

一种基于改进 PSO 的随机最大似然算法

宋华军¹, 刘 芬¹, 陈海华², 张 鹤¹

(1. 中国石油大学(华东)信息与控制工程学院, 山东青岛 266580;
2. 中国石油大学(华东)计算机与通信工程学院, 山东青岛 266580)

摘 要: 随机最大似然算法 (Stochastic Maximum Likelihood, SML) 具有优越的波达方位 (Direction-of-Arrival, DOA) 估计性能, 但 SML 解析过程较高的计算复杂度限制了该算法在实际系统中的应用. 针对 SML 计算复杂度高的问题, 提出一种低复杂度的粒子群优化算法 (Particle Swarm Optimization, PSO), 解决了传统 PSO 算法中粒子数多和迭代次数多的双重缺点. 首先, 根据天线获得的信号, 将旋转不变子空间法 (Estimation of Signal Parameters via Rotational Invariance Techniques, ESPRIT) 求得的闭式解作为 DOA 的预估计值, 同时计算系统此时的信噪比以及 SML 在此信噪比下的克拉-美罗界 (Cramer-Rao bound, CRB). 然后, 根据 DOA 预估计值和当前 CRB 值在 SML 最优解的近邻范围内确定较小的初始化空间, 并在该空间初始化少量粒子. 最后通过设计合适的惯性因子 w , 使粒子以合理的速度搜索最优解. 实验结果表明, 改进 PSO 算法所需的粒子个数和迭代次数大约是传统 PSO 算法的 1/5, 降低了 SML 的解析复杂度, 计算时间是传统 PSO 算法的 1/10, 因此在收敛速度上也有显著的优势.

关键词: 波达方位估计; 粒子群优化算法; 随机最大似然算法; 计算复杂度

中图分类号: TN911.72 **文献标识码:** A **文章编号:** 0372-2112 (2017)08-1989-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.08.026

A Stochastic Maximum Likelihood Algorithm Based on Improved PSO

SONG Hua-jun¹, LIU Fen¹, CHEN Hai-hua², ZHANG He¹

(1. College of Information and Control Engineering, China University of Petroleum (East China), Qingdao, Shandong 266580, China;
2. College of Computer and Communication Engineering, China University of Petroleum, Qingdao, Shandong 266580, China)

Abstract: The Stochastic Maximum Likelihood (SML) achieves exceptional performance of estimating Direction-of-Arrival (DOA). However, the high computational complexity of analytic method limits SML for further applications in practice. Considering the high computational complexity of SML, we propose a low complexity improved PSO algorithm, which outperforms the traditional PSO approach both in the number of particles and iterations. Based on the signals received by antenna, we firstly obtain the closed solution of Estimation of Signal Parameters via Rotational Invariance Techniques (ESPRIT) to pre-estimate the DOA. In addition, we compute the current Signal Noise Ratio (SNR) of the system as well as the SNR based Cramer-Rao Bound (CRB) of the SML. According to the pre-estimated DOA and current CRB, we then determine a small specific initialized space which is closed to the optimal solution of SML. Besides, we set a few particles in the corresponding search space. Finally, we construct the appropriate inertia factor which lead to an appropriate search speed for particles. Experimental results demonstrate that the number of particles and iteration times required by the improved PSO algorithm is about one-fifth of the traditional PSO algorithm, which greatly reduces the computational complexity of SML, the computation time is one-tenth of the traditional PSO algorithm, thus, the proposed method achieves significant merit of convergence speed.

Key words: direction-of-arrival estimation; particle swarm optimization; stochastic maximum likelihood algorithm; computational complexity

1 引言

信号的 DOA 估计在移动通信、雷达、智能天线等方面具有重要的研究意义. 关于 DOA 估计问题, 国内外学者提出了许多解决方法. R. O. Schmit 提出了著名的多重信号分类算法 (Multiple Signal Classification, MUSIC)^[1], 该算法开创了子空间类 DOA 估计算法的研究先河. 几年后, Paulraj, Roy 和 Kailath 等在子空间分解的基础上, 提出了旋转不变子空间算法 ESPRIT^[2], 该算法可以直接得到 DOA 估计的闭式解, 计算复杂度低, 缺点是估计精度不高. 此后, 出现了一系列经典的高分辨 DOA 估计算法: 子空间拟合类算法, 如加权子空间拟合算法 (Weighted Subspace Fitting, WSF)、确定性最大似然算法 (Deterministic Maximum Likelihood, DML) 和随机性最大似然算法 (SML)^[3]. 该类算法通过构造阵列流型矩阵与接收信号数据之间的拟合关系, 通过最大最小化代价函数来估计未知参数. 然而, 这些拟合算法不可避免的涉及高维矩阵处理的问题, 计算复杂度比较大, 因此实时性比较差. 此外, 随着压缩感知理论^[4]的成熟, 其在阵列信号处理中的应用也与日俱增. 研究者们提出了多种基于压缩感知 (稀疏恢复) 思想的 DOA 估计算法, 其中的代表算法有基于稀疏迭代协方差的矩阵估计 (Sparse Iterative Covariance-based Estimation, SPICE) 和稀疏贝叶斯学习等^[5].

在众多 DOA 估计算法中, SML 算法是最为重要的一种. 理论上, SML 算法有着最好的 DOA 估计精度, 但是 SML 的计算过程复杂度比较大, 并且涉及到多维非线性最优化问题, 从而阻碍了它在实际系统中的应用. 针对子空间拟合算法存在的问题, 近年来涌现了一系列优化算法. 此类优化算法主要分为两种类型, 一种类型是针对 DML 的评价标准, 比如交互投影 (Alternating Projection, AP) 算法^[6,7]、高斯-牛顿算法 (Gaussian-Newton, GN)^[8]; 另一种是通用的算法, 比如交互最小化算法 (AM)、基因遗传算法 (GA)、模拟退火算法和粒子群优化算法 (PSO)^[9], 这些方法适用于 DML、SML 和 WSF. 相比现有 SML 优化算法, 粒子群算法作为一种有效的 DOA 优化算法, 由于其在解决多维非线性优化函数方面的优势, 使该算法在科学研究和工程应用中得到了广泛的关注. 然而该算法仍然存在一些问题需要改进, 比如: 需要的粒子数和迭代次数较多, 计算复杂度较大.

本论文提出了一种改进型的 PSO 算法, 该算法可以解决传统 PSO 中粒子数多和迭代次数多的问题, 从而达到减小计算复杂度的目的.

2 阵列信号模型与随机最大似然算法

2.1 阵列信号模型

假设有 q 个远场窄带信号源, 其中心频率为 w_0 , 从不同的角度 $(\theta_1, \theta_2, \dots, \theta_q)$ 入射到阵元数为 p 的平面阵, λ 为信号的波长, 阵元之间的间距为 $d = \lambda/2$. 在理想情况下, 假设阵列中各阵元是各向同性, 不存在通道不一致、互耦等因素的影响, 且接收信号的噪声都是高斯白噪声, 方差为 σ^2 , 则 p 个阵元接收到信号的数学模型为

$$\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{N}(t) \quad (1)$$

式(1)中, $\mathbf{X}(t)$ 为阵列的 $p \times 1$ 维快拍数据矢量, \mathbf{A} 为空间阵列的 $p \times q$ 阵列流型矩阵, 且 $\mathbf{A} = [a(\theta_1), a(\theta_2), \dots, a(\theta_q)]$, $\mathbf{S}(t)$ 为空间信号的 $q \times 1$ 维矢量, $\mathbf{N}(t)$ 为阵列的 $p \times 1$ 维噪声数据矢量. 然后假设接收到的数据经过 M 次快速取样, 最终可以表示为: $\mathbf{X} = [x(t_1), x(t_2), \dots, x(t_M)]$. DOA 估计问题即可表述为: 给定观测数据 \mathbf{X} , 反推出信号的接收方向: $\Theta = \{\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q\}$. 在本文中, θ_i 是信号源的入射方向, $\hat{\theta}_i$ 表示 θ_i 的推导值.

2.2 随机最大似然算法

根据随机最大似然准则^[10] 计算各变量的推导值时, 单次观测数据的似然函数为:

$$f_i(x) = \frac{1}{\pi^M \det\{\mathbf{R}\}} \exp(x_i^H \mathbf{R}^{-1} x_i) \quad (2)$$

式中, π 是圆周率, M 表示快速取样的次数, H 表示共轭转置运算, \mathbf{R} 为观测数据的协方差矩阵. N 次观测数据的联合概率密度函数为

$$f_{SML}\{x_1, x_2, \dots, x_N\} = \prod_{i=1}^N \frac{1}{\pi^M \det\{\mathbf{R}\}} \exp(x_i^H \mathbf{R}^{-1} x_i) \quad (3)$$

式中, $\det\{\cdot\}$ 表示矩阵的行列式, 对联合概率密度函数式(3)取负对数, 得:

$$-\ln f_{SML} = L(M \ln \pi + \ln(\det\{\mathbf{R}\}) + tr\{\mathbf{R}^{-1} \hat{\mathbf{R}}\}) \quad (4)$$

为了得到参数的极大似然估计, 需要计算上述对数似然函数在参数空间上的极大值. 对于 SML, f 是一个关于变量 Θ 的函数, 所以最大似然函数可以表示为:

$$L_{SML}(\Theta) = \sigma^{2(p-q)} \det\{\mathbf{A}^+ \mathbf{R} \mathbf{A}(\Theta)\} \quad (5)$$

$$\hat{\Theta} = \operatorname{argmin} L_{SML}(\Theta) \quad (6)$$

式中, $\mathbf{A}^+ = (\mathbf{A}^H(\Theta) \mathbf{A}(\Theta))^{-1} \mathbf{A}^H(\Theta)$, SML 算法的方位估计就是寻找 $\Theta = [\theta_1, \theta_2, \dots, \theta_p]$ 使似然函数 $L_{SML}(\Theta)$ 取得最小值, 若用直接迭代法求解, 涉及到多维非线性函数的求解, 计算量比较大, 而 PSO 算法已经成功地应用到多维函数求最值的问题中, 因此利用 PSO 算法搜索 $L_{SML}(\Theta)$ 的最小值.

3 基于改进 PSO 的随机最大似然算法

根据粒子的搜索机制, 粒子的初始值越靠近最优

值,粒子就会越快地收敛到精确解,因此在最优解附近进行精细搜索是必要的,所以,从粒子数和迭代次数两方面着手,本文提出了一种减少计算复杂度的改进型 PSO 算法.

3.1 用 ESPRIT 和 CRB 对 DOA 进行预估计

首先用 ESPRIT 算法得到的闭式解作为搜索 SML 精确解的初始值,然后,在初始值的临近范围内初始化一些粒子,由于这些粒子靠近 SML 的精确解,通过粒子的迭代和搜索,可以高效精准地找到最优解.

假设 $\Theta_E = \{\hat{\theta}_{e1}, \hat{\theta}_{e2}, \dots, \hat{\theta}_{eq}\}$ 代表 ESPRIT 算法的闭式解,用 CRB 和 ESPRIT 算法的解来确定这个初始化空间,当快拍数足够大的时候,克拉美罗界的协方差矩阵可以由下式计算:

$$\mathbf{CRB}_S = \begin{bmatrix} \mathbf{CRB}_{S_1} & 0 & 0 \\ 0 & \dots & 0 \\ 0 & 0 & \mathbf{CRB}_{S_q} \end{bmatrix} = \frac{\sigma^2}{2N} \{ \text{Re}[\mathbf{H} * \mathbf{S}^T] \}^{-1} \quad (7)$$

$$\mathbf{H} = \mathbf{D}^H \mathbf{P}_{A(\Theta)}^\perp \mathbf{D} \quad (8)$$

$$\mathbf{D} = \left[\frac{da(\theta_1)}{d(\theta_1)}, \frac{da(\theta_2)}{d(\theta_2)}, \dots, \frac{da(\theta_q)}{d(\theta_q)} \right] \quad (9)$$

其中 N 是快拍数, \mathbf{S} 是信号的协方差矩阵, σ^2 是噪声方差的估计. $\mathbf{P}_{A(\Theta)}$ 为 $\mathbf{A}(\Theta)$ 所张成的空间的投影矩阵, $\mathbf{P}_{A(\Theta)}^\perp$ 表示与 $\mathbf{P}_{A(\Theta)}$ 正交的矩阵,当信源和快拍数不变的时候,每个信源的克拉美罗界 \mathbf{CRB}_{S_i} ($0 < i \leq q$) 都是由它的信噪比决定的,初始化空间可以被定义为一组 Θ 的最小值到最大值的搜索范围:

$$\begin{aligned} \theta_1 &\in [\hat{\theta}_{e1} - \mu \mathbf{CRB}_{S_1}, \hat{\theta}_{e1} + \mu \mathbf{CRB}_{S_1}], \\ \theta_2 &\in [\hat{\theta}_{e2} - \mu \mathbf{CRB}_{S_2}, \hat{\theta}_{e2} + \mu \mathbf{CRB}_{S_2}], \\ &\dots \\ \theta_q &\in [\hat{\theta}_{eq} - \mu \mathbf{CRB}_{S_q}, \hat{\theta}_{eq} + \mu \mathbf{CRB}_{S_q}] \end{aligned} \quad (10)$$

其中 μ 是正整数,我们之所以选择 CRB 作为“评价尺度”,是因为它只跟信源的信噪比有关,当然,当信源和阵列在一个平面上的时候,搜索范围满足以下条件:

$$\begin{aligned} \hat{\theta}_{ei} - \mu \mathbf{CRB}_{S_i} &> -90^\circ \\ \hat{\theta}_{ei} + \mu \mathbf{CRB}_{S_i} &< 90^\circ \end{aligned}$$

初始化空间的大小受参数 μ 的控制, μ 是正整数,当 μ 非常大的时候,比如 $\mu = \infty$ 时,改进算法的优化空间等同原始的整个搜索空间,在这种情况下,改进的算法就等同于传统的 PSO 算法. 在另一种情况下,当 μ 非常小的时候,比如 $\mu = 1$ 的时候,初始化空间就会很小,在这种情况下, SML 的精确解可能就不会在这个小的初始化空间内. 最好的情况是 $\mu = 3$, 精确解正好可以包含在这个小的优化空间.

表 1 展示了粒子数 m 和参数 μ 取不同值,粒子收敛到最优值时各性能之间的对比. 其中, I-times 表示所

有的粒子收敛到最优值所需的平均迭代次数, C-time 表示算法搜索到最优值所需要的时间. 从实验数据可以看出,在不影响 DOA 求解精度的情况下,当粒子数 $m = 5 \sim 10$, $\mu = 1 \sim 10$ 时,粒子收敛到最优值所需的时间较短;当粒子数 $m = 5$, $\mu = 3$ 时,粒子收敛到最优值所需的时间最短,所以在实验部分取粒子个数 m 等于 5, μ 等于 3. 此外,表一大量实验数据表明:参数 μ 的值可以随着数据集 m 的变化而改变,但是不管粒子数 m 取值多少,参数 μ 取 1 ~ 10, 都更有利于粒子的收敛,而且 μ 取值为 3, 实验效果较好.

表 1 粒子个数取不同值时各性能之间的对比

m	μ					
	$\mu = 1$	$\mu = 3$	$\mu = 10$	$\mu = 50$	$\mu = 500$	$\mu = \infty$
m = 3	80	52	72	76	100	1567
	0.075	0.055	0.078	0.085	0.13	0.853
m = 5	51.6	23.5	53	64	100	965
	0.034	0.019	0.048	0.051	0.154	0.543
m = 10	37	31	50	61	105	458.5
	0.042	0.038	0.043	0.068	0.087	0.41
m = 25	30	29	52	63	91	194.5
	0.054	0.059	0.087	0.097	0.158	0.358

图 1(a) 和图 1(b) 展示了传统 PSO 和改进 PSO 算法的初始化图,参数设置如下:信源 $q = 2$, 阵元 $p = 8$, $r = 2$, SNR = 0dB, 入射信号角度为 30° 和 -10° , 真实值代表了 SML 的精确解. 由图易知,传统 PSO 算法的初始化空间比较大,初始化的粒子数比较多. 改进 PSO 算法有一个比较小的初始化空间,初始化的粒子数也比较少,而且所有的粒子都靠近 SML 的精确解.

3.2 对惯性权重 w 的改进

通常情况下,惯性权重 w 取 0.4 ~ 0.9 之间的一个固定值,但是这样不利于搜索全局最优值. 对于传统 PSO 算法,在搜索的初期, w 取值越大,粒子的迭代速度越快;在搜索的后期, w 取值越小,粒子越快地收敛到最优值. 因此,使用 w 随着迭代次数线性变化的公式^[11], 迭代次数越多, w 取值越小,随着迭代的进行,线性的减小 w 的值如下:

$$w(l) = 0.4 + \frac{1}{2l_{\max}^2} (l - l_{\max})^2 \quad (11)$$

式(11)中, l 是当前迭代次数, l_{\max} 是最大迭代次数. 对于改进的 PSO 算法,只需要在全局最优解的附近进行精细搜索,所以 w 越小越好. 为了证明这一观点,以 0.1 为步长,分别取 $w = 0.4 \sim 0.9$ 之间的值进行仿真实验,实验结果证明, w 取值越小,所需要的迭代次数越少,粒子越容易收敛到最优值. 因此在改进的 PSO 算法中, w 取 0.4 最有利于高效精确地搜索 SML 的最优值.




图1 粒子群算法的初始化图

3.3 基于改进 PSO 的 DOA 估计步骤

PSO 作为一种启发式搜索算法,需要解决如何在保证收敛精度的前提下,避免陷入局部最优的问题.改进算法的参数设置部分,在速度公式中加入了随机数,速度与目标函数值相关,这样对不好的解,就赋予了一定的概率跳出局部最优;为了保证收敛性,设置了最大迭代次数和精度要求,当精度满足或达到最大迭代次数时,才让粒子停止迭代,这样就取得了多样性和收敛性之间的平衡性.

基于改进 PSO 的 SML 算法的 DOA 估计分为以下几步:

(1) 根据式(5)表示出 $L_{SML}(\Theta)$,并将 $L_{SML}(\Theta)$ 设为 PSO 算法中的适应度函数,计算 ESPRIT 算法的闭式解和 CRB 来组成一个初始的优化空间 $\theta_i \in [\hat{\theta}_{ei} - \mu CRB_{Si}, \hat{\theta}_{ei} + \mu CRB_{Si}]$, $\mu = 3$ 为尺度参数.

(2) 在自定义的初始化空间随机初始化一些粒子 $\bar{\Theta} = \{\bar{\Theta}_1, \bar{\Theta}_2, \dots, \bar{\Theta}_n\}$,将 $\bar{\Theta}_i$ 代入代价函数求得适应度值,通过比较大小来确定起始的局部最优解 T_i^l 和全局最优解 G^l .

(3) 初始化粒子个数 m ,惯性因子 w ,学习因子和迭

代次数,并使用局部和全局最优解来更新粒子.用 i 代表第 i 个粒子, l 代表第 l 次迭代次数, Θ_i^l 代表第 i 个粒子在第 l 次迭代时的位置, T_i^l 表示第 i 个粒子经过 l 次迭代的局部最优解,易知:

$$\begin{aligned} T_i^0 &= \Theta_i^0, \\ T_i^1 &= \arg \min_{\Theta_i^1, \Theta_i^1} L_w, \end{aligned} \quad (12)$$

...

$$T_i^l = \arg \min_{\Theta_i^l, \Theta_i^l} L_w$$

定义 G^l 代表所有的粒子经过 l 次迭代所能找到的全局最优解,因此

$$G^l = \min \{ T_1^l, T_2^l, \dots, T_m^l \} \quad (13)$$

(4) 通过循环迭代来更新自变量 Θ_i , T_i^l 和 G^l ,根据以上理论分析, w 取 0.4,第 i 个粒子根据下面的公式来更新自己的位置和速度:

$$\theta_i^{l+1} = \theta_i^l + v_i^{l+1} \quad (14)$$

$$V_i^{l+1} = wV_i^l + c_1r_1(T_i^l - \Theta_i^l) + c_2r_2(G^l - \Theta_i^l) \quad (15)$$

其中 c_1, c_2 是学习因子, r_1, r_2 取 $(0, 1)$ 之间的随机数.

(5) 判断是否满足终止条件,即是否达到最大迭代次数或者满足 $|G^{l+1} - G^l| \leq 10^{-5}$. 如果满足,就输出估计结果,算法结束;如果不满足,则转入步骤(4)继续进行循环迭代.

4 仿真与性能分析

在实验中,假设阵列为均匀平面阵列,则引导矢量可以简化为:

$$a(\theta) = [1, e^{-j\phi(\theta)}, \dots, e^{-j(p-1)\phi(\theta)}]^T \quad (16)$$

$$\phi(\theta) = \frac{2\pi\Delta}{\lambda} \sin\theta \quad (17)$$

其中, λ 为信号波长, Δ 为相邻两个阵元之间的距离, θ 能被相位 ϕ 唯一决定的一个必要条件是 $\Delta \leq \lambda/2$, 在实验中, $\Delta = \lambda/2$, 实验中 SNR 的定义为:

$$\text{SNR}_k = 10 \log_{10} \frac{E[|S_k(t)|^2]}{\sigma^2} \quad (18)$$

同时定义均方根误差 (Root-Mean-Square-Error, RMSE) 为:

$$\text{RMSE} = \sqrt{\frac{1}{qN} \sum_{k=1}^q \sum_{m=1}^M |\hat{\theta}_{k,m} - \theta_k|^2} \quad (19)$$

其中, $\hat{\theta}_{k,m}$ 是 θ_k 在第 m 次实验所得出的推导值,采用蒙特卡洛的实验方法,每一种情况进行 100 次实验.

在传统的 PSO 算法中, $m = 25$, w 随着迭代次数线性变化,见式(11).改进的算法中, $m = 5$, $\mu = 3$, $w = 0.4$.

图 2(a) 和图 2(b) 分别展示了传统 PSO 和改进 PSO 算法中粒子的速度随着迭代次数变化的关系图.从图中可以看出,在传统的 PSO 算法中,粒子平均需要迭代 107 次才能全部收敛,改进 PSO 算法却只需要迭代

23.5 次,所以改进后的算法大大降低了 SML 的计算复杂度.

图 2(b)和图 2(c)分别表示 $w = 0.4$ 和 $w = 0.6$ 的时候,改进 PSO 中粒子的速度随迭代次数变化的关系图.当 $w = 0.4$ 的时候,平均只需要 23.5 次所有的粒子

基本上就能收敛;当 $w = 0.6$ 的时候,平均需要 65 次,粒子才能收敛.这个实验结果就验证了对惯性因子 w 的讨论:在改进 PSO 算法中, w 越小则粒子越容易收敛至最优解.




图2 粒子速度随迭代次数变化的关系图

图 3 表示 ESPRIT 算法,传统 PSO 和改进 PSO 算法的 RMSE 随信噪比变化的关系图.对于 ESPRIT 算法来说,当处理相干信号的时候需要做预处理.对于相干信号和非相干信号来说,传统 PSO 算法和改进 PSO 算法的 RMSE 差不多,但是比 ESPRIT 的性能好很多.

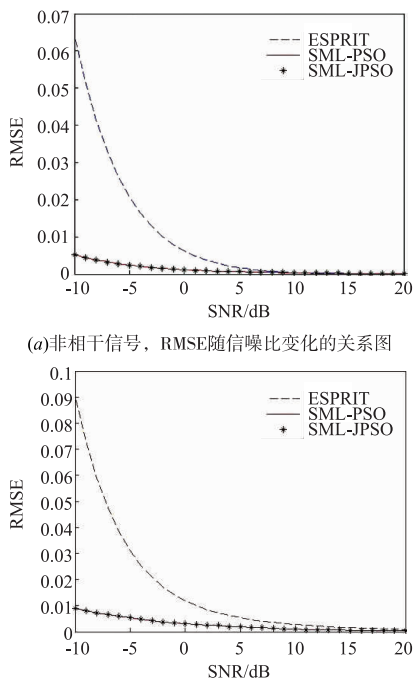


图3 RMSE随信噪比变化的关系图

表 2 分别展示了改进 PSO 算法、PSO 算法、人工遗传算法(GA)和交互最小化算法(AM)在不同方面的结果.参数设置如下:信源 $q = 2$,阵元 $p = 8$, $r = 2$, SNR = 0dB,入射信号角度为 30° 和 -10° .从表 2 的实验数据

可以很明显的看出,传统 PSO 算法需要粒子数 25 个,改进算法需要粒子数 5 个,传统 PSO 算法的平均迭代次数大约为 107.9 次,但是改进 PSO 算法却只需要计算 23.5 次,不管是粒子个数还是平均迭代次数,改进 PSO 算法都是传统 PSO 算法的 1/5. GA 的计算总次数为 33800 次,远远高于 PSO 算法.从花费时间来看,在保证搜索精度的前提下,传统 PSO 算法的计算时间为 0.198s,但是改进 PSO 算法所需时间为 0.019s,仅为传统 PSO 算法的 1/10.

通过具体的仿真实验,用改进的算法跟 GA 算法和 AM 算法进行了对比,GA 所用的计算时间是 2.33s,AM 算法所用的时间是 3.64s,通过对比,实验结果证明了改进 PSO 算法的有效性.

表 2 不同算法各性能之间的对比

	Improved PSO	PSO	GA	AM
粒子个数	5	25	—	—
平均迭代次数	23.5	107.9	—	—
计算总次数	$5 * 23.5 = 118$	$25 * 107.9 = 2697.5$	$200 * 169 = 33800$	—
花费时间(s)	0.019	0.198	2.33	3.64

5 结束语

通过理论分析和实验验证,本文提出的改进 PSO 算法具有较低的计算复杂度,能够高效地解决 SML 估计 DOA 的问题.而且本文改进的算法具有普适性,可以被用于高效地求解子空间拟合类其它算法估计 DOA 等任务.此外,随着分布式计算的快速发展,将其引入到 DOA 估计领域,探索出更高效的解析算法也是一个具有研究意义的课题.

参考文献

- [1] Agarwal K, Pan L, Leong Y K, et al. Practical applications of multiple signal classification[J]. International Journal of RF and Microwave Computer-Aided Engineering, 2012, 22(3): 359 – 369.
- [2] Wang L. Joint 2-D DOA and noncircularity phase estimation method[J]. Journal of Radars, 2012, 1(1): 43 – 49.
- [3] Palanisamy P, Kalyanasundaram N, Raghunandan A. A new DOA estimation algorithm for wideband signals in the presence of unknown spatially correlated noise[J]. Signal Processing, 2009, 89(10): 1921 – 1931.
- [4] Chen H, Suzuki M. Exact formulation for stochastic ML estimation of DOA[J]. Ieice Trans Fundamentals, 2010, 93(11): 2141 – 2152.
- [5] Heidenreich P, Zoubir A M. Fast maximum likelihood DOA estimation in the two-target case with applications to automotive radar[J]. Signal Processing, 2013, 93(12): 3400 – 3409.
- [6] Yan F G, Jin M, Qiao X L. Fast 2-D DOA estimation method in transformed domain with arbitrary arrays[J]. Journal of Electronics, 2013, 41(5): 936 – 942.
- [7] Ziskind I, Wax M. Maximum likelihood localization of multiple sources by alternating projection[J]. IEEE Transactions on Acoustics Speech & Signal Processing, 1988, 36(10): 1553 – 1560.
- [8] Wei L, Shao W, Qi W, et al. Peak-to-peak search: fast and accurate DOA estimation method for arbitrary non-uniform linear array[J]. Electronics Letters, 2015, 51(25): 2078 – 2080.
- [9] Wang J, Zhao Y, Wang Z. Low complexity subspace fitting method for wideband signal location[A]. 2008 5th IFIP International Conference on Wireless and Optical Communications Networks[C]. Surabaya, Indonesia: IEEE, 2008. 1 – 4.
- [10] 罗景青. 阵列信号处理基本理论与应用[M]. 北京: 解放军出版社, 2007.
- [11] Chen H, Li S, Liu J, et al. PSO algorithm for exact Stochastic ML estimation of DOA for incoherent signals[A]. 2015 15th International Symposium on Communications and Information Technologies[C]. Nara, Japan: IEEE, 2015. 189 – 192.

作者简介



宋华军 男, 1978 年生, 博士, 副教授, 硕士生导师, 毕业于中国科学院长春光学精密机械与物理研究所, 美国佛罗里达大学访问学者, 主要研究领域为实时目标跟踪算法、高性能硬件系统设计及无线通信。

E-mail: huajun. song@upc.edu.cn



陈海华(通信作者) 男, 1983 年生, 博士, 讲师. 毕业于日本北见工业大学, 中国科学院计算技术研究所博士后, 主要研究方向为阵列信号处理及无线通信。

E-mail: chenhaihua@upc.edu.cn