

文章编号: 1001-0920(2012)08-1145-05

一种人工物理优化的粒子滤波算法

刘黎明¹, 钱东¹, 刘超华^{1,2}

(1. 哈尔滨工程大学 自动化学院, 哈尔滨 150001; 2. 海军飞行学院 教研部, 辽宁 葫芦岛 125001)

摘要: 为了改善传统粒子滤波中的粒子退化和样本贫化问题, 提出一种人工物理优化的粒子滤波方法. 通过引入人工物理优化, 对粒子滤波重采样过程进行了改进. 人工物理优化虚拟力模型规定粒子间存在相互作用的吸引力或排斥力, 通过优化可以使粒子集提高对后验概率密度的逼近程度, 克服粒子退化的问题. 同时, 由于粒子在移动过程中相互牵制, 优化后粒子集分布性更好, 并避免了粒子重叠或过度拥挤, 从而提高了估计能力, 维持了粒子的多样性. 仿真实验结果验证了所提出算法的有效性, 同时表明, 该算法具有较好的估计精度和稳定性.

关键词: 人工物理; 粒子滤波; 重采样; 重力梯度; 组合导航

中图分类号: U666.1

文献标识码: A

An artificial physics optimized particle filter

LIU Fan-ming¹, QIAN Dong¹, LIU Chao-hua^{1,2}

(1. Automation College, Harbin Engineering University, Harbin 150001, China; 2. The Teaching and Researching Department, Naval Flying Academy, Huludao 125001, China. Correspondent: QIAN Dong, E-mail: qiandong@yeah.net)

Abstract: In this paper, an artificial physics optimized particle filter(APO-PF) is proposed. Artificial physics optimization (APO) is incorporated into resampling process to deal with the sample degeneration and impoverishment of generic particle filter(PF). Virtual force model of the APO specifies that particles have mutually attractive and repulsive force. Through optimization, the APO can distribute particles in high likelihood area, and the sample degeneration is reduced. Synchronously, the APO makes particles contain each other in the motion process, ulteriorly formats better coverage to posterior probability density, which improves estimation performance, particle overlap is avoided and diversity of particle is also maintained. The simulations are performed to show the effectiveness of the algorithm, and the results show that the estimation performance and robustness of the proposed algorithm are superior to that of the generic PF.

Key words: artificial physics; particle filter; resampling; gravity gradient; integrated navigation

1 引言

粒子滤波(PF)应用于定位^[1-2]、目标跟踪^[3-4]等非线性非高斯问题的最优状态估计, 目前已取得较好的效果. 但传统粒子滤波存在粒子退化和样本枯竭的缺点, 相关改进一直是该领域研究探讨的热门问题. 近几年, 多位学者陆续提出将群智能方法与 PF 相融合的思想, 通过优化搜索技术, 使先验粒子不断向高似然区域移动, 达到增加粒子多样性、提高粒子滤波性能的目的. 文献[5-6]分别将粒子群优化和人工免疫算法引入粒子滤波, [7-8]研究了遗传重采样粒子滤波算法, [9]则提出了基于蚁群优化的粒子滤波并分析了收敛性. 群智能方法改进 PF 的核心在于改善重

采样, 优化粒子分布, 这类方法的效果一定程度上取决于所用优化算法.

本文提出一种人工物理优化(APO)的粒子滤波算法, 通过引入人工物理优化, 提高了传统粒子滤波的估计精度, 改善了样本贫化现象. 给出算法的原理和实现过程, 并通过仿真实验具体讨论了该算法的特点和性能.

2 基本粒子滤波算法

粒子滤波是一种基于序贯蒙特卡罗模拟的近似贝叶斯滤波方法, 它利用有限粒子及其权值组成的随机序列近似当前概率分布, 并根据算法不断地进行更新和递推. 考虑如下非线性系统动态模型:

收稿日期: 2011-01-16; 修回日期: 2011-04-29.

基金项目: 国家自然科学基金重点项目(60834005).

作者简介: 刘黎明(1963-), 男, 教授, 博士生导师, 从事水下导航技术、无源导航定位技术等研究; 钱东(1985-), 男, 博士生, 从事重力梯度辅助定位技术的研究.

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

其中: $\mathbf{x}_k \in \mathbf{R}^n$ 为系统状态向量, $\mathbf{y}_k \in \mathbf{R}^m$ 为系统观测向量, \mathbf{w}_k 为过程噪声, \mathbf{v}_k 为观测噪声. 在 k 时刻, 粒子滤波首先通过预测采样获得新粒子集, 即

$$\mathbf{P}_k = \{(\mathbf{x}_k^i, \omega_k^i) | i = 1, 2, \dots, N\}, \quad (2)$$

然后利用下式近似该时刻后验概率密度:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) = \sum_{i=1}^N \omega_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i). \quad (3)$$

其中: $\mathbf{x}_k^i \in \mathbf{R}^n$ 和 ω_k^i 分别为第 i 个粒子和相应归一化权值; N 为粒子数; $\mathbf{y}_{1:k} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k\}$ 为 k 时刻前所有观测; ω_k^i 更新为

$$\omega_k^i \propto \omega_{k-1}^i \frac{p(\mathbf{y}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)}. \quad (4)$$

基本粒子滤波算法由预测、更新和重采样 3 个步骤组成, 算法过程如下^[7]:

Step 1: 初始化. 从 $p(\mathbf{x}_0)$ 中采样得到 $\mathbf{x}_0^i |_{i=1}^N$, 权重 ω_0^i 置为 $1/N$.

Step 2: 预测. 从 $\mathbf{x}_k^i \sim q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 中采样新粒子集.

Step 3: 更新. 当新观测到来时, 用式 (4) 更新粒子权值并归一化.

Step 4: 重采样. 如果有效粒子 N_{eff} 小于设定阈值 N_{th} , 则进行重采样, 返回 $\{\tilde{\mathbf{x}}_k^i, \tilde{\omega}_k^i\} |_{i=1}^N$.

Step 5: 状态估计. $\hat{\mathbf{x}}_k = \sum_{i=1}^N \tilde{\omega}_k^i \tilde{\mathbf{x}}_k^i$.

3 人工物理优化的粒子滤波算法

3.1 人工物理模型

人工物理或拟态物理优化^[10]是受物理学定律启发提出的一种优化算法, 常用于解决群机器人分布式控制, 如编队、聚集和自组织等问题^[11]. 该优化方法的思想可表述如下: 将群体抽象为一个质点力学系统, 群体中的个体都视为一个力源. 个体能对其他个体施加大小不等的虚拟力, 同时也能感知其他个体施加给自己的虚拟力. 虚拟力有引力和斥力之分, 大小取决于感知模型和虚拟力模型. 人工物理优化通过计算个体所受的虚拟力合力, 可使个体向最优值逼近.

感知模型假定个体只具备一定的感知范围, 个体间距离大于感知范围时, 相互作用力将减为零. 通常采用如下的二值感知模型:

$$c(s_i, s_j) = \begin{cases} 1, & \mathbf{d}(s_i, s_j) \leq r_s; \\ 0, & \mathbf{d}(s_i, s_j) > r_s. \end{cases} \quad (5)$$

其中: $c(s_i, s_j)$ 为个体 s_i 对 s_j 的感知矩阵; $\mathbf{d}(s_i, s_j)$ 为 s_i 与 s_j 之间的欧氏距离; r_s 为感知半径.

在感知范围内, 个体 s_i 和 s_j 的虚拟力大小用虚

拟力模型表示. 人工物理方法中, 虚拟力模型可沿用物理学表达式, 也可使用自建力模型, 目前并没有固定的形式, 实际情况中一般根据性能来选取. 本文采用文献 [12] 的虚拟力模型, 其模型公式为

$$\mathbf{F}_{ij} = K_a(d_{ij} - D_{th}) \frac{(\mathbf{x}_j - \mathbf{x}_i)}{d_{ij}}, \quad \mathbf{d}(s_i, s_j) < D_{th}; \quad (6)$$

$$\mathbf{F}_{ij} = K_r(D_{th} - d_{ij}) \frac{(\mathbf{x}_j - \mathbf{x}_i)}{d_{ij}}, \quad \mathbf{d}(s_i, s_j) > D_{th}. \quad (7)$$

其中: \mathbf{F}_{ij} 为 s_j 对于 s_i 的虚拟力; D_{th} 为引力和斥力的阈值; K_a 和 K_r 为系数, 分别调整引力和斥力强度.

在虚拟力模型基础上, 将个体 s_i 所受合力定义为所有虚拟力的矢量和, 即

$$\mathbf{F}_i = \sum \mathbf{F}_{ij}, \quad j = 1, 2, \dots, n, \quad j \neq i, \quad (8)$$

其中 n 为个体数量. 则 s_i 通过下式更新自己的位置, 完成一次迭代:

$$\mathbf{x}'_i = \mathbf{x}_i + \mathbf{F}_i. \quad (9)$$

其中: \mathbf{x}'_i 为更新后的位置, 其值受到最小位移和最大位移的限制, $\mathbf{x}'_i \in [L_{\min}, L_{\max}]$. 满足优化条件或迭代次数后, 迭代终止.

3.2 粒子滤波的改进

人工物理优化具有实现简单、计算量小的优点, 其虚拟力模型引力会使优化对象之间保持一定密度, 避免形成探测盲区. 斥力又使优化对象稀疏, 避免过分密集, 因此, 该优化方法具备较强的全局寻优能力, 优化结果具有较好的分布性^[10]. 如前所述, 群智能粒子滤波性能在一定程度上取决于优化算法, 为了缓解粒子滤波的粒子退化和样本贫化问题, 本文将人工物理优化引入粒子滤波的重采样过程.

为了使粒子向高似然区域聚集, 首先规定所有粒子都受到权值最大粒子的吸引力. 在粒子滤波完成一步预测后, 改进算法将得到的候选粒子集视为人工物理中的个体, 然后通过人工物理优化, 生成新的建议分布, 再对新粒子集进行权值更新和重采样. 算法具体实现过程如下:

Step 1: 初始化. 从 $p(\mathbf{x}_0)$ 中采样得到 $\mathbf{x}_0^i |_{i=1}^N$, 权重 ω_0^i 置为 $1/N$, 同时设置感知半径 r_s , 阈值 D_{th} , 虚拟力系数 K_a 和 K_r , 迭代次数 end_{\max} 等参数. 感知矩阵 \mathbf{c} , 虚拟力矩阵 \mathbf{F} 和当前迭代次数 m_{\max} 置零.

Step 2: 预测. 从 $\mathbf{x}_k^i \sim q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 中采样新粒子集, 利用式 (4) 计算粒子权值.

Step 3: 优化粒子分布.

while $m_{\max} < \text{end}_{\max}$ do

for $i, j = 1, 2, \dots, N$ do

a) 计算粒子间欧氏距离 $\text{dist}(s_i, s_j)$;

b) 按式 (5) 计算感知矩阵 $c(s_i, s_j)$.

```

end for
for  $i = 1, 2, \dots, N$  do
    for  $j = 1, 2, \dots, N, j \neq i$  do

```

c) 计算粒子 s_i 的虚拟力:

若 s_j 权值最大, 则采用引力系数 K_{a1} ,

利用式 (6) 计算 s_i 受到的虚拟力 $F(s_i, s_j)$;

否则, 若 $c(s_i, s_j) = 1$ 且 $\text{dist}(s_i, s_j) > D_{th}$, 则采用引力系数 K_{a2} 计算虚拟力 $F(s_i, s_j)$;

若 $c(s_i, s_j) = 1$ 且 $\text{dist}(s_i, s_j) < D_{th}$, 则利用式 (7) 计算 s_i 受到的虚拟力 $F(s_i, s_j)$.

```

end for

```

d) 利用式 (8) 计算粒子 s_i 受到的合力 $F(i)$.

若 $F(i) > L_{max}$, 则 $F(i) = L_{max}$; 若 $F(i) < L_{min}$, 则 $F(i) = L_{min}$.

e) 通过式 (9) 更新粒子 s_i 的位置.

f) 计算新粒子权值, 如果满足条件, 则更新权值最大的粒子.

```

end for

```

```

end_max = end_max + 1

```

```

end while

```

Step 4: 获得新粒子集, 迭代优化结束. 重新按式 (4) 计算新粒子权值, 并归一化.

Step 5: 重采样. 如果有效粒子 N_{eff} 小于设定阈值 N_{th} , 则进行重采样, 返回 $\{\hat{x}_k^i, \tilde{\omega}_k^i\}_{i=1}^N$.

Step 6: 状态估计. $\hat{x}_k = \sum_{i=1}^N \tilde{\omega}_k^i \hat{x}_k^i$.

计算完粒子所受合虚拟力, 算法及时更新该粒子位置, 可获得更快的收敛速度, 减少迭代次数. 群智能粒子滤波一般使粒子集向高似然区聚集, 但从人工物理优化粒子滤波实现过程可以看出, 该算法通过在改善粒子分布的过程中引入排斥力, 避免了粒子集过分重叠或拥挤, 以保证粒子多样性和对后验概率密度的分布. 下面通过仿真实验验证算法的性能.

4 仿真实验

分别利用典型非线性算例和惯性/重力梯度组合导航问题, 验证人工物理优化粒子滤波 (APO-PF) 的性能. 同时采用基本粒子滤波算法 (PF) 和粒子群优化粒子滤波算法 (PSO-PF)^[5] 与 APO-PF 算法进行对比.

4.1 单变量非线性增长模型问题

首先利用单变量非线性增长模型 (UNGM)^[9] 验证 APO-PF 算法的有效性. 该状态方程和观测方程分别为

$$\begin{aligned}
 x_k &= c_1 x_{k-1} + c_2 \frac{x_{k-1}}{1 + x_{k-1}^2} + \\
 &c_3 \cos(1.2(k-1)) + w_k, \quad (10)
 \end{aligned}$$

$$y_k = x_k^2/20 + v_k. \quad (11)$$

其中: c_1, c_2, c_3 为模型系数; 系统噪声 $w_k \sim N(0, \sigma_w^2)$, 观测噪声 $v_k \sim N(0, \sigma_v^2)$ 为相互独立的高斯白噪声. 仿真中, 取 $c_1 = 1, c_2 = 12, c_3 = 7, \sigma_w^2 = 1, \sigma_v^2 = 1$. APO-PF 参数为: 引力系数 $K_{a1} = 10, K_{a2} = 0.1$, 斥力系数 $K_b = 0.9$, 感知距离 $r_s = 3$, 阈值 $D_{th} = 0.05$.

选取仿真条件, 滤波初值 $x_0 = 0.1, P_0 = 2$, 粒子数 50, 滤波次数 100. 同时, 设定在 $k = 25$ 时刻系统真实状态发生一幅值为 20 的突跳, 检验各算法的鲁棒性. 取 APO-PF 算法和 PSO-PF 算法迭代次数均为 20, 利用 3 种算法对系统状态进行估计, 图 1 给出了经过 50 次独立实验, 各算法状态估计的 RMSE 曲线. k 时刻的 RMSE 值为

$$\text{RMSE}_k = \left[\frac{1}{T} \sum_{m=1}^T (\hat{x}_k^m - x_k^m)^2 \right]^{1/2}. \quad (12)$$

其中: T 为独立仿真次数, \hat{x}_k^m 为第 m 次独立仿真中 k 时刻的状态估值, x_k^m 为 k 时刻的状态真值.

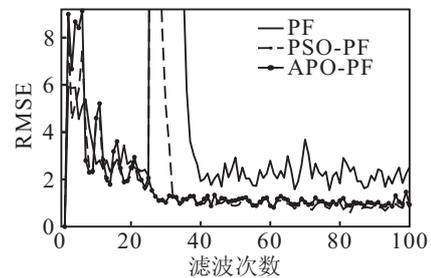


图 1 各算法状态估计的均方根误差曲线

由图 1 可以看出, APO-PF 算法估计精度明显高于传统 PF 算法, 接近于 PSO-PF 算法, 表明了该算法的有效性. 而系统状态出现大扰动时, PSO-PF 算法与 PF 算法都出现了明显的估计偏差, APO-PF 算法则保持了稳定的估计性能. 其原因是 PSO-PF 算法规定所有粒子只受适应度最大粒子的吸引力, 粒子不断向该粒子聚集, 优化后整个粒子集可能重叠于很小的范围, 缩小了搜索空间, 导致系统状态突跳时算法失去了跟踪能力. APO-PF 算法中粒子不会过度集中, 保证了搜索和移动空间, 因此鲁棒性更好. 为了更直接地看出估计结果, 表 1 给出了各算法状态估计均方根误差的统计值.

表 1 各算法状态估计均方根误差的统计结果

算 法	PF	PSO-PF	APO-PF
RMSE 平均	4.686 1	2.254 3	1.700 8

4.2 惯性/重力梯度匹配组合导航问题

图 2 为某惯性导航系统 (INS) 一次海上测试所得实验结果. 数据输出周期 1 s, 记录时间共 7 h, 表 2 给出了系统陀螺和加速度计主要参数. 如图 2 所示, 受

陀螺和加速度计等误差因素的影响, INS 导航误差会随时间增长, 因此实际中常采用外界信息与 INS 相结合以提高定位精度。

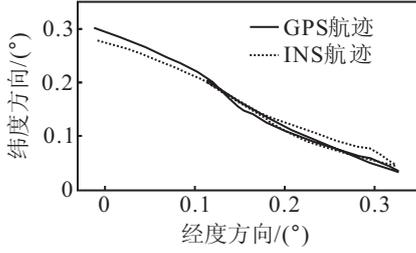


图2 某惯导海上实验数据

表2 陀螺和加速度计主要性能参数

参数项	参数值
陀螺随机游走/(°/h)	0.01
加速度零偏稳定性/ug	50

惯性/重力梯度匹配组合导航通过相关或滤波的方式将实时测量的重力梯度与预先获得的基准重力梯度图相匹配, 估计载体位置. 由于重力梯度包含 $\Gamma_{xx}, \Gamma_{xy}, \Gamma_{xz}, \Gamma_{yy}, \Gamma_{yz}$ 5 个独立张量, 全张量重力梯度仪都会对其进行测量, 观测维数增多, 有利于提供更高的定位精度. 在惯导误差方程基础上取系统状态为 $\mathbf{x} = [\delta\varphi \ \delta\lambda \ \delta V_x \ \delta V_y \ \alpha \ \beta \ \gamma \ \Delta A_x \ \Delta A_y \ \varepsilon_x \ \varepsilon_y \ \varepsilon_z]^T$.

(13)

其中: $\delta\varphi, \delta\lambda$ 为纬度和经度误差; $\delta V_x, \delta V_y$ 为东向和北向速度误差; α, β, γ 为水平和方位误差; $\Delta A_x, \Delta A_y$ 为加速度计零位误差; $\varepsilon_x, \varepsilon_y, \varepsilon_z$ 为陀螺漂移. 则惯性/重力梯度匹配组合导航的系统方程可表示为

$$\dot{\mathbf{x}}(t) = \mathbf{A}(t)\mathbf{x}(t) + \mathbf{B}(t)\mathbf{w}(t). \quad (14)$$

其中: 系统状态转移矩阵为

$$\mathbf{A} = \begin{bmatrix} \mathbf{A}_{2 \times 4} & \mathbf{0}_{2 \times 3} & \mathbf{0}_{2 \times 5} \\ \mathbf{A}_{5 \times 4} & \mathbf{A}_{5 \times 3} & \mathbf{I}_{5 \times 5} \\ * & \mathbf{0}_{5 \times 12} & * \end{bmatrix}, \quad (15)$$

$\mathbf{A}_{2 \times 4}, \mathbf{A}_{5 \times 4}, \mathbf{A}_{5 \times 3}$ 参见文献 [13], 限于篇幅, 这里不具体给出; 系统噪声矩阵 $\mathbf{B} = \mathbf{I}_{12 \times 12}$ 为单位阵.

直接取重力梯度为系统观测, 惯性/重力梯度匹配组合导航的观测模型为

$$\mathbf{y}_{jk} = \mathbf{\Gamma}_{jk}(\varphi, \lambda) + \mathbf{v}_k. \quad (16)$$

其中: \mathbf{y}_{jk} 为重力梯度观测值, 5×1 维, $j, k = x, y, z$ 表示空间方向; (φ, λ) 为载体真实位置; $\mathbf{\Gamma}_{jk}(\varphi, \lambda)$ 为真实位置处重力梯度, 也表示图上重力梯度.

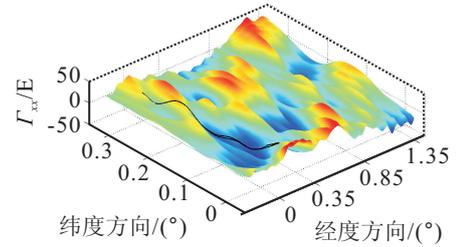
惯性/重力梯度匹配组合导航观测模型具有非线性性和 $\mathbf{\Gamma}_{jk}(\varphi, \lambda)$ 坐标上的对应关系难以解析表示的特点. 常用线性近似滤波方法通过将 $\mathbf{\Gamma}_{jk}(\varphi, \lambda)$ 在当前滤波估值附近取一阶泰勒级数展开, 可得到近似线性化的误差观测方程, 但线性化后仍存在观测矩阵只

能通过平面拟合确定, 滤波易发散的缺点. 式 (15) 中, 载体真实位置 (φ, λ) 不可获得, 将其用惯导指示位置 $(\hat{\varphi}, \hat{\lambda})$ 和位置误差 $(\delta\varphi, \delta\lambda)$ 代替, 则观测方程还可以进一步表示为

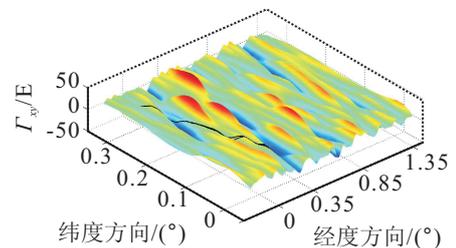
$$\mathbf{y}_{jk} = \mathbf{\Gamma}_{jk}(\hat{\varphi} + \delta\varphi, \hat{\lambda} + \delta\lambda) + \mathbf{v}_k. \quad (17)$$

该方程中, 惯导系统给定 $(\hat{\varphi}, \hat{\lambda})$, 通过系统状态初值和初始方差阵, 粒子滤波可同时生成初始位置误差后验分布的表示 $\delta\varphi_0^i|_{i=1}^N$ 和 $\delta\lambda_0^i|_{i=1}^N$. 因此, 在惯性/重力梯度匹配组合导航中采用粒子滤波方法可以避免常规滤波方法的线性化过程. 但实验表明, 重力梯度匹配维数和特征增多, 系统后验概率密度尖峰变窄, 加剧了粒子滤波中的粒子退化, 基本 PF 算法并不能保证稳定的效果. 为此, 将 APO-PF 算法应用于惯性/重力梯度匹配组合导航问题.

仿真实验中, 基准重力梯度图由该区域自由空间重力异常数据正演获得, 数据分辨率 $30''$. 重力梯度图共 5 组, 限于篇幅, 图 3 中只给出 Γ_{xx} 和 Γ_{xy} 张量. 仿真中, 以 GPS 位置为基准位置, 重力梯度观测值用 GPS 位置处的重力梯度 (如图 3 中黑线所示) 加入高斯白噪声模拟, 不在网格上的数据, 采用双线性插值.



(a) Γ_{xx} 张量



(b) Γ_{xy} 张量

图3 仿真所用基准梯度图

选取仿真条件: 惯导系统单独运行 2h 后开始组合, 系统噪声按表 2 选取, 观测噪声 $\sigma_v^2 = 1 \text{ E}$, 滤波周期取 10s. APO-PF 算法参数: 取感知距离 $r_s = 150 \text{ m}$, 阈值 $D_{th} = 10 \text{ m}$, 其余参数与上例相同. 同时, 取 PSO-PF 和 APO-PF 算法位置误差初值均为 2000m, 粒子数均为 100, 迭代优化次数均为 20, PF 算法位置误差初值 500m, 粒子数 2000. 利用 PF 算法, PSO-PF 算法和 APO-PF 算法对惯性/重力梯度组合导航进行 10 次独立仿真, 图 4 给出了各算法对惯导位置误差的估计结果. 图 4 中, 前两小时数据为零. 滤波开始时, 惯导

经度误差约 500 m, 纬度误差约 1 km. 首先比较 3 种算法的收敛性能. 可以看出, PF 算法跟踪了 1 h 左右开始发散, 而 APO-PF 算法和 PSO-PF 算法比较稳定.

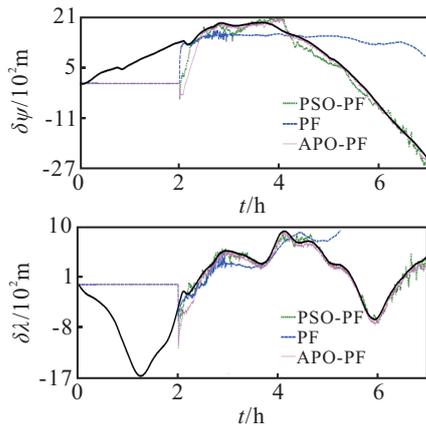


图 4 各算法对 INS 位置误差的估计结果

下面比较 APO-PF 算法和 PSO-PF 算法的估计精度. 图 5 给出了 10 次独立仿真后两种算法对经纬度误差估计的 RMSE 曲线. 在 4 h 前后, APO-PF 算法和 PSO-PF 算法对纬度误差的估计出现较大偏差, 体现了载体转弯对算法的影响. 从图 5 可以看出, PSO-PF 收敛更快, 但 APO-PF 的估计精度优于 PSO-PF 算法.

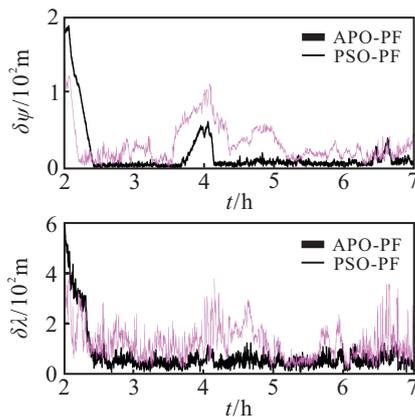


图 5 估计经纬度误差的 RMSE 曲线

表 3 分别给出了 PSO-PF 算法和 APO-PF 算法的运算时间, 以及滤波稳定后 3~7 h 区间内, 两种算法条件下组合导航系统定位的 RMSE 值. 在 30'' × 30'' 基准梯度图上, APO-PF 算法取得了 133.6 m 的定位结果, 提高了导航系统定位精度, 体现了该方法在惯性/重力梯度组合导航问题的应用价值.

表 3 PSO-PF 和 APO-PF 的运算时间和估计误差

算 法	RMSE 平均/m	单次运算时间/s
PSO-PF	370.6	0.348
APO-PF	133.6	0.418

5 结 论

本文从群智能粒子滤波基本思想出发, 提出了一种人工物理优化的粒子滤波方法. 该方法将人工物理优化引入重采样过程, 缓解了粒子退化的问题. 利用人工物理的虚拟力模型, 使粒子集在移动过程中相互牵制, 对后验概率密度形成均匀的覆盖能力, 同时在过度拥挤时相互排斥, 调整分布空间, 保持粒子的多样性. 通过两个算例进行仿真, UNGM 模型验证了算法的有效性, 应用于惯性/重力梯度匹配组合导航, 也获得了较高的估计精度和稳定性. 该方法目前还存在参数较多、收敛速度较慢的弊端. 改善虚拟力模型并验证算法的收敛性将是下一步工作的重点.

参考文献(References)

- [1] Nordlund P J, Gustafsson F. Marginalized particle filter for accurate and reliable terrain-aided navigation[J]. IEEE Trans on Aerospace and Electronic Systems, 2009, 19(7): 945-954.
- [2] Gustafsson F. Particle filter theory and practice with positioning applications[J]. IEEE Aerospace and Electronic Systems Magazine, 2010, 25(7): 53-81.
- [3] Hou S Y, Hung H S, Chang S H, et al. Novel algorithm for tracking multiple targets[J]. J of Marine Science and Technology, 2010, 18(2): 259-267.
- [4] Chang I C, Lin S Y. 3D human motion tracking based on a progressive particle filter[J]. Pattern Recognition, 2010, 43(10): 3621-3635.
- [5] 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, 23(3): 533-537. (Fang Z, Tong G F, Xu X H. A localization method for particle filter based on the optimization of particle swarm[J]. Control Theory & Applications, 2008, 23(3): 533-537.)
- [6] 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): 293-296. (Zhang Q, Wang X, Hu C H, et al. Research on artificial immune particle filter[J]. Control and Decision, 2008, 23(3): 293-296.)
- [7] Park S, Hwang J P, Kim E, et al. A new evolutionary particle filter for the prevention of sample impoverishment[J]. IEEE Trans on Evolutionary Computation, 2009, 13(4): 801-809.
- [8] 刘刚, 梁晓庚. 遗传重采样粒子滤波的目标跟踪研究[J]. 计算机工程与应用, 2010, 46(19): 196-199. (Liu G, Liang X G. Research on target tracking based on gene algorithm's resampling particle filter[J]. Computer Engineering and Applications, 2010, 46(19): 196-199.)

(下转第1156页)