

一种改进的粒子滤波算法及其在GPS/DR组合定位中的应用

杜航原¹ 王文剑^{1,2} 白亮²

(山西大学计算机与信息技术学院 太原 030006)¹

(计算智能与中文信息处理教育部重点实验室 太原 030006)²

摘要 针对粒子滤波的重要性密度函数选择问题,提出一种基于集合卡尔曼滤波(Ensemble Kalman Filter, EnKF)的改进粒子滤波算法。该方法利用集合卡尔曼滤波产生粒子滤波在每一时刻各粒子的重要性密度函数,在融合最新观测信息的同时,使重要性密度函数更加符合状态的真实后验概率分布。为消除样本枯竭现象,对重采样后的粒子进行马尔科夫链蒙特卡洛处理。在仿真实验中,将新算法用于GPS/DR组合定位系统,与粒子滤波、扩展卡尔曼粒子滤波以及无迹粒子滤波进行比较。仿真结果表明,该算法的估计精度高于传统粒子滤波算法,同时其能够有效控制计算量,并且在粒子数目较少时仍能保证较好的估计性能。

关键词 粒子滤波,重要性密度函数,集合卡尔曼滤波,组合定位系统

中图分类号 TP202 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.9.043

Improved Particle Filter and its Application in GPS/DR Integrated Positioning System

DU Hang-yuan¹ WANG Wen-jian^{1,2} BAI Liang²

(School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China)¹

(Computational Intelligence and Chinese Information Processing of Ministry of Education, Taiyuan 030006, China)²

Abstract An improved particle filtering algorithm based on the ensemble Kalman filter (EnKF) was proposed in this paper starting with the selection of importance density function of the particle filter. At each time instant, the importance density function is generated by EnKF which fuses the latest observation information and propagates the system states by using a collection of sampled state vectors, called an ensemble. In this way, the importance density function can be very close to the true posterior probability. Furthermore, to avoid the particle impoverishment problem, the Markov Chain Monte Carlo method was introduced after resampling process. In the simulation, the developed filter was compared with standard particle filter, extended Kalman particle filter and unscented particle filter in GPS/DR integrated system. The simulation results demonstrate the validity of the developed algorithm. Under the same conditions, the new filter is superior to other particle filtering algorithms with the respect to estimation accuracy, as well as it controls the computational load effectively. It is also found that the new filter can obtain outstanding performance even with a small number of particles.

Keywords Particle filter, Importance density function, Ensemble kalman filter, Integrated localization system

1 引言

20世纪80年代,全球定位系统(Global Positioning System, GPS)的出现使运载体定位技术得到空前发展。GPS能够全天候、连续、实时以及高精度地提供运载体的位置、速度和时间信息,具有其他导航系统无法比拟的优越性^[1,2],但是其数据输出频率低、动态环境中可靠性差以及卫星信号受阻后无法保证持续定位信息等缺点在一定程度上限制了GPS的使用范围。航位推算(Dead Reckoning, DR)是一种利用方向和速度信息推算运载体瞬时位置的自主式导航定位技术,

在短时间内具有较高的精度,但其定位误差会随时间逐渐累积^[3,4]。而将GPS和DR有机结合起来,就可以互相弥补不足,确保系统为运载体提供连续可靠的高精度定位信息,近年来这种组合定位技术已经成为导航定位研究的热点问题^[5,6]。

扩展卡尔曼滤波(Extended Kalman Filter, EKF)因计算量相对较小和适合计算机执行的迭代估计形式,成为组合定位系统中一种常见的状态估计方法。然而这一方法存在问题:1)EKF通过一阶泰勒展开对非线性系统进行局部线性化处理,造成高阶截断,对非线性较强的系统会造成较大的估

到稿日期:2015-08-23 返修日期:2015-10-31 本文受国家自然科学基金(61273291, 61305073),山西省高校科技创新项目(2014104),山西省回国留学人员科研资助项目(2012-008)资助。

杜航原(1985—),男,博士,讲师,CCF会员,主要研究方向为智能机器人、非线性滤波技术, E-mail: duhangyuan@sxu.edu.cn; 王文剑(1968—),女,博士,教授,CCF会员,主要研究方向为计算智能、图像处理; 白亮(1982—),男,博士,副教授,CCF会员,主要研究方向为符号聚类、粗糙集理论。

计误差。2)EKF 依赖于高斯假设,处理非高斯问题的能力较差。3)EKF 融合观测信息进行更新时必须计算 Jacobian 矩阵,但一些系统的 Jacobian 矩阵很难求取,甚至是不存在的。这些不足使得 EKF 的数值稳定性、计算效率以及有效性难以满足组合定位系统越来越高的精度要求。近年来,基于序贯蒙特卡洛方法的粒子滤波(Particle Filter, PF)由于具有简单易行、适用于非线性非高斯系统等优点,且其理论计算量与系统维度不相关,特别适用于高维系统,已经被尝试用于 GPS/DR 组合定位系统,并取得了一定成果^[7,8]。

粒子滤波通过寻找一组在状态空间中传播的随机采样点对后验概率密度进行近似,在这种方法中,选择一个适当的重要性密度函数从中采样对算法最终的估计精度具有直接影响^[9]。文献^[10]提出利用 EKF 融合观测信息,产生重要性密度函数,在一定程度上改善了滤波性能,该方法称为扩展卡尔曼粒子滤波(Extended Kalman Particle Filter, EKF-PF)。但由于 EKF 对本身会引入线性化误差,因此算法的精度依然受到限制。文献^[11]提出利用无迹卡尔曼滤波(Unscented Kalman Filter, UKF)生成每一时刻粒子滤波的重要性密度函数,UKF 使用无迹变换避免了线性化过程,无需计算 Jacobian 矩阵,使算法的估计精度有所提高。但 UKF 中 Sigma 点的采样点数与状态维数相关,计算量随着维数增大上升较快,对于高维非线性系统,算法的实时性将受到严重影响^[12]。

集合卡尔曼滤波是一种基于蒙特卡洛方法的卡尔曼滤波,它通过集合采样对非线性函数的概率密度分布进行近似,而不是对非线性函数本身进行近似,从而避免了对系统的线性化过程,同时其集合采样点数可以任意选取,在处理高维非线性系统方面具有很大优势^[13-16]。本文利用集合卡尔曼滤波产生粒子滤波每一时刻的重要性密度函数,使其更接近真实的后验概率密度,并通过马尔科夫链蒙特卡洛(Markov chain Monte Carlo, MCMC)方法^[11,17,18]减弱粒子相关性,使粒子集趋于平稳分布,从而提高粒子多样性,并将这种新的粒子滤波算法用于 GPS/DR 组合定位。仿真实验验证了该算法的优越性。

2 GPS/DR 组合系统模型

对于平面内的运动载体,使用位置、速度和加速度描述其运动状态,本文取组合系统的状态变量为 $\mathbf{X}=[x_e, v_e, a_e, x_n, v_n, a_n]^T$,其中 x_e, v_e, a_e 分别为运载体东向的位置、速度和加速度分量; x_n, v_n, a_n 分别为运载体北向的位置、速度和加速度分量,得到组合系统的状态方程为^[3]:

$$\mathbf{X}(t)=\mathbf{A}\mathbf{X}(t-1)+\mathbf{U}+\mathbf{W}(t) \quad (1)$$

其中,

$$\mathbf{A}=\begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & -\frac{1}{\tau_{a_e}} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & -\frac{1}{\tau_{a_n}} \end{bmatrix}$$

$$\mathbf{U}=\begin{bmatrix} 0 \\ 0 \\ \frac{1}{\tau_{a_e}}\bar{a}_e \\ 0 \\ 0 \\ \frac{1}{\tau_{a_n}}\bar{a}_n \end{bmatrix}, \mathbf{W}(t)=\begin{bmatrix} 0 \\ 0 \\ \omega_{a_e} \\ 0 \\ 0 \\ \omega_{a_n} \end{bmatrix} \quad (2)$$

其中, ω_{a_e} 和 ω_{a_n} 是服从 $N(0, \sigma_{a_e}^2)$ 和 $N(0, \sigma_{a_n}^2)$ 的系统噪声; τ_{a_e} 和 τ_{a_n} 为运载体东向和北向加速度变化率的相关时间常数; $\bar{a}_e$ 和 $\bar{a}_n$ 为东向和北向当前加速度均值。GPS/DR 组合系统的观测方程为:

$$\mathbf{Z}=\mathbf{H}(\mathbf{X})+\mathbf{V}(t) \quad (3)$$

其中,

$$\mathbf{H}(\mathbf{X})=\begin{bmatrix} x_e \\ x_n \\ \frac{v_n a_e - v_e a_n}{v_e^2 + v_n^2} \\ T \sqrt{v_e^2 + v_n^2} \end{bmatrix}, \mathbf{V}(t)=\begin{bmatrix} v_1 \\ v_2 \\ \epsilon_w \\ \epsilon_s \end{bmatrix} \quad (4)$$

其中, T 为采样周期, v_1, v_2, ϵ_w 和 ϵ_s 分别为组合系统各传感器中存在的随机噪声,假设它们分别服从参数为 $(0, \sigma_1^2), (0, \sigma_2^2), (0, \sigma_w^2)$ 和 $(0, \sigma_s^2)$ 的高斯分布。

3 基于集合卡尔曼滤波的粒子滤波算法

对于如下非线性离散系统

$$\mathbf{x}_k=f(\mathbf{x}_{k-1}, \mathbf{v}_{k-1}) \quad (5)$$

$$\mathbf{z}_k=h(\mathbf{x}_k, \mathbf{w}_k) \quad (6)$$

其中, $\mathbf{x}_k \in R^{n_x}$ 为系统在 k 时刻的状态, $\mathbf{z}_k \in R^{n_z}$ 为系统在 k 时刻的观测向量; $\mathbf{v}_k \in R^n$ 和 $\mathbf{w}_k \in R^m$ 分别为 k 时刻的过程噪声和观测噪声;映射 $f: R^{n_x} \times R^n \rightarrow R^{n_x}$ 和 $h: R^{n_x} \times R^m \rightarrow R^{n_z}$ 都为有界非线性函数,分别代表系统的状态模型和观测模型。滤波的目的就是要获得对系统后验分布 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 的估计值,继而得到系统状态的统计特性,如均值、方差、最大后验概率以及置信区间等。

3.1 粒子滤波

粒子滤波的基本思想是:从后验概率密度分布 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 中独立抽取 N 个采样点即粒子,并为粒子分配重要性权值,通过在空间中传播这组加权粒子来近似表示后验概率分布。而在很多情况下,后验分布可能是多变量、高维、多峰、非解析的,很难直接从中采样,为此引入了重要性采样^[10,11],即使用与后验概率具有相同分布且易于采样的重要性密度函数进行替代。同时,为了解决重要性采样引起的粒子“蜕化(Degeneracy)”问题,需要使用“重采样(Resampling)”技术^[11,19]抑制或剔除小权值粒子,并对大权值粒子依其权值进行复制。

粒子滤波的算法基本流程如下:

步骤 1 由重要性密度函数采样生成 N 个粒子。

$$\mathbf{x}_k^{(i)} \sim q(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k), i=1, \dots, N \quad (7)$$

步骤 2 计算每个粒子的重要性权值 $\omega_k^{(i)}$:

$$\omega_k^{(i)} = \omega_{k-1}^{(i)} \frac{p(\mathbf{z}_k | \mathbf{x}_k^{(i)}) p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k^{(i)} | \mathbf{x}_{0:k-1}^{(i)}, \mathbf{z}_{1:k})} \quad (8)$$

其中, $p(\mathbf{z}_k | \mathbf{x}_k^{(i)})$ 和 $p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})$ 分别表示系统的观测似然函

数和状态转移密度。

步骤 3 对权值进行归一化处理:

$$\omega_k^{(i)} = \frac{\omega_k^{(i)}}{\sum_{i=1}^N \omega_k^{(i)}} \quad (9)$$

步骤 4 重采样。

步骤 5 输出估计值:

$$p(\mathbf{x}_k | \mathbf{z}_k) \approx \sum_{i=1}^N \omega_k^{(i)} \cdot \delta(\mathbf{x}_k - \mathbf{x}_k^{(i)}) \quad (10)$$

3.2 集合卡尔曼滤波

EnKF 的本质是一种基于 Monte Carlo 方法的卡尔曼滤波,因其较高的计算效率和处理高维非线性系统的能力,已被广泛应用于数据同化领域。其基本思想是:初始化一组系统状态采样作为背景集合,在卡尔曼滤波框架下利用观测信息对背景集合中的采样点进行更新,得到分析集合。分析集合用来估计系统状态的均值和方差。通过系统模型传递采样集合,可以得到下一时刻的背景数据集。这样使用采样集合近似真实统计值,提高了估计精度,同时有效控制了计算量。

定义采样集合 $\mathbf{X}_k^b = \{\mathbf{x}_{k,i}^b, i=1, 2, \dots, n\}$ 为 k 时刻状态的背景集合,它由 $k-1$ 时刻的分析集合 $\mathbf{X}_{k-1}^a$ 初始化而来, n 为集合样本数。背景集合采样均值和方差可由下式计算:

$$\hat{\mathbf{x}}_k^b = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{k,i}^b \quad (11)$$

$$\hat{\mathbf{P}}_k^b = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_{k,i}^b - \hat{\mathbf{x}}_k^b)(\mathbf{x}_{k,i}^b - \hat{\mathbf{x}}_k^b)^T \quad (12)$$

实际应用中,无须计算 $\hat{\mathbf{P}}_k^b$, 可使用如下公式代替:

$$\hat{\mathbf{P}}_{sh}^b = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_{k,i}^b - \hat{\mathbf{x}}_k^b)(h(\mathbf{x}_{k,i}^b) - h(\hat{\mathbf{x}}_k^b))^T \quad (13)$$

$$\hat{\mathbf{P}}_{hh}^b = \frac{1}{n-1} \sum_{i=1}^n (h(\mathbf{x}_{k,i}^b) - h(\hat{\mathbf{x}}_k^b))(h(\mathbf{x}_{k,i}^b) - h(\hat{\mathbf{x}}_k^b))^T \quad (14)$$

卡尔曼增益的计算方法如下:

$$\mathbf{K}_k = \hat{\mathbf{P}}_{sh}^b (\hat{\mathbf{P}}_{hh}^b + \mathbf{R}_k)^{-1} \quad (15)$$

其中, $\mathbf{R}_k$ 表示 k 时刻的观测误差协方差矩阵。

利用最新观测信息更新背景集合,得到 k 时刻的分析集合 $\mathbf{X}_k^a = \{\mathbf{x}_{k,i}^a, i=1, 2, \dots, n\}$ 如下:

$$\mathbf{x}_{k,i}^a = \mathbf{x}_{k,i}^b + \mathbf{K}_k (\mathbf{z}_k - h(\mathbf{x}_{k,i}^b)) \quad (16)$$

其中, $\mathbf{z}_{k,i}$ 是对以观测值 $\mathbf{z}_k$ 为均值、以 $\mathbf{R}_k$ 为方差的高斯分布的采样。相应地,分析集合的采样均值和方差为:

$$\hat{\mathbf{x}}_k^a = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{k,i}^a \quad (17)$$

$$\hat{\mathbf{P}}_k^a = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_{k,i}^a - \hat{\mathbf{x}}_k^a)(\mathbf{x}_{k,i}^a - \hat{\mathbf{x}}_k^a)^T \quad (18)$$

3.3 利用 EnKF 产生重要性密度函数

EnKF 无须对非线性系统进行线性化,避免了 Jacobian 矩阵的求取,使用采样法近似非线性概率密度分布,提高了计算精度。文献[14]指出,无论随机变量是否服从高斯分布,EnKF 对均值和方差的估计至少可以达到二阶水平,相比 EKF,它产生的重要性分布与真实后验分布的重叠区域更大。此外,相比 UKF,EnKF 的集合采样点数是启发式的,可以灵活设定,使算法计算量得到有效控制。这使得 EnKF 成为产生粒子滤波重要性密度函数的更好选择。

使用 EnKF 产生粒子滤波的重要性密度函数,主要是通过传播后验分布的高斯估计以及将每一时刻的最近观测信息与之融合,即利用 EnKF 对如下后验概率密度进行递归估计。

$$p(\mathbf{x}_k | \mathbf{z}_k) \approx p_N(\mathbf{x}_k | \mathbf{z}_k) = N(\hat{\mathbf{x}}_k, \hat{\mathbf{P}}_k) \quad (19)$$

在粒子滤波的框架中,对每个粒子使用一个独立的 EnKF 来产生和传递高斯重要性密度函数:

$$q(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k) = N(\hat{\mathbf{x}}_k^{(i)}, \hat{\mathbf{P}}_k^{(i)}) \quad (20)$$

在 $k-1$ 时刻,使用 EnKF 和最近观测信息对每个粒子的重要性密度的均值和方差进行更新,在 k 时刻从新的重要性密度分布中采样得到新的粒子,依次递归。

3.4 马尔科夫链蒙特卡洛方法

在重采样阶段,大权值的粒子被多次复制,小权值的粒子被不断剔除,最终粒子集可能会退化为一种粒子,从而导致样本枯竭。为此,要在不影响估计有效性的前提下对粒子的多样性进行恢复。

MCMC 方法利用马尔科夫链对变量的函数 $f(x)$ 的稳态分布进行近似,并根据这个分布对变量空间采样,使粒子分布在感兴趣的空间内,从而达到恢复粒子多样性的目的。Metropolis Hastings(MH)是一种常用的 MCMC 方法,该算法包含以下步骤:

步骤 1 对于初始样本 $\mathbf{x}_{k-1}$,由分布函数 $p(\mathbf{x}_k | \mathbf{x}_{k-1})$ 产生一个候选样本 $\mathbf{x}_k$ 。

步骤 2 由均匀分布函数产生一个随机数 $v: v \sim u[0, 1]$ 。

步骤 3 计算 $\alpha = \min\{1, \frac{f(\mathbf{x}_{k-1})p(\mathbf{x}_k | \mathbf{x}_{k-1})}{f(\mathbf{x}_k)p(\mathbf{x}_{k-1} | \mathbf{x}_k)}\}$, 如果 $\alpha \geq v$, 就接受候选样本作为新的样本,否则,拒绝候选样本。

3.5 集合卡尔曼粒子滤波

本文使用 EnKF 产生粒子滤波的重要性密度函数,使其更接近实际的后验概率分布,同时利用 MCMC 方法恢复粒子多样性,保证对状态空间采样的有效性,将新滤波算法命名为集合卡尔曼粒子滤波(Ensemble Kalman Particle Filter, EnKF-PF)。算法的实现流程如下:

步骤 1 $k=0$ 时刻,对先验概率分布 $p(\mathbf{x}_0)$ 进行随机采样,获得初始粒子集 $\mathbf{x}_0^{(i)} (i=0, \dots, N)$, N 为粒子个数,每个粒子的权值为 $1/N$ 。同时,对初始样本的每个粒子分别定义背景集合 $\mathbf{X}_{0,j}^{b} = \{\mathbf{x}_{0,j}^{b}, j=1, 2, \dots, n\}$ 和分析集合 $\mathbf{X}_{0,j}^{a} = \{\mathbf{x}_{0,j}^{a}, j=1, 2, \dots, n\}$, 利用一组状态高斯采样对背景集合进行初始化。

从初始时刻开始,直到完成迭代,循环执行步骤 2—步骤 7。

步骤 2 使用 EnKF 更新粒子,产生每个粒子的重要性密度函数,包括:

步骤 2.1 利用式(11)~式(14)计算 k 时刻每个粒子背景集合的样本均值和方差,得到 $\hat{\mathbf{x}}_k^{(i),b}$, $\hat{\mathbf{P}}_{sh}^{(i),b}$ 和 $\hat{\mathbf{P}}_{hh}^{(i),b}$ 。

步骤 2.2 利用式(15)和式(16)将 k 时刻每个粒子的背景集合更新至分析集合,即得到 $\mathbf{X}_k^{(i),a} = \{\mathbf{x}_{k,j}^{(i),a}, j=1, 2, \dots, n\}$ 。

步骤 2.3 通过式(17)和式(18)计算每个粒子分析集合的均值 $\hat{\mathbf{x}}_k^{(i),a}$ 和方差 $\hat{\mathbf{P}}_k^{(i),a}$, 将其作为粒子重要性密度函数的高斯近似分布参数,即

$$\hat{\mathbf{x}}_k^{(i)} \sim q(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k) = N(\hat{\mathbf{x}}_k^{(i),a}, \hat{\mathbf{P}}_k^{(i),a}) \quad (21)$$

步骤 3 从步骤 2 获得的重要性分布中采样获得新的粒子集合。

步骤 4 由式(8)计算每个粒子的权值,并利用式(9)进

行归一化处理。

步骤5 根据重要性权值进行重采样处理,并重新分配粒子的权值为 $1/N$ 。

步骤6 对重采样后的粒子集合应用 MCMC 处理,使粒子向高似然区域移动,提高粒子的多样性。

步骤7 利用分析集合通过系统模型产生下一时刻的背景集合,重复步骤2—步骤6。

相比传统的粒子滤波算法,新算法利用 EnKF 在卡尔曼滤波框架下通过集合采样方法近似非线性概率密度,将最近观测信息融入重要性密度函数,使其更接近真实的状态后验分布;此外,MCMC 方法的使用提高了粒子多样性,使样本枯竭问题得到解决,进一步改善了算法估计性能。

4 仿真结果及分析

为验证新算法的有效性,设计两个仿真实验:第一个实验固定集合卡尔曼粒子滤波算法的集合采样点数,将它用于 GPS/DR 组合定位系统,与 PF、EKF-PF、UKF-PF 进行比较分析;第二个实验对不同集合采样数目下新算法在组合定位系统中的性能表现进行考察。仿真所用的计算机环境为 Intel Core2 Duo CPU T7250 @ 2.00GHz, 2GB RAM, Windows 7 操作系统,软件利用 Matlab R2010 编写。为了避免实验随机性对结果分析带来的影响,每种算法都进行 50 次独立重复实验,利用实验结果的统计值进行比较分析。

假定载体沿 45° 航向角做匀速直线运动,其东向和北向的速度为 10m/s,共行驶 300s,采样周期为 $T=1s$,仿真中有关参数设置如下: $\sigma_1^2=(10m)^2$, $\sigma_2^2=(12m)^2$, $\sigma_{\omega}^2=(0.005rad/s)^2$, $\sigma_{\alpha}^2=(0.7m)^2$, $\sigma_{\alpha_e}^2=\sigma_{\alpha_n}^2=(0.3m/s^2)^2$, $\alpha_e=\alpha_n=1$, $\mathbf{X}(0)=diag[0, 10, 0, 0, 10, 0]$, $\mathbf{P}(0)=diag[100, 1, 0.04, 100, 1, 0.04]$ 。

首先,分别使用 PF、EKF-PF、UKF-PF 和 EnKF-PF 对组合系统进行滤波,将样本估计的均值作为每一时刻算法输出值,其中选取粒子数为 100,使用残差采样法进行重采样,EnKF-PF 的集合采样个数为 10。图 1 为 4 种滤波算法对组合系统的位置定位误差,通过比较可以直观地看出,EnKF-PF 方法比标准 PF 和 EKF-PF 对载体位置估计具有更高的精度,其估计误差与 UKF-PF 接近。




图1 位置定位误差比较

为了进一步比较算法性能,引入均方根误差(Root Mean

Squared Error, RMSE),其定义如下:

$$\mathbf{X}_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^n(\mathbf{x}_i-\hat{\mathbf{x}})^2}$$
 (22)

其取值越小表示算法的估计精度越高。

表1列出了4种算法对运载体位置估计的 RMSE 以及算法运行时间。实验结果表明 EKF-PF 的估计精度高于标准 PF 算法,而 EnKF-PF 和 UKF-PF 的精度相当,均高于标准 PF 和 EKF-PF 算法;从算法运行时间来看,标准 PF 算法的最短,其余3种算法由于使用极大后验概率估计产生粒子滤波每一时刻的重要性密度函数,计算量有所增加,其中 UKF-PF 所耗时间最长,新算法的运行时间介于 EKF-PF 和 UKF-PF 之间。

表1 不同算法对位置估计的均方根误差

滤波算法	东向 RMSE(m)	北向 RMSE(m)	运行时间(s)
PF	1.8637	1.7562	1.0384
EKF-PF	1.2843	1.2412	1.1568
UKF-PF	1.0237	0.9571	2.8846
EnKF-PF	1.0258	0.9466	1.3253

以上实验结果表明:PF 算法中粒子的蜕化问题难以避免,随着迭代次数增加,重要性密度函数逐渐远离实际后验分布,导致其估计精度不够高;而 EKF-PF、EnKF-PF 以及 UKF-PF 都利用极大后验估计产生粒子滤波的重要性密度函数,通过融入最新观测信息将先验分布向似然分布移动,估计性能优于标准粒子滤波算法。但由于 EKF 使用一阶泰勒展开,忽略了高阶项,导致较大的线性化误差。而 UKF-PF 和 EnKF-PF 通过采样方法近似非线性分布,避免了线性化过程产生的误差,使估计精度进一步提高。同时对于这种高维非线性系统,UKF-PF 算法在利用 UKF 生成重要性密度函数时产生的 Sigma 采样点数量较多,增加了算法计算量,且其确定性采样策略导致的计算量将随状态维度增加而迅速上升;而 EnKF-PF 在生成重要性密度函数时使用的集合采样点数是可变的,从而能够在估计精度和算法计算量间取得平衡;另外 MCMC 方法的使用提高了粒子多样性,使算法的估计性能进一步提升。

粒子数目的不同也会对滤波算法的估计性能产生影响,图2为粒子数分别为 100,500,1000 和 10000 时 4 种滤波算法对组合系统东向位置估计的均方根误差。可以看出,随着粒子数目的增加,这些粒子滤波算法的估计误差都有所下降。对于本文提出的算法,在粒子数目较少时就可以获得较高的估计精度。




图2 不同粒子数目下各滤波算法误差比较

为考察集合采样点数对新算法性能的影响,保持算法的粒子数目为 100,分别选取集合采样个数为 10,20,30,...,100 进行仿真。表2给出了不同采样点数下组合系统东向位置定

位的 RMSE 和算法的平均运行时间。由这一结果可知,在一定范围内,随着采样点数增加,EnKF-PF 获得的估计误差呈递减趋势,但是当采样点数达到一定值后,估计误差不会随采样数增加而不断降低。例如,采样点数为 50 时的估计误差与采样点数为 100 时相差不大,而算法运行时间却随着采样点数增大而显著延长。由此可知,对于 EnKF-PF,较小的集合采样点数就可以保证算法的估计精度,并且当采样点数达到一定数目后,增加采样点数对进一步提高算法估计精度效果甚微,反而会降低算法的计算效率。

表 2 不同集合采样点数下 EnKF-PF 性能比较

集合采样点数	东向 RMSE(m)	运行时间(s)
10	1.0258	1.3253
20	0.9252	1.6441
30	0.8793	2.0842
40	0.8686	2.6875
50	0.8674	3.5003
60	0.8632	4.2236
70	0.8621	6.3895
80	0.8628	8.2814
90	0.8626	9.6325
100	0.8631	10.7147

结束语 本文提出了一种基于集合卡尔曼滤波的粒子滤波改进算法,使用集合卡尔曼滤波融合观测信息生成粒子滤波的重要性密度函数,使其更接近真实后验概率分布,同时利用 MCMC 方法提高了粒子多样性。将这种新的滤波算法用于 GPS/DR 组合定位系统,仿真实验表明,新算法的估计精度高于标准粒子滤波和扩展卡尔曼粒子滤波,同时相比无迹粒子滤波又能够有效控制计算量,为实现多传感器组合定位提供了一种更加有效可靠的途径。如何在保证算法估计精度的前提下进一步降低计算量,以及在系统中如何进行粒子数和集合采样点数的最优匹配,将是未来我们工作的重点。

参考文献

- [1] El-Rabbany A. Introduction to GPS: The Global Positioning System, Second Edition[M]. Artech House Publishers, 2006: 1-20
- [2] Quddus M, Washington S. Shortest path and vehicle trajectory aided map-matching for low frequency GPS data[J]. Transportation Research Part C: Emerging Technologies, 2015, 55: 328-339
- [3] Bevilacqua D M, Parkinson B. Cascaded Kalman Filters for Accurate Estimation of Multiple Biases, Dead-Reckoning Navigation, and Full State Feedback Control of Ground Vehicles [J]. IEEE Transactions on Control Systems Technology, 2007, 15(2): 199-208
- [4] Bong-Geun C, Ja-Kyung K, Bok-Joong Y, et al. The research of dead reckoning stabilization algorithm using different kinds of sensors[C]//2010 International Conference on Control Automation and Systems (ICCAS 2010). Kintex; IEEE Press, 2010: 1089-1092
- [5] Zhang Hai-tao, Zhao Yu-jiao. The performance comparison and analysis of extended Kalman filters for GPS/DR navigation [J].

- Optik-International Journal for Light and Electron Optics, 2011, 122(9): 777-781
- [6] Tanathong S, Lee I. Using GPS / INS data to enhance image matching for real-time aerial triangulation[J]. Computers & Geosciences, 2014, 72: 244-254
- [7] Gong Yi-song. Research on particle filter algorithm and its application in GPS/DR integrated navigation[D]. Zhengzhou: The PLA Information Engineering University, 2010 (in Chinese)
宫铁松. 粒子滤波算法研究及其在 GPS/DR 组合导航中的应用[D]. 郑州: 解放军信息工程大学, 2010
- [8] Jwo D J, Chung F C, Yu K L. GPS/INS Integration Accuracy Enhancement Using the Interacting Multiple Model Nonlinear Filters[J]. Journal of Applied Research and Technology, 2013, 11(4): 496-509
- [9] Li Zhi, Xie Qiang. Moving Target Tracking Based on Improved Particle Filter[J]. Computer Science, 2014, 41(2): 232-235 (in Chinese)
李志, 谢强. 一种基于改进粒子滤波的运动目标跟踪[J]. 计算机科学, 2014, 41(2): 232-235
- [10] Doucet A, Godsill S, Andrieu C. On Sequential Monte Carlo Methods for Bayesian Filtering[J]. Statistics and Computing, 2000, 10(3): 197-208
- [11] Merwe R V, Doucet A. The Unscented Particle Filter[EB/OL]. http://cslu.cse.ogi.edu/publications/ps/UPF_CSLU_talk.pdf
- [12] Györfy K, Kelemen A, Dávid L. Unscented Kalman Filters and Particle Filter Methods for Nonlinear State Estimation[J]. Procedia Technology, 2014, 12(1): 65-74
- [13] Bourdarie S, Lazaro D, Nieminen P, et al. In-depth Analysis of SREM Count Rate Measurements for Future Use in EnKF Salammb? Data Assimilation Tool[J]. IEEE Transactions on Nuclear Science, 2014, 61(4): 1679-1686
- [14] Lakshminarayanan S, Stensrud D. Ensemble Kalman filter [J]. IEEE Control Systems, 2009, 29(3): 34-46
- [15] Lorentzen R J, Naevdal G. An Iterative Ensemble Kalman Filter [J]. IEEE Transactions on Automatic Control, 2012, 56(8): 1990-1995
- [16] Luo X, Moroz I M. Ensemble Kalman filter with the unscented transform[J]. Physica D, 2009, 238(17): 549-562
- [17] Zhao Z, Kumar M. An MCMC-based particle filter for multiple target tracking[C]//15th International Conference on Information Fusion (Fusion 2012). Singapore: IEEE Press, 2012: 1676-1682
- [18] Arulampalam M S, Maskell S, Gordon N, et al. A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking[J]. IEEE Trans on Signal Processing, 2002, 50(2): 174-188
- [19] Zuo Jun-yi, Zhang Yi-zhe, Liang Yan. Particle Filter Based on Adaptive Part Resampling[J]. Acta Automatica Sinica, 2012, 38(4): 647-652 (in Chinese)
左军毅, 张怡哲, 梁彦. 自适应不完全重采样粒子滤波器[J]. 自动化学报, 2012, 38(4): 647-652