

一种基于改进UPF的运动声阵列交互多模型目标跟踪方法

邸 忆¹, 顾晓辉^{1†}, 龙 飞², 李峻翔³

(1. 南京理工大学 机械工程学院, 南京 210094; 2. 贵州大学 大数据与信息工程学院, 贵阳 550025;
3. 国防科技大学 机电工程与自动化学院, 长沙 410073)

摘 要: 针对运动声阵列在有色噪声环境中的非线性滤波跟踪实时性问题, 提出一种基于改进粒子滤波的交互式多模型目标跟踪(IMM-IUPF)方法. 该方法采用最小斜度单形无迹变换结合变尺度无迹变换的 Sigma 点选取策略, 对标准无迹粒子滤波(UPF)进行改进, 大幅缩减UPF样本选取计算量; 将改进的UPF与交互式多模型(IMM)相结合, 通过定义自适应增益修正系数, 弥补样本点缩减造成的精度降低问题; 最终通过与传统的基于 IMM 的粒子滤波(IMM-PF)和基于 IMM 的无迹粒子滤波(IMM-UPF)进行 Matlab 数值仿真对比验证所提出算法的实用性.

关键词: 运动声阵列跟踪; 交互式多模型; 无迹粒子滤波; Sigma 点

中图分类号: TP391 **文献标志码:** A

An improved UPF-based interacting multiple model target tracking method for dynamic acoustic array

DI Yi¹, GU Xiao-hui^{1†}, LONG Fei², LI Jun-xiang³

(1. School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China; 2. College of Big Data and Information Science, Guizhou University, Guiyang 550025, China; 3. College of Mechatronic Engineering and Automation, National University of Defense Technology, Changsha 410073, China)

Abstract: In order to solve the real-time problem of nonlinear filter tracking using dynamic acoustic array in colored noise environment, an interacting multiple model target tracking method based on the improved unscented particle filter(IMM-IUPF) is proposed. In the method, an improved Sigma point selection strategy based on a minimal skew simplex unscented transform and a scaled unscented transform is adopted, which reduces the computational complexity of Sigma point selection in the standard unscented particle filter(UPF). Then the improved UPF is combined with the interacting multiple model(IMM). In addition, a self-adaptive gain modification coefficient is defined for solving the low-accuracy problem caused by the Sigma point reduction. Finally, the validity and superiority of the proposed algorithm is verified in comparison with traditional the IMM-PF and recent IMM-UPF.

Keywords: dynamic acoustic array tracking; interacting multiple model; unscented particle filter; Sigma point.

0 引 言

运动声阵列跟踪系统(DAA-TS)是由声学传感器与运动载体(如智能子弹药)组成的一种被动式目标跟踪系统,利用机动目标辐射声信号估计目标方位信息,再通过方位信息的变化估计出目标的运动参数(距离、速度、加速度等),从而实现对目标的实时跟踪.运动声阵列跟踪技术本质上属于一种纯方位目标跟踪^[1],由于跟踪系统状态空间模型的强非线性、目标机动状况的随机性以及系统弱观测性,使得目标跟踪的实现具有很大的难度.

通常影响DAA-TS跟踪精度的主要因素包括:跟

踪模型和滤波估计算法. 1)跟踪模型问题主要研究跟踪系统的状态模型是否符合目标实时运动模式,由于单一固定的状态模型往往无法满足机动目标跟踪的要求^[2],需要通过多模型切换的方式实现跟踪系统模型与目标运动模式的匹配,若在保证较高的跟踪精度,则必须确保滤波器的动态模型与目标实际运动相吻合.交互式多模型(IMM)理论^[3-4]很好地解决了多模型切换问题,并被引入到不同类型的目标跟踪系统中^[5-7]. 2)滤波估计问题是目标跟踪的另一个关键问题,被动声目标探测系统是一个仅有角测量的弱观测性系统,其状态空间模型具有较强的非线性

收稿日期: 2016-12-08; 修回日期: 2017-03-14.

基金项目: 国家自然科学基金项目(61263005).

作者简介: 邸忆(1987—),男,博士生,从事声学目标探测及跟踪的研究;顾晓辉(1964—),男,教授,博士生导师,从事目标探测及跟踪、弹药智能化、装备可靠性等研究.

†通讯作者. E-mail: gxiaohui@njust.edu.cn

特征. 对于一般非线性状态估计问题, 可采用 Kalman 滤波相关算法^[8-9], 但在强非线性和非高斯条件下, 上述 Kalman 滤波算法在跟踪状态估计时仍会发生滤波发散^[10-11], 从而导致跟踪精度较低的问题. 粒子滤波算法(PF)^[12]是一种基于贝叶斯估计的非线性滤波算法, 在处理非高斯非线性时变系统的参数估计和状态滤波问题方面有独到的优势. 在近几年的研究中, 国内外学者提出了一类基于建议分布函数选择的优化粒子滤波算法^[13-15], 其中无迹粒子滤波(UPF)^[13]算法是无迹变换(UT)与 PF 算法的结合, 先由 UT 变换产生建议分布, 再通过粒子滤波进行状态估计, 由于同时继承了 UT 变换和 PF 算法的优点, UPF 算法在目标跟踪领域得到了广泛的关注.

针对运动声阵列对地面声目标跟踪问题, 文献[5]提出了一种自适应交互式多模型无迹粒子滤波算法, 将 UPF 与 IMM 算法相结合, 并通过实时修正测量协方差和状态协方差, 增加跟踪系统的自适应调节能力, 从而保证了跟踪精度. 然而, 由于 UPF 算法的精度很大程度上取决于 Sigma 点的选取方式^[16-17], 传统 UPF 通过对称选取的方式取得较多的 Sigma 点, 虽能保证较高的跟踪精度, 但付出了很大的计算代价, 因此文献[5]所提出的 IMM-UPF 算法并不能满足被动声目标跟踪系统对跟踪实时性的要求. 针对该问题, 本文提出一种改进 UPF 的自适应 IMM(IMM-IUPF) 目标跟踪算法. 该算法延续文献[5]的跟踪模型, 采用最小斜度单形无迹变换^[18]的 Sigma 点选取策略, 同时引入变尺度无迹变换^[19], 有效缩减 UPF 样本选取计算量; 通过定义自适应增益修正系数, 弥补样本点缩减造成的精度降低问题, 最后通过与 IMM-UPF 算法以及传统 IMM-PF 算法进行仿真对比, 验证本文所提方法的实用性.

1 运动声阵列跟踪系统模型

运动声阵列对地面二维声学目标的跟踪示意图如图 1 所示, S_1, S_2, S_3, S_4 组成四传声器十字阵列.




图 1 运动声阵列对二维声目标信号检测

在实际情况中, 阵列工作距离超过 1 000 m, 远大于其阵列孔径和目标几何尺寸, 因此远场声学探测时, 地面目标可视为点声源. 弹载声阵列系统的运动状态为 $X_B = [x_B, y_B, z_B, \dot{x}_B, \dot{y}_B, \dot{z}_B, \ddot{x}_B, \ddot{y}_B, \ddot{z}_B]$, 二维目标的运动状态为 $X_T = [x_T, y_T, 0, \dot{x}_T, \dot{y}_T, 0, \ddot{x}_T, \ddot{y}_T, 0]$. 根据对运动声阵列跟踪系统的坐标模型的建立及各个坐标模型之间的转换关系可知, 弹目相对运动状态表示为 $X(k) = X_T(k) - X_B(k)$.

在惯性坐标系中, 跟踪系统的状态方程为

$$X(k) = X_T(k) - X_B(k), \quad (1)$$

其中 $X(k) \in R^n$ 是 k 时刻目标相对声阵列的运动状态向量. 设 $X^a(k)$ 为扩维后状态变量, 则有

$$X^a(k) = \begin{bmatrix} X(k) \\ \xi(k) \end{bmatrix} = \begin{bmatrix} F(k-1) & 1 \\ 0 & D_1(k-1) \end{bmatrix} \begin{bmatrix} X(k-1) \\ \xi(k-1) \end{bmatrix} + \begin{bmatrix} 0 \\ \nu(k) \end{bmatrix}. \quad (2)$$

其中: $F(k) \in R^n$ 是状态转移矩阵; $\xi(k) = D_1(k) \times \xi(k-1) + \nu(k)$ 是系统状态有色噪声, $\nu(k) \in R^n$ 是均值为零、协方差为 $Q(k)$ 的白噪声. 采用扩展状态变量的方法将有色动态系统噪声转化为白噪声来处理^[1].

动态系统在有色噪声条件下的观测方程为

$$Z(k) = H(k) + \zeta(k). \quad (3)$$

其中: $H(k) = \begin{cases} \arctan(r_k/z_k), & x_k \cdot y_k > 0; \\ \arctan(r_k/z_k) + \pi/2, & x_k \cdot y_k < 0; \end{cases}$

$r(k) = \sqrt{x_k^2 + y_k^2}$; $\zeta(k) = D_2(k)\zeta(k-1) + \omega(k)$ 是测量有色噪声, $\omega(k) \in R^n$ 是均值为零、协方差是 $R(k)$ 的白噪声. 由式(2)与(3)构成运动声阵列跟踪系统在有色噪声条件下的跟踪系统模型.

2 无迹粒子滤波及改进

2.1 传统粒子滤波

粒子滤波的基本思想^[12]为: 1) 根据先验分布抽取样本点对待估计量进行描述; 2) 由量测值计算样本似然度, 即样本概率权重; 3) 重采样, 对原样本组进行定量等加权样本选取, 选择最佳样本; 4) 对以上步骤进行迭代, 使样本集逼近目标真实状态. 根据该思想, 粒子滤波能够在状态空间中搜索到一组最佳样本对概率密度函数 $p(X_k|Z_k)$ 进行近似, 以样本均值计算代替积分运算, 以实现目标状态的最小方差估计.

2.2 无迹粒子滤波

无迹粒子滤波(UPF)将 UT 变换与标准粒子滤波相结合, 通过无味变换在状态向量附近选取有限个采样点, 即为 Sigma 点, 再由 Sigma 点得到状态向量的近似统计特性, 由于 UT 变换避免了粒子滤波过程中非

线性函数的近似线性化,后验概率分布及协方差的准确度得到提升^[5]. UPF的基本过程如下.

1) 初始化. 根据系统均值 $\bar{X}^a(k)$ 及协方差 P_k , 计算 $2n_x + 1$ 个 Sigma 点 $X_{i,k}^a$ 及相应权值 W_i , 即

$$X_{i,k}^a = \begin{cases} \bar{X}_{i,k}^a, & i = 0; \\ \bar{X}_{i,k}^a + (\sqrt{(n_x + \lambda)P_k^a})_i, & i = 1, 2, \dots, n_x; \\ \bar{X}_{i,k}^a - (\sqrt{(n_x + \lambda)P_k^a})_i, & i = n_x + 1, \dots, 2n_x. \end{cases}$$

$$W_i = \begin{cases} \lambda / (n_x + \lambda), & i = 0; \\ 1 / [2(n_x + \lambda)], & i = 1, 2, \dots, 2n_x. \end{cases}$$

其中: $\sqrt{(n_x + \lambda)P_k^a}$ 是矩阵平方根 $(n_x + \lambda)P_k^a$ 第 i 行(列)向量; 系数 $\lambda = \alpha^2(n_x + \kappa) - n_x$ 是缩放比例参数, α 是 Sigma 点到中心点的距离, κ 是待选系数, 用以确保 $(n_x + \lambda)P_k^a$ 是半正定矩阵.

2) 计算的均值及协方差估计

$$\bar{X}_{k|k-1}^a = \sum_{i=0}^{2n_x} W_i X_{i,k|k-1}^a,$$

$$P_{k|k-1}^a = \sum_{i=0}^{2n_x} W_i (X_{i,k|k-1}^a - \bar{X}_{i,k|k-1}^a) \cdot (X_{i,k|k-1}^a - \bar{X}_{i,k|k-1}^a)^T.$$

3) 时序更新. 设 $k - 1$ 时刻的状态向量及协方差分别为 $\hat{X}_{k-1|k-1}^a$ 和 $P_{k-1|k-1}^a$, 由式(2)计算 k 时刻的 Sigma 点 $\bar{X}_{i,k|k-1}^a$ 及权值 W_i , 再由状态方程得到一步状态预测及协方差矩阵

$$X_{i,k|k-1}^a = F_{i,k-1} X_{i,k-1}^a,$$

$$\bar{X}_{i,k|k-1}^a = \sum_{i=0}^{2n_x} W_i X_{i,k|k-1}^a,$$

$$P_{i,k|k-1}^a = \sum_{i=0}^{2n_x} W_i (X_{i,k|k-1}^a - \bar{X}_{i,k|k-1}^a) \cdot (X_{i,k|k-1}^a - \bar{X}_{i,k|k-1}^a)^T.$$

4) 量测更新. 由系统量测方程得到量测更新

$$Z_{i,k|k-1} = H_{i,k-1} X_{i,k-1}^a,$$

$$\bar{Z}_{i,k} = \sum_{i=0}^{2n_x} W_i Z_{i,k|k-1},$$

$$P_{Z_k X_k}^a = \sum_{i=0}^{2n_x} W_i (X_{i,k|k-1}^a - \bar{X}_{i,k|k-1}^a) \cdot (Z_{i,k|k-1} - \bar{Z}_{i,k})^T,$$

$$K_k = P_{Z_k X_k}^a (P_{Z_k X_k}^a)^{-1},$$

$$P_k^a = P_{i,k|k-1}^a - K_k P_{Z_k X_k}^a K_k^T,$$

$$\bar{X}_{i,k}^a = \bar{X}_{i,k|k-1}^a + K_k (Z_{i,k} - \bar{Z}_{i,k|k-1}).$$

5) 重要性采样与粒子权重更新, 从分布 $N(\bar{X}_{i,k}^a, P_{i,k}^a)$ 中选取 n 个粒子, $\hat{X}_{i,k}^a \sim q(X_{i,k}^a | X_{i,k-1}^a, Z_k)$, 粒子权值为 $\bar{W}_{i,k} = \bar{W}_{i,k-1} = \frac{p(Z_k | \hat{X}_{i,k}^a) p(\hat{X}_{i,k}^a | X_{i,k-1}^a)}{q(X_{i,k}^a | X_{i,k-1}^a, Z_k)}$,

权值归一化有 $W_{i,k} = \bar{W}_{i,k} / \sum_{i=1}^n \bar{W}_{i,k}$, 则状态输出为

$$\hat{X}_{i,k}^a = \sum_{i=1}^n W_{i,k} X_{i,k}^a.$$

2.3 基于 Sigma 点选取的改进无迹粒子滤波

由上一节分析可以看出, 标准的无迹变换采用对称采样获取 $2n + 1$ 个 Sigma 点, 这种选取方式缺乏一定的灵活性. Sigma 点选取较多, 虽保证了滤波精度, 但极大影响了算法的效率, 尤其是当该算法与 IMM 相结合进行机动目标跟踪时, 其实时性表现并不理想. 为了提升计算效率, 本文采用一种减少 Sigma 采样点的优化无迹粒子滤波方法, 该方法将最小斜度单形无迹变换^[18]与变尺度无迹变换^[19]相结合, 利用最小斜度单形 Sigma 点采样代替无迹粒子滤波的对称 Sigma 点采样, 将 Sigma 点个数减少一半, 再通过引入尺度变换参数去除非高斯条件下高维状态空间非局部效应^[17]带来的较大误差. 算法具体步骤如下.

Step 1: 初始化. 计算 $n_x + 1$ 个 Sigma 点 χ_i 和权重 W_i , 引入尺度变换参数 α 和 β , 其中 α 是比例因子, 控制 Sigma 点的分布状况, 取值范围为 $[10^{-4}, 1]$; β 引入随机变量的先验分布信息. 选择初始权重 $0 \leq W_{m0} \leq 1, 0 \leq W_{c0} \leq 1$, 通过权值比例修正方法计算其他权值 W_i , 即

$$\begin{cases} W_{m0} = \frac{\lambda}{n_x + \lambda}, \\ W_{c0} = \frac{\lambda}{(n_x + \lambda) + (1 - \alpha^2 + \beta)}. \end{cases} \quad (4)$$

$$\begin{cases} W_0^m = \frac{W_{m0}}{\alpha^2} + \left(1 - \frac{1}{\alpha^2}\right); \\ W_0^c = \frac{W_{c0}}{\alpha^2} + (1 - \alpha^2 + \beta); \\ W_1 = \frac{1}{\alpha^2 \cdot 2^{n_x}} (1 - W_0^m), \quad i = 1; \\ W_2 = W_1, \quad i = 2; \\ W_0^m = W_0^c = W_i = \frac{2^{i-1}}{\alpha^2} W_1, \quad i = 3, 4, \dots, n_x + 1. \end{cases} \quad (5)$$

其中 W_i 满足 $\sum_{i=0}^{n_x+1} W_i = 1$. 根据最小斜度无迹变换可得, 一维最小斜度无迹变换单行 Sigma 点为

$$\chi_0^1 = [0], \quad \chi_1^1 = \left[\frac{-1}{\sqrt{2W_1}} \right], \quad \chi_2^1 = \left[\frac{1}{\sqrt{2W_1}} \right],$$

则 $j(j = 2, 3, \dots, n_x)$ 维扩展向量 Sigma 点为

$$\chi_i^j = \begin{cases} [\chi_0^{j-1} \ 0]^T, & i = 0; \\ \left[\chi_i^j \ \frac{-1}{\sqrt{2W_j}} \right]^T, & i = 1, 2, \dots, j; \\ \left[0_j \ \frac{1}{\sqrt{2W_j}} \right]^T, & i = j + 1. \end{cases} \quad (6)$$

那么 $\chi_i = (\chi_i^1, \chi_i^2, \dots, \chi_i^{n_x})^T$. 其中: χ_i^j 是 j 维随机变量第 i 个采样点, 0_j 是 j 维零向量. 因此, 计算 k 时刻采样点可得

$$\chi_k = \begin{bmatrix} \hat{X}_k \\ \hat{X}_k + \sqrt{\alpha^2(n_x + \lambda)}\chi_1 \\ \vdots \\ \hat{X}_k + \sqrt{\alpha^2(n_x + \lambda)}\chi_{n_x} \end{bmatrix}^T. \quad (7)$$

Step 2: 时序更新. Sigma 点通过系统方程传播, 估计 $\hat{X}_{k|k-1}$ 的状态均值和协方差为

$$\bar{X}_{k|k-1} = \sum_{i=0}^{n_x} W_i \chi_{i,k|k-1}; \quad (8)$$

$$P_{k|k-1} = \sum_{i=0}^{n_x} W_i (\chi_{i,k|k-1} - \bar{X}_{k|k-1}) \times (\chi_{i,k|k-1} - \bar{X}_{k|k-1})^T. \quad (9)$$

Step 3: 量测更新. 计算量测预测的均值和协方差, 即

$$Z_{k|k-1} = H_{i,k-1} \chi_{i,k-1}, \quad (10)$$

$$\bar{Z}_{k|k-1} = \sum_{i=0}^{n_x} W_i Z_{i,k|k-1}, \quad (11)$$

$$P_{Z_k} = \alpha^2 \sum_{i=0}^{n_x} W_i (Z_{i,k|k-1} - \bar{Z}_{k|k-1}) \times (Z_{i,k|k-1} - \bar{Z}_{k|k-1})^T, \quad (12)$$

$$P_{XZ} = \sum_{i=0}^{n_x} W_i (X_{i,k|k-1} - \bar{X}_{k|k-1}) \times (X_{i,k|k-1} - \bar{X}_{k|k-1})^T. \quad (13)$$

Step 4: 滤波增益和协方差计算.

$$K_k = P_{XZ} P_{Z_k}^{-1}, \quad (14)$$

$$X_k = \bar{X}_{k-1} + K_k (Z_k - \bar{Z}_{k|k-1}), \quad (15)$$

$$P_k = P_{k|k-1} - K_k P_{Z_k}. \quad (16)$$

Step 5: 重要性采样及粒子权值更新. 从重要密度函数中抽取 n 个粒子, $\hat{X}_{k,i}^a \sim N(X_{k,i}^a; X_{k,i}^a, P_{k,i})$, 粒子权重更新为 $\bar{W}_{k,i} = p(Z_{k,i} | X_{k,i}^a) \bar{W}_{k-1,i}$, 归一化有 $W_{k,i} = \bar{W}_{k,i} / \sum_{i=1}^n \bar{W}_{k,i}$; 如果 $n_{\text{eff}} < n_{\text{th}}$, 则设 $W_{k,i} = 1/n$, 重采样 $\{X_{k,i}^a, W_{k,i}\}_{i=1}^n$, 从而状态输出为 $\hat{X}_{k,i}^a = \sum_{i=1}^n W_{k,i} X_{k,i}^a$.

3 基于IUPF的运动声阵列IMM目标跟踪算法

3.1 IMM目标跟踪模型

设运动声阵列对地目标跟踪过程中有 m 个模型进行多模型交互, 则状态方程及观测方程为

$$X^a(k, l) = \begin{bmatrix} F(k-1, l) & 1 \\ 0 & D_1(k-1, l) \end{bmatrix} \times \begin{bmatrix} X(k-1, l) \\ \xi(k-1, l) \end{bmatrix} + \begin{bmatrix} 0 \\ \nu(k-1, l) \end{bmatrix}, \quad (17)$$

$$Z(k, l) = H(k, l)X(k, l) + \zeta(k, l) = \begin{cases} \arctan(r_{k,l}/z_{k,l}), & x_{k,l} \cdot y_{k,l} > 0 \\ \arctan(r_{k,l}/z_{k,l}) + \pi/2, & x_{k,l} \cdot y_{k,l} < 0 \end{cases} + D_2(k, l)\zeta(k-1, l) + \omega(k, l). \quad (18)$$

其中: $l = 1, 2, \dots, m$, 模型转换符合马尔科夫链.

3.2 目标跟踪过程

Step 1: 模型交互. 初始化 k 时刻的状态变量及协方差, 给定模型转移概率和初始模型概率, 则交互运算有

$$\hat{X}_{k-1|k-1,j} = \sum_{l=1}^m X_{k-1|k-1,l} \mu_{k-1,l|j}, \quad (19)$$

$$\tilde{X}_{k-1|k-1,lj} = X_{k-1|k-1,l} - \hat{X}_{k-1|k-1,j}, \quad (20)$$

$$P_{k-1|k-1,j} = \sum_{l=1}^m \mu_{k-1,l|j} \cdot P_{k-1|k-1,l} + \mu_{k-1,l|j} \cdot (\tilde{X}_{k-1|k-1,lj} \cdot \tilde{X}_{k-1|k-1,lj}^T). \quad (21)$$

其中: $\mu_{k-1,l|j} = 1/c_{k-1,j}$ 是混合概率, $c_{k-1,j}$ 是归一化因子, 且 $c_{k-1,j} = \sum_{l=1}^m \prod_{lj} \mu_{k-1,l}$.

Step 2: IUPF滤波. 对每个模型分别进行 n_x 个粒子的随机采样 $\{X_{k-1,j}^i\}_{i=1}^{n_x}$, 根据式(4)~(16)计算每个粒子的时间更新值

$$\hat{X}_{k|k-1,j}^i = \bar{X}_{k|k-1,j}^i + K_k (Z_k - \bar{Z}_k), \quad (22)$$

$$P_{k,j} = P_{k|k-1,j} - K_{k,j} P_{Z_{k,j}} K_{k,j}^T, \quad (23)$$

$$\bar{Z}_{k,j} = \sum_{i=0}^{n_x} W_i Z_{i,k}. \quad (24)$$

进行IUPF重要性采样, 粒子权值系数更新及重采样, 得到第 j 个模型的状态估计值为

$$\hat{X}_{k|k-1,j}^\alpha = \sum_{i=1}^n W_{k,i} X_{k|k-1,j}^i. \quad (25)$$

计算粒子测量残差及其协方差

$$\varepsilon_{k,i} = Z_{k,i} - \bar{Z}_{k|k-1,i}, \quad (26)$$

$$S_\varepsilon = \sum_{i=0}^{n_x} (Z_{k,i} - \bar{Z}_{k|k-1,i})(Z_{k,i} - \bar{Z}_{k|k-1,i})^T. \quad (27)$$

Step 3: 模型概率更新. 计算模型似然函数

$$A_{k,j} = \frac{1}{n_x} \sum_{i=1}^{n_x} N(\varepsilon_{k,i}; 0, S_\varepsilon), \quad (28)$$

则各模型概率更新为

$$\mu_{k-1,l|j} = \frac{1}{c_k} A_{k,j} c_{k-1,j}, \quad (29)$$

其中 $c_k = \sum_{j=1}^m A_{k,j} c_{k-1,j}$.

Step 4: 融合输出.

$$\hat{X}_{k|k} = \sum_{j=1}^m \mu_{k,j} \hat{X}_{k|k,j}. \quad (30)$$

3.3 自适应增益修正

由式(30)发现, 粒子滤波状态估计与粒子状态以及对应权值存在线性关系, 而粒子权值和粒子状态分别与重要性密度函数和一步预测协方差及增益相关, 而由式(12)、(14)和(16)可知, 协方差以及增益均与测量残差 $Z_{i,k|k-1} - \bar{X}_{k|k-1}$ 存在线性关系, 因此, 通过式(26)和(27)定义一个自适应度修正系数 $\theta_{i,k}$ 作为粒子协方差和增益的调节参数, 即

$$\theta_{i,k} = \begin{cases} 1, & \text{tr}(\varepsilon_{k,i} \varepsilon_{k,i}^T) \leq \text{tr}(S_\varepsilon); \\ \frac{\text{tr}(\varepsilon_{k,i} \varepsilon_{k,i}^T) - \text{tr}(S_\varepsilon)}{\text{tr}(\varepsilon_{k,i} \varepsilon_{k,i}^T)}, & \text{tr}(\varepsilon_{k,i} \varepsilon_{k,i}^T) > \text{tr}(S_\varepsilon). \end{cases} \quad (31)$$

由式(31)可知: $0 < \theta_{i,k} < 1$. 分析式(23)~(27)发现, 若目标发生机动, 则导致观测残差明显变化, 此时 $0 < \theta_{i,k} < 1$; 而目标未发生机动时, 观测误差将保持稳定状态, $\theta_{i,k} = 1$. 因此, 当判定目标发生机动后, 可借助自适应修正系数 $\theta_{i,k}$ 对粒子协方差进行修正, 从而自适应地调整滤波增益, 进而改善跟踪精度. 自适应增益修正具体方法如下:

$$P'_{Z_k Z_k} = \sum_{i=0}^n \frac{W_i}{\theta_{i,k}} (Z_{k,i} - \bar{Z}_{k|k-1,i})(Z_{k,i} - \bar{Z}_{k|k-1,i})^T, \quad (32)$$

$$P'_{Z_k X_k} = \sum_{i=0}^n \frac{W_i}{\theta_{i,k}} (X_{k,i}^a - \bar{X}_{k|k-1,i}^a)(Z_{k,i} - \bar{Z}_{k|k-1,i})^T, \quad (33)$$

$$K'_k = P'_{Z_k X_k} (P'_{Z_k Z_k})^{-1}, \quad (34)$$

$$P'_k = \frac{1}{\theta_{i,k}} P_{k|k-1,i}^a - K'_k P'_{Z_k Z_k} K_k'^T. \quad (35)$$

通过式(32)~(35)自适应地调节粒子协方差及滤波增益, 再经过滤波迭代过程, 对当前时刻协方差进行调整, 从而在粒子权值更新时, 更加有利于缓解降低运动模型偏差所成的估计精度下降问题.

4 仿真实验及分析

4.1 实验参数设定

为了验证本文所提算法的有效性, 采用 Matlab R2015a 进行单目标跟踪仿真实验. 实验环境为 Dell PC, CPU 主频 2.3 GHz, 内存 2 GB. 设定目标初始状态为 $X_0 = [300, 400, 0, 15, 25, 0]$, 运动时间为 100 s, 系统采样周期 $T = 1$ s, 目标运动模式如下: 1 ~ 20 s 为匀速运动模式, x 、 y 方向初始速度分别为 5 m/s 和 25 m/s; 21 ~ 40 s 为弱机动模式, 其中 x 、 y 方向加速度分别为 3 m/s^2 和 -3 m/s^2 ; 61 ~ 80 s 为强机动模式, 且 x 、 y 方向加速度分别为 10 m/s^2 和 -10 m/s^2 ; 81 ~ 100 s 保持匀速运动, 因此, 交互模型包含匀速直线运动模型以及匀速转弯模型, 设定模型初始概率分别为 0.6 和 0.4, 模型转移概率为 $[0.9, 0.1; 0.1, 0.9]$. 初始协方差矩阵为 $P_0 = \text{diag}(10^{-4} \times [4, 1, 0.25, 4, 1, 0.25])$, 观测噪声及系统状态噪声方差为 50, $D_1 = 0.04$, $D_2 = 0.8$, 方位角测量误差为 0.1 m/rad. 对算法基本参数设定为: $\alpha = 0.01$, $\beta = 2$, $\kappa = 0$, 初始粒子数为 500, 初始自适应修正系数 $\theta = 0$, 对本文所提算法进行 100 次 Monte Carlo 仿真实验.

4.2 跟踪性能分析

同等条件下分别对 IMM-PF 和文献[5]提出的 IMM-UPF 算法进行仿真实验. 图2和图3分别给出了目标在 x 轴和 y 轴方向上的距离均方根误差.




图2 x 方向距离均方根误差




图3 y 方向距离均方根误差

从图2和图3可以看出,本文所提算法的目标距离估计均方根误差明显低于传统IMM-UP算法,略高于IMM-UPF算法。

3种算法在 x 轴和 y 轴方向的速度估计均方根误差比较如图4和图5所示。可以看出,本文所提算法的速度估计精度明显高于传统IMM-PF算法,接近于IMM-UPF算法。




图4 x 方向速度均方根误差




图5 y 方向速度均方根误差

不同算法跟踪性能的量化比较统计结果如表1所示,本文所提算法在 x, y 方向的距离估计均方根误差均值分别为12.81 m和13.35 m,速度估计均方根误差均值分别为8.71 m/s和7.91 m/s,相对于IMM-PF,本文算法的跟踪精度提升了35.56%~56.24%;相比较

于IMM-UPF算法,本文算法的跟踪性能略有降低,但仍能满足弹载声阵列对地面目标跟踪的基本要求。

表1 不同算法跟踪性能对比

RMSE	IMM-PF	IMM-UPF ^[5]	本文算法
x 方向位置/m	19.88	11.73	12.81
y 方向位置/m	30.27	12.55	13.35
x 方向速度/(m/s)	30.27	12.55	13.35
y 方向速度/(m/s)	17.64	7.45	7.91
计算时间/s	0.596	0.816	0.412

4.3 算法性能分析

本文算法采用最小斜度单形无迹变换与变尺度无迹变换方法,那么UPF在每一时刻对每个粒子需要计算7个Sigma点,进而IUPF则为4,从而在算法过程中的采样点选取数明显降低,进而使得交互式多模型算法计算复杂度由 $O[m \times (2n + 1)N]$ 降低至 $O[m \times (n + 2)N]$,因此,单次蒙特卡洛计算时间明显小于其他两种算法,约为IMM-UPF算法运算量的一半。由此可知,本文算法在保证基本性能的情况下,有效提升了计算效率。

为了分析IMM-IUPF算法中的滤波增益修正系数对跟踪滤波效果的影响,对算法分别进行考虑增益修正系数和不考虑增益修正系数两组实验,从目标运动的5个阶段中分别抽取第10 s、25 s、50 s、65 s和90 s时目标在 x, y 方向的位置状态估计值,对算法进行两种条件下性能比较,结果如表2所示,其中,条件1和条件2分别代表加入滤波增益修正和未加入增益修正。此外,分析了本文算法中关键参数:粒子数 N 和初始协方差矩阵 P_0 对滤波效果的影响,对本文算法进行不同参数设定,其算法性能对比结果见表3。

表2 自适应增益修正对目标跟踪估计影响

参量	—	10 s	25 s	50 s	65 s	90 s
真实值 ($x/m, y/m$)	—	435, 625	684, 976	2 175, 485	3 220, 40	1 250, 305 0
观测值 ($x/m, y/m$)	—	421, 599	702, 959	2 203, 513	3 229, 31	1 236, 308 0
条件1	修正系数 $\theta_{i,k}$	1	0.628 5	1	0.379 1	1
	估计值 ($x/m, y/m$)	433, 631	691, 985	2 187, 469	3 207, 27	1 259, 306 8
条件2	估计值 ($x/m, y/m$)	433, 631	707, 100 8	2 126, 432	3 181, 16	1 221, 309 2

表3 不同参数设定下3种粒子滤波性能对比

参数	算法	x -RMSE/m	y -RMSE/m	计算时间/s
$N = 500, P_0 = (10^{-4} \times [8, 2, 0.25, 8, 2, 0.25])$	IMM-PF	23.37	32.95	0.603
	IMM-UPF	12.87	13.51	0.826
	IMM-IUPF	13.79	14.04	0.419
$N = 500, P_0 = (10^{-4} \times [4, 1, 0.25, 4, 1, 0.25])$	IMM-PF	19.88	30.27	0.596
	IMM-UPF	11.73	12.55	0.816
	IMM-IUPF	12.81	13.35	0.412
$N = 1\ 000, P_0 = (10^{-4} \times [4, 1, 0.25, 4, 1, 0.25])$	IMM-PF	17.26	26.37	1.356
	IMM-UPF	10.01	10.56	1.802
	IMM-IUPF	10.36	11.03	0.861

分析表2可知:目标在匀速运动阶段的第10s、50s和90s,自适应增益修正系数为1,跟踪过程中不发生滤波增益修正;在目标发生机动的情况下,如第25s和第65s,修正系数分别为0.6285和0.3791,因此,及时对滤波增益进行修正,能够使机动目标的跟踪误差保持在较小的范围内。而未加入自适应增益修正的情况下,目标状态估计的误差在目标发生机动时显著增加,并持续影响后续时刻的跟踪精度。

从表3中可以看出,在不同参数设定下,本文算法和IMM-UPF^[5]均保持了较低的跟踪误差,并且随着粒子数目的增加,IMM-IUPF的跟踪精度逐渐接近IMM-UPF的跟踪精度,但在计算时间方面,前者明显小于后者,说明IMM-IUPF算法更能够满足弹载声阵列跟踪系统对地面目标跟踪的实时性和精度要求。

5 结 论

本文针对交互式多模型目标跟踪融合粒子滤波算法的实时性较差的问题,提出一种基于Sigma点选取的粒子滤波交互式多模型目标跟踪算法。该算法采用最小斜度单形无迹变换和变尺度无迹变换方法,有效地减少了粒子滤波中样本选取的计算时间,再通过引入自适应增益修正系数,提高了目标跟踪算法的稳定性,保证了目标跟踪精度。因此,本文所提算法为运动声阵列目标探测跟踪系统的研究提供了具有较高价值的理论基础。

样本点个数的大幅降低难免造成粒子贫乏现象的出现,因此,下一步工作重心是在已有的理论基础上对粒子滤波重采样步骤的优化,力求得到更加符合弹载跟踪系统总体性能要求的快速目标跟踪算法。

参考文献(References)

- [1] Liu Y L, Gu X H. Deterministic core particle swarm and derivation of CRLB in particle filter tracking algorithm[J]. Control and Decision, 2012, 27(5): 741-746.
- [2] Chen Z, Qu Y, Xi Z, et al. A multiple model tracking algorithm based on an adaptive particle filter[J]. Asian J of Control, 2016, 18(5): 1877-1890.
- [3] Cai Z P, Dai D C, Niu C, et al. Interacting multiple model algorithm with cubature particle filter[J]. Systems Engineering and Electronics, 2014, 36(12): 2366-2370.
- [4] Fu X, Shang Y, Yuan H. Improved diagonal interacting multiple model algorithm for maneuvering target tracking based on H_∞ filter[J]. IET Control Theory and Applications, 2015, 9(12): 1887-1892.
- [5] Liu Y L, Gu X H. Adaptive interacting multiple model unscented particle filter for dynamic acoustic array[J]. Applied Mechanics and Materials, 2013, 301: 407-413.
- [6] Jia B, Blasch E, Pham K D, et al. Space object tracking and maneuver detection via interacting multiple model cubature kalman filters[C]. 2015 IEEE Aerospace Conf. Montana: IEEE, 2015: 1-8.
- [7] Vasuhi S, Vaidehi V. Target tracking using interactive multiple model for wireless sensor network[J]. Information Fusion, 2016, 27(c): 41-53.
- [8] Duan Z, Li X. A new nonlinear state estimator using the fusion of multiple extended Kalman filters[C]. The 18th Int Conf on Information Fusion. Washington: IEEE, 2015: 90-97.
- [9] Gustafsson F, Hendeby G. Some relations between extended and unscented Kalman filters[J]. IEEE Trans on Signal Processing, 2012, 60(2): 545-555.
- [10] Rigatos G G. A derivative-free Kalman filtering approach to state estimation-based control of nonlinear systems[J]. IEEE Trans on Industrial Electronics, 2012, 59(10): 3987-3997.
- [11] Kong L, Kong L F, Wu P L. Adaptive gaussian particle filter for nonlinear state estimation[C]. The 31st Chinese Control Conf. Hefei: IEEE, 2012: 2146-2150.
- [12] 李天成, 范红旗, 孙树栋. 粒子滤波理论、方法及其在多目标跟踪中的应用[J]. 自动化学报, 2015, 41(12): 1981-2002.
(Li T C, Fan H Q, Sun S D. Particle filtering: Theory, approach, and application for multitarget tracking[J]. Acta Automatic Sinica, 2015, 41(12): 1981-2002.)
- [13] Van Der Merwe R, Doucet A, De Freitas N, et al. The unscented particle filter[C]. Conf and Workshop on Neural Information Processing Systems. Denver: MIT Press, 2000: 584-590.
- [14] Rigatos G G. Extended Kalman and particle filtering for sensor fusion in motion control of mobile robots[J]. Mathematics and Computers in Simulation, 2010, 81(3): 590-607.
- [15] 张勇刚, 程然, 黄玉龙, 等. 截断的自适应容积粒子滤波器[J]. 系统工程与电子技术, 2016, 38(2): 382-391.
(Zhang Y G, Cheng R, Huang Y L, et al. Truncated adaptive cubature particle filter[J]. Systems Engineering and Electronics, 2016, 38(2): 382-391.)
- [16] 田隽, 钱建生, 李世银. 迭代最小斜度单型sigma采样UPF算法[J]. 控制与决策, 2011, 26(6): 888-892.
(Tian J, Qian J S, Li S Y. Unscented particle filter using iterated minimal skew simplex UKF[J]. Control and Decision, 2011, 26(6): 888-892.)
- [17] 赵光琼, 陈绍刚, 付奎, 等. 基于变尺度变换减少Sigma点的粒子滤波算法研究[J]. 自动化学报, 2015, 41(7): 1350-1355.
(Zhao G Q, Chen S G, Fu K, et al. A particle filter algorithm based on scaled UKF with reduced Sigma points[J]. Acta Automatic Sinica, 2015, 41(7): 1350-1355.)
- [18] Julier S J. The spherical simplex unscented transformation[C]. Proc of the 2003 American Control Conf. Alaska: IEEE, 2003: 2430-2434.
- [19] Julier S J. The Scaled unscented transformation[C]. Proc of the 2002 American Control Conf. Alaska: IEEE, 2002: 4555-4559.