

·信号与信息处理·

一种基于北斗飞行器在监控显示中的状态动态预测方法

赵秀影^{1,2}, 熊 壮², 肖景新², 胥 文²

(1. 吉林大学 地球探测科学与技术学院, 长春 130022; 2. 空军航空大学 科研部仿真所, 长春 130022)

摘要: 飞行器由北斗回传地面导航台前面若干个时刻的飞行状态数据来实现实时监控, 需对飞行器当前乃至后续若干时刻的状态进行预测。通过 Kalman 滤波、粒子滤波等方法对飞行器飞行状态进行预测与估计的研究, 提出采用多点状态数据的动态加权平均得出飞行器当前及后续的飞行状态数据, 并在数字地球上实时显示, 从而实现飞行器实时监控, 获得很好效果。通过对飞行器真实数据抽取后预测进行算法对照实验, 平均相对误差为 0.03%。

关键词: 动态跟踪; 粒子滤波; 实时监控

中图分类号: TP277.2

文献标识码: A

文章编号: 1673-1255(2015)-06-0060-04

State Dynamic Prediction Method Based on Beidou Navigator in Monitoring and Displaying

ZHAO Xiu-ying^{1,2}, XIONG Zhuang², XIAO Jing-xin², XU Wen²

(1. Earth Exploration Science and Technology College, Jilin University, Changchun 130022, China;

2. Science Research Department Simulation Institute, Air Force Aviation University, Changchun 130022, China)

Abstract: The real-time monitoring on the aircraft is realized by feeding back flight state data at several moments to Beidou land navigation station. The states of the aircraft at present and subsequent moments are needed to be predicted. Based on the studies of prediction and estimation, the flight state of the aircraft through Kalman and particle filter methods, the idea that dynamic weight average of multi-point state data adopted to obtain the flight state data of the aircraft at present and subsequent is presented. And it is displayed on digital earth in real-time to realize aircraft real-time monitoring and a better effect is obtained. The average relative error is 0.03% after predicting extracted aircraft real data and performing algorithm comparison experiment.

Key words: dynamic tracking; particle filter; real-time monitoring

飞行训练时地面需要了解空中的训练过程和对训练效果进行评估, 就需要实时监控以掌握飞机飞行的状态。由于北斗等导航设备只能回传前面若干个时刻的飞行器状态无法确定当前时刻的飞行状态, 只能通过预测手段达到这一目的。Kalman 滤波、粒子滤波对离散状态的预测是很好的方法, 文中主要应用这样的滤波理论对飞行器飞行状态进行动态预测研究。在 EKF 和 UKF 的基础上, 将 EKF、UKF 一起作为建议概率密度, 在某一时刻 k , 首

先由 Unscented 卡尔曼滤波器产生系统的状态估计, 然后用扩展卡尔曼滤波器重复这一过程并产生系统在 k 时刻的最终状态估计, 最后由粒子滤波得出状态概率密度。

1 粒子滤波器

假设动态系统的状态空间模型为

$$x_k = f_k(x_{k-1}, v_{k-1}) \quad (1)$$

式中, x_k 表示系统在 k 时刻所处的状态; z_k 表示 k 时刻的测量向量; 两个函数 $f_k: \mathbb{R}^{n_x} \times \mathbb{R}^{n_z} \rightarrow \mathbb{R}^{n_x}$ 和 $h_k: \mathbb{R}^{n_x} \times \mathbb{R}^{n_z} \rightarrow \mathbb{R}^{n_z}$ 分别表示系统的状态转移函数和测量函数; v_k , u_k 分别表示系统的过程噪声以及测量噪声。

粒子滤波算法最先由 Gordon 提出, 它为离散时间的递归滤波问题提供了一种近似的贝叶斯解决方法, 其基本思想是构造一个基于样本的后验概率密度函数。用 $\{x_{0:k}^i, w_k^i\}_{i=1}^N$ 表示系统后验概率密度函数 $p(x_{0:k}|z_{1:k})$ 的粒子集合, 其中 $\{x_{0:k}^i, i=1, \dots, N\}$ 是支持样本集, 相应的权值为 $\{w_k^i, i=1, \dots, N\}$, 且满足 $\sum_{i=1}^N w_k^i = 1$, 而 $x_{0:k} = \{x_j, j=0, \dots, k\}$ 表示到时刻 k 系统所有状态的集合, 所以时刻 k 的后验密度可以近似表示为

$$p(x_{0:k}|z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0:k} - x_{0:k}^i) \quad (2)$$

于是就有了一种表示真实后验密度 $p(x_{0:k}|z_{1:k})$ 的离散加权近似表示, 而那些关于数学期望的复杂计算(通常带有复杂的积分运算)就可以简化为和运算了, 如下式

$$E(g(x_{0:k})) = \int g(x_{0:k}) p(x_{0:k}|z_{1:k}) dx_{0:k} \quad (3)$$

$$\text{可以近似为: } E(g(x_{0:k})) = \sum_{i=1}^N w_k^i g(x_{0:k}^i) \quad (4)$$

许多粒子滤波器依赖于重要采样技术, 粒子的权值就是根据重要采样技术来选择的, 因此, 建议概率密度的设计就显得非常重要。如果根据重要密度 $q(x_{0:k}|z_{1:k})$ 选择粒子, 那么粒子的权值可以定义为

$$w_k^i \propto \frac{p(x_{0:k}^i|z_{1:k})}{q(x_{0:k}^i|z_{1:k})} \quad (5)$$

在时刻 $k-1$, 如果已经得到 $k-1$ 时刻后验密度 $p(x_{0:k-1}^i|z_{1:k-1})$ 的近似表示的粒子集合, 下一步就是用一个新的粒子集合来近似表示 k 时刻的后验密度 $p(x_{0:k}^i|z_{1:k})$ 。为了得到一种递归的表示方法, 可以将选择的重要密度函数因式分解为

$$q(x_{0:k}|z_{1:k}) = q(x_k|x_{0:k-1}, z_{1:k}) q(x_{0:k-1}|z_{1:k-1}) \quad (6)$$

然后, 通过将获得的新状态 $x_k^i \sim q(x_k|x_{0:k-1}, z_{1:k})$ 加入到已知的粒子集合 $x_{0:k-1}^i \sim q(x_{0:k-1}|z_{1:k-1})$ 中, 得到新的粒子集合 $x_{0:k}^i \sim q(x_{0:k}|z_{1:k})$ 。根据贝叶斯规则, 可以得到权值更新方程如下

$$p(x_{0:k}|z_{1:k}) = \frac{p(z_k|x_{0:k}, z_{1:k-1}) p(x_{0:k}|z_{1:k-1})}{p(z_k|z_{1:k-1})} \quad (7)$$

将式(6)和式(7)代入式(5), 得到权值更新方程如下

$$w_k^i \propto \frac{p(z_k|x_k^i) p(x_k^i|x_{k-1}^i) p(x_{0:k-1}^i|z_{1:k-1})}{q(x_k^i|x_{k-1}^i, z_{1:k}) q(x_{0:k-1}^i|z_{1:k-1})} \propto w_{k-1}^i \frac{p(z_k|x_k^i) p(x_k^i|x_{k-1}^i)}{q(x_k^i|x_{k-1}^i, z_{1:k})} \quad (8)$$

为了得到一种更为简单的形式, 假设 $q(x_k|x_{k-1}, z_{1:k}) = q(x_k|x_{k-1}, z_k)$, 重要密度只取决于 x_{k-1} 和 z_k , 因此, 修正的权值为

$$w_k^i \propto w_{k-1}^i \frac{p(z_k|x_k^i) p(x_k^i|x_{k-1}^i)}{q(x_k^i|x_{k-1}^i, z_k)} \quad (9)$$

基本粒子滤波算法的一个主要问题是退化问题, 即经过几步迭代以后, 除了极少数粒子外, 其他的粒子的权值小到可以忽略不计的程度。减少退化现象影响的方法一般有两种, 一是选择好的重要密度函数; 另一种是使用再采样技术。再采样方法就是去除那些权值较小的粒子, 而复制权值较大的粒子。目前存在多种再采样算法, 如残差采样、最小方差采样、多项式采样等。文中使用残差采样算法。

2 Unscented 变换(UT)

UT 是计算非线性传递的随机向量概率的一种方法。设 x 是 n_x 维的随机向量, $g: \mathbb{R}^{n_x} \rightarrow \mathbb{R}^{n_z}$ 是一非线性函数 $z=g(x)$, 假定 x 的均值和协方差分别为 \bar{x} 和 P_x 。为了计算关于 z 的统计量, 首先选择 $2n_x + 1$ 个带有权值的样本点(SIGMA 点) $S_i = \{W_i, \chi_i\}$, 使其能够完全获取随机变量 x 的真实均值和协方差。SIGMA 点的选择以及权值的确定是根据以下方程

$$\chi_0 = \bar{x}, \quad \chi_i = \bar{x} + (\sqrt{(n_x + \lambda)P_x})_i, \quad i = 1, \dots, n_x$$

$$\chi_i = \bar{x} - (\sqrt{(n_x + \lambda)P_x})_{i-n_x}, \quad i = n_x + 1, \dots, 2n_x \quad (10)$$

$$W_0^{(m)} = \frac{\lambda}{n_x + \lambda}, \quad W_0^{(c)} = \frac{\lambda}{n_x + \lambda} + (1 - \alpha^2 + \beta)$$

$$W_i^{(m)} = W_i^{(c)} = \frac{1}{2(n_x + \lambda)}, \quad i = 1, \dots, 2n_x \quad (11)$$

其中, $\lambda = \alpha^2(n_x + \kappa) - n_x$ 是一个尺度调节因子, α 决定了所选择的 SIGMA 点在其均值 \bar{x} 附近的概率密度情况, 通常将 α 设置为一个很小的正值(如 0.001)。 κ 是次级尺度调节因子, 通常设置为 0, β 是用来结合关于 x 的概率密度的先验知识(对于高斯概率密度, β 的最佳取值为 2)。 $(\sqrt{(n_x + \lambda)P_x})_i$ 是矩

阵 $(n_x + \lambda)P_x$ 平方根的第 i 行, W_i 表示第 i 个 SIGMA 点的权值,且满足 $\sum W_i = 1$ 。 $W_i^{(m)}$ 是用来计算均值的权值, $W_i^{(e)}$ 是用来计算协方差的权值,二者除在初始情况下不同外,在 $i = 1, \dots, 2n_x$ 时都是一样的。

将每个 SIGMA 点通过非线性函数向前传递, $Z_i = g(\chi_i), i = 0, \dots, 2n_x$, 通过计算可以得到 z 的均值和协方差的估计, $\bar{z} = \sum_{i=0}^{2n_x} W_i^{(m)} Z_i$, $P_z = \sum_{i=0}^{2n_x} W_i^{(e)} \{Z_i - \bar{z}\} \{Z_i - \bar{z}\}^T$ 。

3 文中所用的粒子滤波器

在时刻 k , 首先用 UT 变换求出概率密度来更新粒子, 以获得相应的状态估计值 $\bar{x}_{k|k}^i$ 作为 $k-1$ 时刻的状态估计, 即, 令 $\bar{x}_{k-1}^i = \bar{x}_{k|k}^i$ 。经过计算得到 k 时刻最终的状态及其相应的协方差的估计值 \bar{x}_k^i 和 \hat{P}_k^i 。从而可以从建议概率密度 $N(\bar{x}_k^i, \hat{P}_k^i)$ 中抽取粒子。

假设 $k-1$ 时刻的状态及相应协方差的估计分别为 \bar{x}_{k-1}^i 和 \hat{P}_{k-1}^i , 在下一时刻 k , 先更新粒子, 该过程中用到的 SIGMA 点的选择根据方程

$$\bar{x}_{k-1}^{i,\alpha} = \left[\bar{x}_{k-1}^{i,\alpha} \quad \bar{x}_{k-1}^{i,\alpha} \pm \sqrt{(n_\alpha + \lambda)P_{k-1}^{i,\alpha}} \right] \quad (12)$$

此后将 SIGMA 点分别通过系统模型与测量模型向前传递, 得到状态及协方差的预测值为

$$\chi_{k|k-1}^{i,x} = f(\chi_{k-1}^{i,x}, \chi_{k-1}^{i,v}), \quad Z_{k|k-1}^i = h(\chi_{k|k-1}^{i,x}, \chi_{k-1}^{i,u}) \quad (13)$$

$$\bar{x}_{k|k-1}^{i,ukf} = \sum_{j=0}^{2n_\alpha} W_j^{(m)} \chi_{j,k|k-1}^{i,x} \quad (14)$$

$$P_{k|k-1}^{i,ukf} = \sum_{j=0}^{2n_\alpha} W_j^{(e)} [\chi_{j,k|k-1}^{i,x} - \bar{x}_{k|k-1}^{i,ukf}] [\chi_{j,k|k-1}^{i,x} - \bar{x}_{k|k-1}^{i,ukf}]^T \quad (15)$$

其中, $W_j^{(m)}$ 和 $W_j^{(e)}$ 是第 j 个 SIGMA 点的权值, $n_\alpha = n_x + n_v + n_u$ 。所以, 预测的测量值的均值可以按以下方程计算得到

$$\bar{z}_{k|k-1}^{i,ukf} = \sum_{j=0}^{2n_\alpha} W_j^{(m)} Z_{j,k|k-1}^i \quad (16)$$

得到新的测量值 z_k 之后, 更新预测状态估计量 $\bar{x}_{k|k-1}^{i,ukf}$ 如下

$$\bar{x}_{k|k}^i = \bar{x}_{k|k-1}^{i,ukf} + K_k (z_k - \bar{z}_{k|k-1}^{i,ukf}) \quad (17)$$

其中, $K_k = P_{k|k-1}^{i,ukf} P_{z_k}^{-1}$ 为卡尔曼增益, 按下面公式计算得到。

$$P_{z_k}^{-1} = \sum_{j=0}^{2n_\alpha} W_j^{(e)} [Z_{j,k|k-1}^i - \bar{z}_{k|k-1}^i] [Z_{j,k|k-1}^i - \bar{z}_{k|k-1}^i]^T \quad (18)$$

$$P_{\bar{x}_k^i} = \sum_{j=0}^{2n_\alpha} W_j^{(e)} [\chi_{j,k|k-1}^i - \bar{x}_{k|k-1}^i] [Z_{j,k|k-1}^i - \bar{z}_{k|k-1}^i]^T \quad (19)$$

这样就获得了状态估计值 $\bar{x}_{k|k}^i$, 然后执行粒子更新过程。首先预测状态及协方差如下

$$\bar{x}_{k|k-1}^{i,1ef} = f(\bar{x}_{k-1}^i) = f(\bar{x}_{k|k}^i) \quad (20)$$

$$P_{k|k-1}^{i,1ef} = F_k^i \hat{P}_{k-1}^i F_k^{T,i} + G_k^i Q_k G_k^{T,i} \quad (21)$$

据此求取卡尔曼增益为

$$K_k = P_{k|k-1}^{i,1ef} (H_k^i)^T [U_k^i R_k (U_k^i)^T + H_k^i P_{k|k-1}^{i,1ef} (H_k^i)^T]^{-1} \quad (22)$$

修正预测量得到最终所需的估计量如下

$$\hat{P}_{k|k}^i = P_{k|k-1}^{i,1ef} - K_k H_k^i P_{k|k-1}^{i,1ef} \quad (23)$$

$$\bar{x}_{k|k}^i = \bar{x}_{k|k-1}^{i,1ef} + \hat{P}_{k|k}^i (H_k^i)^T R_k^{-1} (z_k - h(\bar{x}_{k|k-1}^i)) \quad (24)$$

其中, Q 为系统噪声的协方差; R 为测量噪声的协方差; F_k^i 和 G_k^i 以及 H_k^i 和 U_k^i 分别为系统模型和测量模型的雅可比矩阵, 最终求得的 $\bar{x}_{k|k}^i$ 和 $\hat{P}_{k|k}^i$ 就是所要求的 k 时刻的估计量。

综上所述, 文中算法可以表示如下。

算法 1: MKPF 算法

(1) 初始化: $k=0$

For $i=1 \dots N$, 从初始先验密度 $p(x_0)$ 中抽取粒子 x_0^i , 并设: $\bar{x}_0^i = E(x_0^i)$; $P_0^i = E[(x_0^i - \bar{x}_0^i)(x_0^i - \bar{x}_0^i)^T]$; $\bar{x}_0^{i,a} = E[x_0^{i,a}] = [(x_0^i)^T, 0, 0]^T$, $P_0^{i,a} = E[(x_0^{i,a} - \bar{x}_0^{i,a})(x_0^{i,a} - \bar{x}_0^{i,a})^T] = \text{diag}(P_0^i Q R)$ 。

(2) For $k=1, 2, \dots$

① For $i=1, \dots, N$:

- 根据 UT 变换后所得概率密度更新粒子。

· 根据方程(10)计算所需的 SIGMA 点。

· 传递 SIGMA 点并计算出一步预测估计值: 方程(13)~方程(16)。

· 获取新的测量值 z_k , 根据方程(17)修正一步预测估计值, 获得修正的状态估计 $\bar{x}_{k|k}^i$ 。

· 令 $\bar{x}_{k-1}^i = \bar{x}_{k|k}^i$, 据方程(20)~方程(21)计算状态及相应协方差的一步预测值。

· 分别求取系统模型及观测模型的雅可比矩阵 F_k^i & G_k^i 和 H_k^i & U_k^i 。

· 计算修正的协方差及状态估计值: 方程(23)~方程(24)。

· 令 $\bar{x}_k^i = \bar{x}_{k|k}^i$, $\hat{P}_k^i = \hat{P}_{k|k}^i$, 最终求得 k 时刻所需的估计量。

- 得到近似服从高斯概率密度的建议概率密度,抽采样本(粒子) $\hat{x}_k^i \sim q(x_k^i | x_{0:k-1}^i, z_{1:k}^i) = N(\bar{x}_k^i, \hat{P}_k^i)$ 。

- 根据方程(24)为每个样本赋以权值 w_k^i 。

ENDFOR

② For $i=1, \dots, N$

归一化权值: $w_k^i = w_k^i / \sum_{j=1:N} w_k^j$ 。

ENDFOR

(3)再采样过程

① 消除权值较小的粒子,复制权值较大的粒子,获得 N 个随机样本 $x_{0:k}^i$, 近似服从概率密度 $p(x_{0:k}^i | z_{1:k}^i)$ 。

② 为再采样之后的粒子赋以相同的权值

For $i=1, \dots, N$, $w_k^i = 1/N$. ENDFOR。

4 实验结果与结论

图1实验是在C#与skyline接口环境下进行的。首先对飞行器实际飞行数据每50帧读出一帧,再对读出数据采用文中方法预测出没有读出的数据,最后再把预测数据与真实数据对照,两组数据基本吻合,并依据公式 $\left(\frac{1}{T} \sum_{k=1}^T ((\hat{x}_k - x_k)/x_k)^2\right)^{1/2}$ (其中, \hat{x}_k 为文中预测值; x_k 为已知的精确值)计算出它们的平均相对误差为0.03%。




图1 绿色线是实际的数据,粉色线是预测的数据

由实际飞机遵照预测数据实施实验飞行,观察看飞机飞行还很平稳,无大的抖动。文中的算法耗时短、计算速度快,可实现实时预测飞行。不足之

处是需要加边界条件对个别不符合实际的预测值加以限制,若要消除这种野值与抖动,可考虑在预测时对粒子的筛选增加一些条件。

参考文献

- [1] Welch G, Bishop G. An introduction to the kalman filter[J]. University of North Carolina at Chapel Hill: Technical Report, TR 95-041, 2004.
- [2] Julier S J, Uhlmann J K. Unscented filtering and nonlinear estimation[J]. Proceedings of the IEEE, 2004, 92(3):401-422.
- [3] DENG Xiao-long, XIE Jian-ying, GUO Wei-zhong. Bayesian target tracking based on particle filter[J]. Journal of Systems Engineering and Electronics, 2005, 16(3):545-549.
- [4] Fox D, Hightower J, Liao L, et al. Bayesian filtering for location estimation[J]. IEEE Pervasive Computing, 2003, 2(3):24-33.
- [5] Kalsson Rickard. Particle filtering for positioning and tracking applications [D]. Department of Electrical Engineering, Linköpings Universitet, 2005.
- [6] Rekleitis I M. A particle filter tutorial for mobile robot localization[J]. Montreal, Quebec, Canada: Centre for Intelligent Machines, McGill University, Technical Report: TM-CIM-04-02, 2004.
- [7] CHANG Cheng, Ansari Rashid. Kernel particle filter for visual tracking[J]. IEEE Signal Processing Letters, 2005, 12(3): 242-245.
- [8] Kwok C, Fox D, Meila M. Real-Time particle filters[J]. Proceedings of the IEEE, 2004, 92(3):469-484.
- [9] 陆光华, 彭学愚, 张林让, 等. 随机信号处理[M]. 西安: 西安电子科技大学出版社, 2002: 48-57.
- [10] 刘贵喜, 绍明礼, 刘先红, 等. 真实场景下视频运动目标自动自提取方法[J]. 光学学报, 2006, 26(8): 1150-1155.
- [11] 杨超, 刘建伟, 曹泉, 等. 基于高斯背景建模的视频车辆跟踪方法[J]. 图像处理, 2009, 25(5): 271-273.
- [12] 王典. 基于混合高斯的背景建模与阴影抑制算法研究[D]. 西安: 西北工业大学, 2006.
- [13] 付梦印, 邓志红, 张继伟. Kalman 滤波理论及其在导航系统中的应用[M]. 北京: 北京科学出版社, 2003: 79-93.
- [14] 胡士强, 敬忠良. 粒子滤波算法综述[J]. 控制与决策, 2005, 20(4): 361-365.
- [15] 吴宝成. 粒子滤波重采样算法研究及其应用[D]. 哈尔滨: 哈尔滨工业大学, 2006.