

文章编号: 1001-0920(2011)06-0888-05

迭代最小斜度单型 sigma 采样 UPF 算法

田 隽^{1,2}, 钱建生¹, 李世银¹

(1. 中国矿业大学 信息与电气工程学院, 江苏 徐州 221008; 2. 徐州工程学院 信电工程学院, 江苏 徐州 221009)

摘要: 针对 condensation 算法以状态转移作为建议分布从而导致权值蜕化的问题, 提出了以迭代最小斜度单型 sigmaUKF 建立建议分布的 UPF 算法. 以最小斜度单型 UKF 产生统计线性误差项, 再对 IEKF 推导产生不依赖于系统非线性映射 Jacobian 矩阵的迭代式, 以此对状态均值、协方差进行迭代修正, 以近似 0 残差使状态收敛到 MAP 估计. 平滑了状态一步预测误差, 从而提高了估计精度. 结果表明, 该算法扩大了预测样本与观测似然峰值区的重叠区域, 提高了非线性系统的状态估计精度.

关键词: 建议分布; 最小斜度单型 sigma 采样; 迭代无味卡尔曼滤波; 粒子滤波

中图分类号: TP391

文献标识码: A

Unscented particle filter using iterated minimal skew simplex UKF

TIAN Jun^{1,2}, QIAN Jian-sheng¹, LI Shi-yin¹

(1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221008, China; 2. School of Electronic and Information Engineering, Xuzhou Institute of Technology, Xuzhou 221009, China. Correspondent: TIAN Jun, E-mail: tian_jun2328@tom.com)

Abstract: To resolve the weight degeneracy in condensation algorithm which uses transition prior as the proposal distribution, a unscented particle filter algorithm(ISUKF-PF) is proposed by using iterated minimal skew simplex UKF(ISUKF) as the proposal distribution. Statistical liner error propagations are obtained by ISUKF; and the IEKF iterated equations are derived by replacing the system model Jacobian matrix with statistical liner error propagation terms. Then the states mean and covariance are iterated and updated by the IEKF iterated equations to be convergent to the state MAP estimation for near zero-residual. The outputs of the ISUKF-PF have the higher estimation accuracy, smoothing errors by one-step prediction of states estimations. The results show that the ISUKF achieves the more overlap regions of prediction samples and peak zones of observation likelihood and increases the accuracy of state estimating in nonlinear system.

Key words: proposal distribution; minimal skew simplex sigma points; iterated unscented Kalman filter; particle filter

1 引言

经典粒子滤波(如 condensation 算法^[1])通常选取系统状态的转移概率作为建议分布, 由于没有考虑系统状态的最新观测, 产生的预测样本同真实的后验概率所产生的样本偏差较大, 特别是在似然函数位于状态方程尾部的时候. 随着迭代次数的增加, 重要性权的方差增大, 出现权值蜕化问题. 文献[2]在理论上证明了 $q(x_t|x_{t-1}, y_{1:t}) = p(x_t|x_{t-1}, y_t)$ 为使重要性权方差达到极小值的最优建议分布, 将观测对预测样本的修正作用纳入采样阶段, 扩大了预测样本与似然函数的峰值重叠区域. 由于观测模型与状态模型的非线性, 优化建议分布的过程成为随机量经过非线性映射后

的统计特性估计问题. EKF 及其各种改进型是解决非线性估计问题的传统方法. [3] 将 EKF 作为 PF 采样函数产生预测样本, 但当系统模型存在严重非线性时, EKF 对 Taylor 展开式的高阶截断产生较大误差, 且涉及到非线性映射函数的 Jacobian 矩阵复杂运算, 工程实现难度较高. [4] 将 IEKF 作为 PF 建议分布, 运用 Gauss-Newton 法得到 MAP 意义下的状态估计, 但是仍要计算 Jacobian, 实现困难. [5] 将 UKF 与 PF 结合, 以确定点集的无迹变换取代函数近似, 用对平方根矩阵求 cholksy 分解来替代 Jacobian 矩阵求解, 在获得更高采样精度的同时降低了计算复杂度. 由于 UKF 充分利用了最新观测对预测样本的修正作用, 产生

收稿日期: 2010-03-24; 修回日期: 2010-06-02.

基金项目: 国家 863 计划项目(2008AA062200); 江苏省产学研联合创新基金项目(BY2009114).

作者简介: 田隽(1981—), 女, 讲师, 博士生, 从事计算机视觉及智能视觉的研究; 钱建生(1964—), 男, 教授, 博士生导师, 从事宽带网络技术、智能视觉等研究.

的采样函数具有重尾特征, 使得以不同 sigma 采样策略做 U 变换的 UKF 成为 PF 建议分布的研究热点. [6] 将对称 UKF、最小斜度单型 UKF 和超球面 UKF 从估计精度和计算耗时上进行分析比较, 最小斜度单型 UKF 具有最低计算开销的优势, 但估计精度不及对称 UKF. 因为 U 变换估计精度与所选 sigma 点数成正比, 所以如何在不增加 sigma 采样点数的情况下提高 U 变换估计精度是 UKF 的改进方向. [7] 对 UKF 与状态真值误差进行了分析, 得出 UKF 的误差源于高阶失配而非 EKF 的高阶截断误差. 此分析为采用迭代法改进非线性系统线性化程度提供了理论基础, 以此来平滑状态一步预测产生的高阶失配, 能够取得比线性化后的线性滤波更高的估计精度和更小的误差. [8] 理论证明了统计线性误差项比线性误差项具有更高的估计精度.

本文利用最小斜度单型 sigma 采样的 UKF 产生统计线性误差项, 对 IEKF 进行推导以获得不依赖系统非线性映射 Jacobian 矩阵的迭代式, 对前者得到的状态估计及其协方差进行迭代修正以近似 0 残差, 使状态收敛到 MAP. MC 仿真证明, 迭代最小斜度单型 sigma 采样 UPF (ISUKF-PF), 在保持最小斜度单行 UKF (SkewUKF) 计算优势的同时能够减小状态估计误差, 提高估计精度, 与 SkewUKF-PF 比较, 估计准确率提高 27.89%.

2 U 变换 sigma 采样策略及问题描述

2.1 U 变换

U 变换的理论基础基于近似非线性变换的概率分布比近似非线性变换本身容易. UT 建立在一组确定性采样的 sigma 点集上, 采样满足给定均值和协方差的 sigma 点, 对每个 sigma 点施以非线性变换, 用经历过变换的点的统计特性来逼近非线性变换分布函数的统计特性. 文献 [9] 在理论上证明了此种逼近对于任意非线性系统至少可达 2 阶滤波精度. UT 与随机性采样型滤波器不同, 以 PF 为例, 由于采样的不确定性, 样本多次迭代后存在权值蜕化问题, 且误差在经历相继的非线性变换传递后变得更大. 而 UT 的确定性避免了随机性采样的误差. 因此将以 UT 为核心的 UKF 作为 PF 建议分布, 利用 PF 框架状态和观测两大真实的非线性模型, 能够在确保估计精度前提下, 以更少的样本点数减少计算开销, 获得更好的数值稳定性. UT 的演变形式是基于不同的 sigma 点集 (对称点集、最小斜度单型和超球面单型) 采样策略. 文献 [6] 从匹配精度和计算耗时两方面对上述 3 种 sigma 采样策略进行比较论证, 结果表明最小斜度虽在估计精度上低于对称点集, 但在计算开销上表现出的优势使其成为高采样率实时系统首选.

2.2 最小斜度单型 sigma 采样策略

N 维空间中少于 $n + 1$ 个点的点集总是存在于少于 n 维的子空间中, 因此点集协方差是奇异的. 单型 sigma 点集采样策略要求采样点数必须满足

$$\min(p + 1, n) \geq \text{rank} \left[\sum_{i=0}^p \omega_i (\chi_i - \bar{x})(\chi_i - \bar{x})^T \right],$$

即当 P_{xx} 满秩时, 需要 $N + 1$ 个仿射独立的 sigma 点才能构成一个给定均值和非奇异方差的单型.

最小斜度的 sigma 点要求匹配 x 的一二阶矩, 并最小化三阶矩 (斜度). 从观测上只能获得分布的均值和协方差信息, 而关于分布的对称性无从获得. 因为分布能以任意角度倾斜, 若分布对称 (斜度为 0), 则平均误差最小. sigma 点的权值与中心点距离是不同的, 各个 sigma 点的重要性也不同. 低维扩维形成的 sigma 点权重比高维直接形成的 sigma 点权重重大, 距离中心点近. 随着维数增大, 权值降低, 距离中心点越来越远. 最小斜度单型采样的 sigma 点分布呈轴对称 (对称采样呈中心对称), 分布的 3 阶矩为 0, 确保了对于任意分布达到 2 阶截断精度, 对于高斯分布达到 3 阶截断精度.

由于 U 变换计算复杂度与 sigma 采样点数成正比关系, 对于采用最小斜度单型 UKF 做非线性估计的研究集中于在不增加采样点数的情况下提高采样精度.

3 IEKF 统计线性误差项迭代式推导

当系统是强非线性或扰动较大时, 以函数近似并作高阶截断的线性化法得不到满意的状态收敛值, 因此 IEKF^[10] 以迭代滤波来改进线性化法的非线性近似程度. 由于统计线性误差项比线性误差项具有更高的估计精度, 为了使最小斜度单行 sigam 采样获得的一步预测项直接可用, 需将 IEKF 传统迭代式转换为不依赖于系统非线性映射 Jacobian 矩阵的统计线性误差项迭代式. 以 IEKF 实现最大似然估计意义下的状态更新过程如下:

根据 Bayesian 估计理论有

$$p(z|x) = 1/\sqrt{(2\pi)^m |R|} \exp(-1/2(z - h(x))^T R^{-1}(z - h(x))),$$

$$p(x) = 1/\sqrt{(2\pi)^n |P|} \exp(-1/2(\hat{x} - x)^T P^{-1}(\hat{x} - x)).$$

极大化 $p(z|x)p(x)$ 等同于极小化下式:

$$\varphi(x) = 1/2[(z - h(x))^T R^{-1}(z - h(x)) + (\hat{x} - x)^T P^{-1}(\hat{x} - x)] + k, \quad (1)$$

$$\varphi(x) \approx 1/2[(Z - g(x))C^{-1}(Z - g(x))]. \quad (2)$$

令 $S^T S = C^{-1}$, 且有

$$f(x) = S(Z - g(x)),$$

$$Z = \begin{bmatrix} z \\ \hat{x} \end{bmatrix}, g(x) = \begin{bmatrix} h(x) \\ x \end{bmatrix}, C = \begin{bmatrix} R & 0 \\ 0 & P \end{bmatrix}. \quad (3)$$

将式(3)带入(2)有

$$\varphi(x) = 1/2 \| f(x) \|^2. \quad (4)$$

牛顿法以迭代序列解决此优化问题, 极小化式(4)时的 x_{i+1} 估计为

$$x_{i+1} = x_i - (\nabla^2 \varphi(x_i))^{-1} \nabla \varphi(x_i), \quad (5)$$

其中 $\nabla^2 \varphi(x_i)$ 为 $\varphi(x_i)$ 的黑塞矩阵. Gauss-Newton 法对于最小化残差问题的有效近似法, 以 $f'(x_i)^T f'(x_i)$ 对黑塞矩阵 $\nabla^2 \varphi(x_i)$ 近似, $f'(x_i)$ 为式(3)的 Jacobian 矩阵, 以 Gauss-Newton 法对式(5)近似为

$$x_{i+1} = x_i - (f'(x_i)^T f'(x_i))^{-1} f'(x_i)^T f'(x_i). \quad (6)$$

将 $f'(x_i) = -SG_i$ 代入式(6), 得到

$$x_{i+1} = (G_i^T C^{-1} G_i)^{-1} G_i^T C^{-1} (Z - g(x_i) + G_i x_i), \quad (7)$$

其中 G_i 是 $g(x_i)$ 的 Jacobian 矩阵. 将式(7)迭代至收敛, 收敛后更新的协方差由下式近似:

$$\hat{p}_{k+1} = (G_i^T C^{-1} G_i)^{-1} = (H_i^T R^{-1} H_i + P^{-1})^{-1}, \quad (8)$$

其中 H_i 为 $h_i(x)$ 的 Jacobian 矩阵. 与其他线性化法(如 EKF, UKF)不同的是, Gauss-Newton 法以接近 0 残差局部收敛至 MAP.

由矩阵求逆法则扩展式(7)有

$$\begin{aligned} x_{i+1} = & x_i + (H_i^T R^{-1} H_i + P^{-1})^{-1} [H_i^T R^{-1} (Z - \\ & h(x_i)) + P^{-1} (\hat{x}_k - x_i)] = \\ & \hat{x}_k + K (Z - h(x_i) - H_i (\hat{x}_k - x_i)), \end{aligned} \quad (9)$$

其中 $K = PH_i^T (H_i PH_i^T + R)^{-1}$ 为 Kalman 增益. 收敛后协方差更新为

$$\hat{p}_{k+1} = (I - KH_i)P. \quad (10)$$

定义线性函数 $z = Hx$, 有

$$\begin{aligned} \text{cov}(z) = E[(\hat{z} - z)(\hat{z} - z)^T] = & E[(H\hat{x} - Hx)(H\hat{x} - Hx)^T] = \\ & H \text{cov}(x) H^T = HPH^T, \end{aligned} \quad (11)$$

$$\begin{aligned} \text{cov}(x, z) = E[(\hat{x} - x)(\hat{z} - z)^T] = & E[(\hat{x} - x)(H\hat{x} - Hx)^T] = \\ & \text{cov}(x)H^T = PH^T. \end{aligned} \quad (12)$$

由式(11)和(12)得到不依赖 Jacobian 矩阵的迭代式为

$$x_{i+1} = \hat{x} + \text{cov}(x, z)(\text{cov}(z) + R)^{-1}(z - h(x_i) -$$

$$\text{cov}(x, z)^T P^{-1}(\hat{x}_k - x_i)), \quad (13)$$

$$p_{k+1} =$$

$$p_k - \text{cov}(x, z)(\text{cov}(z) + R)^{-1} \text{cov}(x, z)^T. \quad (14)$$

4 迭代最小斜度单型 sigma 采样 UPF 算法

最小斜度单型 sigmaUKF 中, 状态一步预测的非线性误差会通过观测模型传递到观测量一步预测, 且最终可能导致滤波器发散. 因此本文采用迭代滤波算法, 通过观测修正作用平滑状态一步预测误差, 获得 MAP 意义下的状态估计. 在获得建议分布函数统计特性后, 采样即是对原粒子样本通过建议分布统计特性线性组合后得到的融合最新观测的采样预测.

迭代最小斜度单型 sigma 采样 UPF 算法实现如下:

Step 1: 初始化

$$\hat{x}_0 = E[x_0],$$

$$P_0 = \text{cholesky}\{E(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T\}.$$

Step 2: 迭代最小斜度单型 sigma 采样.

1) 采样 $n + 2$ 个 σ 点, 选择任意 $0 \leq w_0 \leq 1$, 计算权值序列

$$\omega_i = \begin{cases} (1 - w_0)/2^n, & i = 1; \\ w_1, & i = 2; \\ 2^{i-1}w_1, & i = 3, 4, \dots, n + 1. \end{cases}$$

初始化 1 维向量序列

$$\chi_0^1 = [0], \chi_1^1 = [-1/\sqrt{2w_1}], \chi_2^1 = [1/\sqrt{2w_1}].$$

扩展至 n 维为

$$\chi_i^{j+1} = \begin{cases} [\chi_0^j \ 0]^T, & i = 0; \\ [\chi_i^j \ -1/\sqrt{2w_j}]^T, & i = 1, 2, \dots, j; \\ [0_j \ 1/\sqrt{2w_j}]^T, & i = j + 1. \end{cases}$$

其中 χ_i^j 表示第 i 个 σ 的第 j 维空间向量.

2) 预测更新, 将 σ 通过状态方程非线性传递, 以实现状态预测. 状态方程非线性变换为

$$\chi_{k|k+1} = f_k(\chi_{k+1}).$$

状态预测均值和协方差分别为

$$\hat{\chi}_{k|k+1} = \sum_{i=0}^n w_i \chi_{k|k+1},$$

$$P_{x_{k|k+1}} = \text{qr}\{[\sqrt{w_i}(\chi_{1:n,k|k+1} - \hat{\chi}_{k|k+1})\sqrt{R^w}]\}.$$

3) σ 点进入观测方程传递, 计算观测均值、协方差和互协方差分别为

$$z_{k|k+1} = h_k(\chi_{k|k+1}), \hat{z}_{k|k+1} = \sum_{i=0}^n w_i z_{ik|k+1},$$

$$P_{z_{k|k+1}} = \text{qr}\{[\sqrt{w_i}(z_{1:n,k|k+1} - \hat{z}_{k|k+1})\sqrt{R^e}]\},$$

$$P_{z_k|k-1} = \text{cholesky}\{P_{z_k|k-1}, z_{0,k|k-1} - \hat{z}_{k|k-1}, w_0\},$$

$$P_{xz} = \sum_{i=0}^n w_i [\chi_{i,k|k-1} - \hat{\chi}_{k|k-1}] [z_{i,k|k-1} - \hat{z}_{k|k-1}]^T.$$

4) 利用 IEKF 迭代式实现观测更新为

$$x_{k+1} = \hat{x} + \text{cov}(x, z)(\text{cov}(z) + R)^{-1}(z - h(x_i) - \text{cov}(x, z)^T P^{-1}(\hat{x}_k - x_i)),$$

$$p_{k+1} = p_k - \text{cov}(x, z)(\text{cov}(z) + R)^{-1} \text{cov}(x, z)^T.$$

判断是否收敛至 MAP 估计, 否则返回 3)。

Step 3: 构造建议分布, 从中采样得到预测样本为

$$\chi_i \sim q(x_t | x_{t-1}, z_{1:t}) = \mathcal{N}(\chi_i; \bar{x}_{k+1|k+1}, p_{k+1|k+1}).$$

Step 4: 根据观测模型得到似然函数, 更新粒子权重, 即

$$\omega_k^i \propto \omega_{k-1}^i [p(z_k | x_k^i) p(x_k^i | x_{k-1}^i) / q(x_k^i | x_{k-1}^i, z_k)].$$

$$\text{权重归一化 } \omega_k^i = \omega_k^i / \sum_{i=1}^{N_s} \omega_k^i.$$

Step 5: 重采样. 若 $N_{\text{eff}} < N_{\text{th}}$, 则重新初始化权重 $\omega_k^i = 1/N_s$, 进入残差重采样, 得到 $\{\chi_i, \omega_k^i\}_{i=1}^{N_s}$.

Step 6: t 时刻 ISUKF-PF 输出为

$$p(x_k | z_{1:k}) \approx \sum_{i=1}^{N_s} \omega_k^i \delta(x_k - x_k^i),$$

$$\hat{x}_k = E(x_k | z_{1:k}) \approx \sum_{i=1}^{N_s} \omega_k^i x_k^i,$$

$$\hat{p}_k = \sum_{i=1}^{N_s} \omega_k^i (\hat{x}_k - x_k^i)(\hat{x}_k - x_k^i)^T.$$

其中: N_s 为 ISUKF-PF 粒子样本点数, cholesky 为乔勒斯基分解, $\text{qr}\{\}$ 为矩阵的 QR 分解, N_{eff} 为有效样本容量。

5 实验结果与分析

为了验证本文算法在非线形系统中的估计性能, 采用文献 [2] 中的经典算例作数值仿真, 将本文算法 (ISUKF-PF), Condensation-PF(PF), EKF-PF, 对称点集 UKF-PF(SymUKF-PF), 最小斜度单型 UKF-PF(SkewUKF-PF) 分别作 100 次 MC 仿真, 从估计精度、计算耗时两方面进行比较说明。

仿真系统模型与观测模型为

$$x_{k+1} = 1 + \sin(\omega\pi k) + \phi_1 x_k + \omega_k.$$

$$y_k = \begin{cases} \phi_2 x_k^2 + v_k, & t \leq 30; \\ \phi_3 x_k - 2 + v_k, & t > 30. \end{cases}$$

其中: ω_k 服从 gamma 分布的随机噪声, 且

$$\omega_k \sim Ga(3, 2), \quad \omega = 4 * 10^{-2},$$

$$\phi_1 = 0.5, \quad \phi_2 = 0.2, \quad \phi_3 = 0.5.$$

观测噪声 $v_k \sim \mathcal{N}(0, 10^{-5})$, 采样 60 次, 每次随机

起始并重复 100 次实验. 粒子数 $N_s = 200$, 采用残差重采样. 状态模型中存在一项与状态无关的时间正弦函数, 可看作状态噪声中的时变部分, 此模型为较复杂的递推非线性滤波, 其精确解析解是不存在的. 因此采用上述 5 种不同建议分布的 PF 对其作状态逼近.

以样本均值 $\bar{x}_t = 1/N \sum_{i=1}^N \omega_t^i x_t^i$ 作为输出, 对上述 5 种 PF 做样本均值 RMSE 比较, 如图 1 所示, 5 种 PF 状态后验均值与状态真值比较如图 2 所示. 其中

$$\text{RMSE}(\hat{x}_k) = \left[1/N_{MC} \sum_{i=1}^{N_{MC}} (x_k - \hat{x}_k^i)^2 \right]^{1/2}.$$




图 1 5 种 PF 状态均值 RMSE 比较




图 2 5 种 PF 状态后验均值与状态真值比较

由图 1 和图 2 可以看出, 以 5 种不同建议分布作为采样预测的 PF 中, PF 与 EKF-PF 估计误差最大. 由于 Condensation-PF 以状态转移作为建议分布, 没有考虑到观测对于预测样本的修正作用, 致使在较高观测精度时, 预测样本与观测似然区域出现较大偏离; 而 EKF-PF 的性能虽有所改善, 但由于 EKF 采用在固定点以 Taylor 级数展开, 并作一阶线性截断的线性化法, 不可避免地引入截断误差, 特别是在固定点扰动领域内非线性变换程度较强的情况下, 导致估计精度下降. SymUKF-PF, SkewUKF-PF 以及 ISUKF-PF 同属于 UKF-PF 类, 对分布的均值和协方差采取了与 EKF-PF 完全不同的逼近方法, 通过确定性采样 sigma 点的非线性变换来真实地逼近状态和观测这两大非线性模型. 采用类 UKF 作为建议分布, 能较好地解决尖锐型似然函数与预测样本重叠区域过小的问题, 其中 SymUKF-PF 与 ISUKF-PF 估计精度最高, 以更小的估计误差更好地贴近真实目标状态. SymUKF-PF 以 $2n + 1$ 个 sigma 点采样取得了比 $n + 2$ 单型采样 SkewUPF-PF 更高的估计精度. 而本文

ISUKF-PF引入迭代滤波的思想,在更新状态时将其视为一种MAP,在前次滤波估计结果的基础上进行线性化.与SymUKF-PF相比,迭代平滑了状态一步预测误差,获得了与Gauss-Newton寻优等价的极大后验逼近.从图2可以看出多个状态均值RMSE峰值点,表明ISUKF-PF取得最小估计误差,并以近似0误差贴近目标真实状态.

为了说明ISUKF-PF迭代次数与估计精度的关系,在不同迭代次数下对ISUKF-PF作状态均值RMSE比较,结果如图3所示.迭代次数与估计精度并非线性递增关系,当迭代次数达到3时,迭代对提高估计精度已无贡献,说明ISUKF-PF以有限迭代计算代价换取估计精度的提高是可行的.




图3 迭代次数与估计精度关系

表1为估计精度与计算耗时.从表1可以看出,本文ISUKF-PF提高估计精度的同时保留了低计算开销的优势,在非线形系统模型中,对于状态估计的准确率明显优于其他PF算法,与SkewUKF-PF比较,总体准确率提高了27.89%.

表1 估计精度与计算耗时

	RMSE-Mean	Computation times
PF	0.4597	4.5970
EKF-PF	0.1532	14.3580
SymUKF-PF	0.1050	49.1043
SkewUKF-PF	0.2572	42.2125
ISUKF-PF	0.0821	45.1940

6 结 论

根据本文提出的ISUKF-PF,对非线性系统模型进行数值仿真,并将本文算法与PF, EKF-PF, SymUKF-PF和SkewUKF-PF算法进行状态均值RMSE比较和状态真值误差比较.在算法估计精度和计算开销两方面进行分析,并对ISUKF-PF迭代与收益关系进行可行性分析.现对实验和比较结果进行评价,所得结论如下:

1) 针对传统PF以状态转移作为建议分布,由于没有考虑观测对于预测样本的修正作用,在观测似然呈尖锐型时,导致预测样本与观测似然峰值区域重叠过小的问题. ISUKF-PF利用迭代最小斜度单

型sigmaUKF作为建议分布,以确定性采样的非线性变换逼近系统与观测模型的非线性传递,准确估计经历非线性变换后的预测样本,致使预测样本向观测似然峰值区域移动.

2) 对类UKF作非线性状态估计的研究集中于在不增加采样点的情况下提高估计精度. 本文将IEKF与最小斜度单型SigmaUKF相结合,提出了迭代最小斜度单型sigmaUKF建议分布. 由于统计线性误差传递项具有比线性误差传递项更高的估计精度,本文对IEKF迭代式推导得到不依赖于系统非线性映射Jacobian矩阵的迭代式,以SkewUKF产生统计线性误差传递项,利用IEKF迭代对状态估计、协方差进行迭代修正,以近似0残差使状态收敛到MAP估计,平滑状态一步预测误差,从而提高估计精度. 与SkewUKF-PF比较,估计准确率提高了27.89%.

3) 当迭代次数达到3以上时,迭代不再对提高估计精度有贡献,说明ISUKF-PF能以有限迭代计算开销为代价换取估计精度收益,为高采样率实时系统应用提供了可能.

参考文献(References)

- [1] Isard M, Blake A. Condensation-conditional density propagation for visual tracking[J]. Int J Computer Vision, 1998, 29(1): 5-28.
- [2] Doucet A, Godsill S, Andrieu C. On sequential monte carlo sampling methods for bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.
- [3] De Freitas J F G, Niranjan M, Gee A H, et al. Sequential monte carlo methods to train neural network models[J]. Neural Computation, 2000, 12(4): 955-993.
- [4] 李良群, 姬红兵, 罗军辉. 迭代扩展卡尔曼粒子滤波器[J]. 西安电子科技大学学报, 2007, 34(3): 233-238. (Li L Q, Ji H B, Luo J H. Iterated extended Kalman particle filtering[J]. J of Xidian University, 2004, 25(3): 330-334.)
- [5] Merwe R, Doucet A, Freitas N, et al. The unscented particle filter[R]. London: Cambridge University Engineering Department, 2000.
- [6] 杨峰, 潘泉, 梁彦, 等. 多源信息空间配准中的UT变换采样策略研究[J]. 系统仿真学报, 2006, 18(3): 713-717. (Yang F, Pan Q, Liang Y, et al. Research on sampling strategies of UT transformation for space alignment of distributed multi-sensor information[J]. J of System Simulation, 2006, 18(3): 713-717.)
- [7] 程水英, 毛云祥. 迭代无味卡尔曼滤波器[J]. 数据采集与处理, 2009, 24(增): 43-47. (Cheng S Y, Mao Y X. Iterated unscented Kalman filter[J]. J of Data Acquisition & Processing, 2009, 24(S): 43-47.)

(下转第897页)