

参数自适应混沌粒子群算法在盲源分离中的应用

杨汉华

(盐城工学院 电气工程学院, 江苏 盐城 224051)

摘 要: 独立分量分析(ICA)是盲源信号分离中应用最为广泛技术,其应用过程需要对目标函数进行优化,传统粒子群算法(PSO)对其进行优化时,存在易陷入局部最优、稳定性差等缺陷,针对此问题,提出采用参数自适应混沌粒子群算法对 ICA 进行优化.首先采用对 PSO 的参数进行自适应调整,提高粒子的搜索能力,然后对粒子群进行混沌扰动,提高算法收敛速度.仿真结果表明,使用参数自适应混沌粒子群算法可以有效解决 ICA 的目标函数优化问题,极大提高了盲源信号的分离效果.

关键词: 盲源分离;独立分量分析;自适应;混沌粒子群算法

中图分类号: TN911

文献标识码: A

文章编号: 1000-7180(2012)10-0202-04

Application of Adaptive Parameter Chaotic Particle Swarm Optimization Algorithm for Blind Source Separation

YANG Han-hua

(College of Electrical Engineering, Yancheng Institute of Technology, Yancheng 224051, China)

Abstract: Independent component analysis (ICA) is a blind source separation technology, and in its application process the objective function needs to be optimized, the traditional algorithm of particle (PSO) easily falls into local optimization, instability and other defects. In order to solve this problem, ICA is optimized by the parameter adaptive chaos particle swarm optimization algorithm. Firstly, PSO parameter are adaptive adjusted to improve the search ability of particle, and the particle is chaos disturbed to improve the convergence rate. The results show that the proposed method has solved the ICA objective function optimization problems, and greatly improve the blind source separation effect.

Key words: blind sources separation; independent component analysis; adaptive; chaotic particle swarm optimization

1 引言

盲源信号分离(blind source separation, BSS)又简称盲分离,是一种新代的数字信号处理技术,指在没有先验知识的情况下,对接收到的信号进行处理,从中分离出源信号的过程,其在无线通信、语音处理、噪声消除和地球物理信号处理等领域应用广泛,具有较高的实用价值^[1].

盲源信号分离有多种分类方法,按照信号混合方式可以分为线性混合信号和非线性混合信号分离算法^[2].在实际环境中,观测的混合信号通常是通过非线性混合叠加而成,比线性混合复杂,线性分离算

法不适合用于解决线性混合盲源信号分离问题^[3].非线性盲源信号分离算法是当前研究的热点,学者们提出许多分离算法,如统计学、神经网络、信息论等理论的盲源信号分离算法^[4-6].其中独立分量分析(Independent Component Analysis, ICA)是由 Como 于 1994 年对独立主分分析(Principal Component Analysis, PCA)进行扩展形成的盲源信号分离算法,成为当前最主要的盲源信号分离算法^[7].在基于 ICA 的盲源信号分离算法中,独立性判断准则确定后,通过采用目标函数优化算法确定分离矩阵 W .传统目标函数优化采用最陡梯度下降算法和自然梯度法,它们存在收敛速度慢、计算量大等缺

陷^[8]. 最近有人提出采用遗传算法(Genetic Algorithm, GA)、粒子群优化算法(Particle Swarm Optimization, PSO)等仿生算法对 ICA 的目标函数进行优化,取得很好的效果^[9-10]. 但是它们也存在进化后期收敛速度慢、易陷入局部最优等缺陷,盲源信号分离效果有待进一步提高.

为了获得更好的盲源信号分离效果,提出一种参数自适应混沌粒子群算法,并将其应用于 ICA 的盲源信号分离算法目标函数优化. 仿真结果表明,该算法可以有效解决了 ICA 中的目标函数优化难题,极大地提高了盲源信号分离的效果.

2 非线性信号的盲源分离模型

设有 m 个原始信号和传感器,对于线性盲源信号分离问题,观测信号和源信号之间的关系为

$$x(t) = As(t) + v(n) \quad (1)$$

式中, $s(t)$ 为 n 个源信号构成的向量; $v(n)$ 为系统的加性噪声; $x(t)$ 为原信号经过观测器得到的混合向量; A 为 $n \times n$ 维信道混合矩阵. 忽略噪声 $v(n)$ 影响,通过盲源分离算法得到的输出估计为

$$y(t) = Wx(t) = WA s(t) = PDs(t) \quad (2)$$

从式(2)可知,若 W 满足 $WA = PD$,则表示源信号 $s(t)$ 恢复. 但线性盲源分离算法不适合于非线性混合信号. 对于非线性混合信号,观测信号和源信号之间的关系为

$$x(t) = f(As(t)) + v(n) \quad (3)$$

式中, $f()$ 为非线性混合函数.

非线性混合信号的分离模型为

$$y(t) = g(x(t)) \quad (4)$$

综合上述可知,非线性盲源混合和分离原理如图 1 所示.




图 1 非线性盲源信号混合和分离原理图

由于 ICA 算法与盲源信号分离都需要确定分离矩阵,因此具有一定的相似性. 从式(3)可知,要 $x(t)$ 是 $s(t)$ 的混合, $x(t)$ 有比 $s(t)$ 更高的高斯性,因

此对于式(4),ICA 就是寻找一个矩阵 W 使分离后的各分量 y_i 相互独立,那么认为测量信号与源信号最相似,实现盲源分离. 根据 ICA 工作基本原理可知,独立成分分析的实现包括目标函数和优化方法. 本研究采用互信作为目标函数,即有

$$I(y) = \sum_{i=1}^n H(y_i) - H(x) - \log|W| \quad (5)$$

式中, $H(x)$ 表示微分熵.

目标函数确定后,就要利用目标函数优化算法来确定分离矩阵 W . 传统梯度下降优化算法易陷入局部最优,难以获得全局最优解. 为解决此难题,出现了一些智能仿生算法的盲分离方法,这些算法同样存在各自的不足. 本研究针对基本 PSO 算法的不足,首先引入自适应参数策略对粒子的加速系统进行调整,提高了粒子的全局和局部搜索能力,同时存在在粒子搜索过程中,引入混沌机制,防止早熟现象和局部最优出现.

3 自适应参数 CPSO 的盲源信号分离算法

3.1 基本粒子群算法

在基本粒子群(PSO)算法中,每一个粒子代表待优化问题的潜在解,粒子质量由目标函数来确定. 首先初始化一群随机粒子,粒子在解空间追随当前最优粒子飞行方面找到最优解. x_i 和 v_i 分别为粒子 i 的位置和速度, p_i 和 p_g 分别为粒子 i 和群体历史的最优位置,速度和位置通过式(6)、(7)进行更新.

$$\begin{aligned} v_{id}^{k+1} = & \omega^k \times v_{id}^k + c_1 \times rand_1 \times (p_{id}^k - x_{id}^k) + \\ & c_2 \times rand_2 \times (p_{gd}^k - x_{id}^k) \end{aligned} \quad (6)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^k \quad (7)$$

式中, k 为当前迭代次数; ω^k 为惯性权重 c_1, c_2 为加速度系数; $rand_1$ 和 $rand_2$ 为随机数.

大量研究表明, ω^k 较小时,收敛速度快,较大时,则易跳出局部极小点,因此,随着迭代次数增加, ω^k 根据式(8)进行变化.

$$\omega^k = \omega_{\max} - k \cdot \frac{\omega_{\max} - \omega_{\min}}{iter_{\max}} \quad (8)$$

式中, $iter_{\max}$ 为最大进化代数.

在基本 PSO 算法中,随迭代次数增大, c_1, c_2 为固定值,惯性权值 ω 线性减小,这样粒子在搜索过程中,无法保证其对解空间进行完全遍历. 这样,为了解决该问题,采用自适应参数策略对粒子的加速系统进行调整,具体为:在粒子群搜索初期,粒子群平均适应度(f_{avg})和整体最优适应度(f_g)之间的差

异较大,随着不断迭代,它们间差异就越来越小, c_1 和 c_2 的取值分别为:

$$\begin{cases} c_1(k) = 2.5 - 2\exp(-\alpha|f_{\text{avg}} - f_g|) \\ c_2(k) = 0.5 + 2\exp(-\alpha|f_{\text{avg}} - f_g|) \end{cases} \quad (9)$$

式中, α 控制系数.

由式(9)可知,对于任意粒子, $c_1(k)$ 非线性减小,而 $c_2(k)$ 非线性增大,最终找到的全局最优解. 但是对全局极值不只 1 个的优问题,一个粒子若找到一个当前最优位置,那么其他粒子迅速向其靠拢,此时,该最优位置基为局部最优点,粒子群陷入局部最优,出现早熟.

混沌是一种非线性现象,具有对初始条件敏感性、遍历性、随机性等特点,可以利用混沌运动的这些特性进行优化搜索. 当粒子群出现早熟收敛现象,入局部最优时,通过对其混沌扰动帮助逃离局部最优点. 采用 Logistic 映射产生混沌变量,其迭代公式为

$$z_{i+1} = \mu z_i (1 - z_i), i = 0, 1, \dots, \mu \in (2, 4] \quad (10)$$

式中, μ 为控制参量.

个体位置优劣由的适应度值决定,随着粒子群不断进化,个体间差异越来越小,因此根据所有个体适应度整体变化可以判断种群是否出现早熟判断状态. 粒子群的适应度方差(σ^2)定义为

$$\sigma^2 = \sum_{i=1}^N \left(\frac{f_i - f_{\text{avg}}}{f} \right)^2 \quad (11)$$

式中, f_{avg} 为粒子群的平均适应度; f_i 为个体 i 的适应度; N 为粒子群规模; f 为归一化定标因子,其取值采用如下公式:

$$f = \begin{cases} \max_{1 \leq i \leq N} |f_i - f_{\text{avg}}|, & \max_{1 \leq i \leq N} |f_i - f_{\text{avg}}| > 1 \\ 1, & \max_{1 \leq i \leq N} |f_i - f_{\text{avg}}| \leq 1 \end{cases} \quad (12)$$

σ^2 反映了粒子群中个体的聚集程度, σ^2 越大,表示粒子群中个体的聚集程度越小;反之越大. 随着迭代次数增加,粒子群个体适应度差异越来越小,那 σ^2 相应越来越小. 当 σ^2 小于给定阈值时,表示出现早熟收敛现象,易出现局部最优值.

3.2 自适应参数 CPSO 的盲源信号分离混沌流程

step1: 读取待分离的盲源信号.

Step2: 对信号进行预处理,主要包括中心化和白化,使观测向量期望值为 0.

Step3: 初始化粒子群参数. 主要包括 c_1, c_2 的值; 最大迭代次数 K_{max} ; 粒子数 N ; 惯性权值的最大值与最小值.

Step4: 采用混沌方式产生初始粒子群. 从 N 个粒子中选择性能比较好的 m 粒子作为初始解,并随机产生 m 个初始速度.

Step5: 计算每一个粒子的适应度值,同时对个体最优值和群体最优值进行更新.

Step6: 计算粒子的适应度方差(σ^2),若 $\sigma^2 < C$ (C 表示阈值),则表示出现早熟现象,就需要对粒子进行混沌扰动,转 step7,不然转步骤 step8.

Step7: 对出现早熟的粒子进行混沌扰动.

Step8: 根据式(9)对惯性权值进行自适应调度,并更新粒子的速度和位置.

Step9: 判断是否达到最大迭代次数 K_{max} . 如果达到,则停止迭代,返回全局最优位置 W .

Step10: 输出分离信号 $y(t)$.

4 仿真测试

4.1 源信号

为了验证参数适应混沌粒子算法在盲源信号分离中的效果,对其进行仿真测试. 取两路信号作为源信号,一路为正弦信号,一路为调频信号,它们的函数形式见式(13),设置采样点数为横坐标,幅度为纵坐标,两种波形具体如图 2 所示. 设定粒子数 20 个, $c_1 = c_2 = 2$, 最大迭代次数 500, $c_1 = c_2 = 2$, $\omega_{\text{max}} = 0.9$, $\omega_{\text{min}} = 0.4$.




图 2 源信号

混合矩阵为 $A = \begin{bmatrix} -0.7520 & -0.6885 \\ -0.7483 & -0.5165 \end{bmatrix}$, 那么

得到的混合信号如图 3 所示.

4.2 结果与分析

4.2.1 分离效果

利用参数自适应混沌粒子算法首对混合信号进行分离,得到的分离结果如图 4 所示.

从图 4 可知,参数自适应混沌粒子群算法的输出信号与源信号峰度相似,输出和源信号吻合得相当的好,说明信号分离精度相当的高,证明了其应用




图3 混合信号




图4 盲源信号的分离信号结果

于盲源信号分离的有效性和可行性。

4.2.2 与其他分离算法对比

为了说明参数自适应混沌粒子算法的优越性,在相同的实验条件下,采用ICA算法(ICA)、粒子群优化ICA的算法(PSO-ICA)作为对比算法,进行仿真实验。各算法的评价标准为源信号与分离信号的相关系数和信噪比,仿真结果见表1和表2。

表1 源信号与分离信号的相关系数

分离算法	正弦信号	调频信号
本文算法	0.998 7	0.998 5
ICA	0.991 4	0.991 7
PSO-ICA	0.995 0	0.989 4

表2 源信号与分离信号的信噪比

分离算法	正弦信号	调频信号
本文算法	33.82	32.73
ICA	31.48	30.65
PSO-ICA	33.15	31.13

从表1可知,在所有的分离算法中,参数适应混沌粒子群算法的源信号与分离信号的相关系数最接近1,表示分离信号与源信号之间的估计相当精确,这证明本文算法的分离效果要优于对比算法ICA和PSO-ICA。

从表2可知,参数适应混沌粒子群算法的源信号与分离信号的信噪比参数最大,说明信号间的干扰相当小,分离效果较优,分离结果比较稳定,相对于ICA和PSO-ICA,具有较明显的优势。

5 结束语

针对传统独立分量分析盲源分离算法存在的不足,将混沌机制和粒子群算法相结合,同时对粒子群算法参数调整进行改进,然后将它们引入到盲源信号分离中。仿真结果表明,相对于对比算法,参数自适应混沌粒子算法可以获得较高精度的分离结果,可以将该算法应用于无线通信的接收技术中。

参考文献:

- [1] 马建仓,牛亦龙,陈海洋. 盲信号处理[M]. 北京:国防工业出版社,2006.
- [2] Ainoren Y, Engelberg S, Fridman S. The cocktail party problem[J]. IEEE Instrumentation & Measurement Magazine, 2008, 11(3): 44-48.
- [3] 刘据,聂开宝,何振亚. 非线性混叠信号的可分离性及分离方法研究[J]. 电子与信息学报, 2003, 25(1): 54-61.
- [4] Liyanage S R, Xu J X, Guan C T, et al. EEG signal separation for multi-class motor imagery using common spatial patterns based on joint Approximate Digitalization[C]// Neural Networks, The 2010 International Joint Conference on. 2010: 1-6.
- [5] Bertrand Rivet, Laurent Girin, Christian Jutten. Mixing audiovisual speech processing and blind source separation for the extraction of speech signals from convolute mixtures[J]. Audio, Speech, and Language Processing, IEEE Trans. on, 2007, 15(1): 96-108.
- [6] 李良敏. 基于遗传算法的盲源分离算法[J]. 西安交通大学学报, 2005, 39(7): 740-743.
- [7] 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.
- [8] Gupta. M, Jin. L, Homma. N. Radial Basis Function Neural Networks[M]. Static and Dynamic Neural Networks, 2003: 223-252.
- [9] Yimin Wang, Jue Zhang. Water demand prediction based on RBF neural network[C]// Intelligent Control and Automation. 2008, : 4514-4516.
- [10] Wilamowski B M, Cotton N J, Kayank O, et al. Computing grandient vector and jacobian matrix in arbitrarily connected neural networks[J]. Industrial Electronics, IEEE Trans. on, 2008, 10(55): 3784-3790.

作者简介:

杨汉华 男, (1971-), 硕士, 讲师, 研究方向为智能信息处理。