

基于时间可预测性的差分搜索盲信号分离算法

陈雷^{1,2}, 张立毅¹, 郭艳菊³, 黄勇¹, 梁静毅¹

(1. 天津商业大学 信息工程学院, 天津 300134; 2. 天津大学 精密仪器与光电子工程学院, 天津 300072;

3. 河北工业大学 信息工程学院, 天津 300401)

摘要: 针对基于仿生智能优化的盲信号分离算法计算量偏大的问题, 提出了一种新的基于差分搜索的盲信号分离算法。采用信号在时间上的可预测性度量作为目标函数, 使用差分搜索算法对目标函数进行优化求解。利用去相关消源方法从混合信号中去除每次分离出的源信号成分, 通过逐次分离最终实现对所有源信号的成功恢复。仿真实验表明, 所提算法可以有效实现对混合信号的盲分离。与其他算法相比, 该算法在保证更高分离精度的同时, 具有更低的运算量。

关键词: 盲信号分离; 时间可预测性; 差分搜索算法; 消源

中图分类号: TN911.7

文献标识码: A

文章编号: 1000-436X(2014)06-0117-09

Blind signal separation algorithm based on temporal predictability and differential search algorithm

CHEN Lei^{1,2}, ZHANG Li-yi¹, GUO Yan-ju³, HUANG Yong¹, LIANG Jing-yi¹

(1. School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China;

2. School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;

3. School of Information Engineering, Hebei University of Technology, Tianjin 300401, China)

Abstract: A novel blind signal separation algorithm based on differential search was proposed for solving the high calculated amount problem in blind signal separation algorithm based on bio-inspired optimization. The temporal predictability of signal was used as the objective function and the differential search algorithm was used for solving it. The source signal component separated was wiped off using deflation method and all the source signals could be recovered successfully by repeating the separation process. Simulation results show that the algorithm can achieve blind separation from mixed signals efficiently with very high separation precision and very low computing time.

Key words: blind signal separation; temporal predictability; differential search algorithm; deflation

1 引言

盲信号分离技术是在未知信号混合信息的情况下, 仅由观测到的混合信号恢复出各源信号成分的技术。随着人们对盲信号分离问题研究的不断深入, 盲信号分离算法已广泛应用于声音、图像、通信和生物医学等各领域^[1-4]。传统的盲信号分离算法中采用的优化方法主要是梯度法^[5-7], 然而, 梯度法容易陷入局部收敛, 且收敛性受初始值和步长影响较大。同时, 由于算法多要涉及非线性函数的

选取问题, 还会存在寻优精度不高的局限性。

仿生智能优化方法是以仿生学、数学和计算机科学为基础, 涉及生理学、心理学、神经科学和系统科学等多学科知识的优化方法。近些年, 学者们已提出了很多行之有效的仿生智能优化算法, 如粒子群优化 (PSO, particle swarm optimization) 算法、差分进化 (DE, differential evolution) 算法和人工蜂群 (ABC, artificial bee colony) 算法等, 并已在复杂优化问题的求解和实际应用中发挥了巨大作用^[8]。

针对梯度类优化方法的局限性, 近几年国内外

收稿日期: 2013-10-14; 修回日期: 2014-01-15

基金项目: 国家自然科学基金资助项目(11127202, 60802049)

Foundation Item: The National Natural Science Foundation of China(11127202, 60802049)

已有一些学者将仿生智能优化方法用于解决盲信号分离问题^[9-12]，利用仿生智能优化算法优异的寻优能力，实现了更好分离效果。如文献[9]采用自适应粒子群优化算法对基于负熵的目标函数进行求解，并通过目标函数值对粒子群进化过程中的惯性因子进行动态调整，从而提高了信号的分离性能。文献[10]采用改进的人工蜂群优化算法对基于峭度的目标函数进行求解，从而使分离效果更加稳定。文献[11]采用粒子群优化算法对基于峭度的目标函数进行求解，实现了对信号的逐次盲分离。文献[12]则深入研究了采用人工蜂群算法对基于峭度和负熵相结合的目标函数进行优化求解的盲分离算法。

然而，上述几种新近提出的分离算法在提高分离精度和算法稳定性的同时，都存在一个共同点，即算法计算量较高，分离速度较慢。这是因为算法中所采用的目标函数均基于四阶累积量—峭度，尽管文献[9]采用的目标函数是以负熵为理论出发点，但最终的算法实现过程中仍然是将负熵近似为四阶累积量进行信号的分离。因此，这些算法尽管具有较高的分离精度和稳定性，但由于算法中的生物群体（粒子群，蜂群等）在每次进化迭代过程均要利用所有混合信号样本点重新计算累积量值，因而使得算法的计算量偏大。

针对这一问题，本文提出一种新的基于信号时间可预测性的低计算量差分搜索盲信号分离算法。该算法利用了源信号时间结构上的可预测性，采用基于信号时间可预测性的目标函数，利用差分搜索（DS, differential search）算法^[13]这一新近提出的仿生智能优化算法对目标函数进行优化求解，从而实现了对源信号的成功分离。由于本文提出的分离算法在每代进化计算过程中仅重复使用首次进化前利用混合信号计算出的协方差矩阵，而无须对所有混合信号样本点进行累积量的重新计算，因而在实现了更高分离精度的前提下，较之采用基于峭度理论的算法具有更低的计算量。

2 信号的时间可预测性分离原理

在盲信号分离问题的求解方法中，主要是基于信号独立性的模型，即 ICA(independent component analysis)模型。而自然界中的许多信号，如语音信号、音乐信号、机械震动信号以及地震信号等，在时间域上具有连续、缓变的特性。因此，如果待分离的混合信号是由这些具有时间结构特性的源信

号构成，则可以利用信号中蕴含的时间结构信息来实现对源信号的分离。

根据文献[14]，构成混合信号 $x_i(t)$ 的任何一路源信号 $s_i(t)$ 在时间上的可预测性都要优于 $x_i(t)$ 。如两路不同频率的正弦信号相加后得到的信号波形的时间可预测性将差于每一路原来的正弦信号。因此，可以定义一个量度来评价信号的时间可预测性进行信号的分离。

设来自 N 个信号源的源信号矢量为 $\mathbf{s}(t)=[s_1(t), s_2(t), \dots, s_N(t)]^T$ ，通过瞬时线性混合得到 K 个观测信号（即混合信号）矢量为 $\mathbf{x}(t)=[x_1(t), x_2(t), \dots, x_K(t)]^T$ ，且 $N=K$ 。混合过程用矢量矩阵表示为

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

其中， \mathbf{A} 为满秩可逆的混合矩阵。针对逐次盲信号分离过程，分离模型可表示为

$$y_i(t) = \mathbf{w}_i \mathbf{x}(t) \quad (2)$$

其中， \mathbf{w}_i 为第 i 次分离行向量； $y_i(t)$ 为第 i 次分离出的某一路源信号的估计，即

$$y_i(t) = \mathbf{w}_i \mathbf{x}(t) = \mathbf{w}_i \mathbf{A}\mathbf{s}(t) = \lambda_k s_k(t) \quad (3)$$

其中， $i=1, 2, \dots, N$ ； $k=1, 2, \dots, N$ ； λ_k 为加权系数。

因此，可以定义量度 $F(\mathbf{w}_i, \mathbf{x})$ 来评价由 \mathbf{w}_i 所恢复的信号 $y_i(t)$ 的时间可预测性，信号的可预测性的量度 $F(\mathbf{w}_i, \mathbf{x})$ 定义为^[14]

$$F(\mathbf{w}_i, \mathbf{x}) = \log \frac{V(\mathbf{w}_i, \mathbf{x})}{U(\mathbf{w}_i, \mathbf{x})} = \log \frac{\sum_{t=1}^q (y_i(t) - \bar{y}_i(t))^2}{\sum_{t=1}^q (y_i(t) - \tilde{y}_i(t))^2} \quad (4)$$

其中， $\tilde{y}_i(t)$ 和 $\bar{y}_i(t)$ 分别为第 i 次分离出的信号的短期去均值量和长期去均值量。即

$$\bar{y}_i(t) = y_i(t) - \frac{1}{q} \sum_{k=1}^q y_i(k) \quad (5)$$

$$\tilde{y}_i(t) = y_i(t) - \frac{1}{2m+1} \sum_{k=t-m}^{t+m} y_i(k) \quad (6)$$

其中， q 为每路信号的样本点总数， m 为在时刻 t 处取附近样本点均值的窗宽度。

根据 $y_i = \mathbf{w}_i \mathbf{x}$ ，式 (4) 可重写为

$$\begin{aligned} F(\mathbf{w}_i, \mathbf{x}) &= \log \frac{(\mathbf{w}_i \mathbf{x} - \mathbf{w}_i \bar{\mathbf{x}})(\mathbf{w}_i \mathbf{x} - \mathbf{w}_i \bar{\mathbf{x}})^T}{(\mathbf{w}_i \mathbf{x} - \mathbf{w}_i \tilde{\mathbf{x}})(\mathbf{w}_i \mathbf{x} - \mathbf{w}_i \tilde{\mathbf{x}})^T} \\ &= \log \frac{\mathbf{w}_i \left[(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{x} - \bar{\mathbf{x}})^T \right] \mathbf{w}_i^T}{\mathbf{w}_i \left[(\mathbf{x} - \tilde{\mathbf{x}})(\mathbf{x} - \tilde{\mathbf{x}})^T \right] \mathbf{w}_i^T} \end{aligned} \quad (7)$$

$$\text{定义 } \bar{C}_{ij} = \sum_{t=1}^q (x_i(t) - \bar{x}_i(t))(x_j(t) - \bar{x}_j(t)) \quad (8)$$

$$\tilde{C}_{ij} = \sum_{t=1}^q (x_i(t) - \tilde{x}_i(t))(x_j(t) - \tilde{x}_j(t)) \quad (9)$$

其中, $i, j \in \{1, 2, \dots, N\}$, 用 \bar{C} 表示 $N \times N$ 维的长期协方差矩阵, \tilde{C} 表示 $N \times N$ 维的短期协方差矩阵。则式(7)可改写为

$$F(\mathbf{w}_i, \mathbf{x}) = \log \frac{\mathbf{w}_i \bar{C} \mathbf{w}_i^T}{\mathbf{w}_i \tilde{C} \mathbf{w}_i^T} \quad (10)$$

则盲信号分离问题可归结为下式的优化求解问题

$$\max J(\mathbf{w}_i) = \log \frac{\mathbf{w}_i \bar{C} \mathbf{w}_i^T}{\mathbf{w}_i \tilde{C} \mathbf{w}_i^T} \quad (11)$$

通过求解上述优化问题, 得到最大化信号时间可预测性量度 $F(\mathbf{w}_i, \mathbf{x})$ 的分离向量 \mathbf{w}_i , 即可分离出一路源信号。

3 差分搜索算法

差分搜索算法是土耳其学者 Civicioglu^[13]于2012年提出的仿生智能优化算法, 算法是根据植物学家 Brownian 提出的生物体迁徙过程中的随机漫步行^[15]研究提出的。

不同于粒子群算法^[16]、人工蜂群算法^[17]和 JADE、JDE 等差分进化算法^[18,19], DS 算法在搜索过程中不会完全由最优解引导运动, 搜索过程很好地平衡了群体搜索的目的性与随机性。因此, 它的搜索策略非常适合求解难度较大的多模态问题。下面对 DS 算法进行简要介绍。

设搜索群体大小为 N , $X_i (i = \{1, 2, 3, \dots, N\})$ 表示群体中的第 i 个搜索个体。种群的搜索空间即为待优化问题的解变量空间, 其维数为 D 。 $x_{ij} (j = \{1, 2, 3, \dots, D\})$ 即为第 i 个搜索个体在第 j 维的取值, 最大进化代数数为 G 。DS 算法的具体步骤描述如下。

1) 初始化种群

随机产生 N 个搜索个体, x_{ij} 由下式定义

$$x_{ij} = \text{rand}(up_j - low_j) + low_j \quad (12)$$

其中, up_j 和 low_j 分别代表搜索个体所处位置在第 j 维取值的上限值和下限值。根据待求解的适应度函数分别计算每个搜索个体的适应度值 $f(X_i)$ 。

2) 仿生变异过程

DS 算法在每一代进化过程中, 依据式(13)进行仿生变异操作, 从而使搜索群体在保证多样性的基础上向最优解靠近。

$$StopoverSite_i = X_i + R_g \text{map}_i (\text{donor}_i - X_i) \quad (13)$$

其中, R_g 是采用正态随机数发生器产生的随机数。 map_i 为按一定选择策略构造的 0 与 1 组成的向量。 donor 为每一代进化之前, 将 N 个搜索个体随机重新排序组成的矩阵, 从而通过 $(\text{donor} - X)$ 实现仿生变异操作。 $StopoverSite$ 为仿生变异操作的结果, 即新产生的 N 个备选位置。

3) 边界控制

边界控制的目的是对在仿生变异过程中, 在某些维度上取值超出边界范围的个体 $StopoverSite_i$ 重新赋值, 以保证搜索个体处于搜索范围之内。边界控制的具体操作规则为: 当 $StopoverSite_{ij} < low_j$ 或 $StopoverSite_{ij} > up_j$ 时, 按照式(14)进行赋值

$$StopoverSite_{ij} = \text{rand}(up_j - low_j) + low_j \quad (14)$$

4) 优势个体选择与位置更新

比较当前 $StopoverSite_i$ 与 X_i 的适应度值, 如果 $StopoverSite_i$ 优于 X_i , 则将此 X_i 更新为 $StopoverSite_i$ 的位置。DS 算法原理简单易行, 它在每一代进化过程中选择优势位置进行搜索个体的位置更新, 在保证种群多样性的前提下, 实现了群体向全局最优位置的运动, 并最终搜索到问题的全局最优解。

在文献[13]中, 对 DS 算法与 ABC^[17]、JADE^[18]、JDE^[19]和 PSO2011^[20]等新近提出的几种仿生智能优化算法进行了客观、详尽的实验比较。实验结果验证了 DS 算法较之上述几种算法具有更加优异的优化求解能力, 具备更强的克服局部收敛的能力和更高的搜索精度。因此, 本文将采用 DS 算法作为优化求解方法进行信号的盲分离。

4 基于时间可预测性和差分搜索的盲信号分离

4.1 算法原理

根据信号在时间上的可预测性原理, 盲信号分离问题可以归结为式(11)所示的优化求解问题。本文采用差分搜索算法对式(11)进行优化求解, 从而得到分离向量 \mathbf{w}_i , 然后根据式(2)得到一路源信号的估计 $y_i(t)$ 。

对于多路信号的盲分离问题, 需要进行多次优

化求解过程, 才能把所有源信号分离出来。但如果不对混合信号进行处理, 则在多次分离过程中会出现信号重复提取的现象。因此本算法在每次分离过程之后, 要从原混合信号中去除该次分离出的源信号成分, 然后再进行下一次分离, 最终通过多次基于差分搜索的优化求解过程分离出所有源信号。由于本算法是利用信号在时间上的可预测性来进行信号分离, 并非利用信号的独立性原理, 因此在进行信号分离之前无须对混合信号进行白化操作。

采用 DS 算法求解式(11)的优化问题时, 首先要根据待求变量进行参数编码。在本算法中, 待求变量即为分离行向量 w_i 中的各分量。即对于 N 路源信号的分离问题, 分离行向量为 $w_i = [w_{i,1}, w_{i,2}, \dots, w_{i,N}]$, 则 DS 算法中搜索群体的参数编码为 $(w_{i,1}, w_{i,2}, \dots, w_{i,N})$, 即每个搜索个体所代表的位置为一个 N 维向量。为了进一步减少变量维数并缩小群体的搜索范围, 本文利用球坐标变换原理对分离向量进行变换, 即

$$\begin{aligned} w_{i,1} &= \cos \theta_{i,N-1} \cos \theta_{i,N-2} \cdots \cos \theta_{i,2} \cos \theta_{i,1} \\ w_{i,2} &= \cos \theta_{i,N-1} \cos \theta_{i,N-2} \cdots \cos \theta_{i,2} \sin \theta_{i,1} \\ w_{i,3} &= \cos \theta_{i,N-1} \cos \theta_{i,N-2} \cdots \sin \theta_{i,2} \\ &\dots \\ w_{i,N-1} &= \cos \theta_{i,N-1} \sin \theta_{i,N-2} \\ w_{i,N} &= \sin \theta_{i,N-1} \end{aligned} \quad (15)$$

式中, $0 \leq \theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1} \leq 2\pi$ 。令 $\theta_i = [\theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1}]$, 则式(11)的优化问题转化为下式的优化问题

$$\max J(\theta_i) = \log \frac{w_i \bar{C} w_i^T}{w_i \tilde{C} w_i^T} \quad (16)$$

可以进一步将目标函数简化得到

$$\max J(\theta_i) = \frac{w_i \bar{C} w_i^T}{w_i \tilde{C} w_i^T} \quad (17)$$

因此, 对 w_i 的优化求解问题即转化为对角度向量 $\theta_i = [\theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1}]$ 的优化求解问题, 搜索群体的参数编码转变为 $(\theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1})$ 。搜索群体需要求解的待求变量维数从 N 维减少为 $N-1$ 维, 同时搜索群体的搜索范围缩小为 $0 \leq \theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1} \leq 2\pi$, 降低了群体的搜索难度, 节约了搜索时间。

为了防止重复分离出同一源信号的情况, 本文在每次分离过程之后针对混合信号进行消源处理, 以去除混合信号中的该路源信号成分。设采用本文

算法分离出的第 1 路信号为 $y_1(t) = \lambda_k s_k(t)$, 则 $x'_i(t)$ 为从混合信号 $x_i(t)$ 中去除 $y_1(t)$ 成分后得到的新混合信号。

$$x'_i(t) = x_i(t) - \frac{E(x_i(t)y_1(t))}{E(y_1(t)y_1(t))} y_1(t) \quad (18)$$

通过式(18)的消源计算, $x'_i(t)$ 中已经不再含有源信号 $s_k(t)$ 的成分。在下次信号分离过程中使用 $x'_i(t)$ 代替 $x_i(t)$ 作为混合信号, 即可得到另外一路新的源信号的估计。重复基于本文算法的分离过程和消源过程, 即可逐一分离出所有源信号。由于每次对混合信号进行消源计算之后, 其中的源信号成分都会减少一路, 在进行第 p 次分离时, 仅需从消源后的混合信号中任选 $N-p+1$ 路信号进行分离计算即可。因此, 本文算法中在逐次分离出所有源信号过程中的计算量是逐渐减少的。

4.2 算法实现步骤

根据上述所提出算法原理, 基于时间可预测性的差分搜索盲信号分离算法的具体实现步骤如下。

步骤 1 根据混合信号中源信号的数量确定搜索个体的维数和编码。

步骤 2 在约束范围内随机产生一定数量的搜索个体, 初始化搜索个体的位置。

步骤 3 根据式(15)和式(17)计算出每个搜索个体的适应度值。

步骤 4 根据式(13)进行仿生变异操作, 得到 *StopoverSite*, 并对 *StopoverSite* 进行边界控制操作。

步骤 5 比较 *StopoverSite_i* 与搜索个体 i 当前位置的适应度值, 如果 *StopoverSite_i* 优于搜索个体 i 当前位置, 则将此搜索个体 i 的当前位置更新为 *StopoverSite_i* 的位置。

步骤 6 如果已经达到预设进化代数, 则根据式(15), 由 $\theta_i = [\theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1}]$ 得到分离向量 $w_i = [w_{i,1}, w_{i,2}, \dots, w_{i,N}]$, 根据式(2)输出分离信号, 进入步骤 7; 否则返回步骤 3。

步骤 7 根据式(18)对混合信号进行消源计算, 得到新的混合信号。

步骤 8 如果已经分离出所有源信号, 则停止计算; 否则, 从新混合信号中任选 $N-p+1$ 路信号作为下次分离的混合信号, 返回步骤 1。

可见, 在使用本算法逐一分离源信号的过程中, 参与分离运算的新混合信号数量会逐渐减少, 待优化变量 $\theta_i = [\theta_{i,1}, \theta_{i,2}, \dots, \theta_{i,N-1}]$ 的维数也相应减

少,使得差分搜索变量空间的维数逐渐降低,运算量减小。并且由于本文算法在每次根据式(17)的目标函数计算搜索个体的适应度值时仅利用了 \bar{C} 和 \tilde{C} 2个 $N \times N$ 维的方阵,所以分离算法的总计算量很低。而基于四阶累积量(峭度)的仿生智能盲分离算法在计算每个搜索个体的适应度值时都要使用各路混合信号的所有样本点重新计算累积量,所以计算量会较高。

5 仿真分析

为了验证本文所提出算法的有效性,从RIKEN脑科学研究所-The Cichocki Laboratory for Advanced Brain Signal Processing提供的语音数据库中选取3路语音信号作为源信号进行分离实验,采样点数为8000。实验中对源信号采用随机产生的矩阵

A 进行混合,然后使用本文算法对混合信号进行盲分离实验。源信号、混合信号和分离信号波形分别如图1(a)~图1(c)所示;分离信号与源信号的分组散点图如图1(d)所示。

$$A = \begin{bmatrix} 0.8147 & 0.9134 & 0.2785 \\ 0.9058 & 0.6324 & 0.5469 \\ 0.1270 & 0.0975 & 0.9575 \end{bmatrix}$$

计算机仿真实验平台配置为: Intel Core i5 处理器,主频 2.8 GHz; 4 GB 内存; Windows 7 旗舰版 64 位 SP1 操作系统, MATLAB 2013a 版本。本文算法中的差分搜索算法的各参数值设置为: 种群大小 $N = 20$, 搜索个体维数 $D = 2$, 进化代数为 200 代, $low_j = -2\pi$, $up_j = 2\pi$ 。

通过比较本文算法得到的分离信号和源信号

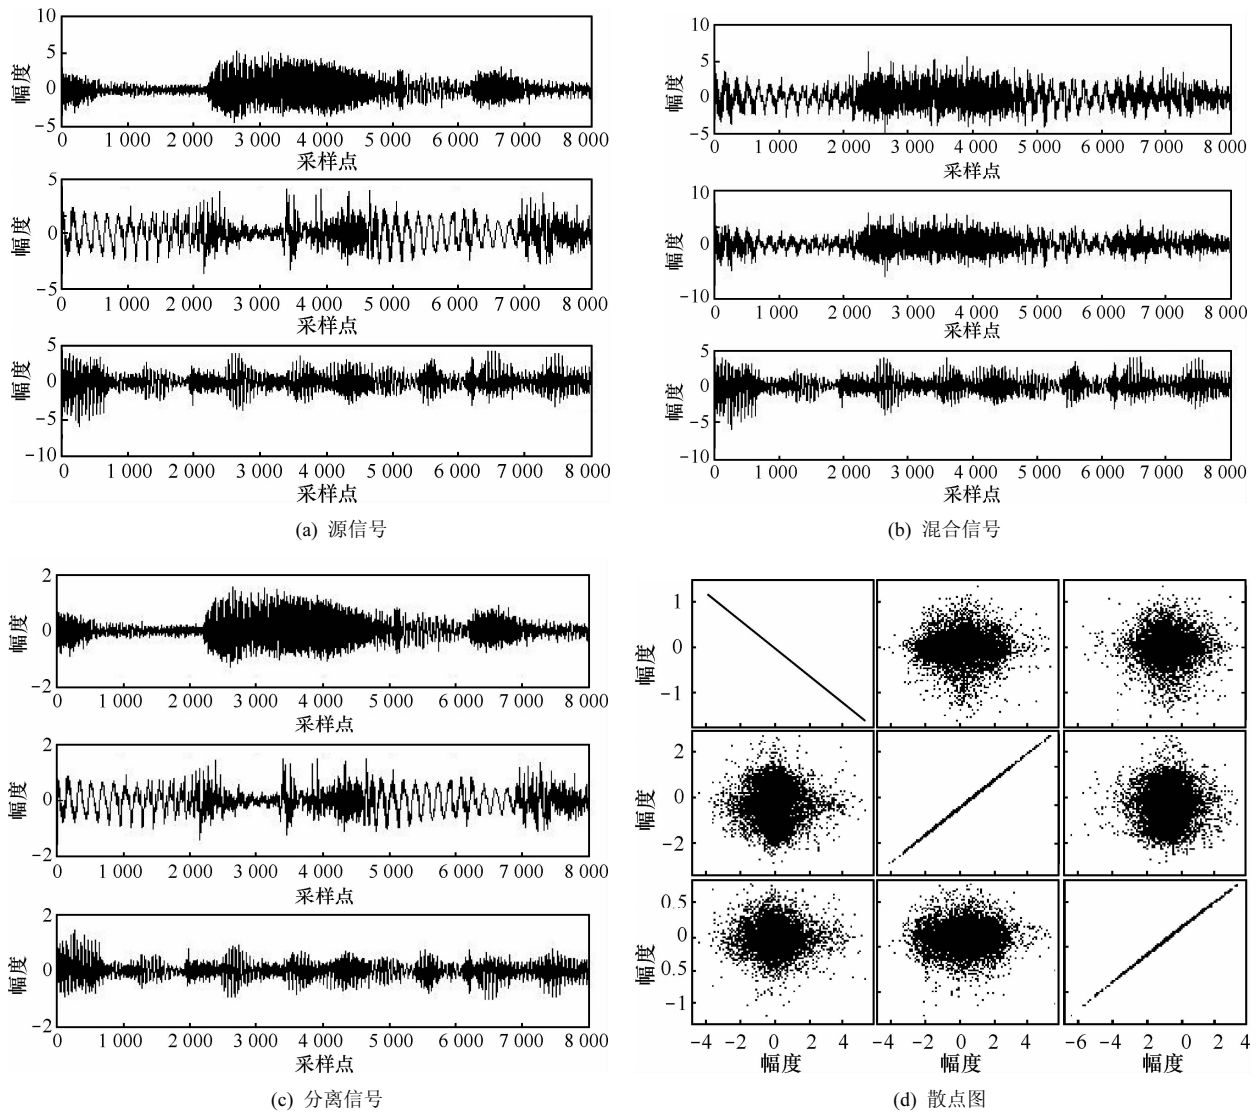




图1 信号盲分离实验结果

波形可知, 该算法具有很好的分离效果, 分离出的信号波形与源信号的吻合度很高。并且, 在信号散点图中可见, 所有分离出的信号与其对应的源信号的散点图均是一条细长的直线, 说明该算法分离出的信号与源信号的相似度很高。

图 2 所示为差分搜索算法在搜索最优分离向量时的进化曲线。在本文算法中, 针对 3 路信号的分离, 仅需进行 2 次分离过程。因为在第 2 次分离、消源后剩下的混合信号中已不含有其他源信号的成分, 只需从中选取一路信号作为第 3 路源信号的恢复即可, 而无需进行第 3 次分离计算过程。本文算法的这一特点也会降低分离算法的整体计算量。通过进化曲线可以看出, DS 算法利用其优异的全局搜索能力搜索到使目标函数值最大的分离向量, 算法收敛速度很快。



(a) 第一次分离



(b) 第二次分离

图 2 DS 算法进化曲线

为了更加客观的定量分析本文算法的分离效果和性能, 采用相关系数的绝对值 ζ_{ik} 、重构信噪比 S/N 以及算法运行时间 3 个指标来对算法进行评

价, 并与文献[9~12]的基于仿生智能优化的盲信号分离算法进行比较、分析以说明本文算法的优势。

针对各种算法均进行 20 次蒙特卡罗仿真实验, 其得到的相关系数绝对值和重构信噪比的性能指标统计数据分别如表 1 和表 2 所示。

文献[9]的算法参数设置: 粒子种群规模 $M=20$, 粒子维数 $D=9$, $c_1=c_2=2$, 每一维粒子速度限制在 $[-0.8, 0.8]$, 惯性因子 w 从 0.9 至 0.4 之间线性下降, 并随适应度值的变化自适应动态调整, 进化代数为 200 代。

文献[10]的算法参数设置: 采蜜蜂和跟随蜂数量均为 20, 蜜源维数 $D=9$, $limit=40$, $c_{min}=0$, $c_{max}=1$, $\alpha=50$, $\beta=6$, 进化代数为 200 代。

文献[11]的算法参数设置: 粒子种群规模 $M=20$, 粒子维数 $D=2$, $c_1=c_2=2$, 每一维粒子速度限制在 $[-0.8, 0.8]$, 惯性因子 w 在粒子群进化过程中从 0.8 至 0.3 线性下降。进化代数为 200 代。

文献[12]的算法参数设置: 采蜜蜂和跟随蜂数量均为 20, 蜜源维数 $D=3$, $limit=40$, 进化代数为 200 代。下面对实验结果进行比较分析。

1) 相关系数的绝对值 ζ_{ik} 定义为^[21]

$$\zeta_{ik} = \frac{\left| \sum_{t=1}^q y_i(t) s_k(t) \right|}{\sqrt{\sum_{t=1}^q y_i^2(t) \sum_{t=1}^q s_k^2(t)}} \quad (19)$$

当 $y_i(t) = \lambda_k s_k(t)$ 时, $\zeta_{ik} = 1$ 。 ζ_{ik} 的值越接近于 1, 表示分离信号与源信号的相似程度越高。

2) 重构信噪比 S/N 定义为^[22]

$$S/N = -10 \lg \frac{\sum_{t=1}^q (s_i(t))^2}{\sum_{t=1}^q (s_i(t) - y_i(t))^2} \quad (20)$$

S/N 的值越大, 表示分离信号与源信号的误差越小, 分离效果越好。

通过比较表 1 和表 2 中的数据可知, 本文算法的分离性能稳定。每一路分离信号与对应源信号的相关系数绝对值均超过 0.999, 信号的重构信噪比均超过 30 dB, 这说明本文算法分离出的信号与源信号的相似程度已经很高。并且, 本文算法对于 3 路信号分离的相关系数平均值和重构信噪比总平均值分别达到 0.999 82 dB 和 36.454 6 dB, 其性能

表 1 相关系数绝对值

| 算法 | 信号 1 | | | 信号 2 | | | 信号 3 | | | 总平均值 /dB |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | 最大值/dB | 最小值/dB | 平均值/dB | 最大值/dB | 最小值/dB | 平均值/dB | 最大值/dB | 最小值/dB | 平均值/dB | |
| 文献[9] | 0.999 94 | 0.999 76 | 0.999 92 | 0.999 84 | 0.999 50 | 0.999 78 | 0.999 66 | 0.998 92 | 0.999 46 | 0.999 72 |
| 文献[10] | 0.999 98 | 0.999 81 | 0.999 93 | 0.999 97 | 0.999 69 | 0.999 81 | 0.999 80 | 0.999 29 | 0.999 50 | 0.999 75 |
| 文献[11] | 0.999 73 | 0.999 73 | 0.999 73 | 0.999 74 | 0.999 71 | 0.999 73 | 0.999 61 | 0.999 60 | 0.999 60 | 0.999 69 |
| 文献[12] | 0.999 66 | 0.999 23 | 0.999 60 | 0.999 99 | 0.999 30 | 0.999 76 | 0.999 90 | 0.999 51 | 0.999 74 | 0.999 70 |
| 本文算法 | 1.000 00 | 0.999 97 | 0.999 99 | 0.999 88 | 0.999 87 | 0.999 87 | 0.999 62 | 0.999 60 | 0.999 61 | 0.999 82 |

表 2 重构信噪比

| 算法 | 信号 1 | | | 信号 2 | | | 信号 3 | | | 总平均值 /dB |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | 最大值/dB | 最小值/dB | 平均值/dB | 最大值/dB | 最小值/dB | 平均值/dB | 最大值/dB | 最小值/dB | 平均值/dB | |
| 文献[9] | 34.671 0 | 32.733 4 | 34.343 5 | 34.984 0 | 33.346 9 | 34.026 3 | 32.866 1 | 31.000 7 | 31.504 6 | 33.291 5 |
| 文献[10] | 40.475 0 | 29.173 6 | 34.399 0 | 41.294 9 | 32.024 3 | 34.415 4 | 35.716 9 | 30.230 4 | 31.723 7 | 33.512 7 |
| 文献[11] | 30.357 6 | 30.338 6 | 30.349 5 | 32.823 3 | 32.637 7 | 32.725 3 | 33.325 8 | 33.315 9 | 33.317 8 | 32.130 9 |
| 文献[12] | 33.410 0 | 29.798 8 | 32.396 7 | 41.721 5 | 24.052 4 | 32.773 9 | 37.082 6 | 30.174 0 | 33.007 1 | 32.725 9 |
| 本文算法 | 42.736 2 | 37.367 1 | 41.218 2 | 36.155 8 | 35.851 7 | 36.024 7 | 32.398 4 | 31.754 8 | 32.120 8 | 36.454 6 |

指标均优于文献[9~12]的 4 种算法。

由于本文算法较之文献[9~12]算法更为明显的优势在于计算量低，因此需要进一步在算法计算量上进行比较分析。针对基于仿生智能优化的盲信号分离算法而言，不同仿生智能优化算法的每次优化求解过程具有随机性，且在其每一代进化过程中的计算步骤和计算量各不相同，进化曲线并不能有效体现出不同分离算法的计算量差异。所以，本文进一步通过比较不同分离算法在相同计算机硬件平台下，执行相同分离任务的计算时间，来更加客观地评价算法的计算量。各种算法进行上述 3 路语音信号盲分离的 20 次蒙特卡罗仿真实验平均运行时间统计如表 3 所示。

表 3 算法运行时间

| 算法 | 最大值/s | 最小值/s | 平均值/s |
|--------|--------|--------|--------|
| 文献[9] | 9.953 | 8.576 | 9.061 |
| 文献[10] | 19.998 | 17.442 | 18.113 |
| 文献[11] | 7.533 | 7.175 | 7.235 |
| 文献[12] | 9.679 | 9.524 | 9.561 |
| 本文算法 | 0.1928 | 0.1201 | 0.1472 |

通过比较本文算法与文献[9~12]的 4 种基于仿生智能优化的盲信号分离算法的运行时间可知，本文算法在保持了基于仿生智能优化的盲信号分离算法稳定性强、分离精度高、无须进行非线性函数

选取和算法原理清晰等优点的同时，有效避免了采用仿生智能优化算法进行信号分离时计算量大、计算时间长的问题。在实现了更好分离效果的同时，本文算法所耗计算时间仅为文献[10]中算法的 1/120、文献[9]和文献[12]中的算法的 1/60，与计算量最小的文献[11]中的算法相比亦仅为其计算时间的 1/50。可见，本文算法在保证更加优异的分离效果的前提下，具有更低的计算量。

下面通过重构信噪比曲线来进一步说明搜索个体维数和种群规模对算法分离性能的影响。在 DS 算法的各项参数中：1) 搜索个体的维数 D 是由源信号数量决定的。即当源信号数量为 3 时，搜索个体维数 $D=2$ ；当源信号数量为 5 时，搜索个体维数 $D=4$ ；当源信号数量为 8 时，搜索个体维数 $D=7$ 。2) 种群规模 M 可以为人为设定，可根据搜索个体维数的增加而适当扩大种群规模，从而保证种群的多样性，增加全局收敛的顽健性。

在图 3 中，不同符号的曲线代表不同的种群规模，进化代数 2 000 代，图中数据为 20 次蒙特卡罗仿真实验得到的平均结果。由图可知，当源信号路数较少时（如 3 路情况），不同种群规模情况下的分离性能均比较好，重构信噪比均高于 35 dB。随着源信号路数的逐渐增加，当种群规模比较小的时候，重构信噪比下降很快。当源信号路数为 8，种群规模为 10 的情况下，重构信噪比已经低于

5 dB。而如果将种群规模由 10 增大到 100, 对于相同的源信号路数, 重构信噪比会有比较明显的提高, 其值均能达到 25 dB 左右。




图 3 重构信噪比曲线

因此, 分析图中数据可知, 当本文算法求解的盲信号分离问题的路数较低时(即搜索个体维数 D 较低时), 较小的种群规模 ($M=10$ 或 $M=20$) 即能实现较好的分离效果。但随着源信号路数的增加, 信号分离的难度逐渐增加, 较小的种群规模难以体现出群体智能的优势, 算法的分离性能会有所下降。这时可以通过扩大种群规模的方法得到更好的分离性能。但当种群达到一定规模后(100 以上), 分离性能的提升已经不明显, 但此时重构信噪比的下降已经趋于平缓, 能够使分离性能保持在较好的水平。

综上可知, 对于源信号路数较少的情况, 本文算法中可选择较小的种群规模, 这样可以在保证较低的计算量前提下得到较好的分离效果; 而对于源信号路数较多的情况, 需要适当增大种群规模, 充分发挥群体智能的作用以得到更好的分离性能。

6 结束语

本文在信号时间可预测性度量的理论基础上, 提出了一种基于差分搜索优化的低计算量盲信号分离算法。该算法利用了信号的时间结构信息, 采用差分搜索优化算法对目标函数进行优化求解, 并通过去相关方法对混合信号进行消源处理, 通过逐次分离与消源计算过程实现了对所有源信号的成功恢复。仿真实验结果表明, 本文算法的信号分离效果很好, 且相对于其他基于仿生

智能优化的盲信号分离算法具有更低的计算量和更高的分离精度。


参考文献:

- [1] MATO-MENDEZ F J, SOBREIRA-SEOANE M A. Blind separation to improve classification of traffic noise[J]. *Applied Acoustics*, 2011, 72(8): 590-598.
- [2] OZGEN M T, KURUOGLU E E, HERRANZ D. Astrophysical image separation by blind time-frequency source separation methods[J]. *Digital Signal Processing*, 2009, 19(2): 360-369.
- [3] IKHLEF A, ABED-MERAIM K, GUENEC D L. Blind signal separation and equalization with controlled delay for MIMO convolutive systems[J]. *Signal Processing*, 2010, 90(9): 2655-2666.
- [4] SALIDO RUIZ R A, RANTA R, LOUIS-DORR V. EEG montage analysis in the blind source separation framework[J]. *Biomedical Signal Processing and Control*, 2011, 6(1):77-84.
- [5] CICHOCKI A, THAWONMAS R, AMARI S. Sequential blind signal extraction in order specified by stochastic properties[J]. *Electronics Letters*, 1997, 33(1):64-65.
- [6] HYVARINEN A. Fast and robust fixed-point algorithms for independent component analysis[J]. *IEEE Transactions on Neural Networks*, 1999, 10(3):626-634.
- [7] 孙守宇, 郑君里, 吴里江等. 峭度自适应学习率的盲信源分离[J]. *电子学报*, 2005, 33(3):473-476.
SUN S Y, ZHENG J L, WU L J, *et al.* Blind source separation with kurtosis adaptive learning rate[J]. *Acta Electronica Sinica*, 2005, 33(3): 473-476.
- [8] 段海滨, 张祥银, 徐春芳. 仿生智能计算[M]. 北京:科学出版社,2011.
DUAN H B, ZHANG X Y, XU C F. *Bio-inspired Computing*[M]. Beijing: Science Press, 2011.
- [9] 张朝柱, 张健沛, 孙晓东. 基于自适应粒子群优化的盲源分离[J]. *系统工程与电子技术*, 2009, 31(6): 1275-1278.
ZHANG C Z, ZHANG J P, SUN X D. Blind source separation based on adaptive particle swarm optimization[J]. *Systems Engineering and Electronics*, 2009, 31(6): 1275-1278.
- [10] 张银雪, 田学民, 邓晓刚. 基于改进人工蜂群算法的盲源分离方法[J]. *电子学报*, 2012, 40(10):2026-2030.
ZHANG Y X, TIAN X M, DENG X G. Blind source separation based on modified artificial bee colony algorithm[J]. *Acta Electronica Sinica*, 2012, 40(10): 2026-2030.
- [11] 陈雷, 张立毅, 郭艳菊等. 基于粒子群优化的有序盲信号分离算法[J]. *天津大学学报*, 2011, 44(2):174-179.
CHEN L, ZHANG L Y, GUO Y J, *et al.* Sequential blind signal separation algorithm based on particle swarm optimization[J]. *Journal of Tianjin University*, 2011, 44(2): 174-179.
- [12] MAVADDATY S, EBRAHIMZADEH A. A comparative study of bees colony algorithm for blind source separation[A]. 20th Iranian Conference on Electrical Engineering[C]. 2012.1172-1177.
- [13] CIVICIOGLU P. Transforming geocentric cartesian coordinates to geodetic coordinates by using differential search algorithm[J]. *Com-*

puters and Geosciences, 2012, 46: 229-247.

- [14] STONE J V. Independent Component Analysis-A Tutorial Introduction[M]. MIT Press, 2004.
- [15] TRIANNI V, TUCI E, PASSINO K M, *et al.* Swarm cognition: an interdisciplinary approach to the study of self-organising biological collectives[J]. Swarm Intelligence, 2011, 5(1): 3-18.
- [16] KENNEDY J, EBERHART R C. Particle swarm optimization[A]. Proceedings of IEEE International Conference on Neural Networks[C]. Perth, Australia, 1995. 1942-1948.
- [17] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony(ABC) algorithm[J]. Journal of Global Optimization, 2007, 39(3):459-471
- [18] ZHANG J, SANDERSON A C. JADE: adaptive differential evolution with optional external archive[J]. IEEE Transactions on Evolutionary Computation, 2009, 13(5): 945-958.
- [19] WANG Y, CAI Z X, ZHANG Q F. Differential evolution with composite trial vector generation strategies and control parameters[J]. IEEE Transactions on Evolutionary Computation, 2011, 15(1): 55-66.
- [20] OMRAN M G H, CLERC M. SPSO 2011[EB/OL]. <http://www.particleswarm.info/Programs.html>.
- [21] FREEDMAN D, PISANI R, PURVES R. Statistics[M]. W W Norton & Company, 2007.
- [22] BOFILL P, ZIBULEVSKY M. Underdetermined blind source separation using sparse representations[J]. Signal Processing, 2001, 81(11): 2353-2362.

作者简介:



陈雷(1980-), 男, 河北唐山人, 天津商业大学副教授、主要研究方向为盲信号处理、仿生智能计算等。



张立毅[通信作者](1963-), 男, 山西忻州人, 天津大学教授、博士生导师, 主要研究方向为盲信号处理, 信号检测与处理等。E-mail:zhangliyi@tjcu.edu.cn。

郭艳菊(1980-), 女, 河北邢台人, 河北工业大学讲师, 主要研究方向为智能计算, 图像处理等。

黄勇(1990-), 男, 湖南益阳人, 天津商业大学硕士生, 主要研究方向为仿生智能计算。

梁静毅(1963-), 女, 河北大城人, 天津商业大学副教授, 主要研究方向为计算机网络、信号控制与处理。