

# 搜索能力自适应增强的群智能粒子滤波

刘云龙<sup>1,2</sup>, 林宝军<sup>1</sup>

(1. 中国科学院光电研究院, 北京 100190; 2. 中国科学院研究生院, 北京 100049)

**摘要:** 针对传统粒子滤波的退化、样本枯竭现象及其导致的状态推理精度差的问题, 提出了一种新型粒子滤波算法。利用群智能优化算法中的粒子群优化算法作为优化手段, 改进粒子的先验分布。通过自适应地调节粒子的惯性权值增强粒子群的探索和开发能力, 减少粒子群优化算法的早熟现象, 使得采样后的粒子朝着高似然区域移动, 从而有效地提高系统状态推理精度。利用 Crame'r-Rao lower bound 定义了算法有效性的度量。通过仿真实验证明该算法是有效和稳定的。

**关键词:** 粒子滤波; 粒子群优化算法; 搜索能力

中图分类号: TM 76

文献标志码: A

DOI: 10.3969/j.issn.1001-506X.2010.07.039

## Swarm intelligence particle filtering based on adaptive enhancing search ability

LIU Yun-long<sup>1,2</sup>, LIN Bao-jun<sup>1</sup>

(1. The Academy of Opto-electronics, Chinese Academy of Sciences, Beijing 100190, China;

2. Graduate Univ. of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** For addressing poor inference precision with canonical particle filtering resulting from weight degeneracy and sample impoverish, a new particle filtering algorithm is proposed, which utilizes the improved particle swarm optimization for improving priori particles distribution. Through adaptively adjusting inertia weight, particles exploration ability and exploitation ability are both enhanced so that premature phenomenon with particle swarm optimization is weakened. As a result, particles can move toward high likelihood areas, which can effectively increase status inference precision. The proposed algorithm validity is measured by Crame'r-Rao lower bound. Simulation results show that the proposed particle filtering is valid and stable.

**Keywords:** particle filter; particle swarm optimization algorithm (PSOA); search ability

## 0 引言

粒子滤波(particle filtering, PF)又称序贯 Monte Carlo (sequential Monte Carlo, SMC)方法是一种基于 Bayesian 估计的迭代次优滤波算法<sup>[1]</sup>。基本的粒子滤波算法以序贯重要性采样(sequential importance sampling, SIS)为基础的。SIS 给 PF 带来的主要缺陷是“退化”问题<sup>[2]</sup>, 大量计算资源花费在意义不大的粒子上。为了减少退化问题对滤波的影响, 通常采用重采样方法<sup>[3]</sup>来解决“退化”问题, 但却引起了“样本枯竭”<sup>[4]</sup>。

为了改善粒子滤波性能, 最近许多智能算法被引入其中。例如基于遗传算法的粒子滤波<sup>[5]</sup>、基于粒子群优化算法的粒子滤波<sup>[6]</sup>、人工免疫粒子滤波算法<sup>[7]</sup>等, 然而这些算法都忽略了一些智能优化算法存在的问题。遗传算法和粒子群优化算法都存在着早收敛和寻优能力不足的问题, 很

多时候只能收敛到局部最优解。人工免疫算法虽然在一定程度上减少了以上问题, 但其累积信息的利用能力却下降了, 导致算法的局部搜索能力降低<sup>[8]</sup>。如果不对这些智能算法进行改进而简单的将其引入粒子滤波中, 对滤波性能的提升是没有保障的。粒子群优化算法具有算法简单、可行性好、收敛快等优点。针对它存在的问题本文对其进行改进, 通过自适应地调节粒子惯性权值从而增强粒子的探索能力与开发能力。在粒子滤波的 SIS 之后运用改进的粒子群优化算法, 可以使先验粒子向高似然域移动, 增加粒子集的多样性, 减轻了 PF 的退化现象并解决了样本枯竭问题, 提高了粒子估计精度。

## 1 粒子滤波

考虑非线性动态状态空间(dynamic state space, DSS)模型

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{v}_{k-1}) \\ \mathbf{y}_k = h(\mathbf{x}_k, \mathbf{w}_k) \end{cases} \quad (1)$$

式中,  $f(\cdot, \cdot)$  和  $h(\cdot, \cdot)$  分别为已知的状态转移函数和测量函数, 且至少有一个为非线性的;  $\mathbf{x}_k$  为  $k$  时刻系统的状态向量;  $\mathbf{y}_k$  为  $k$  时刻系统的观测向量;  $\mathbf{v}_{k-1}$  为  $k-1$  时刻的过程噪声;  $\mathbf{w}_k$  为  $k$  时刻的测量噪声。由于 DSS 的非线性, 使得用非线性 Bayesian 方法估计  $p(\mathbf{x}_k | \mathbf{y}_{1:k})$  很难得到解析解。PF 通过非参数化的蒙特卡罗方法实现递推 Bayesian 估计, 采用样本形式对状态的先验和后验信息进行估计, 为非线性离散时间的 Bayesian 递推滤波问题提供了一种近似的求解方法。其基本思想是通过观测  $\mathbf{y}_{1:k}$  递推地用状态空间的一组加权的随机样本  $\{\mathbf{x}_k^i, \tilde{w}_k^i\}_{i=1}^{N_s}$  ( $k=1, 2, \dots$ ) 来近似估计所求状态的后验概率密度函数

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) \approx \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (2)$$

式中,  $N_s$  为用于状态估计的样本数;  $\tilde{w}_k^i$  为归一化重要性权。它通过以下公式进行更新和归一化

$$\begin{cases} w_k^i = w_{k-1}^i \frac{p(\mathbf{y}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)} \\ \tilde{w}_k^i = w_k^i / \sum_{i=1}^{N_s} w_k^i \end{cases} \quad (3)$$

式中,  $q(\cdot | \cdot)$  为重要性密度函数, 它的最优选择标准是使重要性权的方差最小化, 即  $q_{\text{opt}}(\mathbf{x}_k | \mathbf{x}_{0:k-1}^i, \mathbf{y}_{1:k}) = p(\mathbf{x}_k | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ , 从而推出  $w_k^i = w_{k-1}^i p(\mathbf{y}_k | \mathbf{x}_{k-1}^i)$ , 但由于积分  $p(\mathbf{y}_k | \mathbf{x}_{k-1}^i) = \int p(\mathbf{y}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{x}_{k-1}^i) d\mathbf{x}_k$  通常是非解析的, 并且需要从非标准分布中采样粒子, 所以重要性权值很难计算。使用最重要的重要性密度函数是先验转移密度  $q(\mathbf{x}_k | \mathbf{x}_{0:k-1}^i, \mathbf{y}_{1:k}) = p(\mathbf{x}_k | \mathbf{x}_{k-1}^i)$ 。这时的重要性权更新公式变为  $w_k^i = w_{k-1}^i p(\mathbf{y}_k | \mathbf{x}_k^i)$ 。它使得粒子的采样和权值的递推计算容易实现, 但由于没有引入最近的观测值信息, 具有一定的盲目性。当先验概率产生的粒子有较少部分处于高似然域或似然函数同先验分布相比过于集中, 并且状态噪声明显高于观测噪声时权值退化问题严重。具体的传统粒子滤波算法参照文献[9]。

## 2 本文粒子群优化算法及粒子滤波

传统粒子群优化(particle swarm optimization, PSO)算法的实现过程可描述为: 设粒子群体的规模为  $N$ , 每一个粒子可看作多维空间中的点, 在计算过程中, 对于粒子  $i$  ( $i=1, 2, \dots, N$ ), 在第  $t+1$  次迭代时, 根据以下公式更新自己第  $d$  维空间上的速度和位置<sup>[10]</sup>

$$\begin{cases} v_{id}(t+1) = w(t)v_{id}(t) + c_1 rand1_{id}(t)(pbest_{id}(t) - \\ \quad x_{id}(t)) + c_2 rand2_{id}(t)(gbest_d(t) - x_{id}(t)) \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \end{cases} \quad (4)$$

式中,  $x_{id}$ 、 $pbest_{id}$  和  $gbest_d$  分别表示粒子所在位置、粒子个体

历史最优位置和群体的全局历史最优位置的第  $d$  维坐标。 $v_{id}$  表示粒子在第  $d$  维空间上的速度,  $rand1_{id}$  和  $rand2_{id}$  是粒子在第  $d$  维空间上取值于  $[0, 1]$  上的随机数;  $c_1$  和  $c_2$  为常数, 通常取  $c_1 = c_2 = 2$ , 称为学习因子或加速系数。 $w(t)$  是惯性权值(inertia weight, IW), 作用是保持粒子的运动惯性。

针对传统 PSO 的“早熟”和寻优能力不足的问题, 本文对其进行改进: 将粒子群按粒子的适应度大小划分为两个子群, 高适应度的子群负责局部高似然区域的精细寻优, 低适应度的子群负责在更大的空间寻优。同时通过检测群体粒子的多样性, 对群体的搜索范围和寻优能力进行有效的自适应调节。这样便平衡了粒子探索能力与开发能力, 减少了“早熟”现象的发生。

### 2.1 粒子群搜索能力的自适应增强

本文对群体多样性的度量公式如下

$$diversity_j(t) = \frac{1}{N_j(t)} \sum_{i=1}^{N_j(t)} (\|\mathbf{x}_i(t) - \overline{\mathbf{x}_j(t)}\|) \quad (5)$$

式中,  $\mathbf{x}_i(t)$  代表粒子  $i$  的(状态);  $\overline{\mathbf{x}_j(t)}$  为子群  $j$  的粒子位置(状态)均值;  $\|\cdot\|$  为范数标志, 代表粒子  $i$  到群体平均位置的距离度量, 这里取欧式距离;  $j$  为 1 和  $j$  为 2 分别代表高适应度子群和低适应度子群的序号;  $N_j$  为子群的规模。如果子群的多样性比较差, 则  $diversity_j(t)$  的值小, 反之  $diversity_j(t)$  的值较大。通过设定阈值  $diversity_{\min}$  可以对群体的多样性进行监控。当  $diversity_j(t) < diversity_{\min}$  时, 说明粒子的多样性较差, 应该在更大的空间上重新分配粒子, 增加子群的探索能力, 因此粒子的位置更新通过在搜索空间中重新随机分配位置实现。对粒子完成重新分配以后, 标志着该子群开始了探索阶段, 随着搜索的进行,  $diversity_j(t)$  逐渐减小, 子群惯性权值  $w_j(t)$  随着减小从而增强群体的开发能力。 $w_j(t)$  随着  $diversity_j(t)$  继续减小,  $diversity_j(t)$  跌破阈值  $diversity_{\min}$  时, 子群的粒子再次被重新分配。如此往复, 探索与开发交替进行, 直到达到一定的迭代次数或达到一定的寻优精度。

从以上论述可知, 惯性权值  $w_j(t)$  与  $diversity_j(t)$  成正相关, 这里用线性映射描述它们的关系

$$w_j(t) = \frac{w_{j\max} - w_{j\min}}{diversity_{\max} - diversity_{\min}} \cdot$$

$$(diversity_j(t) - diversity_{\min}) + w_{j\min}, j = 1, 2 \quad (6)$$

式中,  $w_{j\max}$ 、 $w_{j\min}$  分别为子群  $j$  惯性权值取值的上界和下界;  $diversity_{\max}$ 、 $diversity_{\min}$  分别是子群多样性度量的上界和下界。当  $diversity_j(t) > diversity_{\max}$  时, 令  $diversity_j(t)$  等于  $diversity_{\max}$ , 从而以最大的惯性权值调节粒子的探索能力。

### 2.2 本文粒子群优化算法流程

改进的粒子群优化算法流程图如图 1 所示。

### 2.3 本文滤波算法

本文提出的粒子滤波算法流程图如图 2 所示。

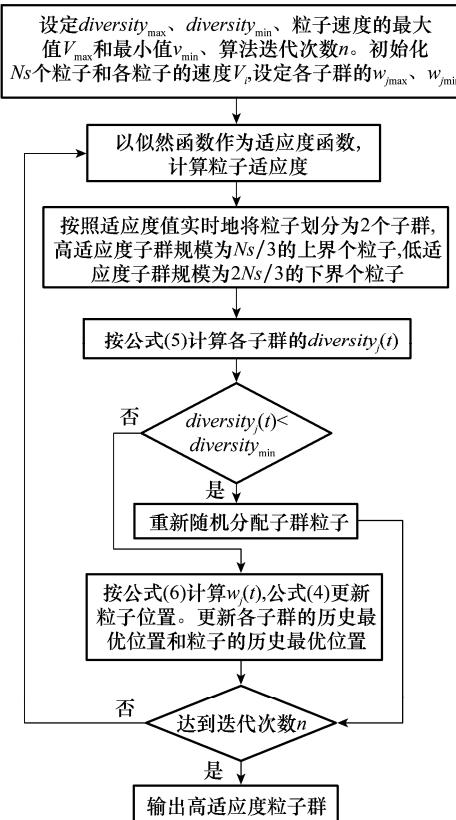


图 1 改进的粒子群优化算法流程图

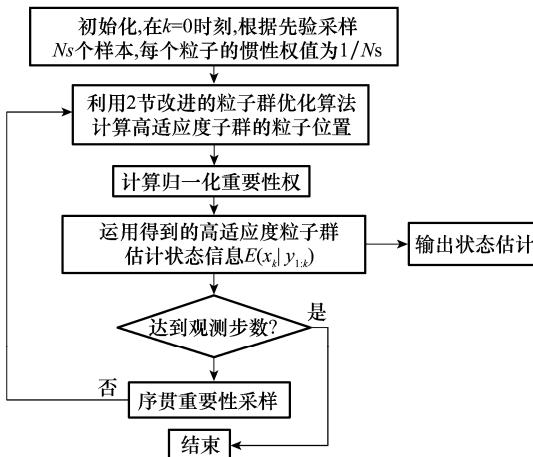


图 2 本文提出的粒子滤波流程图

将第 2 节改进的 PSO 引入 PF 中, 增强了用于状态估计的粒子发现高似然区域的能力。并且取高适应度的粒子用于系统状态估计, 这样可以减少重要性权值的方差, 从而避免退化的发生, 同时提高估计精度。因此在本文粒子滤波中取消了重采样过程。

### 3 有效性分析

Crame'r-Rao 下界(Crame'r-Rao low bound, CRLB)提供了滤波结果的均方误差(mean square error, MSE)的下

界。对于非线性滤波问题, CRLB 是一种非常有用的工具, 它可以作为不同滤波算法的性能比较基准, 并且可以很好地衡量算法的有效性。CRLB 可以预测算法可达的最优化能, 也可作为滤波系统的设计工具。粒子滤波作为解决非线性滤波问题的一种近似方法, 它的最优可达性能, 可以通过 CRLB 来求取。本文通过推导仿真模型的 CRLB 并将仿真得到的滤波结果的 MSE 与 CRLB 比较, 从而度量本文算法的有效性。通过以下公式<sup>[1]</sup>迭代推导仿真模型的 CRLB 下界。

$$\begin{aligned} \mathbf{J}_{k+1} &= \mathbf{D}_k^{22} - \mathbf{D}_k^{21}(\mathbf{J}_k + \mathbf{D}_k^{11})^{-1}\mathbf{D}_k^{12} (k > 0) \\ \mathbf{J}_0 &= \mathbf{P}_0^{-1} \\ \mathbf{D}_k^{11} &= E\{\mathbf{F}_k^T \mathbf{Q}_k^{-1} \mathbf{F}_k\} \\ \mathbf{D}_k^{21} &= (\mathbf{D}_k^{12})^T = -E\{\mathbf{F}_k^T\} \mathbf{Q}_k^{-1} \\ \mathbf{D}_k^{22} &= \mathbf{Q}_k^{-1} + E\{\mathbf{H}_{k+1}^T \mathbf{R}_{k+1}^{-1} \mathbf{H}_{k+1}\} \\ \mathbf{F}_k &= [\nabla_{x_k} f_k^T(\mathbf{x}_k)]^T \\ \mathbf{H}_{k+1} &= [\nabla_{x_{k+1}} h_{k+1}^T(\mathbf{x}_{k+1})]^T \end{aligned} \quad (7)$$

式中,  $\mathbf{J}_k$  为  $k$  时刻滤波信息矩阵;  $E$  为均值操作符;  $\mathbf{Q}_k$  为  $k$  时刻过程噪声的协方差矩阵;  $\mathbf{R}_{k+1}$  为  $k+1$  时刻观测噪声的协方差矩阵;  $f_k$  代表  $k$  时刻状态转移函数;  $h_{k+1}$  代表  $k+1$  时刻测量函数;  $\mathbf{F}_k$ 、 $\mathbf{H}_{k+1}$  分别为真实状态  $\mathbf{x}_k$ 、 $\mathbf{x}_{k+1}$  的 Jacobian 矩阵;  $\nabla$  代表取偏导数操作;  $-1$  代表取逆操作;  $T$  代表转置。这样通过迭代可以逐次求出  $\mathbf{J}_k^{-1}$ , 得到各时刻 MSE 的 CRLB。

本文采用的一维仿真模型为单变量非静态增长模型, 它的状态方程和测量方程为

$$\begin{cases} x_{k+1} = 0.5x_k + 25x_k/(1+x_k^2) + 8\cos(1.2k) + u_k \\ y_{k+1} = x_{k+1}^2/20 + v_{k+1} \end{cases} \quad (8)$$

$u_k \sim N(0, 10)$ 、 $v_k \sim N(0, 1)$  为相互独立的白噪声变量, 这是一个具有加性噪声的离散非线性递推 Bayesian 滤波问题, 最优解不存在解析形式。以下为该模型 CRLB 的推导结果

$$\begin{aligned} \mathbf{J}_{k+1} &= \mathbf{D}_k^{22} - \mathbf{D}_k^{21}(\mathbf{J}_k + \mathbf{D}_k^{11})^{-1}\mathbf{D}_k^{12} = \\ &\quad \mathbf{Q}_k^{-1} + E\{0.01\mathbf{E}_{k+1}^2 R_{k+1}^{-1}\} - \\ &\quad (E\{0.5 + 25(1-x_k^2)/(1+x_k^2)^2\} \mathbf{Q}_k^{-1})^2 \cdot \\ &\quad (E\{0.5 + 25(1-x_k^2)/(1+x_k^2)^2\}^2 \mathbf{Q}_k^{-1}) \end{aligned} \quad (9)$$

本文仿真实验为一维情况, 因此式(7)中的变量都为单变量。实验中引入的过程噪声服从  $u_k \sim N(0, 10)$  分布, 测量噪声服从  $v_k \sim N(0, 1)$  分布, 因此  $\mathbf{Q}_k^{-1} = 0.1$ ,  $R_k^{-1} = 1$ 。初始真实信号的状态分布为  $x_0 \sim N(0, 10)$ , 因此  $p_0 = 10$ ,  $J_0 = 1/P_0 = 0.1$ 。通过迭代可得  $CRLB(x_k) = J_k^{-1}$ 。本文定义算法的有效性为

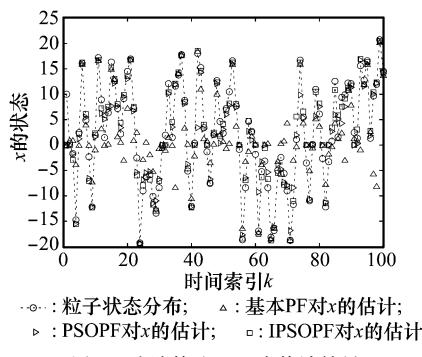
$$eff = E\{eff(\hat{x}_k)\} = E\{\sqrt{CRLB(\hat{x})}/RMSE(\hat{x})\} \approx \frac{1}{N_{step}} \sum_{k=0}^{N_{step}-1} \sqrt{CRLB(\hat{x}_k)}/RMSE(\hat{x}_k) \quad (10)$$

式中,  $\hat{x}$  为对真实状态  $x$  的估计;  $eff(\hat{x}_k)$  代表  $k$  时刻算法的有效性;  $N_{step}$  为算法迭代估计次数, RMSE 为均方根误差。算法滤波结果的  $RMSE(\hat{x}_k)$  越接近  $\sqrt{CRLB(\hat{x}_k)}$ , 说明算法对信号状态  $x_k$  的估计越具有高的有效性。 $eff$

整体滤波过程的角度以  $eff(\hat{x}_k)$  均值度量了算法对真实状态估计的有效性。由 CRLB 的定义可知,  $RMSE(\hat{x}_k) \geq \sqrt{CRLB(\hat{x}_k)}$ , 因此  $eff \leq 1$ , 且  $eff$  越大, 算法越有效。

## 4 实验及结果分析

本实验的仿真的粒子数为 1 000, 迭代估计步数为 100 步, 初始采样粒子服从  $N(0, 10)$  的高斯分布。粒子群优化算法相应的参数设置为:  $diversity_{min} = 6$ ,  $diversity_{max} = 50$ ,  $w1_{max} = 0.6$ ,  $w1_{min} = 0.2$ ,  $w2_{max} = 0.9$ ,  $w2_{min} = 0.5$ ,  $v_{max} = 20$ ,  $v_{min} = -20$ 。搜索空间为  $[-25, 25]$ 。粒子群的迭代次数为 20 次。图 3 为本文算法、粒子群优化粒子滤波 (particle swarm optimization particle filtering, PSOPF)<sup>[6]</sup>、基本 PF 算法的 100 步估计结果。从图中可以直观地看出本文算法的滤波结果更接近真实状态。



多次独立实验后, 对算法  $k$  时刻的滤波精度度量一般采用均方根误差 (root mean square error, RMSE)

$$RMSE(\hat{x}_k) = \left[ \frac{1}{N_{ep}} \sum_{i=1}^{N_{ep}} (\hat{x}_k^i - x_k^i)^2 \right]^{1/2} \quad (11)$$

式中,  $N_{ep}$  为独立实验次数;  $\hat{x}_k^i$  为第  $i$  次独立实验  $k$  时刻状态的估计值;  $x_k^i$  为第  $i$  次独立实验  $k$  时刻状态的真实值。图 4 为 3 种算法经过 100 次独立实验后, 状态估计的均方根误差曲线图和仿真模型的 CRLB 的平方根。由于篇幅有限, 本文只代表性地列出算法时间索引的第 51~60 步迭代估计的 RMSE, 数据如表 1 所示。从图 4 和表 1 可看出本文算法的 RMSE 更小且更接近 CRLB 的平方根, 因此有更好的推理精度。

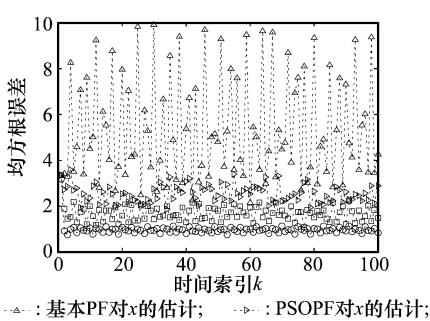


表 1 时间索引为 50~60 的算法迭代估计的 RMSE

时间索引	51	52	53	54	55
PF	9.285 7	3.722 8	5.264 5	7.979 7	3.570 4
PSOPF	3.042 6	2.321 4	2.939 8	2.239 9	3.386 6
本文算法	1.286 8	2.045 2	1.524 5	1.706 3	2.063 1
时间索引	56	57	58	59	60
PF	7.592 9	4.024 6	3.316 3	9.467 6	2.150 6
PSOPF	2.546 2	2.383 8	2.655 2	2.749 4	2.515 7
本文算法	1.534 1	1.994 7	1.724 8	1.591 5	1.936 3

本文以 RMSE 的标准差度量算法的稳定性。RMSE 为滤波结果与真实状态之间误差水平的度量, 它通过多次 Monte Carlo 实验实现统计意义上滤波结果与真实状态之间误差期望的估计。RMSE 的标准差可以反映算法滤波结果误差的波动性, 是算法误差波动的期望值, 因此它也反映了算法滤波结果的波动性, 其值越小说明滤波结果围绕某个误差水平的滤波值的波动越小, 算法越稳定。算法的有效性通过计算本文定义的  $eff$  来度量。如果  $eff$  的值越大, 说明滤波结果整体上越接近真实值, 因此算法越有效。

图 5 为 100 次独立实验各种算法  $eff(x_k)$  的曲线图。表 2 为 100 次独立实验各种算法的  $eff$  和 RMSE 的标准差。从图 5 和表 2 中可看出本文算法具有整体更大的  $eff(x_k)$  值和  $eff$  值, 并且具有更小的 RMSE 的标准差, 因此本文算法同其他算法比较, 有更好的有效性和稳定性。

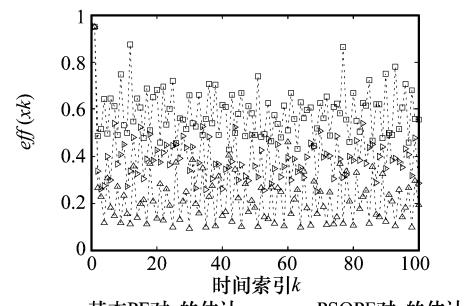


表 2 100 次独立实验各种算法的  $eff$  和 RMSE 的标准差

算法	PF	PSOPF	本文算法
$eff$	0.216 0	0.388 6	0.585 1
RMSE 的标准差	2.278 5	0.380 1	0.332 1

## 5 结论

基本的粒子滤波算法在实际应用中常会产生退化现象, 这使得系统状态的推理精度大打折扣。作为群智能优化算法, 传统的 PSO 存在着探索能力和开发能力失衡的问题, 易产生早熟现象。若简单地用其优化 PF, 并不能保证 PF 滤波的性能。通过自适应的调节粒子的惯性权值对传统 PSO 进行了改进, 可以解决 PSO 的寻优能力不足问题。本文将改进后的粒子群优化算法引入粒子滤波中, 使先验分布粒子向高似然域方向移动, 选择较好的粒子用于状态估计从而提高滤波精度。实验结果表明, 本文提出的算法

在滤波有效性和稳定性方面要优于 PSOPF<sup>[6]</sup> 和基本的 PF 算法, 因此是可行的。

## 参考文献:

- [1] Ristic B, Arulampalam S, Gordon N. *Beyond the Kalman filter particle filters for tracking applications* [M]. Boston-London: Artech House, 2004.
- [2] Sankaranarayanan A C, Srivastava A, Chellappa R. Algorithmic and architectural optimizations for computationally efficient particle filtering[J]. *IEEE Trans. on Image Processing*, 2008, 17(5): 737–748.
- [3] 王健, 金永镐, 董华春, 等. 基于新的采样更新方法的粒子滤波算法[J]. 系统工程与电子技术, 2008, 30(6): 1148–1150. (Wang Jian, Jin Yonggao, Dong Huachun, et al. Particle filter algorithm based on a new sampling method [J]. *Systems Engineering and Electronics*, 2008, 30(6): 1148–1150.)
- [4] Orguner U, Gustafsson F. Risk-sensitive particle filters for mi-

gating sample impoverishment[J]. *IEEE Trans. on Signal Processing*, 2008, 56(10): 5001–5012.

- [5] Uosaki K, Kimura Y, Hatanaka T. Nonlinear state estimation by evolution strategies based particle filters[C] // *IEEE Congress on Evolutionary Computation*, 2003: 2102–2109.
- [6] 方正, 佟国峰, 徐心和. 基于粒子群优化的粒子滤波定位方法[J]. 控制理论与应用, 2008, 25(3): 533–537.
- [7] 张琪, 王鑫, 胡昌华, 等. 人工免疫粒子滤波算法的研究[J]. 控制与决策, 2008, 23(3): 293–301.
- [8] 郑日荣. 基于欧式距离和精英交叉的免疫算法研究[D]. 广州: 华南理工大学, 2004.
- [9] Doucet A, Johansen A M. A tutorial on particle filtering and smoothing: fifteen years later[R]. Vancouver: Canada Department of Statistics, University of British Columbia, 2008.
- [10] Kennedy J. Some issues and practices for particle swarms[C] // *Proc. of the IEEE Swarm Intelligence Symposium*, 2007: 162–169.

(上接第 1447 页)

断得到的统计数据是否可靠, 直到判断得到可信数据, 最后进行结果评估。

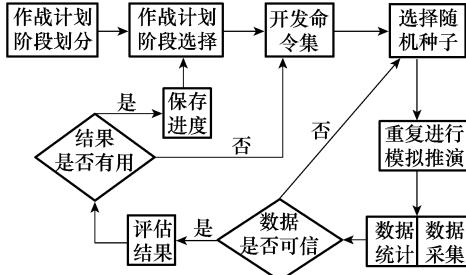


图 6 自动重复模式

图 7 所示为交互重复模式, 它通过人机交互对一份完整作战计划或某一节计划进行重复仿真, 对仿真结果进行统计并基于此进行结果分析。其基本原理与自动重复模式相同, 不同的是交互重复模式使用的是交互式命令, 这样有利于军事人员对计划过程的控制。

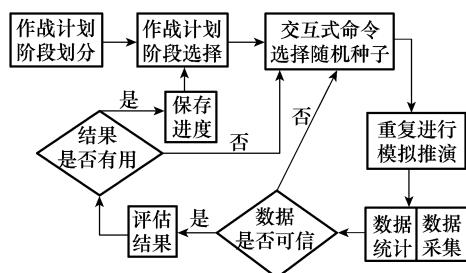


图 7 交互重复模式

## 4 结 论

本文将计划拟制过程看做一个符合逻辑的军事决策过程, 对计划拟制过程进行分析, 为分析研究兵棋系统军事需求奠定基础; 然后基于计划拟制过程和计划系列产品的开发流程, 分析、论证了兵棋对作战行动方案开发和分析应提供的辅助支持能力; 通过对开发兵棋系统时应采取的建模方式进行分析进一步明确兵棋系统的使用需求, 从而为兵棋系统的设计开发提供参考依据。

## 参考文献:

- [1] 杨南征. 虚拟演兵-兵棋、作战模拟与仿真[M]. 北京: 解放军出版社, 2007.
- [2] Headquarters Department of the Army. Army planning and orders production [R]. Washington, DC, 2005.
- [3] Perla P. *The art of Wargaming* [M]. Annapolis, MD, Naval Institute press, 1990.
- [4] The national security committee of cabinet of Australia [R]. *Australian Defence White Paper*, 2000.
- [5] Zhang L, Falzon L, Davies M, et al. On relationships between key concepts of operational level planning[C] // *Proc. of the 5th International Command and Control Research and Technology Symposium*, Australia War Memorial, 2000: 468–484.
- [6] Boukhtouta A, Bedrouni A, Berger J, et al. A survey of military planning systems[C] // *Proc. of 9th International Command & Control Research and Technology Symposium*, 2004: 1031–1046.
- [7] Ellen F R. Using the joint theater level simulation (JTLS) for analysis[C] // *Proc. of 9th International Command & Control Research and Technology Symposium*, 2004: 375–397.