

改进型粒子滤波算法在多站纯方位被动跟踪中的应用

李银伢, 谭维茜, 盛安冬

(南京理工大学 自动化学院, 江苏 南京 210014)

摘要: 针对多站纯方位被动定位与跟踪问题, 给出了一种基于均匀重采样和带自适应因子的改进型粒子滤波算法. 首先, 基于无迹卡尔曼(UKF)粒子滤波器, 将参考分布融入最新观测信息, 得到符合真实状态的后验概率分布; 借助重采样和使用鲁棒估计, 改善了粒子滤波的退化问题. 其次, 引入自适应因子以调整UKF的状态模型协方差与观测模型协方差的比例, 得到较高精度的概率分布. 仿真结果表明, 改进的粒子滤波算法能够实现多站纯方位被动跟踪, 比传统非线性滤波器有更高的跟踪精度.

关键词: 粒子滤波; 被动跟踪; 纯方位

中图分类号: TP274 **文献标识码:** A

Application of improved particle filter algorithm to bearings-only passive tracking in multiple stations

LI Yin-ya, TAN Wei-qian, SHENG An-dong

(School of Automation, Nanjing University of Science and Technology, Nanjing Jiangsu 210014, China)

Abstract: For the problem of bearings-only passive localization and tracking in multiple stations, we propose an improved particle filter algorithm with an adaptive factor based on evenly re-sampling. In the unscented Kalman filter(UKF) particle filter, the posterior probability distribution of true state-values is obtained by integrating the reference distribution with the latest observed information. The degeneracy phenomenon in the particle filter is relieved by re-sampling and robust estimation approaches. By introducing an adaptive factor for adjusting the proportion between the state-model covariance and the observation-model covariance of UKF, we obtain a probability distribution with higher precision. Simulation results show that the proposed particle filter algorithm provides higher precision than the traditional nonlinear filters in bearings-only passive localization and tracking for multiple stations.

Key words: particle filter; passive tracking; bearings-only

1 引言(Introduction)

目标跟踪技术就跟踪方式而言, 可将其分为主动式和被动式两种^[1]. 在现实战争环境下, 被动式跟踪系统具有较强的生存能力和作战能力, 因此这种无源定位跟踪技术受到了世界各国有关部门的高度重视, 也成为研究的热点和难点课题. 纯方位目标运动分析是无源定位跟踪技术的一个重要分支^[2,3], 但纯方位被动跟踪本质上是一个非线性估计问题, 加之系统可观性较差, 均导致了常规递推滤波算法^[4,5]在收敛精度及收敛时间上往往满足不了要求^[6].

随着计算机技术的快速发展, Gordon^[7]等学者提出的粒子滤波(particle filter, PF)逐渐成为研究非线性非高斯动态系统最优估计问题的一种有效方法, 在现代目标跟踪领域得到了广泛应用^[8]. 如Doucet等将PF应用于单站被动纯角度目标跟踪问题^[9], 取得了优于扩展卡尔曼滤波(extended Kalman filter, EKF)的跟踪结果; Hue^[10]等把粒子滤波器推广到多

目标跟踪和数据关联; Gordon^[11]等对杂波中的机动目标跟踪问题提出混合粒子滤波器; Meginnity^[12]等提出机动目标跟踪的多模型粒子滤波器; Doucet^[13]等对跳跃Markov系统状态估计提出了更有效的粒子滤波器算法. 现代计算机技术的发展以及粒子方法具有的巨大潜力使得PF成为当前一个相当活跃的研究领域, 对于现代跟踪领域中的非线性非高斯估计问题, 有关研究表明, PF是解决此类非线性估计问题的有力工具之一^[14,15].

粒子滤波器设计的关键之一是如何选取合理的参考分布. 目前常规做法是使参考分布等于状态的先验转移概率密度^[7], 这种方法的缺陷在于选取粒子时没有利用当前的测量值, 使得PF算法严重依赖于模型. 一旦模型不准确, 或者出现异常扰动, 则这种参考分布不能有效地表示真实分布. 同时在这种分布下, 计算权重时也没有考虑模型噪声. 本文针对以上问题, 在基于UKF(unscented Kalman filter)粒

子滤波器之上,将参考分布融入最新观测信息,使之符合真实状态的后验概率分布.对于PF的退化问题,借助Gordon^[11]等人提出的重采样思想和杨元喜院士的抗差估计理论^[16~18],提出了一种基于UKFPPF的改进型粒子滤波算法(new unscented particle filter, NUPF),给出了新算法的详细实现步骤,仿真结果验证了新算法的有效性,可以为多站纯方位被动跟踪中的非线性滤波问题提供有益的参考.

2 问题描述(Problem statement)

被动跟踪系统是一个弱可观测强非线性系统^[19],其可观测性问题通常可以采用移动单站跟踪和多站融合跟踪两种途径来解决.前一种方法对载机运动提出了苛刻要求,其性能也不尽人意^[20];后者由于其搜索范围大、作用距离远和可靠性高等特点,越来越受到人们的青睐^[21].本文采用第二种多站融合跟踪方式.

假设在三维直角坐标系 $Oxyz$ 下, N 个观测站分别分布在 C_1, C_2, \dots, C_n 处,其坐标分别为 $C_i(x_i, y_i, z_i)$ ($i = 1, 2, \dots, N$),且观测期间保持固定. $C_i x' y' z'$ 是以第 i 个观测站 C_i 为原点,各坐标轴分别平行于坐标系 $Oxyz$ 各轴的观测直角坐标系.观测站与目标的几何关系如图1所示.




图1 观测站与目标的几何关系

Fig. 1 The geometric relation between observation stations and the target

在 k 时刻,目标位于 $A(x_t, y_t, z_t)$ 处, B 为 A 在平面 $x' C_i y'$ 上的投影,第 i 个观测站测得的方位角为 $\alpha_i(k)$,俯仰角为 $\beta_i(k)$,由三角关系可得:

$$\alpha_i(k) = \arctan \frac{y_t(k) - y_i}{x_t(k) - x_i}, \quad (1)$$

$$\beta_i(k) = \arctan \frac{z_t(k) - z_i}{\sqrt{(x_t(k) - x_i)^2 + (y_t(k) - y_i)^2}}. \quad (2)$$

在已知两个或两个以上观测站布站信息的情况下,只要获得目标相对观测站的方位角和俯仰角,根据空间多站点的观测射线相交原理,便可确定目标的空间位置 (x_t, y_t, z_t) ,实现目标的跟踪与预测^[22].

目标的运动模型与测量模型可以描述为:

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \mathbf{w}_{k-1}), \quad (3)$$

$$\mathbf{z}_k = h_k(\mathbf{x}_k, \mathbf{v}_k), \quad (4)$$

其中: $\mathbf{x}_k, \mathbf{z}_k$ 分别为系统在 k 时刻的状态向量和测量向量, $\mathbf{w}_{k-1}, \mathbf{v}_k$ 分别表示过程噪声和量测噪声, $\mathbf{w}_{k-1} \sim \mathcal{N}(0, Q_{k-1}), \mathbf{v}_k \sim \mathcal{N}(0, R_k)$, Q_{k-1} 和 R_k 分别为过程噪声和量测噪声的协方差矩阵.定义 $Z_k = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$ 为至 k 时刻为止的所有测量值的集合.本文要解决的问题是利用多个观测站的测角信息和非线性滤波算法,实现对目标的定位和跟踪.

3 改进的NUPF算法(Improved NUPF algorithm)

本小节基于抗差估计理论^[16~18],提出一种基于UKFPPF的滤波改进算法NUPF,引入自适应因子调整系统模型对滤波估值的贡献,结合自适应UKF重点采样,提高UKFPPF的滤波精度.

标准卡尔曼滤波算法中,目标的运动模型与测量模型变为:

$$\mathbf{x}_k = F_k \mathbf{x}_{k-1} + \Gamma_{k-1} \mathbf{w}_{k-1}, \quad (5)$$

$$\mathbf{z}_k = H_k \mathbf{x}_k + \mathbf{v}_k, \quad (6)$$

其中: F_k 和 H_k 分别为状态转移矩阵和观测矩阵, Γ_{k-1} 为噪声矩阵, $\mathbf{w}_{k-1}, \mathbf{v}_k$ 的定义同式(3)(4).对应式(5)(6)的标准卡尔曼滤波解由式(7)~(11)给出.

$$\hat{\mathbf{x}}_{k|k-1} = F_k \hat{\mathbf{x}}_{k-1|k-1}, \quad (7)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + \Gamma_{k-1} Q_{k-1} \Gamma_{k-1}^T, \quad (8)$$

$$G_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1}, \quad (9)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + G_k (\mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1}), \quad (10)$$

$$P_{k|k} = (I - G_k H_k) P_{k|k-1}. \quad (11)$$

自适应滤波的构造大多基于预测残差序列,定义残差向量和预测残差向量分别为:

$$\mathbf{V}_k = H_k \hat{\mathbf{x}}_{k|k} - \mathbf{z}_k, \quad (12)$$

$$\bar{\mathbf{V}}_k = H_k \hat{\mathbf{x}}_{k|k-1} - \mathbf{z}_k. \quad (13)$$

\mathbf{V}_k 与 $\bar{\mathbf{V}}_k$ 所表示的信息量不同: \mathbf{V}_k 由 k 时刻的已经融入相应观测信息的滤波值 $\hat{\mathbf{x}}_{k|k}$ 决定,而 $\bar{\mathbf{V}}_k$ 由 k 时刻的预测状态 $\hat{\mathbf{x}}_{k|k-1}$ 决定.若观测信息 \mathbf{z}_k 可靠,则 $\bar{\mathbf{V}}_k$ 的大小主要反映 $\hat{\mathbf{x}}_{k|k-1}$ 的可靠性,因而 $\bar{\mathbf{V}}_k$ 比 \mathbf{V}_k 更能反映动态系统的扰动情况.

定义状态改正向量为

$$\Delta_{\mathbf{x}_k} = \hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k-1}. \quad (14)$$

由式(10)知 $\Delta_{\mathbf{x}_k} = G_k (\mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1})$,由 $\hat{\mathbf{x}}_{k|k-1}$ 的无偏性可得

$$E(\Delta_{\mathbf{x}_k}) = E[G_k (\mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1})] = 0. \quad (15)$$

从而有

$$P_{\Delta \mathbf{x}_k} = E(\Delta \mathbf{x}_k \Delta \mathbf{x}_k^T) =$$

$$G_k(H_k P_{k|k-1} H_k^T + R_k)G_k^T. \quad (16)$$

令 $P_Q = \Gamma_{k-1} Q_{k-1} \Gamma_{k-1}^T$, 联系式(8), 可得

$$P_{\Delta \mathbf{x}_k} = G_k[H_k(F_k P_{k-1|k-1} F_k^T + P_Q)H_k^T + R_k]G_k^T. \quad (17)$$

而式(10)又可以表示为^[17]

$$\hat{\mathbf{x}}_{k|k} = (H_k^T R_k^{-1} H_k + P_{k|k-1}^{-1})^{-1}(H_k^T R_k^{-1} \mathbf{z}_k + P_{k|k-1}^{-1} \hat{\mathbf{x}}_{k|k-1}). \quad (18)$$

由式(18)可知, $\hat{\mathbf{x}}_{k|k}$ 实际为预测状态向量 $\hat{\mathbf{x}}_{k|k-1}$ 与新的观测向量 \mathbf{z}_k 的加权平均值. 若 $P_{k|k-1}$ 取得合理, 则状态参数受异常扰动的影响就小. 由式(16)(17)可知, $P_{k|k-1}$ 又受到 P_Q 的影响, 一旦实际模型出现较大扰动, 则 P_Q 并不能代表当前噪声的真实水平, 此时计算得到的 $P_{k|k-1}$ 也就有大的偏差^[17]. 考虑到上述情况, 笔者引入抗差估计理论中的自适应因子 ρ , 在实际模型出现扰动时, 将 $P_{k|k-1}$ 变成 $P_{k|k-1}/\rho$, 其中自适应因子 ρ 定义为^[18]

$$\rho = \begin{cases} 1, & |\Delta \bar{V}_k| \leq c_0, \\ \frac{c_0}{|\Delta \bar{V}_k|} \left(\frac{c_1 - |\Delta \bar{V}_k|}{c_1 - c_0} \right)^2, & c_0 < |\Delta \bar{V}_k| \leq c_1, \\ 0, & |\Delta \bar{V}_k| > c_1, \end{cases} \quad (19)$$

其中: c_0 可取 1.0 ~ 1.5, c_1 可取 3.0 ~ 4.5^[18], $\Delta \bar{V}_k$ 为模型误差判别统计量. 由于 \bar{V}_k 能较好的反映异常扰动, 故以 \bar{V}_k 为变量构造状态模型误差判别统计量

$$\Delta \bar{V}_k = \sqrt{\frac{\bar{V}_k^T \bar{V}_k}{\text{tr}(P_{z_k})}}. \quad (20)$$

式(20)中 P_{z_k} 为预测测量方差. 若观测信息 \mathbf{z}_k 可信, 则 $\Delta \bar{V}_k$ 越大表明模型误差越大, 因此相应状态模型预测信息在状态估计中的贡献就应该越小. 如果统计量小于 c_0 , 则预测状态在可以接受的范围, 此时的自适应滤波就等价于原来的UKF来进行量测更新; 如果其统计量大于 c_1 , 则该预测状态不能在滤波中利用. 对于递推滤波解, ρ 不能等于零, 故自适应因子 ρ 简化为两段函数^[17]

$$\rho = \begin{cases} 1, & |\Delta \bar{V}_k| \leq c, \\ \frac{c}{|\Delta \bar{V}_k|}, & |\Delta \bar{V}_k| > c, \end{cases} \quad (21)$$

其中常数 c 的取值与目标运动模型和观测精度有关, 是一个经验参数, c 可取为 2.5^[17].

由上述分析和式(21)可知, 自适应因子 ρ 起着调节状态模型信息与观测信息的功能, UKF的自适应滤波解和相应的协方差矩阵分别为:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \bar{G}_k(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}), \quad (22)$$

$$P_{k|k} = \frac{P_{k|k-1}}{\rho} - \bar{G}_k P_{z_k} \bar{G}_k^T, \quad (23)$$

其中:

$$\bar{G}_k = P_{\mathbf{x}_k \mathbf{z}_k} \bar{P}_{z_k}^{-1} / \rho, \quad (24)$$

$$\bar{P}_{z_k} = \frac{P_{z_k} - R_k}{\rho} + R_k, \quad (25)$$

$$P_{z_k} = \sum_{j=0}^{2n_x} W_j^c (\boldsymbol{\varsigma}_{k|k-1}^j - \hat{\mathbf{z}}_{k|k-1})(\boldsymbol{\varsigma}_{k|k-1}^j - \hat{\mathbf{z}}_{k|k-1})^T + R_k, \quad (26)$$

$$P_{\mathbf{x}_k \mathbf{z}_k} = \sum_{j=0}^{2n_x} W_j^c (\boldsymbol{\xi}_{k|k-1}^j - \hat{\mathbf{x}}_{k|k-1})(\boldsymbol{\xi}_{k|k-1}^j - \hat{\mathbf{x}}_{k|k-1})^T, \quad (27)$$

其中: $\boldsymbol{\xi}_{k|k-1}^j$ 表示 k 时刻的 Sigma 点, $\boldsymbol{\varsigma}_{k|k-1}^j = h_k \cdot (\boldsymbol{\xi}_{k|k-1}^j)$ 表示第 k 时刻的 Sigma 点通过量测方程后的一步提前预测量, $\hat{\mathbf{z}}_{k|k-1} = \sum_{j=0}^{2n_x} W_j^m \boldsymbol{\varsigma}_{k|k-1}^j$; W_j^m 和 W_j^c 分别为均值和协方差的权值, $j = 0, 1, \dots, 2n_x$, n_x 是状态向量的维数.

NUPF滤波算法具体实现步骤可以描述如下:

1) $k=0$, 初始化. 从初始状态变量的先验概率分布 $p(\mathbf{x}_0)$ 中抽取 N_s 个粒子 $\{\mathbf{x}_0^i, w_0^i\}_{i=1}^{N_s}$, 并令 $w_0^i = 1/N_s$, $k=1$.

2) 采用UT(unscented transformation)变换对每个粒子创建Sigma点:

$$\boldsymbol{\xi}_{k-1|k-1}^{(i)j} = \begin{cases} \hat{\mathbf{x}}_{k-1|k-1}^{(i)}, & j=0, \\ \hat{\mathbf{x}}_{k-1|k-1}^{(i)} + \sqrt{(n_x + \lambda) P_{k-1|k-1}^{(i)}}, & j=1, 2, \dots, n_x, \\ \hat{\mathbf{x}}_{k-1|k-1}^{(i)} - \sqrt{(n_x + \lambda) P_{k-1|k-1}^{(i)}}, & j=n_x+1, n_x+2, \dots, 2n_x, \end{cases} \quad (28)$$

以及相应权值

$$\begin{cases} W_0^m = \frac{\lambda}{\lambda + n_x}, \\ W_0^c = \frac{\lambda}{\lambda + n_x} + (1 - \alpha^2 + \beta), \\ W_l^m = W_l^c = 0.5/(\lambda + n_x), \end{cases} \quad (29)$$

其中: $l = 1, 2, \dots, 2n_x$, $i = 1, 2, \dots, N_s$, $\lambda = \alpha^2(n_x + \kappa) - n_x$ 为一比例系数, 调节Sigma点与均值的距离; α 决定 $\hat{\mathbf{x}}_{k-1|k-1}$ 周围Sigma点的分布情况, 通常设置为一个较小的正数(例如 $10^{-4} \leq \alpha < 1$); κ 是另一比例系数, 通常设置为 0 或 $3 - n_x$; 参数 β 反应关于状态的先验分布, 对于高斯分布情况, $\beta = 2$ 是最优的^[23]; $\sqrt{(n_x + \lambda) P_{k-1|k-1}^{(i)j}}$ 表示矩阵平方根第 j 行.

3) 时序更新. 根据式(30)~(34)对每个粒子进行时序更新:

$$\boldsymbol{\xi}_{k|k-1}^{(i)j} = f_k(\boldsymbol{\xi}_{k-1|k-1}^{(i)j}), \quad (30)$$

$$\hat{\mathbf{x}}_{k|k-1}^{(i)} = \sum_{j=0}^{2n_x} W_j^m \boldsymbol{\xi}_{k|k-1}^{(i)j}, \quad (31)$$

$$P_{k|k-1}^{(i)} = Q_{k-1} + \sum_{j=0}^{2n_x} W_j^c [\xi_{k|k-1}^{(i)j} - \hat{\mathbf{x}}_{k|k-1}^{(i)}][\xi_{k|k-1}^{(i)j} - \hat{\mathbf{x}}_{k|k-1}^{(i)}]^T, \quad (32)$$

$$\mathbf{s}_{k|k-1}^{(i)j} = h_k(\xi_{k|k-1}^{(i)j}), \quad (33)$$

$$\hat{\mathbf{z}}_{k|k-1}^{(i)} = \sum_{j=0}^{2n_x} W_j^m \mathbf{s}_{k|k-1}^{(i)j}. \quad (34)$$

4) 引入自适应因子 ρ . 获得最新的观测信息后, 根据式(13)(20)和式(21)在线分别计算预测残差向量 $\bar{\mathbf{V}}_k$ 、判别统计量 $\Delta \bar{\mathbf{V}}_k$ 及自适应因子 ρ .

5) 量测更新. 根据式(22)(23)对每个粒子进行量测更新, 得到滤波更新后的粒子集 $\{\hat{\mathbf{x}}_{k|k}^{(i)}, P_{k|k}^{(i)}\}_{i=1}^{N_s}$.

6) 重要性抽样. 从参考分布 $q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k}^i)$ 中抽取 N_s 个粒子, 并进行重要性权值更新 w_k^i 及归一化权值, 得到粒子集 $\{\mathbf{x}_k^i, \tilde{w}_k^i\}_{i=1}^{N_s}$.

7) 重采样阶段. 根据下式:

$$\hat{N}_{\text{eff}} = \left[\sum_{i=1}^{N_s} (\tilde{w}_k^i)^2 \right]^{-1}, \quad (35)$$

计算有效粒子数 \hat{N}_{eff} . 如果 \hat{N}_{eff} 小于门槛值 N_T , 采用基于权值选择的均匀重采样方法, 将原来的带权样本 $\{\mathbf{x}_k^i, \tilde{w}_k^i\}_{i=1}^{N_s}$ 映射为等权重样本 $\{\mathbf{x}_k^i, N_s^{-1}\}_{i=1}^{N_s}$; 如果 \hat{N}_{eff} 大于门槛值 N_T , 则不加入重采样过程. 门槛值 N_T 一般可取 $2N_s/3$ [9].

8) 状态估计. 根据式(36)输出状态估计 $\hat{\mathbf{x}}_k$:

$$\mathbf{x}_k \simeq \hat{\mathbf{x}}_k = \sum_{i=1}^{N_s} \tilde{w}_k^i \mathbf{x}_k^i. \quad (36)$$

根据式(37)对 $p(\mathbf{x}_k | Z_k)$ 进行估计:

$$\hat{p}(\mathbf{x}_k | Z_k) = \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i), \quad (37)$$

其中 $\delta(\cdot)$ 表示狄拉克函数.

4 多站纯方位被动跟踪算法(Multi-station bearings-only passive tracking algorithm)

本节给出的多站纯方位被动跟踪算法, 包含单站测角数据时间漂移校准、多站异步测角数据时间配准、最小二乘法定位和非线性NUPF滤波4个环节, 算法具体步骤描述如下:

Step 1 单站测角数据时间漂移校准.

在第 k 时刻第 i 个观测站测得的方位角和俯仰角信息为 $\{\alpha_i(k), \beta_i(k)\} (i = 1, 2, \dots, N)$, 则 N 个观测站可获得 N 组测角信息, 每一组测角信息对应一组时标. 但是传感器并不是严格按固定采样周期提供相应的测角信息的, 所以每组时标相对固定采样周期时标序列存在时间漂移问题. 在所有传感器统一时钟的情况下, 这种时间漂移问题可以通过插值方法将测角信息校准到固定采样周期序列之上.

Step 2 多站异步测角数据时间配准.

由于不同的观测站采样周期可能不统一, 因此根

据实际情况, 采用虚拟融合法或内插外推法进行异步测角数据的时间配准, 将各站经过时间漂移校准的测角数据配准到统一的时间间隔下. 当采样周期之比为整数时, 采用时间模型简单的虚拟融合法[24]; 当采样周期之比为非整数时, 采用内插外推法进行时间配准[25].

Step 3 最小二乘法定位.

若观测站 i 的坐标为 $C_i(x_i, y_i, z_i) (i = 1, 2, \dots, N)$, 目标坐标为 $A(x_t, y_t, z_t)$, 则根据观测站测得的方位角 $\alpha_i(k)$ 和俯仰角 $\beta_i(k)$ 可以确定一条空间的定位线, N 个观测站就有 N 条定位线. 在没有观测误差的情况下, 这 N 条定位线应交于一点, 这个交点就是目标的位置. 但在实际情况中, 观测误差是无法避免的, 因此这 N 条定位线往往不交于一点. 根据最小二乘法的基本思想, 可以认为与 N 条定位线的距离和最短的点, 就是目标的估计位置[26]. 利用经过预处理的测角信息对目标位置进行粗估计, 为下一步的滤波和预测提供实时的观测信息 \mathbf{z}_k .

Step 4 非线性NUPF滤波.

采用第3节的NUPF算法进行滤波与预测, 详细步骤参见第3节中NUPF算法1)~8).

Step 5 判断循环.

判断是否为最后一步跟踪滤波, 若是, 则结束跟踪; 若否, 则返回Step 1, 重复上述流程, 估计下一个时刻的目标状态.

5 仿真(Simulation)

多站观测系统最简单、最基本的实现方式是双观测站系统, 多站观测的情况可以由双站推广得到. 本节考虑双观测站情形. 布站条件如下: 两观测站相距1000 m, 以两者基线的中点为原点, 建立空间直角坐标系. 观测器的坐标分别为 $C_1 = (0, 500, 0)$ m, $C_2 = (0, -500, 0)$ m. 仿真航路: 目标初始位置 $(-1000, 600, 1000)$ m, 沿着 x, z 方向作速率分别为50 m/s和0 m/s的匀速运动. 目标真值航路在 xOy 平面的投影图如图2所示.




图2 目标真值航路在 xOy 平面的投影图

Fig. 2 The projection map of the target true value route in the xOy plane

相应的状态方程和观测方程分别如下:

$$\begin{cases} x_k = x_{k-1} + 50T + w_{x_{k-1}}, \\ y_k = 330 + 200 \sin(\omega T(k-1)) + \\ \quad 0.5y_{k-1} + w_{y_{k-1}}, \\ h_k = h_{k-1} + w_{h_{k-1}}, \end{cases} \quad (38)$$

$$\begin{cases} z_{x_k} = x_k + v_{x_k}, \\ z_{y_k} = 0.5y_k + 300 + v_{y_k}, \\ z_{h_k} = h_k + v_{h_k}, \end{cases} \quad (39)$$

其中: T 为采样周期; $w_{x_{k-1}}$, $w_{y_{k-1}}$ 和 $w_{h_{k-1}}$ 为过程噪声, 均为均值为零, 方差为 25m^2 的高斯白噪声序列; v_{x_k} , v_{y_k} 和 v_{h_k} 为量测高斯白噪声, 其均值为零, 第 k 时刻对应的方差可根据测角精度和最小二乘定位法确定^[26]; ω 为转弯速率, 这里取转弯速率为 0.175rad/s ; 传感器1采样周期 320ms , 传感器2采样周期 640ms , 采样点时刻存在均值为 0 , 均方差为 5ms 的采样时漂; 方位角和俯仰角测角精度均为 7mil ($6000\text{mil} = \pi = 360^\circ$). 其它滤波参数设置如下: $\alpha = 0.1, c = 2.5, \beta = 2.0, \kappa = 0, N_s = 500$, 初始状态分布均为均值为 0 , 方差为 10m^2 的正态分布. 仿真统计全航路的斜距离估计误差以及50次蒙特卡洛试验的均方根误差RMSE.

图3, 4分别给出了各种非线性滤波算法跟踪目标时的斜距离估计误差曲线及其相应的RMSE曲线, 其中: k 表示测量点数, v 表示蒙特卡洛试验次数. 表1, 2分别给出了各种滤波算法斜距离估计误差和50次蒙特卡洛仿真的均方根误差. 从仿真结果可以得出如下结论: 利用多个观测站协同工作对目标实施定位与跟踪是可行的; 采用本文给出的NUPF算法对目标状态的估计精度均优于EKF, UKF和普通PF. 其中, 本文提出的NUPF算法, 不仅利用了新的观测信息, 所引入的自适应因子起到了调节状态模型信息与观测信息的功能, 得到了比EKFPF和UKFPF更好的参考分布, 同时均匀重采样方法增加了样本的多样性, 在一定程度上缓和了样本的贫化. 因此, 本文给出的NUPF算法能够实现多站纯方位被动跟踪, 并在非线性滤波中获得了比传统滤波方法更高的跟踪精度.

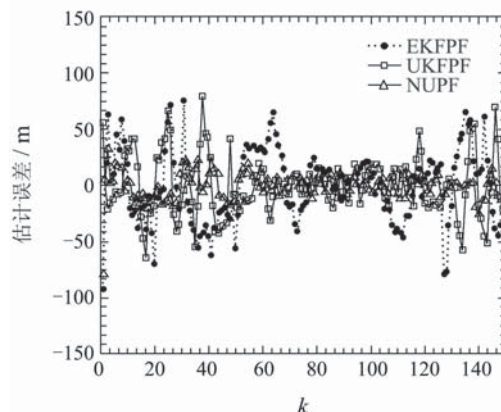
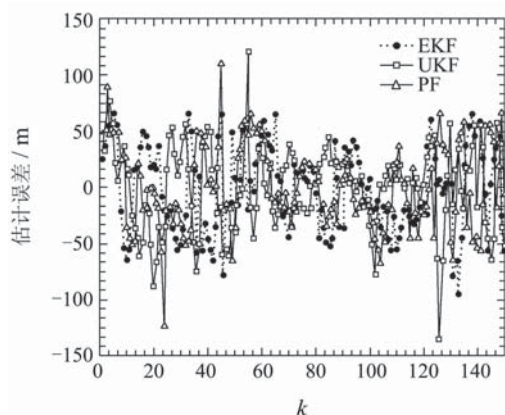


图 3 各种滤波算法斜距离估计误差
Fig. 3 The estimation errors of slant range with different filter algorithms

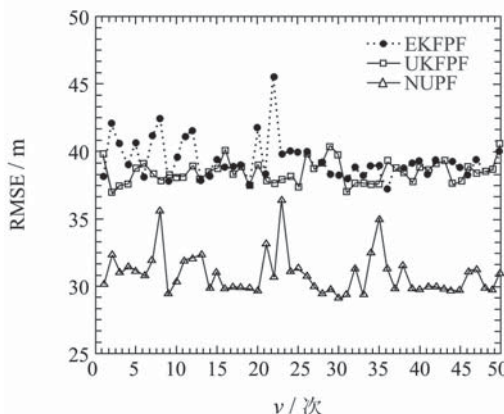



图 4 各种滤波算法的均方根误差
Fig. 4 The RMSE vs. different filter algorithms

6 结论(Conclusions)

本文针对多站纯方位被动定位与跟踪问题, 提出了一种基于UKF带自适应因子的改进型粒子滤波算法, 并将该算法应用到纯方位被动定位与跟踪中, 取得了优于传统滤波算法的跟踪精度. 值得提出的是, 在多站纯方位被动跟踪中, 观测站点之间的相对空间位置及其所对应的相对基线测量的精度, 以及观测器的测角精度, 均会影响到目标定位和估计的精度. 如何优化空间布站, 减少基线偏差, 以及如何提高观测设备的总体测角精度, 使被动跟踪系统性能得到进一步提升, 是值得进一步研究的课题.

表1 各种滤波算法的斜距离估计误差
Table 1 The estimation errors of slant range with different filter algorithms

算法	斜距离估计误差	
	均值/m	均方差/m
EKF	-27.9835	38.6875
UKF	-1.6812	38.1563
PF	-1.2544	37.7840
EKFPF	-0.8956	30.2451
UKFPF	-0.7821	27.8457
NUPF	-0.1285	12.3745

表2 50次蒙特卡洛仿真的均方根误差
Table 2 The RMSEs with 50 Monte Carlo simulations

算法	RMSE	
	均值/m	均方差/m
EKF	38.8726	3.6586
UKF	38.2147	3.5680
PF	37.4211	2.9613
EKFPF	30.8012	2.2541
UKFPF	27.9545	2.8564
NUPF	12.5647	1.8519

参考文献(References):

- [1] DARKO M. Bearings only multi-sensor maneuvering target tracking[J]. *Systems & Control Letters*, 2008, 57(3): 216 – 221.
- [2] DARKO M. Bearings only single-sensor target tracking using Gaussian mixtures[J]. *Automatica*, 2009, 45(9): 2088 – 2092.
- [3] ALFONSO F. Target tracking with bearings – only measurements [J]. *Automatica*, 1999, 78(1): 61 – 78.
- [4] SUNAHARA Y, YAMASHITA K. An approximate method of state estimation for non-linear dynamical systems with state-dependent noise[J]. *International Journal of Control*, 1970, 11(6): 957 – 972.
- [5] JULIER S J, UHLMANN J K. A new approach for filtering nonlinear system[C] // *Proceedings of the 1995 American Control Conference*. New York: IEEE, 1995, 3: 1628 – 1632.
- [6] KUTLUYIL D. Bearings-only target localization using total least squares[J]. *Signal Processing*, 2005, 85(9): 1695 – 1710.
- [7] GORDON N, SALMOND D J, SMITH A F M. Novel approach to nonlinear and non-gaussian bayesian state estimation[J]. *IEE Proceedings, Part F: Radar and Signal Processing*, 1993, 140(2): 107 – 113.
- [8] OPPENHEIM G, PHILIPPE A, RIGAL J D. The particle filters and their applications[J]. *Chemometrics and Intelligent Laboratory Systems*, 2008, 91(1): 87 – 93.
- [9] DOUCET A, FREITAS N D, GORDON N. *Sequential Monte Carlo Methods in Practice*[M]. New York: Springer-Verlag, 2001.
- [10] HUE C, CADRE J P L, PEREZ P. Sequential Monte Carlo methods for multiple target tracking and data fusion[J]. *IEEE Transactions on Signal Processing*, 2002, 50(2): 309 – 325.
- [11] GORDON N. A hybrid bootstrap filter for target tracking in clutter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1997, 33(1): 353 – 358.
- [12] MEGINNITY S, IRWIN G W. Multiple model bootstrap filter for maneuvering target tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(3): 1006 – 1012.
- [13] DOUCET A, GORDON N J, KRISHNAMURTHY V. Particle filter for state estimation of jump markov linear systems[J]. *IEEE Transactions on Signal Processing*, 2001, 49(3): 613 – 624.
- [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, 371.
(HU Shiqiang, JING Zhongliang. Overview of particle filter algorithm[J]. *Control and Decision*, 2005, 20(4): 361 – 365, 371.)
- [15] 杨小军, 潘泉, 王睿, 等. 粒子滤波进展与展望[J]. *控制理论与应用*, 2006, 23(2): 261 – 267.
(YANG Xiaojun, PAN Quan, WANG Rui, et al. Development and prospect of particle filtering[J]. *Control Theory & Applications*, 2006, 23(2): 261 – 267.)
- [16] 杨元喜. 自适应动态导航定位[M]. 北京: 测绘出版社, 2006.
(YANG Yuanxi. *Adaptive Dynamic Navigation and Positioning*[M]. Beijing: Surveying and Mapping Press, 2006.)
- [17] 徐天河, 杨元喜. 改进的Sage自适应滤波方法[J]. *测绘科学*, 2000, 25(3): 22 – 24.
(XU Tianhe, YANG Yuanxi. The improved method of Sage adaptive filtering[J]. *Science of Surveying and Mapping*, 2000, 25(3): 22 – 24.)
- [18] YANG Y X, HE H B, XU G C. A new adaptively robust filtering for kinematic geodetic positioning[J]. *Journal of Geodesy*, 2001, 75(2): 109 – 116.
- [19] 杨柏胜, 姬红兵. 基于无迹卡尔曼滤波的被动多传感器融合跟踪[J]. *控制与决策*, 2008, 23(4): 460 – 463.
(YANG Baisheng, JI Hongbing. Multi-passive-sensor fusion tracking based on unscented Kalman filter[J]. *Control and Decision*, 2008, 23(4): 460 – 463.)
- [20] BLACKMAN S, POPOLI R. *Design and Analysis of Modern Tracking System*[M]. Norwood: Artech House, 1999.
- [21] 程咏梅, 潘泉, 张洪才, 等. 基于推广卡尔曼滤波的多站被动式融合跟踪[J]. *系统仿真学报*, 2003, 15(4): 548 – 550.
(CHENG Yongmei, PAN Quan, ZHANG Hongcai, et al. Multistation passive fusion tracking based on extended Kalman filter[J]. *Journal of System Simulation*, 2003, 15(4): 548 – 550.)
- [22] 王勇, 王晓鸣, 李文彬. 基于双智能雷的目标跟踪方法研究[J]. *探测与控制学报*, 2006, 28(6): 33 – 35.
(WANG Yong, WANG Xiaoming, LI Wenbin. Approach to tracking target based on double AHMS[J]. *Journal of Detection & Control*, 2006, 28(6): 33 – 35.)
- [23] JULIER S J. The scaled unscented transformation[C] // *Proceedings of the 2002 American Control Conference*. New York: IEEE, 2002: 4555 – 4559.
- [24] 彭焱, 徐毓, 金宏斌. 多传感器数据融合系统中时间配准算法分析[J]. *雷达与对抗*, 2005, (2): 16 – 19, 34.
(PENG Yan, XU Yu, JING Hongbin. Analysis of time registration in multi-sensor data fusion system[J]. *Radar & ECM*, 2005, (2): 16 – 19, 34.)
- [25] 梁凯, 潘泉, 宋国明, 等. 多传感器时间对准方法的研究[J]. *陕西科技大学学报*, 2006, 24(6): 111 – 114.
(LIANG Kai, PAN Quan, SONG Guoming, et al. The study of multi-sensor time registration method[J]. *Journal of Shanxi University of Science & Technology*, 2006, 24(6): 111 – 114.)
- [26] 邱玲, 沈振康. 三维纯角度被动跟踪定位的最小二乘-卡尔曼滤波算法[J]. *红外与激光工程*, 2001, 30(2): 83 – 86.
(QIU Ling, SHEN Zhenkang. LS-Kalman algorithm for passive target location and tracking with bearing-only measurements[J]. *Infrared and Laser Engineering*, 2001, 30(2): 83 – 86.)

作者简介:

李银伢 (1976—), 男, 副教授, 博士, 目前研究方向为满意待机控制、非线性估计理论及其应用, E-mail: liyinya@mail.njust.edu.cn;

谭维茜 (1984—), 女, 硕士研究生, 目前研究方向为粒子滤波算法及其应用, E-mail: cicitan1015@126.com;

盛安冬 (1964—), 男, 博士生导师, 研究员, 目前研究方向为多源信息融合理论与技术, E-mail: shengandong@mail.njust.edu.cn.