增加了算法的计算复杂度; 而自然梯度算法和相对梯度算法则解决了在黎曼空间里的最优下降问题, 从而提高了算法的收敛速度, 是一类十分有效的盲

分离方法. 此类算法均属于一种自适应最小二乘(LMS)类算法^[6], 初始参数设置以及学习速率的选择对算法的分离效果具有很强约束性. 如果学习速率选择过小, 那么虽然会带来较好的收敛精度, 但是在收敛速度上就会变得很慢; 相反, 如果选择较大的学习速率, 虽然提高了算法的收敛速度, 但是收敛精度就会下降, 有时甚至会导致算法的发散. 因此, 采用变步长技术无疑是一种可取的方法^[7], 但是采用变步长技术的分离算法在对变化信号以及混合环境的跟踪上还存在一定不足.

自适应递推最小二乘类(RLS)算法在收敛速度和跟踪能力上较 LMS 类算法具有更大的优势^[6], 比如文献^[8]将 RLS 技术和主分量分析(PCA)相结合以实现信号的盲分离, 并证实了方法的有效性. 文献^[9,10]在此基础上, 将 RLS 和非线性 PCA 技术进行结合, 针对盲分离问题提出了一系列的在线自适应以及离线批处理算法, 在分离的速度、精度以及对

非平稳特性的跟踪上较LMS算法具有较大的优势.

在上述的理论基础之上, 本文针对RLS方法在非平稳信号分离中的应用展开研究. 文献[11]等利用了信号的二阶非平稳特性提出了一类有效的代价函数; 利用常规梯度或者是自然梯度方法, 文献[12,13]结合神经网络理论对一类代价函数进行推导, 给出了相应的学习算法. 然而正如上文所提到的, 参数设置以及学习速率的选择始终是此类算法的核心问题, 一旦选取不合适, 则可能导致算法收敛速度慢、分离精度下降乃至发散等现象. 本文结合递推最小二乘原理对文献[11]提出的代价函数进行修正, 提出一种具有指数加权结构的代价函数表达式. 采用自适应递推最小二乘算法对该代价函数进行推导, 给出一种非平稳信号的RLS类算法. 通过引入合适的遗忘因子, 提高了算法对非平稳环境的跟踪性能. 针对仿真信号和实际信号设计相应的实验并验证了算法的有效性.

2 一般代价函数及学习算法 (General cost function and algorithm)

2.1 盲分离模型及假设 (Model and assumptions of BSS)

文中针对线性混合模型进行分析, 同时假定源信号数目与传感器数目相同. 令传感器信号向量为 $\mathbf{x}(t) = [x_1(t) \cdots x_n(t)]^T$, 源信号向量为 $\mathbf{s}(t) = [s_1(t) \cdots s_n(t)]^T$, 在忽略噪声影响的情况下, 混合模型可以用下面的式子表示:

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

其中: 矩阵 A 是 $n \times n$ 的非奇异实方阵, 代表未知的混合矩阵; n 是源信号(传感器)个数.

盲分离的任务就是在 A , $\mathbf{s}(t)$ 均未知的情况下, 利用传感器输出向量 $\mathbf{x}(t)$ 分离出源信号向量 $\mathbf{s}(t)$. 由于能够获得的信息极少, 所以在盲分离问题存在信号幅值和排序的不确定性, 具体可以参考文献[1]. 在不考虑上述的不确定性情况下, 信号的分离模型可以用下式表示:

$$\mathbf{y}(t) = W\mathbf{x}(t) = WAs(t) = DP\mathbf{s}(t). \quad (2)$$

其中: W 是 $n \times n$ 阶的非奇异分离矩阵; D 是 $n \times n$ 的非奇异对角矩阵; P 是 $n \times n$ 的置换矩阵. 从上式可以发现信号得到准确分离情况下有: $WA = I$.

针对本文所研究的问题, 对源信号作如下较宽松的假设^[11]:

假设 1 混合矩阵 A 非奇异, 即为满秩矩阵;

假设 2 源信号 $\mathbf{s}(t)$ 是各分量为零均值的独立信号, 即源信号向量的协方差阵是对角阵:

$$R_s = E[\mathbf{s}(t) \mathbf{s}^T(t)] =$$

$$\text{diag}\{r_1(t), \cdots, r_n(t)\}. \quad (3)$$

假设 3 源信号 $\mathbf{s}(t)$ 是二阶非平稳的, 并且有 $\frac{r_i(t)}{r_j(t)} (i, j = 1, \cdots, n; i \neq j)$ 随时间变化不是常数 ($r_i(t)$ 是 $s_i(t)$ 的方差).

需要指出的是, 上述的前两条假设是一般的盲分离算法所共有的, 而假设3则是本文算法得以实现的关键, 正是由于假设3的成立, 使得我们可以仅利用信号的二阶统计量信息来构造相应的代价函数, 实现非平稳信号的分离^[11].

2.2 一般代价函数 (General cost function)

文献[11]最早利用了信号的二阶非平稳特性, 在源信号满足上述3条假设的基础之上构造并证明了一种基于解相关理论的代价函数, 通过最小化该代价函数使得在任意时刻 t 网络输出的自相关矩阵均(近似)为对角矩阵, 从而实现分离. 该代价函数如下:

$$J(W, t) = \frac{1}{2} \left\{ \sum_{i=1}^n \log \langle y_i^2(t) \rangle - \log |\langle \mathbf{y}(t) \mathbf{y}^T(t) \rangle| \right\}. \quad (4)$$

其中: W 为分离矩阵; t 为离散时间点;

$$\mathbf{y}(t) = W\mathbf{x}(t) = [y_1(t) \cdots y_n(t)]^T;$$

符号“ $\langle \rangle$ ”和“ $|\cdot|$ ”表示取数学期望和行列式.

2.3 学习算法 (Learning algorithm)

构造一简单的前馈网络模型用以实现信号的分离: $\mathbf{y} = W\mathbf{x}$. 通过代价函数式(4)对 W 求常规梯度, 经过简单的计算推导可以得到如下的常规梯度学习算法:

$$W(t+1) = W(t) + \eta(I - \langle \Lambda^{-1}(t) \rangle \langle \mathbf{y}(t) \mathbf{y}^T(t) \rangle) W^{-T}(t). \quad (5)$$

在式(5)中: η 为一较小的学习速率; $\Lambda(t) = \text{diag}\{\langle \mathbf{y}(t) \mathbf{y}^T(t) \rangle\}$. 另外, 从公式(5)可以看出, 在每次对 W 的迭代计算中, 均需要进行矩阵 W 的求逆操作, 这不但增加了算法的计算复杂度, 同时也降低了算法的稳定性.

通过引入自然梯度, 文献[12]对代价函数进行重新推导, 得到了基于自然梯度下降原理的新的学习算法式:

$$W(t+1) = W(t) + \eta(I - \langle \Lambda^{-1}(t) \rangle \langle \mathbf{y}(t) \mathbf{y}^T(t) \rangle) W(t). \quad (6)$$

从式(6)可以发现, 自然梯度算法避免了对矩阵 W 的求逆操作, 不但降低算法的复杂度, 同时由于自然梯度的等变化性决定了算法(6)具有等变化性, 是一种有效的分离算法.

注 1 算法(5)和(6)中的学习速率均需要进行适当的

选择. 过小或者是过大的学习速率都是不合适的, 选择由大变小的学习速率是一个可行的方法. 但是针对不同的信号, 想在收敛速度和收敛精度达到满意的效果是十分困难的.

注 2 方差阵 $\langle \Lambda^{-1}(t) \rangle$, $\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle$ 必须进行实时估计. 一般采用滑动平均的方法进行估计, 而这种估计方法很难实现对时变非平稳信号的准确跟踪, 所以对算法的计算精度也会带来一定的影响.

3 新代价函数及 RLS 学习算法 (New cost function and RLS algorithm)

为了避免算法(5)(6)中学习速率选择和方差估计的困难, 同时提高算法的收敛速度, 将递推最小二乘 (RLS)原理引入到上述的非平稳信号分离代价函数(4)中, 对其进行相应的修正, 给出一种基于递推最小二乘原理的新的代价函数表达式. 利用递推最小二乘原理, 推导出一种递推最小二乘非平稳盲分离算法. 相对于一般的基于梯度的LMS类算法, 该算法能够有效地提高盲分离效果的收敛速度, 同时对缓慢变化的环境具有一定跟踪能力, 从而提高了算法在非平稳分离环境中的分离效果.

3.1 新代价函数(New cost function)

基本代价函数中的数学期望往往是不能够准确计算的, 基于文献[9,10]等的思想, 用一种指数加权的方法来取代基本代价函数中关于取数学期望的操作, 得到如下的修正代价函数:

$$Q(W(t)) = \frac{1}{2} \sum_{j=1}^t \lambda^{t-j} \left\{ \sum_{i=1}^n \log y_i^2(j) - \log |\mathbf{y}(j)\mathbf{y}^T(j)| \right\}. \quad (7)$$

其中: λ 是一个介于0和1之间且非常接近于1的常数, 称之为遗忘因子; $\mathbf{y}(j) = W(t)\mathbf{x}(j) \quad j = 1, \dots, t$. 这里之所以利用 $W(t)$ 而不是 $W(j)$ 来计算 $\mathbf{y}(j)$, 主要是原因是: 在更新过程中, 算法是收敛的, 所以 $W(t)$ 比 $W(j)$ 的分离效果更好, 因此, $\mathbf{y}(j) = W(t)\mathbf{x}(j)$ 较 $\mathbf{y}'(j) = W(j)\mathbf{x}(j)$ 的误差更小, 所以从代价函数最小化角度来说, 上述代价函数是合理的.

3.2 RLS学习算法(RLS algorithm)

接下来利用RLS算法对代价函数式(7)计算最优分离矩阵的估计问题.

首先, 计算(7)对 $W(t)$ 的微分

$$\frac{d(Q(W(t)))}{dW(t)} = \sum_{j=1}^t \lambda^{t-j} \{ \Lambda^{-1}(j)\mathbf{y}(j)\mathbf{x}^T(j) - W(t)^{-T} \}. \quad (8)$$

令 $\frac{d(Q(W(t)))}{dW(t)} = 0$, 可得到最优分离矩阵 $W(t)$ 的

解为

$$W(t) = N(t)M^{-1}(t). \quad (9)$$

其中:

$$\begin{aligned} M(t) &= \sum_{j=1}^t \lambda^{t-j} \{ \mathbf{x}(j)\mathbf{y}^T(j) \}, \\ N(t) &= \sum_{j=1}^t \lambda^{t-j} \Lambda(j), \\ \Lambda(j) &= \text{diag} \{ \mathbf{y}(j)\mathbf{y}^T(j) \}. \end{aligned}$$

其次, 推导最优估计矩阵 $W(t)$ 的自适应更新过程. 根据 $M(t)$, $N(t)$ 的定义, 本文可以得到:

$$\begin{cases} M(t) = \lambda M(t-1) + \mathbf{x}(t)\mathbf{y}^T(t), \\ N(t) = \lambda N(t-1) + \text{diag} \{ \mathbf{y}(t)\mathbf{y}^T(t) \} = \\ \lambda N(t-1) + \Lambda(t). \end{cases} \quad (10)$$

令 $P(t) = M^{-1}(t)$, 由矩阵求逆引理及 $M(t)$ 的递推公式可以得到:

$$P(t) = (\lambda M(t-1) + \mathbf{x}(t)\mathbf{y}^T(t))^{-1} = \frac{1}{\lambda} (P(t-1) - P(t-1)\mathbf{x}(t)\mathbf{h}(t)). \quad (11)$$

其中

$$\mathbf{h}(t) = \frac{\mathbf{y}^T(t)P(t-1)}{\lambda + \mathbf{y}^T(t)P(t-1)\mathbf{x}(t)}.$$

最后, 将式(10)(11)代入到式(9)中得到 $W(t)$ 的更新表达式如下:

$$\begin{aligned} W(t) &= N(t)M^{-1}(t) = \\ W(t-1) - W(t-1)\mathbf{x}(t)\mathbf{h}(t) + \frac{1}{\lambda} \Lambda(t)P(t). \end{aligned} \quad (12)$$

综合式(9)~(12), 可以得到一种新的非平稳信号RLS分离算法, 其计算步骤如下:

- Step 1** 参数初始化: $W(0), P(0), \lambda$;
- Step 2** 令 $t = 1$, 计算 $\mathbf{y}(t) = W(t-1)\mathbf{x}(t)$;
- Step 3** 计算 $\Lambda(t) = \text{diag} \{ \mathbf{y}(t)\mathbf{y}^T(t) \}$;
- Step 4** 计算

$$\mathbf{h}(t) = \frac{\mathbf{y}^T(t)P(t-1)}{\lambda + \mathbf{y}^T(t)P(t-1)\mathbf{x}(t)};$$

- Step 5** 计算

$$P(t) = \frac{1}{\lambda} (P(t-1) - P(t-1)\mathbf{x}(t)\mathbf{h}(t));$$

- Step 6** 更新 $W(t)$:

$$\begin{aligned} W(t) &= W(t-1)(I - \mathbf{x}(t)\mathbf{h}(t)) + \\ &\frac{1}{\lambda} \Lambda(t)P(t); \end{aligned}$$

- Step 7** 令 $t = 2, 3, \dots$, 重复Step 2~6, 直至算法收敛, 迭代结束, 此时的 $W(t)$ 就是最优分离矩阵.

4 计算机仿真分析(Computer simulations)

为了验证算法的有效性,针对非平稳仿真信号和实际语音信号分别设计了相应实验,并在实验中对不同算法的分离效果进行比较.

实验1 仿真信号.

实验1采用仿真信号进行分离实验,3个源信号分别为:

$$s_1(t) = g(t),$$

$g(t)$ 是服从均值为0、方差为1高斯分布信号;

$$s_2(t) = g(t) \times 2 \sin \frac{\pi t}{600}$$

为高斯信号 $g(t)$ 与正弦信号乘积;

$$s_3(t) = g(t) \times 2 \cos \frac{\pi t}{800}$$

为高斯信号 $g(t)$ 与余弦信号乘积,3组数据分别采样5000点, $t = 1 \sim 5000$.混合矩阵 A 为由(0, 1)均匀分布随机生成的矩阵:

$$A = \begin{bmatrix} 0.85 & 0.67 & 0.68 \\ 0.53 & 0.84 & 0.38 \\ 0.21 & 0.45 & 0.63 \end{bmatrix}.$$

为了评价分离算法的收敛性能,采用PI性能指数对算法进行分析,其定义为:

$$\text{PI} = \frac{1}{n(n-1)} \sum_{i=1}^n \left\{ \left(\sum_{k=1}^n \frac{|g_{ik}|}{\max_j |g_{ij}|} - 1 \right) + \left(\sum_{k=1}^n \frac{|g_{ki}|}{\max_j |g_{ji}|} - 1 \right) \right\}. \quad (13)$$

式中: g_{ij} 为全局传输矩阵 G 的元素; $\max_j |g_{ij}|$ 表示 G 的第 i 行元素绝对值中的最大值; $\max_j |g_{ji}|$ 表示 G 的第 j 列元素绝对值中的最大值.分离出的信号 $\mathbf{y}(t)$ 与源信号 $\mathbf{s}(t)$ 的波形完全相同时 $\text{PI} = 0$.实际中,当PI达到 10^{-2} 数值时就可以说明算法分离性能已经相当好.

算法式(5)(6)中涉及到对信号方差及协方差的估计,由于信号的非平稳特性,可以采用滑动平均对其进行估计,因此可以得到信号时变方差的实时估计如下:

$$\text{令 } A = \text{diag} \{ \langle y_1^2(t) \rangle, \dots, \langle y_n^2(t) \rangle \} = \text{diag} \{ r_1(t), \dots, r_n(t) \},$$

给定学习速率 $0 < \eta_0 < 1$, $r_i(t)$ 的实时估计为

$$r_i(t) = (1 - \eta_0)r_i(t-1) + \eta_0 y_i^2(t). \quad (14)$$

同理可以得到时变协方差矩阵实时估计:

$$R_y(t) = (1 - \eta_0)R_y(t-1) + \eta_0 \mathbf{y}(t)\mathbf{y}^T(t). \quad (15)$$

其中

$$R_y(t) = E [\mathbf{y}(t)\mathbf{y}^T(t)].$$

作为比较,实验中对3种不同的算法进行对比,分别记常规梯度算法式(5)为算法1;自然梯度算法式(6)为算法2;本文提出的RLS算法式(9)~(12):算法.算法1和2的参数设置相同,学习速率 $\eta = 0.0003$, $\eta_0 = 0.001$,分离矩阵初值 $W(0)$ 为单位矩阵.算法3遗忘因子 $\lambda = 0.9985$,分离矩阵初值 $W(0)$ 为单位矩阵, $P(0) = 0.1 * I$.图1给出了经过40000次运行后3种算法的PI值与迭代次数分布曲线图.




图1 3种算法PI曲线(实验1)

Fig. 1 PI curves of three algorithm in Experiment 1

观察图1可以发现,在算法收敛速度、精度以及稳定性上,本文算法即算法3较算法1和算法2均具有较大的优势.显然,算法3的收敛速度是最快的,算法2次之,算法1最慢.且经过有限次迭代,算法3的最终PI值为0.05左右,较算法1(约为0.35)和算法2(约为0.15)更小.在稳定性上算法3也具有其他两种算法无可比拟的优势.综合考虑3种算法的分离性能,本文的RLS算法最好,自然梯度算法(6)次之,常规梯度算法(5)最差.

实验2 实际语音信号.

实验2源信号采用实际语音信号,其来源为ICALAB工具包^[14].采样频率为5120 Hz,具体实验步骤和方法与实验1一致,初始参数设置如下:算法1和2的参数设置相同,学习速率 $\eta = 0.0003$, $\eta_0 = 0.005$,分离矩阵初值 $W(0)$ 为单位矩阵.算法3遗忘因子 $\lambda = 0.9995$,分离矩阵初值 $W(0)$ 为单位矩阵, $P(0) = 0.1 * I$.

图2分别是源信号、混合信号、算法1分离信号、算法2分离信号以及算法3分离信号.

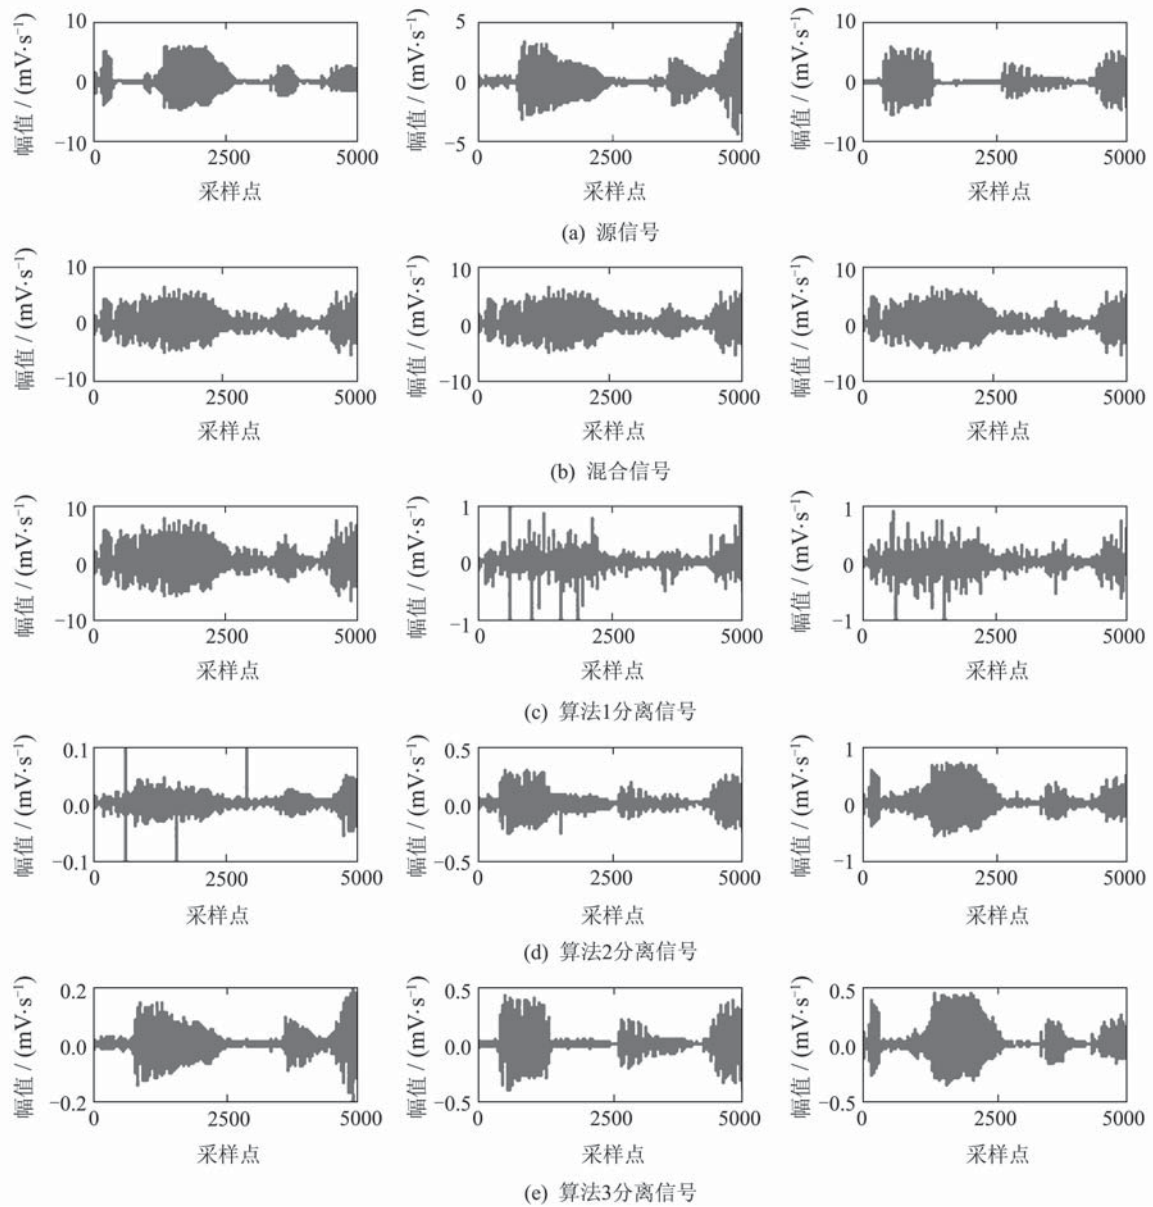


图 2 源信号、混合信号和分离信号(实验2)

Fig. 2 Source, mixed and separated signals in Experiment 2




图 3 3种算法PI曲线(实验2)

Fig. 3 PI curves of three algorithms in Experiment 2

图3为3种算法的PI曲线图,从图中可以看出算法3在收敛速度、收敛精度以及稳定性上体现出

较好的性能,而常规梯度和自然梯度算法的分离性能相对较差.从实验仿真结果来看,本文提出的RLS算法在非平稳信号分离中表现出了良好的性能.

5 结论(Conclusion)

如何有效的利用信号的非平稳性实现信号的分离具有重要的应用价值.本文对一类基于信号二阶非平稳性的代价函数进行指数加权修正,提出一种具有递归形式的新代价函数,利用递推最小二乘算法(RLS)实现最优分离矩阵的自适应更新,逐步实现信号的分离,从而避免了在LMS类算法中关于学习速率的选择困难的问题.实验证明该算法具有收敛速度快,分离精度高和稳定性好的特点,能够有效的实现非平稳信号的分离.

参考文献(References):

- [1] HYVARINEN A, KARHUNEN J, OJA E. *Independent Component Analysis*[M]. New York: Wiley, 2001.
- [2] 何昭水, 谢胜利, 章晋龙. 基于QR分解的盲源分离几何算法[J]. 控制理论与应用, 2005, 22(1): 17 – 22.
(HE Zhaoshui, XIE Shengli, ZHANG Jinlong. Geometrical algorithm of blind source separation based on QR decomposition[J]. *Control Theory & Applications*, 2005, 22(1): 17 – 22.)
- [3] HYVARINEN A. A unifying model for blind separation of independent sources[J]. *Signal Processing*, 2005, 85(2): 1419 – 1427.
- [4] AMARI S. Natural gradient works efficiently in learning[J]. *Neural Computation*, 1998, 10(2): 271 – 276.
- [5] CARDOSO J F, LAHELD B H. Equivariant adaptive source separation[J]. *IEEE Transactions on Signal Processing*, 1996, 44(12): 3017 – 3030.
- [6] 朱孝龙, 张贤达, 冶继民. 基于自然梯度的递归最小二乘盲信号分离[J]. 中国科学(E辑), 2003, 33(8): 741 – 748.
(ZHU Xiaolong, ZHANG Xianda, YE Jimin. Natural gradient-based recursive least-squares algorithm for blind source separation[J]. *Science in China(Series E)*, 2003, 33(8): 741 – 748.)
- [7] HSIEH S T, SUN T Y, LIN C L, et al. Effective learning rate adjustment of blind source separation based on an improved particle swarm optimizer[J]. *IEEE Transactions on Evolutionary Computation*, 2008, 12(2): 242 – 251.
- [8] PAJUNEN P, KARHUNEN J. Least-squares methods for blind source separation based on nonlinear PCA[J]. *International Journal of Neural Systems*, 1998, 8(5/6): 601 – 612.
- [9] ZHU X L, ZHANG X D. Adaptive RLS algorithm for blind source separation using a natural gradient[J]. *IEEE Signal Processing Letters*, 2002, 9(12): 432 – 435.
- [10] ZZHU X L, ZHANG X D, DING Z Z, et al. Adaptive nonlinear PCA algorithms for blind source separation without prewhitening[J]. *IEEE Transactions on Circuits and Systems-I: Regular Papers*, 2006, 53(3): 745 – 753.
- [11] MATSUOKA K, OHYA M, KAWAMOTO M. A neural net for blind separation of nonstationary signals[J]. *Neural Networks*, 1995, 8(3): 411 – 419.
- [12] CHOI S, CICHOCKI A, AMARI S. Equivariant nonstationary source separation[J]. *Neural Networks*, 2002, 15(1): 121 – 130.
- [13] MEYER BASE A, GRUBER P, THEIS F, et al. Blind source separation based on self-organizing neural network[J]. *Engineering Applications of Artificial Intelligence*, 2006, 19(3): 305 – 311.
- [14] CICHOCKI A, AMARI S, SIWEK K, et al. ICALAB Toolboxes[OL]. <http://www.bsp.brain.riken.jp/ICALAB>, 2009.

作者简介:

徐洪涛 (1982—), 男, 博士研究生, 主要研究方向为导弹自动监测技术与故障诊断, E-mail: xuhongtaoopp@163.com;

王跃钢 (1958—), 男, 博士, 教授, 博士生导师, 主要研究方向为导航、制导与控制;

陈霞 (1983—), 女, 博士研究生, 主要研究方向为计算机图像处理.