

IMM 迭代扩展卡尔曼粒子滤波跟踪算法

张俊根 姬红兵

(西安电子科技大学电子工程学院 西安 710071)

摘要: 该文提出了一种交互式多模型(IMM)迭代扩展卡尔曼粒子滤波机动目标跟踪算法。该算法在多模型中使用了改进的粒子滤波器,通过对迭代扩展卡尔曼滤波(IEKF)的测量更新按照高斯牛顿方法进行修正,减小了非线性滤波带来的线性化误差,然后利用修正的 IEKF 来产生粒子滤波的重要性密度函数,使其融入最新观测信息。最后将所提算法与交互式多模型粒子滤波(IMMPF)进行了比较,仿真结果表明该算法具有更好的跟踪性能。

关键词: 机动目标跟踪; 交互式多模型; 迭代扩展卡尔曼滤波; 粒子滤波

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2010)05-1116-05

DOI: 10.3724/SP.J.1146.2009.00298

IMM Iterated Extended Kalman Particle Filter Based Target Tracking

Zhang Jun-gen Ji Hong-bing

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: A new algorithm based on Interacting Multiple Model (IMM) iterated extended Kalman particle filter is proposed for maneuvering target tracking, which uses an improved Particle Filter (PF) in multiple model. First, the Iterated Extended Kalman Filter (IEKF) is modified by providing a new measurement update based on Gauss-Newton iteration, thus the linearity error is reduced. Then the modified IEKF is used to generate the importance density function of PF, which integrates the latest observation into system state transition density. Finally, simulation results are presented to demonstrate the improved performance of the proposed method over Interacting Multiple Model Particle Filter (IMMPF).

Key words: Maneuvering target tracking; Interacting Multiple Model (IMM); Iterated Extended Kalman Filter (IEKF); Particle Filter (PF)

1 引言

在机动目标跟踪中,交互式多模型(Interacting Multiple Model, IMM)算法是一种很有效的方法^[1,2]。该方法的特点是通过马尔可夫转移概率对多模型进行切换,自动调节滤波带宽,能跟踪目标的任意机动。但其各模型滤波算法通常采用卡尔曼滤波或扩展卡尔曼滤波算法,对于非线性、非高斯系统模型,其滤波性能将大大降低。

近年来,粒子滤波器被应用于目标跟踪,以解决其中的非线性、非高斯问题^[3]。文献[4,5]提出了交互式多模型粒子滤波(Interacting Multiple Model Particle Filter, IMMPF)算法,将其应用于机动目标的跟踪。但由于标准粒子滤波算法是用系统状态的转移概率作为重要性密度函数,没有利用最新观测信息,使得产生的粒子样本经常集中在后验概率分布的尾部,从而导致粒子选择的盲目性,降低了滤

波精度^[6],另外,粒子滤波通常采用大量的粒子数目,将带来很大的计算负荷,影响跟踪的实时性。

本文在文献[7]的基础上,结合 IMM 滤波的思想,提出了一种 IMM 迭代扩展卡尔曼粒子滤波算法,其多模型使用了改进的粒子滤波器,利用修正的迭代扩展卡尔曼滤波(Iterated Extended Kalman Filter, IEKF)来产生粒子滤波的重要性密度函数,减小了非线性滤波的线性化误差,同时使重要性密度函数融入了最新观测信息,更好地逼近真实状态的后验概率分布。仿真结果表明所提算法跟踪精度要高于 IMMPF,并且计算量要小得多。

2 跟踪模型

IMM 滤波算法中模型的状态方程和观测方程可以表述为^[1]

$$\mathbf{x}_{k,i} = \mathbf{F}_i(\mathbf{x}_{k-1,i}) + \mathbf{w}_{k-1,i} \quad (1)$$

$$\mathbf{z}_{k,i} = \mathbf{h}(\mathbf{x}_{k,i}) + \mathbf{v}_k \quad (2)$$

其中 $\mathbf{x}_{k,i}$ 表示在模型 $i(i=1,2,\dots,M)$ 下的目标运动状态矢量, $\mathbf{z}_{k,i}$ 是观测矢量, $\mathbf{w}_{k,i}$ 和 $\mathbf{v}_k$ 分别为过程噪声和观测噪声,假定相互独立,且服从高斯分布,协

2009-03-09 收到, 2010-01-29 改回

国家自然科学基金(60871074)资助课题

通信作者: 张俊根 zhang_jungen@sina.com

方差分别为 $\mathbf{Q}_i$ 和 $\mathbf{R}$ 。系统模型之间的转移概率用马尔可夫链表示为

$$P\{m_{k+1} = j | m_k = i\} = p_{ij}, \quad i, j = 1, 2, \dots, M \quad (3)$$

这样, 利用给定的初始状态 $\mathbf{x}_0$, 初始模型概率 $\{\mu_{0,i}\}_{i=1}^M$, 以及各个时刻的观测量 z_k , 就可以估计出目标运动状态 $\mathbf{x}_k$ 。

3 IMM 迭代扩展卡尔曼粒子滤波算法

3.1 迭代扩展卡尔曼滤波(IEKF)及其修正算法

IEKF 与 EKF 的不同之处主要在于测量更新过程, 对于 IEKF, 在得到状态预测 $\hat{\mathbf{x}}_{k|k-1}$ 及相应的协方差 $\mathbf{P}_{k|k-1}$ 后, 进行如下的迭代运算:

$$\hat{\mathbf{x}}_{k|k,0} = \hat{\mathbf{x}}_{k|k-1}, \quad \mathbf{P}_{k|k,0} = \mathbf{P}_{k|k-1} \quad (4)$$

$$\hat{\mathbf{x}}_{k|k,i+1} = \hat{\mathbf{x}}_{k|k-1} + K_{k,i} (z_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k,i}) - \mathbf{H}_{k,i} (\hat{\mathbf{x}}_{k|k-1} - \hat{\mathbf{x}}_{k|k,i})) \quad (5)$$

$$\mathbf{P}_{k|k,i+1} = (\mathbf{I} - K_{k,i} \mathbf{H}_{k,i}) \mathbf{P}_{k|k-1} \quad (6)$$

式中 $\mathbf{H}_{k,i} = \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k,i}}$, $K_{k,i} = \mathbf{P}_{k|k-1} (\mathbf{H}_{k,i})^T (\mathbf{H}_{k,i} \mathbf{P}_{k|k-1} (\mathbf{H}_{k,i})^T + \mathbf{R}_k)^{-1}$, i 为迭代次数。迭代终止条件在不同的情况下可以不同, 一个通常采用的迭代终止准则是: $\|\hat{\mathbf{x}}_{k,i+1} - \hat{\mathbf{x}}_{k,i}\| \leq \mathbf{V}_{th}$, 其中 $\|y\| = \sqrt{y^T y}$ 是 $y \in \mathbf{R}^m$ 上的普通范数, $\mathbf{V}_{th}$ 为预设门限值。

文献[8]证明了 IEKF 迭代结果与高斯牛顿方法估计的结果是一致的, 因此 IEKF 可以保证全局收敛。理论上, IEKF 优于 EKF 和 MVEKF, 然而, 实际中并不完全如此, 因为: (1) 文献[8]给出的结论是建立在必须满足局部线性化条件的假设之上, 也就是说, 状态估计必须足够接近于真实值, 这在很多应用中不是总能成立, 因为初始估计误差可能会很大。(2) 高斯牛顿方法虽然能保证全局收敛, 但不能保证达到似然面^[9]。另外, 预设门限 $\mathbf{V}_{th}$ 对迭代过程很关键, 要选择一个合适的值不容易。

为此, 对 IEKF 进行修正。为方便起见, 把当前观测与状态估计合并为一个“观测”向量, 因此, 得到扩展的观测量与测量方程:

$$\mathbf{Z} = [z, \mathbf{x}^-]^T \quad (7)$$

$$\mathbf{g}(\mathbf{x}) = [\mathbf{h}(\mathbf{x}), \mathbf{x}]^T \quad (8)$$

其中 $\mathbf{x}^-$ 为迭代初始值, $\mathbf{Z}$ 服从高斯分布 $\mathbf{N}(\mathbf{g}(\mathbf{x}), \tilde{\mathbf{Q}})$, $\tilde{\mathbf{Q}} = \begin{bmatrix} \mathbf{R} & \mathbf{0} \\ \mathbf{0} & \mathbf{P} \end{bmatrix}$, $\mathbf{P}$ 是 $\mathbf{x}^-$ 的协方差阵。这样, 更

新问题就可以描述成: 给定 $\mathbf{Z}, \tilde{\mathbf{Q}}$ 和 $\mathbf{g}$, 找到更好的状态估计和对应的协方差。

按照高斯牛顿方法, 对于目标函数:

$$f(\xi) = \frac{1}{2} \|\mathbf{r}(\xi)\|^2 \quad (9)$$

其中函数 $\mathbf{r}: \mathbf{R}^m \rightarrow \mathbf{R}^m$ 是二阶可微的, 迭代公式可表示为

$$\mathbf{x}_{i+1} = \mathbf{x}_i - (\mathbf{r}'(\mathbf{x}_i)^T \mathbf{r}'(\mathbf{x}_i))^{-1} \mathbf{r}'(\mathbf{x}_i)^T \mathbf{r}(\mathbf{x}_i) \quad (10)$$

定义:

$$\mathbf{r}(\xi) = \mathbf{S}(\mathbf{Z} - \mathbf{g}(\xi)) \quad (11)$$

其中 $\mathbf{S}$ 满足 $\mathbf{S}^T \mathbf{S} = \tilde{\mathbf{Q}}^{-1}$, 并有 $\mathbf{r}'(\xi) = -\mathbf{S} \mathbf{g}'(\xi)$, $\mathbf{g}'(\xi) = \frac{\partial \mathbf{g}(\xi)}{\partial \xi} = [\mathbf{H}, \mathbf{I}]^T$ 。将式(7), 式(8)和式(11)

代入式(10), 并利用矩阵求逆引理可得

$$\begin{aligned} \mathbf{x}_{i+1} &= \mathbf{x}_i + \left(\mathbf{g}'(\mathbf{x}_i)^T \mathbf{S}^T \mathbf{S} \mathbf{g}'(\mathbf{x}_i) \right)^{-1} \mathbf{g}'(\mathbf{x}_i)^T \\ &\quad \cdot \mathbf{S}^T \mathbf{S} (\mathbf{Z} - \mathbf{g}(\mathbf{x}_i)) = \left(\mathbf{H}_i^T \mathbf{R}^{-1} \mathbf{H}_i + \mathbf{P}^{-1} \right)^{-1} \\ &\quad \cdot \left(\mathbf{H}_i^T \mathbf{R}^{-1} (z - \mathbf{h}(\mathbf{x}_i) + \mathbf{H}_i \mathbf{x}_i) + \mathbf{P}^{-1} \mathbf{x}^- \right) \\ &= \mathbf{x}^- + \left(\mathbf{H}_i^T \mathbf{R}^{-1} \mathbf{H}_i + \mathbf{P}^{-1} \right)^{-1} \mathbf{H}_i^T \mathbf{R}^{-1} \\ &\quad \cdot (z - \mathbf{h}(\mathbf{x}_i) - \mathbf{H}_i (\mathbf{x}^- - \mathbf{x}_i)) \\ &= \mathbf{x}^- + K_i (z - \mathbf{h}(\mathbf{x}_i) - \mathbf{H}_i (\mathbf{x}^- - \mathbf{x}_i)) \\ &= \mathbf{x}^- + K_i (\mathbf{e}_z + \mathbf{e}_x) \end{aligned} \quad (12)$$

式中 $K_i = (\mathbf{H}_i^T \mathbf{R}^{-1} \mathbf{H}_i + \mathbf{P}^{-1})^{-1} \mathbf{H}_i^T \mathbf{R}^{-1}$, $\mathbf{e}_z = z - \mathbf{h}(\mathbf{x}_i)$, $\mathbf{e}_x = \mathbf{H}_i (\mathbf{x}_i - \mathbf{x}^-)$ 。

比较式(12)和式(5), 可发现 IEKF 的状态迭代估计实际上和高斯牛顿迭代是一致的。式(12)中, 测量更新包括两项, 即 $\mathbf{e}_z$ 和 $\mathbf{e}_x$ 。很明显 $\mathbf{e}_x$ 包含 $\mathbf{x}^-$, 因此初始值 $\mathbf{x}^-$ 的优劣将直接对迭代的最终效果产生很大影响。为减小 $\mathbf{x}^-$ 的影响, 利用每次滤波迭代值 $\mathbf{x}^i$ 来替换初始值 $\mathbf{x}^-$, 引入到扩展的“观测”向量中, 并按上述高斯牛顿迭代法进行一步更新, 得到对 IEKF 状态估计的一个修正公式

$$\mathbf{x}_{i+1} = \mathbf{x}_i + K_i (z - \mathbf{h}(\mathbf{x}_i)) \quad (13)$$

与式(5)相比较, 式(13)更简单, 当仅做一次迭代时, 两式实际是相同的。增益 K_i 与协方差矩阵采用卡尔曼滤波算法进行更新, 这样, 就得到一组新的状态和协方差迭代更新公式^[10]:

$$\hat{\mathbf{x}}_{k|k,i+1} = \hat{\mathbf{x}}_{k|k,i} + K_{k,i} (z_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k,i})) \quad (14)$$

$$\mathbf{P}_{k|k,i+1} = \mathbf{P}_{k|k,i} - K_{k,i} \mathbf{H}_{k,i} \mathbf{P}_{k|k,i} \quad (15)$$

式中 $\mathbf{H}_{k,i} = \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k,i}}$, $K_i = \left((\mathbf{H}_{k,i})^T \mathbf{R}_k^{-1} \mathbf{H}_{k,i} + (\mathbf{P}_{k|k,i})^{-1} \right)^{-1} (\mathbf{H}_{k,i})^T \mathbf{R}_k^{-1}$ 。

下面推导最大似然迭代终止条件。对于 $\mathbf{Z}$, 可以得到似然函数计算式:

$$\Lambda(\xi) = \text{const} \cdot \exp \left[-\frac{1}{2} (\mathbf{Z} - \mathbf{g}(\xi))^T \tilde{\mathbf{Q}}^{-1} (\mathbf{Z} - \mathbf{g}(\xi)) \right] \quad (16)$$

其中 ξ 为一自由变量, $\tilde{Q} = \begin{bmatrix} R & 0 \\ 0 & P_i \end{bmatrix}$, 进一步可以得

到状态 x 的最大似然估计:

$$x^* = \arg \max [\Lambda(\xi)] \quad (17)$$

式(17)等价于 $x^* = \arg \min [q(\xi)]$, 其中

$$q(\xi) = -\frac{1}{2} (Z - g(\xi))^T \tilde{Q}^{-1} (Z - g(\xi)) \quad (18)$$

假定 $q(\xi_{i+1}) < q(\xi_i)$, 即是说, $q(\xi_{i+1})$ 要比 $q(\xi_i)$ 更接近于最大似然面, ξ_{i+1} 要比 ξ_i 更接近于最优解。根据式(7), 式(8)和式(18), 有

$$\begin{aligned} & [z - h(\xi_{i+1})]^T R^{-1} [z - h(\xi_{i+1})] + (x_i - \xi_{i+1})^T \\ & \cdot P_i^{-1} (x_i - \xi_{i+1}) < [z - h(\xi_i)]^T R^{-1} [z - h(\xi_i)] \\ & + (x_i - \xi_i)^T P_i^{-1} (x_i - \xi_i) \end{aligned} \quad (19)$$

令 ξ_i 为每次迭代估计值, 式(19)就简化为

$$\tilde{x}_{k,i}^T P_{k,i}^{-1} \tilde{x}_{k,i} + \tilde{z}_{k,i}^T R_k^{-1} \tilde{z}_{k,i} < \tilde{z}_{k,i-1}^T R_k^{-1} \tilde{z}_{k,i-1} \quad (20)$$

其中 $\tilde{x}_{k,i} = \tilde{x}_{k|i} - \hat{x}_{k|i-1}$, $\tilde{z}_{k,i} = z_k - h(\hat{x}_{k|i})$ 。

3.2 IMM 迭代扩展卡尔曼粒子滤波算法

与 IMMPF 算法相比, 本文所提算法的不同之处在于多模型采用改进的粒子滤波器, 利用修正的 IEKF 来产生粒子滤波的重要性密度函数, 减小了线性化误差, 并且使重要性密度函数融入了最新观测信息, 将更符合状态变量的实际后验概率分布。在保证跟踪精度的情况下, 可以采用更少的粒子数来近似后验分布, 减小了计算量。算法每一个循环包含: 交互运算、滤波、模型概率更新、融合输出, 下面分别阐述。

(1) 交互运算 初始化 $k=1$ 时的状态量 $\{x_{k-1|i-1,i}\}_{i=1}^M$ 及其协方差 $\{P_{k-1|i-1,i}\}_{i=1}^M$, 其中 $i=1, 2, \dots, M$;

给定模型转移概率 Π_{ij} , 已知模型概率 $\{\mu_{k-1,i}\}_{i=1}^M$, 进行交互运算

$$\hat{x}_{k-1|i-1,j} = \sum_{i=1}^M x_{k-1|i-1,i} \mu_{k-1,i|j} \quad (21)$$

$$\begin{aligned} P_{k-1|i-1,j} = & \sum_{i=1}^M \mu_{k-1,i|j} \left[P_{k-1|i-1,i} + (x_{k-1|i-1,i} - \hat{x}_{k-1|i-1,j}) \right. \\ & \cdot (x_{k-1|i-1,i} - \hat{x}_{k-1|i-1,j})^T \Big] \end{aligned} \quad (22)$$

其中 $\mu_{k-1,i|j} = \frac{1}{c_{k-1,j}} \Pi_{ij} \mu_{k-1,i}$ 是混合概率, $c_{k-1,j} =$

$\sum_{i=1}^M \Pi_{ij} \mu_{k-1,i}$ 是归一化因子, $j=1, 2, \dots, M$ 。

(2) 滤波 随机抽取采样点

$$x_{k-1|i-1,i}^l \sim N(\hat{x}_{k-1|i-1,i}, P_{k-1|i-1,i}) \quad (23)$$

其中 $l=1, 2, \dots, N_s$, N_s 为粒子数;

粒子预测

$$x_{k|k-1,i}^l = F_i(x_{k-1|i-1,i}^l) \quad (24)$$

$$P_{k|k-1,i}^l = Q_i + F_i P_{k-1|i-1,i} F_i^T \quad (25)$$

$$z_{k|k-1,i}^l = h(\hat{x}_{k|k-1,i}^l) \quad (26)$$

计算残差

$$\delta_{k,i}^l = z_k - z_{k|k-1,i}^l \quad (27)$$

利用上一节修正的 IEKF 进行粒子更新, 可得 $\hat{x}_{k|k,i}^l$ 和 $P_{k|k,i}^l$; 构造重要性密度函数 $x_{k|k,i}^l \sim N(\hat{x}_{k|k,i}^l, P_{k|k,i}^l)$, 并产生预测样本; 计算权系数 $\omega_{k,i}^l \propto \omega_{k-1,i}^l \cdot \frac{p(z_k | x_{k|k,i}^l) p(x_{k|k,i}^l | x_{k|k-1,i}^l)}{q(x_{k|k,i}^l | x_{k|k-1,i}^l, z_k)}$ 并归一化; 重采样, 从

$\{x_{k|k,i}^l\}$ 中根据重要性权值重新采样得到一组新的粒子 $\{\hat{x}_{k|k,i}^j, j=1, 2, \dots, N_s\}$, 并重新分配粒子的权值 $\omega_{k,i}^l = 1/N_s$ 。

输出状态估计

$$\hat{x}_{k|k,i} = \frac{1}{N_s} \sum_{j=1}^{N_s} \hat{x}_{k|k,i}^j \quad (28)$$

协方差

$$P_{k|k,i} = \frac{1}{N_s} \sum_{j=1}^{N_s} [\hat{x}_{k|k,i} - \hat{x}_{k|k,i}^j] \cdot [\hat{x}_{k|k,i} - \hat{x}_{k|k,i}^j]^T \quad (29)$$

(3) 模型概率更新 计算模型的似然函数

$$A_{k,i} = \frac{1}{N_s} \sum_{l=1}^{N_s} N(\delta_{k,i}^l; 0, S_{k,i}) \quad (30)$$

其中

$$S_{k,i} = R + \frac{1}{N_s} \sum_{j=1}^{N_s} [z_{k|k-1,i}^j - \hat{z}_{k|k-1,i}] \cdot [z_{k|k-1,i}^j - \hat{z}_{k|k-1,i}]^T,$$

$$\hat{z}_{k|k-1,i} = \frac{1}{N_s} \sum_{j=1}^{N_s} z_{k|k-1,i}^j.$$

各模型概率更新

$$\mu_{k,i} = \frac{1}{c_k} A_{k,i} c_{k-1,i} \quad (31)$$

其中 $c_k = \sum_i A_{k,i} c_{k-1,i}$ 。

(4) 融合输出

$$\hat{x}_{k|k} = \sum_{i=1}^M \mu_{k,i} \hat{x}_{k|k,i} \quad (32)$$

4 仿真结果及分析

下面对本文所提算法进行仿真实验验证, 并与 IMMPF 算法进行对比。采用的模型如式(1)和式(2)描述, 其中 $x_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, 表示 2 维坐标的位置(m)和速度分量(m/s)。目标运动航迹设置如下: 初始状态为 $x_0 = [6000, 20, 6000, 20]^T$, 采样间隔 1 s,

前 25 个采样间隔内反时针转弯, 转弯速率为 0.1 rad/s ; 之后匀速直线运动, 持续时间为 10 个采样间隔; 最后在第 36 到 60 个采样间隔内顺时针转弯, 转弯速率为 0.1 rad/s 。

这里采用 3 个模型构成算法的模型集。

$$\text{模型 1 匀速运动模型 } F_1(\mathbf{x}_k) = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}_k$$

模型 2 匀速转弯模型

$$F_2(\mathbf{x}_k) = \begin{bmatrix} 1 & \frac{\sin(\omega)}{\omega} & 0 & \frac{\cos(\omega) - 1}{\omega} \\ 0 & \cos(\omega) & 0 & -\sin(\omega) \\ 0 & \frac{1 - \cos(\omega)}{\omega} & 1 & \frac{\sin(\omega)}{\omega} \\ 0 & \sin(\omega) & 0 & \cos(\omega) \end{bmatrix} \mathbf{x}_k$$

其中, ω 是转弯速率;

模型 3 与模型 2 基本相同, 只是模型 2 中 $\omega > 0$, 描述目标反时针转弯, 而模型 3 中 $\omega < 0$ 对应目标顺时针转弯。

各模型初始概率 $\mu_{0,1} = 0.6$, $\mu_{0,2} = 0.2$ 和 $\mu_{0,3} = 0.2$, 模型转移概率矩阵为 $\Pi = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0.1 & 0.8 & 0.1 \\ 0.1 & 0.1 & 0.8 \end{bmatrix}$ 。观测

模型为 $\mathbf{H}(\mathbf{x}_k) = [\sqrt{x_k^2 + y_k^2}, \tan^{-1}(y_k/x_k)]^T$, 目标观测距离标准差 $\sigma_r = 30 \text{ m}$, 方位标准差 $\sigma_\theta = 2 \text{ mrad}$, IMMPF 的粒子数为 800, 改进算法的粒子数为 100, 采用残差采样法, Monte Carlo 仿真次数 $M = 200$ 。实验是在一台 Pentium 4 CPU 3.06 GHz 计算机上进行的。

定义位置估计均方根误差为

$$E_k^{\text{posi}} = \left[\frac{1}{M} \sum_{j=1}^M \left[(x_{k,j} - \hat{x}_{k|k,j})^2 + (y_{k,j} - \hat{y}_{k|k,j})^2 \right] \right]^{1/2} \quad (33)$$

图 1 所示为两种算法的位置估计均方根误差, 表 1 给出了不同观测方位标准差 σ_θ 情况下各算法的位置估计均方根误差及失跟次数, 表 2 给出了算法的平均运行时间。

从图 1 可以看出, 目标在整个运动过程中, 本文算法的跟踪误差始终要小于 IMMPF, 在目标两次变轨机动时, IMMPF 算法的跟踪误差迅速增大, 并且对第二次的变轨跟踪调整比较慢, 出现了延迟现象, 无论目标平稳运动还是变轨机动, 本文算法都能对目标进行稳定跟踪。这主要是由于 IMMPF 在粒子滤波过程中, 采用系统状态的转移概率作为重




图 1 位置估计均方根误差

表 1 不同观测方位标准差情况下位置估计均方根误差及失跟次数

$\sigma_\theta (\text{mrad})$	算法	均方根误差(m)		失跟次数
		Mean	Var	
2	IMMPF	33.7971	42.1856	2
	本文算法	24.6602	8.1037	0
5	IMMPF	43.1531	51.3930	3
	本文算法	31.0116	10.8389	0
10	IMMPF	55.5967	72.7841	5
	本文算法	40.4342	14.3487	0

表 2 两种算法平均运行时间

算法	运行时间(s)
IMMPF	16.3457
本文算法	5.6954

要性密度函数, 没有利用最新观测信息, 当目标做机动时, 观测信息发生了非平稳的突变, 数据出现在系统转移概率分布的尾部^[11], 以这种分布产生的粒子偏离了真实的后验概率分布, 降低了滤波精度, 甚至引起发散。本文算法在多模型粒子滤波中, 利用修正的 IEKF 来计算重要性概率分布, 减小了非线性滤波带来的线性化误差, 同时, 粒子的产生充分考虑了当前时刻的量测, 使得粒子的分布更加接近其后验概率分布, 跟踪精度要高于 IMMPF。

从表 1 可以看出, 随着观测方位标准差的增大, 各算法跟踪性能都有所下降, 本文算法的跟踪误差要小于 IMMPF, 并且估计均方根误差的方差明显小于 IMMPF, 这在目标跟踪应用中显得更为重要。在 200 次独立实验中, IMMPF 算法出现的目标失跟次数逐渐增大, 本文算法没有发生目标失跟现象, 稳定性要优于 IMMPF 算法。从表 2 可知, 本文算法的平均运行时间明显小于 IMMPF, 这是由于所提算法在多模型中采用了改进的粒子滤波器, 在保证跟踪精度的前提下, 能够采用更少的粒子数来近似状态后验分布, 减小了计算量, 提高了算法的实时性。

5 结束语

本文提出了一种 IMM 迭代扩展卡尔曼粒子滤波跟踪算法, 该算法通过对 IEKF 进行修正, 并利用修正后的 IEKF 来产生粒子滤波的重要性密度函数, 结合 IMM 算法对机动目标进行跟踪。仿真结果表明, 所提算法的跟踪精度要高于 IMMPF, 稳定性要优于 IMMPF, 在计算量方面, 比 IMMPF 要小。

参 考 文 献

- [1] Mazor E, Averbuch A, and Bar-Shalom Y, *et al.* Interacting multiple model methods in target tracking: a survey[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1998, 34(1): 103-123.
- [2] Kim Byung-doo and Lee Ja-sung. IMM algorithm based on the analytic solution of steady state Kalman filter for radar target tracking[C]. *IEEE International Radar Conference*, Arlington, Virginia, USA, May, 2005: 757-762.
- [3] Cappe O, Godsill S J, and Moulines E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. *Proceedings of the IEEE*, 2007, 95(5): 899-924.
- [4] Boers Y and Driessen J N. Interacting multiple model particle filter[J]. *IEEE Proceedings-Radar Sonar Navigation*, 2003, 150(5): 344-349.
- [5] Morelande M R and Challa S. Maneuvering target tracking in clutter using particle filters[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(1): 252-270.
- [6] Arulampalam M S, Maskell S, and Gordon N, *et al.* A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. *IEEE Transactions on Signal Processing*, 2002, 50(2): 174-188.
- [7] 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(2): 233-238.
Li Liang-qun, Ji Hong-bing, and Luo Jun-hui. Iterated extended Kalman particle filtering[J]. *Journal of Xidian University*, 2007, 34(2): 233-238.
- [8] Bell B M and Cathey F W. The iterated Kalman filter update as a Gauss-Newton method[J]. *IEEE Transactions on Automatic Control*, 1993, 38(2): 294-297.
- [9] Johnston L A and Krishnamurthy V. Derivation of a sawtooth iterated extended Kalman smoother via the AECM algorithm[J]. *IEEE Transactions on Signal Processing*, 2001, 49(9): 1899-1909.
- [10] 杨争斌, 郭福成, 周一宇. 迭代IMM机动目标被动单站跟踪算法[J]. *宇航学报*, 2008, 29(1): 304-310.
Yang Zheng-bin, Guo Fu-cheng, and Zhou Yi-yu. Iterated IMM algorithm for maneuvering target tracking by a single passive observer[J]. *Journal of Astronautics*, 2008, 29(1): 304-310.
- [11] Van der R and Doucet Merwe F, *et al.* The unscented particle filter[R]. Technical Report CUED/F-INFENG/TR 380, Cambridge University Engineering Department, Cambridge, England, 2000.

张俊根: 男, 1979 年生, 博士生, 研究方向为信号处理与检测、目标跟踪。

姬红兵: 男, 1963 年生, 教授, 博士生导师, 研究方向为光电信息处理、智能信息处理、被动多传感器定位与跟踪、雷达目标识别与分类、微弱信号检测与识别、医学影像处理等。