

文章编号: 1001-0920(2011)05-0748-05

基于自组织神经网络的非平稳信号盲分离

徐洪涛, 王跃钢, 邓卫强

(第二炮兵工程学院 304教研室, 西安 710025)

摘要: 针对具有二阶非平稳特性的源信号盲分离问题, 提出一种基于自组织神经网络的在线盲源分离新算法. 利用自组织神经网络构建一种多层盲分离网络模型, 以网络输出层信号的相关性为代价函数, 采用自然梯度原理对网络参数进行学习, 最小化该代价函数从而实现信号分离. 将多层自组织神经网络和自然梯度原理相结合, 提高了分离算法的灵活性和性能. 最后将该算法与其他算法进行了仿真对比, 仿真结果表明该算法具有较好的收敛精度及稳定性.

关键词: 盲源分离; 自组织网络; 非平稳信号; 自然梯度

中图分类号: TP911

文献标识码: A

Blind separation of non-stationary sources based on self-organizing neural network

XU Hong-tao, WANG Yue-gang, DENG Wei-qiang

(304 Staff Room, The Second Artillery Engineering College, Xi'an 710025, China. Correspondent: XU Hong-tao, E-mail: xuhongtao@163.com)

Abstract: Aiming to the blind separation of non-stationary sources, a new on-line algorithm base on self-organizing network is proposed. The separation structure and cost function are established by utilizing the multilayer networks. The learning rule for the network's parameters is derived from the nature gradient descent minimization of the cost function that takes the minimum only when the network outputs are uncorrelated with each other. The multilayer networks and nature gradient principal are combined, which improves the performance in non-stationary signals separation. Finally, simulation results show that the proposed algorithm has good convergence precision and stability.

Key words: blind source separation; self-organizing network; non-stationary signal; nature gradient

1 引言

盲源分离技术在信号处理领域已得到越来越广泛的重视, 特别是在语音声学信号处理、通信信号处理、图像处理以及生物医学信号处理等领域都得到了普遍应用^[1-2]. 盲分离(BSS)技术是指在一个具有多个源信号的复杂环境中, 如何利用有效的分离手段对传感器输出信号进行处理, 从而分离出独立的源信号分量, 所以有时也称为独立分量分析. 所谓的“盲”指的是源信号以及对应的环境参数是未知的, 仅利用混合信号进行分离.

传统盲分离方法大多基于信号的平稳性和非高斯性, 利用信息论原理构建代价函数实现信号分离^[3-4], 此类方法基于对源信号概率分布特性的假设

以及相应的高阶累计量的估计, 在计算精度和算法复杂度上存在一定的不足. 文献[5]给出了基于信号二阶统计量的盲信号分离方法, 但是也仅仅局限于具有一定时间结构特性的平稳信号.

工程实际中遇到的许多信号都具有非平稳性, 传统盲分离方法在处理非平稳信号时效果较差, 因而研究如何实现非平稳信号的有效分离具有重要的应用价值. 文献[6]较早地开展了非平稳信号分离研究, 该文利用信号的方差时变特性, 构造非负代价函数, 采用梯度下降法通过递归网络学习以实现信号分离. [7]利用近似联合对角化方法对具有时间结构的非平稳信号进行分离, 由于要求信号短时平稳, 使得在应用上具有一定的局限性. [8]采用与[6]相同的代价函

收稿日期: 2010-01-27; 修回日期: 2010-04-24.

基金项目: 国家安全重大基础研究项目(973-61355020301).

作者简介: 徐洪涛(1982-), 男, 博士生, 从事导弹自动检测技术与故障诊断的研究; 王跃钢(1958-), 男, 教授, 博士生导师, 从事导弹导航、制导与控制等研究.

数, 利用自然梯度算法对基于递归网络和前馈网络的分离模型进行讨论并给出了相应算法, 由于采用单层网络结构, 算法分离效果不够灵活. [9] 利用一种自组织的前馈、递归联合非全联网络结构模型, 采用常规梯度对类似代价函数进行学习, 在算法收敛速度及灵活性上也存在不足.

在前述的理论基础之上, 本文提出了一种非平稳信号盲分离新方法. 首先构建一种灵活的全联自组织组合神经网络分离模型, 并利用 Hebbian 规则对网络输入输出进行学习, 基于该网络模型和信号的二阶非平稳特性构造非负代价函数. 然后利用自然梯度学习规则对网络参数的迭代计算, 使该代价函数达到最小, 从而实现信号分离. 最后对该算法进行仿真实验并与其他两种类似算法进行了比较.

2 盲分离模型及假设

本文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 $\mathbf{x}(t) = [x_1(t), \dots, x_n(t)]^T$, 源信号向量为 $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$, 在忽略噪声影响的情况下, 混合模型为

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

其中: 矩阵 \mathbf{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.

盲分离的任务是在矩阵 \mathbf{A} 未知的情况下, 利用传感器输出向量 $\mathbf{y}(t)$ 分离出源信号向量 $\mathbf{s}(t)$. 由于能够获得的信息极少, 在盲分离问题中存在信号幅值和排序的不确定性^[6]. 在不考虑上述不确定性情况下, 信号的分离模型为

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) = \mathbf{W}\mathbf{A}\mathbf{s}(t) = \mathbf{D}\mathbf{P}\mathbf{s}(t). \quad (2)$$

其中: \mathbf{W} 是 $n \times n$ 阶的非奇异分离矩阵, \mathbf{D} 是 $n \times n$ 的非奇异对角矩阵, \mathbf{P} 是 $n \times n$ 的置换矩阵. 从式 (2) 可以发现, 在信号准确分离情况下有 $\mathbf{W}\mathbf{A} = \mathbf{I}$.

针对所研究的问题, 对源信号作如下较宽松的假设^[6]:

假设 1 混合矩阵 \mathbf{A} 非奇异, 即为满秩矩阵.

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

$$\mathbf{R}_s = \mathbf{E}[\mathbf{s}(t)\mathbf{s}^T(t)] = \text{diag}\{r_1(t), \dots, r_n(t)\}. \quad (3)$$

假设 3 源信号 $\mathbf{s}(t)$ 是二阶非平稳的, 且有 $r_i(t)/r_j(t) (i, j = 1, 2, \dots, n, i \neq j)$ 随时间变化, 不是常数 ($r_i(t)$ 是 $s_i(t)$ 的方差).

需要注意的是, 假设 1 和假设 2 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. 二阶非平稳信号主要体现在其方差的时变特性上,

假设 3 要求任意源信号之间的方差变化特性相互独立, 即对于实际的非平稳独立源信号而言, 必须满足具有相互独立的方差变化特性的要求, 显然一般的非平稳信号均能满足这一条件.

3 网络模型及代价函数构造

文献 [6] 采用非全联简化递归网络模型来实现信号的分, [8] 与其类似, 分别对递归网络和前馈网络两种分离模型进行详细讨论, 但仅局限于单层网络模型. [9] 采用一种自组织复合网络模型, 但并非全联结构 ($w_{ii} = 0$). 本文在此基础上, 讨论一种更具灵活性的全联组合网络模型, 即采用前馈和递归相结合, 利用多层网络灵活性强的特点使分离算法具有更好的灵活性和适应性. 该网络模型结构如图 1 所示.




图 1 组合网络模型

图 1 中: 矢量 \mathbf{x}, \mathbf{y} 分别代表网络的输入、输出, 即混合信号和估计源信号; \mathbf{M}, \mathbf{W} 代表 $n \times n$ 的前馈、递归网络参数矩阵.

网络输入输出关系为

$$\mathbf{y}(t) = (\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{x}(t), \quad (4)$$

通过对网络参数 \mathbf{M} 和 \mathbf{W} 的学习, 最终使得网络输出满足

$$\mathbf{y}(t) = (\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{x}(t) = (\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{A}\mathbf{s}(t) = \mathbf{D}\mathbf{P}\mathbf{s}(t), \quad (5)$$

从而实现信号的分离. 显然, 当网络学习结束, 即信号达到完全分离时 (不考虑不确定性), 有

$$(\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{A} = \mathbf{D}\mathbf{P}. \quad (6)$$

即矩阵 \mathbf{M}, \mathbf{W} 满足式 (6) 时, 可实现信号的分离.

下面的定理给出用于实现信号分离的代价函数表达式.

定理 1 以下 3 条论述是等价的:

- 1) 矩阵 \mathbf{M}, \mathbf{W} 满足式 (6);
- 2) $\langle y_i(t)y_j(t) \rangle (i, j = 1, 2, \dots, n, i \neq j)$ 在任意时刻总为 0, 即不相关;
- 3) 非负代价函数

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

在任意时间均达到最小值 0.

证明 1)→2) 显然是成立的;

证 2)→1). 令 $\mathbf{M}(t) = \langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle = (\mathbf{I} + \mathbf{W})^{-1} \times \mathbf{M}\mathbf{A}\mathbf{R}(t)\mathbf{A}^T\mathbf{M}^T(\mathbf{I} + \mathbf{W}^T)^{-1}$, 其中 $\mathbf{R}(t) = \langle \mathbf{s}(t)\mathbf{s}^T(t) \rangle$. 由假设 2 可知, $\mathbf{M}(t)$, $\mathbf{R}(t)$ 均为对角矩阵, 结合假设 3 可以证明^[6], $(\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{A} = \mathbf{D}\mathbf{P}$, 具体证明过程略.

再证 2)←3). 由 Hadamard 不等式可知: 对于任意的非负定对称矩阵 $\mathbf{R} = [r_{ij}]$, 满足不等式 $\det(\mathbf{R}) \leq \prod_{i=1}^n r_{ii}$, 当且仅当矩阵 $\mathbf{R} = [r_{ij}]$ 是对角矩阵时等号成立. 令 $\mathbf{R} = \langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle$, 当且仅当 $\langle y_i(t)y_j(t) \rangle = 0$ ($i, j = 1, 2, \dots, n, i \neq j$) 时, 非负函数 $\mathbf{Q}(\mathbf{W}, \mathbf{M}, t)$ 取最小值 0. \square

4 自然梯度学习算法

文献 [9] 采用常规梯度对网络参数矩阵 \mathbf{M} 和 \mathbf{W} 进行推导, 给出了学习算法的迭代更新过程. 根据文献 [10] 的讨论, 当参数空间为黎曼空间时, 函数最速下降方向不再是常规梯度, 而是自然梯度. 本文利用自然梯度下降原理对代价函数 (7) 进行推导, 得出一种新的、具有等变化性的自然梯度学习算法.

算法推导可分为 4 步进行, 推导过程如下: 记代价函数 (7) 的全微分为

$$\begin{aligned} d\mathbf{Q}(\mathbf{W}, \mathbf{M}, t) = & \frac{1}{2} d \left(\underbrace{\sum_{i=1}^n \log \langle y_i^2(t) \rangle}_p \right) - \frac{1}{2} d \left(\underbrace{\log |\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle|}_q \right), \\ \mathbf{A}(t) = & \text{diag}\{y_1^2(t), \dots, y_n^2(t)\}. \end{aligned} \quad (8)$$

Step 1 首先计算 q 项对 \mathbf{W} 的微分

$$\begin{aligned} d(\log |\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle|) = & d(\log |(\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\langle \mathbf{x}(t)\mathbf{x}^T(t) \rangle\mathbf{M}^T(\mathbf{I} + \mathbf{W}^T)^{-1}|) = \\ & 2d(\log |(\mathbf{I} + \mathbf{W})^{-1}|) + d \log |\langle \mathbf{x}(t)\mathbf{x}^T(t) \rangle| + 2d \log |\mathbf{M}| = \\ & -2\text{tr}((\mathbf{I} + \mathbf{W})^{-1}d\mathbf{W}). \end{aligned} \quad (9)$$

对其进行变量代换, 令 $d\mathbf{V} = (\mathbf{I} + \mathbf{W})^{-1}d\mathbf{W}$, $d\mathbf{y} = -(\mathbf{I} + \mathbf{W})^{-1}d\mathbf{W}(\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\mathbf{x}(t) = -d\mathbf{V}\mathbf{y}$, 则

$$d(\log |\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle|) = -2\text{tr}\{d\mathbf{V}\}. \quad (10)$$

Step 2 计算 p 项对 \mathbf{W} 的微分, 即

$$\begin{aligned} d \left(\sum_{i=1}^n \log \langle y_i^2(t) \rangle \right) = & \sum_{i=1}^n \frac{2\langle y_i(t)dy_i(t) \rangle}{\langle y_i^2(t) \rangle} = \\ & 2\text{E}\{\mathbf{y}^T(t)\mathbf{A}^{-1}(t)d\mathbf{y}(t)\} = \\ & -2\text{E}\{\mathbf{y}^T(t)\mathbf{A}^{-1}(t)d\mathbf{V}\mathbf{y}\}, \end{aligned} \quad (11)$$

则

$$\begin{aligned} \Delta\mathbf{V} = & -\eta d\mathbf{Q}/d\mathbf{V} = \\ & \eta(\langle \mathbf{A}^{-1}(t) \rangle \langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle - \mathbf{I}). \end{aligned} \quad (12)$$

其中: η 为较小的学习速率, 进而得到 \mathbf{W} 迭代算法

$$\Delta\mathbf{W} = (\mathbf{I} + \mathbf{W})\Delta\mathbf{V} =$$

$$\eta(\mathbf{I} + \mathbf{W})(\langle \mathbf{A}^{-1}(t) \rangle \langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle - \mathbf{I}). \quad (13)$$

Step 3 计算 q 项对 \mathbf{M} 的微分

$$\begin{aligned} d(\log |\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle|) = & d(\log |(\mathbf{I} + \mathbf{W})^{-1}\mathbf{M}\langle \mathbf{x}(t)\mathbf{x}^T(t) \rangle\mathbf{M}^T(\mathbf{I} + \mathbf{W}^T)^{-1}|) = \\ & 2d(\log |(\mathbf{I} + \mathbf{W})^{-1}|) + d \log |\langle \mathbf{x}(t)\mathbf{x}^T(t) \rangle| + 2d \log |\mathbf{M}| = \\ & -2\text{tr}(d(\log \mathbf{M}^{-1})) = 2\text{tr}(d\mathbf{M}\mathbf{M}^{-1}). \end{aligned} \quad (14)$$

同上进行变量代换, 令 $d\mathbf{N} = d\mathbf{M}\mathbf{M}^{-1}$, $d\mathbf{y} = (\mathbf{I} + \mathbf{W})^{-1}d\mathbf{M}\mathbf{x}(t) = (\mathbf{I} + \mathbf{W})^{-1}d\mathbf{N}(\mathbf{I} + \mathbf{W})\mathbf{y}$, 则

$$d(\log |\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle|) = 2\text{tr}\{d\mathbf{V}\}. \quad (15)$$

Step 4 计算 p 项对 \mathbf{M} 的微分

$$\begin{aligned} d \left(\sum_{i=1}^n \log \langle y_i^2(t) \rangle \right) = & \sum_{i=1}^n \frac{2\langle y_i(t)dy_i(t) \rangle}{\langle y_i^2(t) \rangle} = 2\text{E}\{\mathbf{y}^T(t)\mathbf{A}^{-1}(t)d\mathbf{y}(t)\} = \\ & 2\text{E}\{\mathbf{y}^T(t)\mathbf{A}^{-1}(t)(\mathbf{I} + \mathbf{W})^{-1}d\mathbf{N}(\mathbf{I} + \mathbf{W})\mathbf{y}\}, \end{aligned} \quad (16)$$

则有

$$\begin{aligned} \Delta\mathbf{N} = & \eta(\mathbf{I} - (\mathbf{I} + \mathbf{W})^{-T}\langle \mathbf{A}^{-1} \rangle) \times \\ & (\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle (\mathbf{I} + \mathbf{W})^T), \end{aligned} \quad (17)$$

进而得到 \mathbf{M} 迭代算法

$$\begin{aligned} \Delta\mathbf{M} = & \Delta\mathbf{N}\mathbf{M} = \\ & \eta(\mathbf{I} - (\mathbf{I} + \mathbf{W})^{-T}\langle \mathbf{A}^{-1} \rangle)(\langle \mathbf{y}(t)\mathbf{y}^T(t) \rangle (\mathbf{I} + \mathbf{W})^T)\mathbf{M}. \end{aligned} \quad (18)$$

式 (13), (18) 联合构成了基于自然梯度的非平稳信号盲分离算法. 比较文献 [6, 8-9] 所提出的算法发现, 虽然几种算法在原理上都比较接近, 但本文方法在综合已有算法的基础上进行了改进, 且已有算法均是本文算法在一定条件下的特例. 算法 (13), (18) 采用多层网络模型结构, 利用自然梯度原理进行推导得出, 保证了算法具有等变化性, 同时具有更高效的灵活性和稳健性.

现对本文算法与文献 [9] 分离算法的复杂性作一简要分析: 在一次迭代过程中, 算法 (13) 涉及到对角矩阵的求逆及矩阵乘法, 总共需要约 $n^3 + 3n^2 + 2n$ 次乘法运算; 同样, 算法 (18) 需要进行 $4n^3 + 3n^2 + 2n$ 次乘法运算, 所以本文算法完成一次迭代总共大约需要 $5n^3 + 6n^2 + 4n$ 次乘法运算. 文献 [9] 的算法一次迭代大约需要进行 $6n^3 + 6n^2 + 4n$ 次乘法运算, 两种算法的计算量基本一致, 均为 $O(n^3)$. 但是文献 [9] 的算法涉及到 3 次矩阵求逆, 而本文算法因只有 1 次矩阵求逆而具有较好的稳定性.

5 算法仿真分析

为了验证算法的分离性能, 设计了相应的仿真实验, 并对 3 种不同算法的分离效果进行了比较.

本文算法中式(13)和(18)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, 可采用滑动平均对其进行估计, 得到信号时变方差的实时估计. 令: $\mathbf{A} = \text{diag}\{\langle y_1^2(t) \rangle, \dots, \langle y_n^2(t) \rangle\} = \text{diag}\{r_1(t), \dots, r_n(t)\}$, 给定学习速率 $0 < \eta_0 < 1$, $r_i(t)$ 的实时估计为

$$r_i(t) = (1 - \eta_0)r_i(t - 1) + \eta_0 y_i^2(t). \quad (19)$$

同理, 可得到时变协方差矩阵实时估计

$$\mathbf{R}_y(t) = (1 - \eta_0)\mathbf{R}_y(t - 1) + \eta_0 \mathbf{y}(t)\mathbf{y}^T(t), \quad (20)$$

其中 $\mathbf{R}_y(t) = \text{E}[\mathbf{y}(t)\mathbf{y}^T(t)]$. 关于学习速率 η_0 , 可依据源信号非平稳特性的强烈程度进行适当的选取: 若信号方差变化缓慢, 则可选择较小的 η_0 , 从而(协)方差矩阵变化也较缓慢; 反之选用较大的学习速率, 保证估计能够更加真实地逼近信号的非平稳变化特性.

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

$$\text{PI} = \frac{1}{n(n-1)} \sum_{i=1}^n \left\{ \left(\sum_{k=1}^n \frac{|g_{ik}|}{\max_j |g_{ij}|} - 1 \right) + \left(\sum_{k=1}^n \frac{|g_{ki}|}{\max_j |g_{ji}|} - 1 \right) \right\}. \quad (21)$$

式中: g_{ij} 为全局传输矩阵 \mathbf{G} 的元素, $\max_j |g_{ij}|$ 为 \mathbf{G}

的第 i 行元素绝对值中的最大值, $\max_j |g_{ji}|$ 为 \mathbf{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 $\text{PI} = 0$, 但在实际中, 当PI达到 10^{-2} 数值时算法也具有较好的分离性能.

实验源信号选用3个非平稳的语音信号, 来源于ICALAB工具包^[11], 是3个不同的男声用不同的语调说“halo”时的麦克风录音, 采样频率为10 KHz, 总共纪录时间2s, 本文取其中的0.5s共计5000个采样点信号作为实验信号. 随机混合矩阵为

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

对混合信号分别采用以下3种算法进行实验:

- 1) 本文提出的算法(算法1);
 - 2) 文献[8]提出的基于递归网络自然梯度算法(算法2);
 - 3) 文献[9]提出的基于自组织网络常规梯度算法(算法3).
- 参数设置为: 递归网络参数 \mathbf{W} 初值为 $\mathbf{0}$ 矩阵, 前馈网络参数 \mathbf{M} 初值设为单位矩阵, 算法学习速率 $\eta = 0.0005$, 方差实时估计速率 $\eta_0 = 0.05$.

图2分别给出了源信号、混合信号和分别采用3种分离算法的估计源信号的波形图. 从左至右: 第1行是3个独立的语音源信号; 第2行是经过矩阵 \mathbf{A} 混




图2 原始信号、混合信号以及3种算法分离信号

合产生的 3 个混合信号;第 3~第 5 行分别是采用 3 种不同算法经过 50 000 次的迭代计算所得到的相应的分离信号。

图 3 给出了 3 种算法 PI 指数随迭代次数的收敛曲线。经过 50 000 次迭代后 3 种算法的最终 PI 值(下标代表相应的算法)见表 1。




图 3 3 种算法的 PI 曲线比较

表 1 3 种算法 PI 指数

算法	PI 指数/50 000 次迭代
算法 1	$PI_1 = 0.015$
算法 2	$PI_2 = 0.24$
算法 3	$PI_3 = 0.032$

观察图 3 和表 1 发现:基于自然梯度学习规则的多层自组织网络盲分离算法(算法 1)分离精度最好,收敛速度最快,经过近 8 000 步迭代,PI 值迅速下降并最终稳定在 0.015 左右,直至迭代结束。基于常规梯度学习规则的多层自组织网络盲分离算法(算法 3)的收敛曲线与算法 1 接近,但在收敛速度及最终的稳定性上却不如算法 1,经过将近 15 000 步左右的迭代才达到理想的分离精度且稳定性较差。原因在于当参数空间是黎曼空间时,目标函数的最速下降方向不再是常规梯度而是自然梯度,从而在收敛速度上算法 1 较算法 3 更快,分离精度上由于采用相同的分离网络模型使得两种算法比较接近。在有限的迭代次数中,算法 2 相对算法 1 和算法 3 在分离精度及收敛速度上均未达到满意的效果。

6 结 论

在工程实际应用中非平稳信号盲分离具有重要的研究价值,本文就如何利用信号的非平稳特性实现信号分离展开研究。首先建立了一种基于自组织前馈、递归组合网络结构的盲分离模型,并利用源信号的二阶非平稳特性构造代价函数;然后利用自然梯度学习规则最小化该代价函数,经过推导得出了一类新的非平稳信号盲分离算法;最后通过仿真实验对算法

分离的性能进行验证并与两种类似算法进行比较。实验结果表明,该算法在收敛速度、稳定性和分离精度上较其他类似的算法具有较大的优势。另外在实验中发现,算法性能在一定程度上受到学习速率大小以及方差估计精度的影响,实际应用中需要精心设计。

参考文献(References)

- [1] 林静然,彭启琮,邵怀宗,等.用于宽带非平稳信源分离的一种盲波束算法[J].电子科技大学学报,2008,37(3): 343-346.
(Lin J R, Peng Q C, Shao H Z, et al. Deterministic blind beamforming for broadband nonstationary source separation[J]. J of University of Electronic Science and Technology of China, 2008, 37(3): 343-346.)
- [2] Pedersen M S, Wang D L, Larsen J, et al. Two-microphone separation of speech mixtures[J]. IEEE Trans on Neural Networks, 2008, 19(3): 475-492.
- [3] Cardoso J F. Blind signal separation: Statistical principles[J]. Proc of the IEEE, 1998, 86(10): 2009-2025.
- [4] Hyvarinen A. A unifying model for blind separation of independent sources[J]. Signal Processing, 2005, 85(2): 1419-1427.
- [5] Belouchrani A, Abed-Meraim K, Cardoso J F, et al. A blind source separation technique using second-order statistics[J]. IEEE Trans on Signal Processing, 1997, 45(2): 434-444.
- [6] Matsuoka K, Ohya M, Kawamoto M. A neural net for blind separation of nonstationary signals[J]. Neural Networks, 1995, 8(3): 411-419.
- [7] Choi S, Cichocki A, Belouchrani A. Blind separation of second-order nonstationary temporally colored sources[C]. Proc of the IEEE on Statistical Signal Processing. Singapore, 2001: 444-447.
- [8] Choi S, Cichocki A, Amari S. Equivariant nonstationary source separation[J]. Neural Networks, 2002, 15(1): 121-130.
- [9] 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.
- [10] Amari S. Natural gradient works efficiently in learning[J]. Neural Computation, 1998, 10(2): 271-276.
- [11] Cichocki A, Amari S, Siwek K, et al. ICALAB Toolboxes [DB/OL]. (2009-12-01). <http://www.bsp.brain.riken.jp/ICALAB>.