

# 基于量测迭代更新集合卡尔曼滤波的机动目标跟踪算法

胡振涛<sup>1,2</sup>, 张 勇<sup>1,3†</sup>, 刘先省<sup>2</sup>

(1. 河南大学 图像处理与模式识别研究所, 河南 开封 475004; 2. 河南大学 计算机与信息工程学院, 河南 开封 475004;  
3. 河南大学 财务处, 河南 开封 475004)

**摘要:** 在机动目标跟踪中, 用于模型辨识和状态估计的非线性滤波器的合理选择和优化是提升滤波精度的关键。融合量测迭代更新集合卡尔曼滤波和交互式多模型(interacting multiple models, IMM)方法, 本文提出了基于量测迭代更新集合卡尔曼滤波的机动目标跟踪算法。通过迭代更新思想的引入构建了一种量测迭代更新下集合卡尔曼滤波的实现结构, 并将其作为IMM的模型滤波器实现对于目标运动模式和状态的辨识与估计。针对算法结合过程中滤波精度和计算量的平衡, 设计了用于输入交互环节的状态估计样本, 同时简化输入交互环节和输出交互环节中滤波误差协方差矩阵的交互过程。理论分析和仿真结果验证了算法的可行性和有效性。

**关键词:** 机动目标跟踪; 非线性滤波; 集合卡尔曼滤波; 交互式多模型

中图分类号: TP391 文献标识码: A

## Maneuvering target tracking algorithm based on ensemble Kalman filter with observation iterated update

HU Zhen-tao<sup>1,2</sup>, ZHANG Yong<sup>1,3†</sup>, LIU Xian-xing<sup>2</sup>

(1. Institute of Image Processing and Pattern Recognition, Henan University, Kaifeng Henan 475004, China;  
2. College of Computer and Information Engineering, Henan University, Kaifeng Henan 475004, China;  
3. Finance Department, Henan University, Kaifeng Henan 475004, China)

**Abstract:** The reasonable selection and optimization of nonlinear filter used in maneuvering target tracking is the key to realize the identification model and the estimation of state. Combining with ensemble Kalman filter with observation iterated update and interacting multiple models, a novel maneuvering target tracking algorithm based on ensemble Kalman filter with observation iterated update is proposed. Firstly, according to the mechanism of iterated observation update, the realization framework of ensemble Kalman filter with observation iterated update is constructed. And then, the improved method is taken as model filter in interacting multiple models to identify and estimate the motion mode and target state. Aiming to the balance between filtering precision and calculated amount in the combination of two algorithms, state estimation samples are designed to use in interactive input, and simultaneously the interactive processes of estimation error covariance matrix in interactive input and interactive output are simplified. The theoretical analysis and experimental results show the feasibility and validity of the new algorithm.

**Key words:** maneuvering target tracking; nonlinear filter; ensemble Kalman filter; interacting multiple model

## 1 引言(Introduction)

目标跟踪是人们运用各种观测和计算手段, 实现主体对被关注运动客体的状态建模、估计、跟踪的过程。目标跟踪作为一门新兴的科学技术在军事、民用以及经济社会领域都有着十分重要的作用<sup>[1]</sup>。从目标运动形式和强度上, 目标跟踪问题可以分为机动目标跟踪和非机动目标跟踪两类。当目标做机动时, 由于

目标运动特征的多样性和复杂性, 使用单一、固定的模型难以准确描述目标的运动状态, 人们通常采用多模型的实现结构<sup>[2]</sup>。多模型方法通过选择或设计一个模型集来描述系统的行为模式, 模型集中每个模型与一个特定的系统模式相匹配, 系统状态估计是多个并行运行滤波器估计结果的合理综合<sup>[3]</sup>。在多模型方法和改进算法中, 交互式多模型(interacting multiple

收稿日期: 2013-04-16; 录用日期: 2014-07-11。

<sup>†</sup>通信作者。E-mail: zhangyong@henu.edu; Tel.: +86 13903788243。

基金项目: 国家自然科学基金资助项目(61300214); 河南省高校科技创新团队支持计划资助项目(13IRTSTHN021); 河南省基础与前沿技术研究计划资助项目(132300410148); 河南省教育厅科学技术研究重点资助项目(13A413066); 中国博士后基金资助项目(2014M551999); 河南省博士后基金资助项目(2013029); 河南大学教学改革重点资助项目(HDXJJG2013-07); 河南大学优秀青年培育基金资助项目(0000A40366); 河南省社会科学规划资助项目(2011FZH005); 河南省青年骨干教师资助计划(2013GGJS-026)。

models, IMM)提供了一种解决系统模式切换问题的有效方法. IMM采用模型“软切换”机制, 在模型辨识和状态估计精度之间进行平衡<sup>[4-6]</sup>. 标准IMM中模型滤波器选用卡尔曼滤波(Kalman filter, KF), 针对线性高斯系统能够取得较好的估计精度. 但当被估计系统具有强非线性、非高斯特性时, 其所选用非线性滤波器性能直接影响跟踪精度和算法实现的计算复杂度<sup>[7-8]</sup>.

考虑到KF在实现递推贝叶斯估计上的优越性, 在KF框架下结合局部线性化技术, 首先提出了扩展卡尔曼滤波(extended Kalman filter, EKF)<sup>[9-10]</sup>. 对于强非线性系统, 由于舍入误差的积累效应, EKF易产生滤波发散现象. 结合UT变换和数值差分等技术人们又相继提出了无需计算Jacobian矩阵的非线性滤波方法, 如无迹卡尔曼滤波器(unscented Kalman filter, UKF)<sup>[11-12]</sup>、中心差分滤波器(CDF)<sup>[13]</sup>、容积滤波(CKF)<sup>[14]</sup>等. 此类方法的共同缺陷在于当被估计系统具有强非线性、非高斯特性时, 算法收敛性急剧下降. 伴随着计算机性能的提升, 结合序贯蒙特卡罗仿真方法(SMC)和递推贝叶斯思想构建的粒子滤波器(particle filter, PF)日益受到人们的广泛关注. PF同样采用预测和更新两个基本步骤. 不同于KF, 预测步骤是利用序贯重要性采样技术, 更新步骤则是通过重采样方法<sup>[15]</sup>. PF滤波精度优于EKF和UKF等已有非线性滤波算法, 但PF实现机理使得无法克服其固有的粒子退化和粒子多样性溃退问题. 另外, PF滤波精度取决于系统状态的维数和粒子数目, 导致算法参数缺乏对应用对象的普适性<sup>[16]</sup>. 此外, 结合递推贝叶斯和集合预报思想, Evensen等学者提出了集合Kalman滤波(ensemble Kalman filter, EnKF)<sup>[17]</sup>. EnKF采用SMC方法生成表征状态统计量的初始样本集合, 并对初始样本集合中的每个样本应用系统状态转移函数, 进而通过计算状态转移后样本集合的均值和协方差实现当前时刻状态估计值的求解<sup>[18]</sup>. 由于EnKF实现中引入数据同化技术有效改善了量测噪声随机性对滤波精度的不利影响, 在计算量方面优于PF.

基于以上分析, 通过IMM和EnKF两种算法实现结构的动态融合, 本文给出一种新的实现多模型系统状态估计处理方法. 首先, 为进一步提升IMM中所采用模型滤波器的估计精度, 在EnKF框架下, 结合迭代更新策略构建了基于量测迭代更新的集合卡尔曼滤波器(iterated ensemble Kalman filter, IEnKF). 接下来, 将IEnKF应用于IMM框架, 即以IEnKF作为IMM的模型滤波器. 在此基础上, 提出了一种基于量测迭代更新的集合卡尔曼滤波的机动目标跟踪算法(IMM-IEnKF). 文中以典型机动目标运动模型验证了算法的优越性.

## 2 量测迭代更新EnKF(EnKF with observation iterated update)

### 2.1 集合卡尔曼滤波(Ensemble Kalman filter)

定义 $\hat{x}_{k-1/k-1} \in \mathbb{R}^{n \times q}$ 和 $\hat{x}_{k/k-1} \in \mathbb{R}^{n \times q}$ 分别为 $k-1$ 时刻状态估计样本集和 $k$ 时刻状态一步预测样本集.  $n$ 和 $q$ 分别表示被估计系统状态维数和样本集中的样本个数:

$$\hat{x}_{k-1/k-1} \triangleq (\mathbf{x}_{k-1/k-1}^1, \mathbf{x}_{k-1/k-1}^2, \dots, \mathbf{x}_{k-1/k-1}^q), \quad (1)$$

$$\hat{x}_{k/k-1} \triangleq (\mathbf{x}_{k/k-1}^1, \mathbf{x}_{k/k-1}^2, \dots, \mathbf{x}_{k/k-1}^q), \quad (2)$$

状态一步预测均值 $\bar{x}_{k/k-1}$ 和状态一步预测误差协方差矩阵 $\mathbf{P}_{k/k-1}$ 由式(3)和式(4)获得:

$$\bar{x}_{k/k-1} = \frac{1}{q} \sum_{i=1}^q \hat{x}_{k/k-1}^i, \quad (3)$$

$$\mathbf{P}_{k/k-1} = \frac{1}{q-1} \tilde{\mathbf{e}}_{k/k-1}^{\text{xx}} (\tilde{\mathbf{e}}_{k/k-1}^{\text{xx}})^T, \quad (4)$$

其中 $\tilde{\mathbf{e}}_{k/k-1}^{\text{xx}}$ 表示状态一步预测误差:

$$\begin{aligned} \tilde{\mathbf{e}}_{k/k-1}^{\text{xx}} \triangleq & (\hat{x}_{k/k-1}^1 - \bar{x}_{k/k-1}, \hat{x}_{k/k-1}^2 - \bar{x}_{k/k-1}, \\ & \dots, \hat{x}_{k/k-1}^q - \bar{x}_{k/k-1}). \end{aligned} \quad (5)$$

为实现滤波增益 $\mathbf{K}_k$ 的计算, 首先需要求解状态一步预测和量测误差协方差矩阵 $\mathbf{P}_k^{\text{xz}}$ 和量测残差协方差矩阵 $\mathbf{P}_k^{\text{zz}}$ :

$$\mathbf{P}_k^{\text{xz}} = \frac{1}{q-1} \tilde{\mathbf{e}}_{k/k-1}^{\text{zx}} (\tilde{\mathbf{e}}_k^{\text{zx}})^T, \quad (6)$$

$$\mathbf{P}_k^{\text{zz}} = \frac{1}{q-1} \tilde{\mathbf{e}}_k^{\text{zz}} (\tilde{\mathbf{e}}_k^{\text{zz}})^T, \quad (7)$$

其中 $\tilde{\mathbf{e}}_k^{\text{zz}} \in \mathbb{R}^{r \times q}$ 表示量测残差向量:

$$\begin{aligned} \tilde{\mathbf{e}}_k^{\text{zz}} \triangleq & (\mathbf{z}_k^1 - \bar{\mathbf{z}}_{k/k-1}, \mathbf{z}_k^2 - \bar{\mathbf{z}}_{k/k-1}, \\ & \dots, \mathbf{z}_k^q - \bar{\mathbf{z}}_{k/k-1}), \end{aligned} \quad (8)$$

$$\mathbf{z}_k^i = \mathbf{z}_k + \mathbf{v}_k^i, \quad (9)$$

$$\bar{\mathbf{z}}_{k/k-1} = h(\bar{x}_{k/k-1}), \quad (10)$$

$\mathbf{z}_k^i$ 表示附加扰动(高斯白噪声)的量测数据,  $\mathbf{v}_k^i$ 服从均值为零, 方差为 $\sigma_{v,k}$ (量测传感器的精度)的高斯分布. 式(9)中所体现思想即利用数理统计方法降低量测数据随机性的数据同化方法<sup>[19]</sup>.  $\mathbf{z}_k^i$ 的引入主要为解决量测噪声随机性对滤波精度的不利影响.  $\bar{\mathbf{z}}_{k/k-1}$ 表示量测预测值,  $h(\cdot)$ 表示状态空间到量测空间的映射算子. 接下来, 在 $\mathbf{K}_k$ 求解的基础上依据式(12)获得 $k$ 时刻用于状态估计的样本 $\hat{x}_{k/k}^i$ :

$$\mathbf{K}_k = \mathbf{P}_k^{\text{xz}} (\mathbf{P}_k^{\text{zz}})^{-1}, \quad (11)$$

$$\hat{x}_{k/k}^i = \hat{x}_{k/k-1}^i + \mathbf{K}_k (\mathbf{z}_k^i - h(\hat{x}_{k/k-1}^i)). \quad (12)$$

最终, 结合式(13)和式(15)计算状态估计值 $\bar{x}_{k/k}$ 和

状态估计误差协方差矩阵  $\mathbf{P}_{k/k}$ :

$$\bar{x}_{k/k} = \frac{1}{q} \sum_{i=1}^q \hat{x}_{k/k}^i, \quad (13)$$

$$\mathbf{P}_{k/k} = \frac{1}{q-1} \tilde{e}_{k/k}^{xx} (\tilde{e}_{k/k}^{xx})^T, \quad (14)$$

$$\begin{aligned} \tilde{e}_{k/k}^{xx} &\triangleq (\hat{x}_{k/k}^1 - \bar{x}_{k/k}, \hat{x}_{k/k}^2 - \bar{x}_{k/k}, \\ &\dots, \hat{x}_{k/k}^q - \bar{x}_{k/k}), \end{aligned} \quad (15)$$

其中  $\tilde{e}_{k/k}^{xx}$  表示状态估计误差.

## 2.2 量测迭代更新策略(The observation iterated update strategy)

由EnKF算法实现过程可知, 对于当前时刻系统状态估计仅利用了状态建模信息  $\hat{x}_{k/k-1}^i$ . 而  $\hat{x}_{k/k}^i$  本身是在  $\hat{x}_{k/k-1}^i$  基础上, 结合  $\mathbf{K}_k$  以及最新量测信息  $\mathbf{z}_k^i$  实现的进一步优化. 因此,  $\hat{x}_{k/k}^i$  在对被估计系统真实状态  $\mathbf{x}_k$  逼近程度要优于  $\hat{x}_{k/k-1}^i$ . 显然, 如果采用  $\hat{x}_{k/k}^i$  替代  $\hat{x}_{k/k-1}^i$  进行量测更新无疑将能够改善EnKF的滤波精度. 量测迭代更新思想的基本出发点, 即将系统围绕状态估计  $\hat{x}_{k/k}^i$  替代  $\hat{x}_{k/k-1}^i$  重新进行量测更新. IEnKF实现具体步骤如下:

首先, 结合EnKF算法实现过程, 通过求解  $\bar{x}_{k/k-1}$  和  $\mathbf{P}_{k/k-1}$ , 实现状态一步预测环节:

$$\bar{x}_{k/k-1} = \frac{1}{q} \sum_{i=1}^q \hat{x}_{k/k-1,L}^i, \quad (16)$$

$$\mathbf{P}_{k/k-1} = \frac{1}{q-1} \tilde{e}_{k/k-1,L}^{xx} (\tilde{e}_{k/k-1,L}^{xx})^T, \quad (17)$$

$l$  表示量测更新中第  $l$  次迭代实现,  $l = 1, 2, \dots, L$ .  $L$  表示最大迭代次数. 其次, 利用迭代更新的方式实现状态估计的优化. 利用数据同化技术对第  $l$  次量测更新中  $\mathbf{z}_{k,l}^i$  进行采样, 并依据式(10)计算  $\bar{z}_{k/k-1}$ .

$$\mathbf{z}_{k,l}^i = \mathbf{z}_k + \mathbf{v}_{k,l}^i. \quad (18)$$

接下来, 在求解  $\mathbf{P}_{k,l}^{xz}$  和  $\mathbf{P}_{k,l}^{zz}$  的基础上计算第  $l$  次量测更新的  $\mathbf{K}_{k,l}$  和  $\hat{x}_{k/k,l}^i$ :

$$\mathbf{P}_{k,l}^{xz} = \frac{1}{q-1} \tilde{e}_{k/k-1}^{xz} (\tilde{e}_{k/l}^{xz})^T, \quad (19)$$

$$\mathbf{P}_{k,l}^{zz} = \frac{1}{q-1} \tilde{e}_{k/l}^{zz} (\tilde{e}_{k/l}^{zz})^T, \quad (20)$$

$$\mathbf{K}_{k,l} = \hat{\mathbf{P}}_{k,l}^{xz} (\hat{\mathbf{P}}_{k,l}^{zz})^{-1}, \quad (21)$$

$$\hat{x}_{k/k,l}^i = \hat{x}_{k/k,l-1}^i + \mathbf{K}_k (\mathbf{z}_{k,l}^i - h(\hat{x}_{k/k,l-1}^i)), \quad (22)$$

最终, 结合式(23)和式(24)实现  $\bar{x}_{k/k,l}$  和  $\mathbf{P}_{k/k,l}$  的求解:

$$\bar{x}_{k/k,l} = \frac{1}{q} \sum_{i=1}^q \hat{x}_{k/k,l}^i, \quad (23)$$

$$\mathbf{P}_{k/k,l} = \frac{1}{q-1} \tilde{e}_{k/k,l}^{xx} (\tilde{e}_{k/k,l}^{xx})^T, \quad (24)$$

反复利用量测更新方式改善滤波精度的能力是有限的. 在实际应用中, 考虑算法滤波精度和计算量之

间的平衡, 迭代次数不应太多, 迭代次数通常  $L$  取 1 至 2 次<sup>[20]</sup>.

## 3 基于量测迭代EnKF的机动目标跟踪算法 (Maneuvering target tracking algorithm based on EnKF with observation iterated update)

在IMM算法实际应用中, 模型辨识和状态估计精度提升的关键在于依据被估计对象特点和性能合理选择用于模型滤波器. 考虑到IEnKF相对于EnKF具有更高的滤波精度, 通过IEnKF与IMM有机结合, 以实现IMM性能的改善. 在此基础上, 本节提出了一种基于量测迭代更新集合卡尔曼滤波的交互式多模型算法.

### 3.1 交互式多模型(Interacting multiple model)

考虑以下具有模型切换的多模型非线性系统:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, r_k, \mathbf{u}_{k-1}), \quad (25)$$

$$\mathbf{z}_k = h(\mathbf{x}_k, r_k, \mathbf{v}_k), \quad (26)$$

$$r_k \sim p(r_k | r_{k-1}), \quad (27)$$

其中:  $\mathbf{x}_k$  和  $\mathbf{z}_k$  分别表示系统状态变量和量测值.  $\mathbf{u}_k$  和  $\mathbf{v}_k$  为满足独立同分布特性的系统噪声和量测噪声.  $r_k$  表示  $k$  时刻系统模型的状态. 定义  $D \triangleq \{1, 2, \dots, d\}$  为满足离散时间、齐次、有限状态的一阶Markov 链的模型状态集.  $\mu_0^a = P_r \{r_0 = a\}$  表示模型状态初始概率. 模型状态的先验转移概率和转移概率矩阵分别为  $\pi_{ab} = P_r \{r_{k+1} = b | r_k = a\}$  和  $\boldsymbol{\Pi} = [\pi_1 \ \pi_2 \ \dots \ \pi_d]^T$ ,  $\boldsymbol{\pi}_a = [\pi_{a1} \ \pi_{a2} \ \dots \ \pi_{ad}]$ , 且  $\sum_{b=1}^d \pi_{ab} = 1$ ,  $a, b, d \in D$ . IMM实现的基本思想在于保持系统中所有模型并行滤波, 并通过计算模型概率权重对各模型滤波的输出进行估计综合. IMM实现步骤主要分为输入交互、模型滤波、模型概率更新和输出交互 4 个环节<sup>[4]</sup>. 输入交互环节中需要计算模型预测概率  $\bar{\mu}_{k-1}^a$ 、模型混合概率  $\bar{\mu}_{k-1}^{a/b}$ 、各模型的模型混合状态估计  $\bar{x}_{k-1/k-1}^a$  以及混合状态估计误差协方差  $\bar{P}_{k-1/k-1}^a$ . 模型滤波环节即对每个模型并行滤波, 在这个环节得到各模型状态估计  $\bar{x}_{k/k}^a$ 、状态估计误差协方差矩阵  $\mathbf{P}_{k/k}^a$ 、量测残差  $\tilde{e}_k^{zz,a}$  以及残差协方差  $\mathbf{P}_k^{zz,a}$ . 模型概率更新环节主要是利用  $\tilde{e}_k^{zz,a}$  和  $\mathbf{P}_k^{zz,a}$  计算模型集中每个模型似然度  $\ell_k^a$  和模型概率  $\mu_k^a$ . 输出交互环节则是通过  $\bar{x}_{k/k}^a$  和  $\bar{P}_{k/k}^a$  求解  $k$  时刻系统状态估计  $\bar{x}_{k/k}$  和状态估计误差协方差阵  $\bar{P}_{k/k}$ .

### 3.2 基于量测迭代更新EnKF的IMM算法 (Interacting multiple model based on EnKF with observation iterated update)

考虑到IMM框架中模型滤波器的滤波精度直接决定着机动目标跟踪的效果, 将IEnKF动态引入IMM

算法框架, 并将其作为IMM的模型滤波器即IMM-IEnKF算法实现思想. IMM-IEnKF实现过程如下: 已知 $k-1$ 时刻模型集中各模型概率 $\mu_{k-1}^a$ ,  $\boldsymbol{\Pi}$ 及系统状态估计样本集 $\{\hat{x}_{k-1/k-1,L}^{i,a}, i=1, 2, \dots, q\}$ . 首先, 利用 $\mu_{k-1}^a$ 和 $\boldsymbol{\Pi}$ 计算 $\bar{\mu}_{k-1}^b$ 和 $\bar{\mu}_{k-1}^{a/b}$ , 并利用模型滤波器输出的状态估计样本 $\hat{x}_{k-1/k-1,L}^{i,a}$ 计算 $k-1$ 时刻各模型的混合状态估计的样本集 $\{\bar{x}_{k-1/k-1,L}^{i,a}, i=1, 2, \dots, q\}$ :

$$\bar{\mu}_{k-1}^b = \sum_{a=1}^d \pi_{ab} \mu_{k-1}^a, \quad (28)$$

$$\bar{\mu}_{k-1}^{a/b} = \frac{\pi_{ab} \mu_{k-1}^a}{\bar{\mu}_{k-1}^b}, \quad (29)$$

$$\bar{x}_{k-1/k-1,L}^{i,a} = \sum_{b=1}^d \hat{x}_{k-1/k-1,L}^{i,b} \bar{\mu}_{k-1}^{a/b}. \quad (30)$$

其次, 在各模型滤波具体实现中以IEnKF作为模型滤波器. 首先结合表征系统状态转移特性式(25)完成对时刻状态一步预测样本集 $\{\bar{x}_{k/k-1,L}^{i,a}, i=1, 2, \dots, q\}$ 的采样. 进而由式(16)–(23)计算 $k$ 时刻各模型的 $\bar{x}_{k/k-1}^a$ ,  $\mathbf{P}_{k/k-1}^a$ ,  $\mathbf{P}_k^{xz,a}$ ,  $\mathbf{P}_k^{zz,a}$ ,  $\mathbf{K}_{k,L}^a$ 以及 $\bar{x}_{k/k}^a$ 和 $\mathbf{P}_{k/k}^a$ . 接下来, 依据式(31)–(32)求解 $k$ 时刻各模型的 $\ell_k^a$ 和 $\mu_k^a$ :

$$\ell_k^a = (2\pi)^{-1/2} |\mathbf{P}_{k,L}^{zz,a}|^{-1/2} \cdot \exp\left(-\frac{1}{2} (\tilde{e}_{k,L}^{zz,a})^\top (\mathbf{P}_{k,L}^{zz,a})^{-1} (\tilde{e}_{k,L}^{zz,a})\right), \quad (31)$$

$$\mu_k^a = \frac{\bar{\mu}_{k-1}^a \ell_k^a}{\sum_{b=1}^d \bar{\mu}_{k-1}^b \ell_k^b}. \quad (32)$$

最终, 综合模型滤波环节得到 $\bar{x}_{k/k}^a$ 计算 $\bar{x}_{k/k}$ :

$$\bar{x}_{k/k} = \sum_{a=1}^d \bar{x}_{k/k}^a \mu_k^a. \quad (33)$$

相比传统IMM实现结构, IMM-IEnKF中设计了模型滤波器的系统状态估计样本集计算步骤, 并简化了输入交互环节和输出交互环节中滤波误差协方差矩阵的交互过程. 系统状态估计样本集计算主要是考虑到系统状态估计样本所蕴含对于状态逼近的信息必然高于其均值信息. 因此在IEnKF的输入交互环节直接采用系统状态估计样本进行输入交互必然优于利用其均值的方式. 而对输入交互环节和输出交互环节中滤波误差协方差矩阵的交互过程简化, 则主要是考虑IEnKF递推实现并不需要状态估计协方差矩阵的直接参与, 这种处理方式也有利于降低算法的计算量.

#### 4 仿真结果与分析(Simulation results and analysis)

为验证算法的可行性和有效性, 实验中采用基于两坐标雷达量测数据实现机动目标跟踪的仿真场景.

雷达扫描区域目标运动过程如下: 被观测目标在前10个采样周期做转弯角速度为 $+0.4 \text{ rad/s}^2$ 的匀速圆周运动; 在第11–25个采样周期内做转弯角速度为 $-0.2 \text{ rad/s}^2$ 的匀速圆周运动, 在随后的10个采样周期仍做转弯角速度为 $+0.4 \text{ rad/s}^2$ 的匀速圆周运动. 其中, 正号和负号表示匀速转弯运动的方向, “+”表示逆时针, “–”表示顺时针. 结合机动目标运动的动力学特性和雷达传感器物理特性, 跟踪系统状态方程和量测方程如下:

$$\mathbf{x}_k = \begin{cases} \mathbf{F}_1 \mathbf{x}_{k-1} + \boldsymbol{\Gamma} u_{1,k-1}, & 1 \leq k \leq 10, \\ \mathbf{F}_2 \mathbf{x}_{k-1} + \boldsymbol{\Gamma} u_{2,k-1}, & 11 < k \leq 25, \\ \mathbf{F}_1 \mathbf{x}_{k-1} + \boldsymbol{\Gamma} u_{1,k-1}, & 26 < k \leq 35, \end{cases}$$

$$\mathbf{z}_k = [\gamma_k \ \theta_k]^\top + \mathbf{v}_k,$$

$$\gamma_k = \sqrt{x_k^2 + y_k^2},$$

$$\theta_k = \tan^{-1} \frac{y_k}{x_k},$$

$$\mathbf{x}_k = [x_k \ \dot{x}_k \ y_k \ \dot{y}_k]^\top,$$

其中:  $x_k$ ,  $\dot{x}_k$ ,  $y_k$ 和 $\dot{y}_k$ 分别表示目标状态在水平方向和竖直方向上位置分量和速度分量.

$$\mathbf{F}_1 = \begin{bmatrix} 1 & \frac{\sin(w_1\tau)}{w_1} & 0 & -\frac{1-\cos(w_1\tau)}{w_1} \\ 0 & \cos(w_1\tau) & 0 & -\sin(w_1\tau) \\ 0 & \frac{1-\cos(w_1\tau)}{w_1} & 1 & \frac{\sin(w_1\tau)}{w_1} \\ 0 & \sin(w_1\tau) & 0 & \cos(w_1\tau) \end{bmatrix},$$

$$\mathbf{F}_2 = \begin{bmatrix} 1 & \frac{\sin(w_2\tau)}{w_2} & 0 & -\frac{1-\cos(w_2\tau)}{w_2} \\ 0 & \cos(w_2\tau) & 0 & -\sin(w_2\tau) \\ 0 & \frac{1-\cos(w_2\tau)}{w_2} & 1 & \frac{\sin(w_2\tau)}{w_2} \\ 0 & \sin(w_2\tau) & 0 & \cos(w_2\tau) \end{bmatrix}$$

为系统状态转移矩阵.  $w_1 = +0.4 \text{ rad/s}^2$ 和 $w_2 = -0.2 \text{ rad/s}^2$ 表示目标运动的转弯角速度, 采样间隔 $\tau$ 为0.5. 系统过程噪声 $\mathbf{u}_{1,k}$ 和 $\mathbf{u}_{2,k}$ 采用均值为零, 标准差分别为0.2 $\mathbf{I}$ 和0.4 $\mathbf{I}$ 的高斯白噪声,  $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ . 量测噪声

$\mathbf{v}_k$ 采用均值为零, 标准差为 $\begin{bmatrix} R_\gamma & 0 \\ 0 & R_\theta \end{bmatrix}$ 的高斯白噪声.

其中径向距分量的噪声标准差 $R_\gamma$ 为km, 方位角分量的噪声标准差 $R_\theta$ 为 $0.1^\circ$ .  $\boldsymbol{\Gamma} = \begin{bmatrix} \tau^2/2 & \tau & 0 & 0 \\ 0 & 0 & \tau^2/2 & \tau \end{bmatrix}^\top$  表示过程噪声矩阵. Monte Carlo仿真循环次数为50. 仿真步长为35. PF中样本个数为1000, EnKF和IEnKF中的样本数为500, IEnKF实现中最大迭代次数目 $L$ 为2. 目标状态初值为 $\mathbf{x}_0 = [5 \ 0.5 \ 4 \ 0.3]^\top$ . 仿真实验中对比了IMM-EKF, IMM-UKF, IMM-EnKF, IMM-

PF 和 IMM-IEnKF 等 5 种算法, 即分别以 EKF, UKF, EnKF, PF 和 IEnKF 作为 IMM 的模型滤波器.

图 1 给出了基于仿真实验场景设定下目标的真实运动轨迹和量测信息. 图 2~6 以模型辨识概率作为模型选择的准确性指标, 分别给出 IMM-EKF, IMM-UKF, IMM-PF, IMM-EnKF 和 IMM-IEnKF 等 5 种算法滤波实现中模型匹配情况. 图 7 和图 8 给出了 50 次独立实验条件下状态估计的均方根误差(root mean square error, RMSE) 比较.

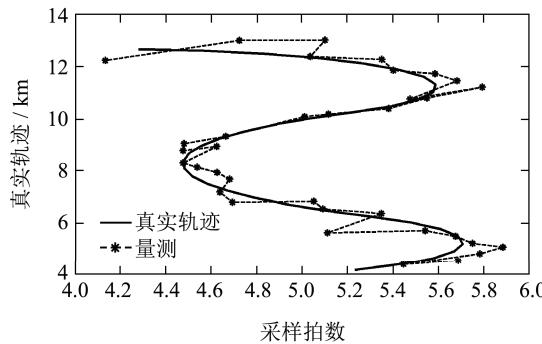


图 1 目标轨迹与量测

Fig. 1 Target trajectory and observation

首先, 由图 2~6 中 5 种算法模型辨识准确性上可知 IMM-EKF 的准确性最差, 其原因就在于 EKF 无法提供高精度的状态结果. 其次, IMM-UKF 优于 IMM-EKF, 同时 IMM-PF 和 IMM-EnKF 在一定程度上则优于 IMM-UKF, 但以上 4 种算法共同的缺陷是模型辨识准确性上在滤波实现过程中存在较大波动. 而 IMM-IEnKF 相对其他 4 种算法在模型辨识准确性和稳定性方面均获得了改善. 众所周知, 在 IMM 框架下采用精度较好的模型滤波器能够支持 IMM 实现有效表征当前时刻状态演化模型的有效辨识, 而模型的准确辨识反过来将支持子滤波器在下一时刻滤波实现中获得好的状态估计结果, 这种特性进一步反映在图 7 和图 8. 可以看出在算法滤波精度方面, 各算法状态估计精度由好到差依次是 IMM-IEnKF, IMM-PF, IMM-EnKF, IMM-UKF 和 IMM-EKF.

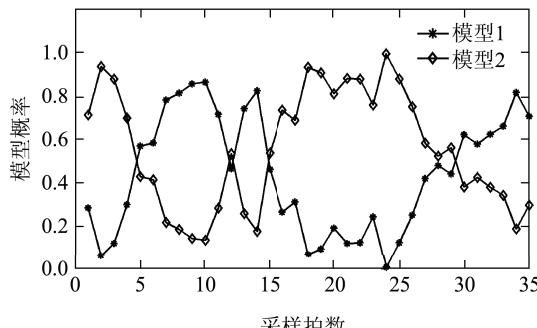


图 2 IMM-EKF 模型概率

Fig. 2 Model probability based on IMM-EKF

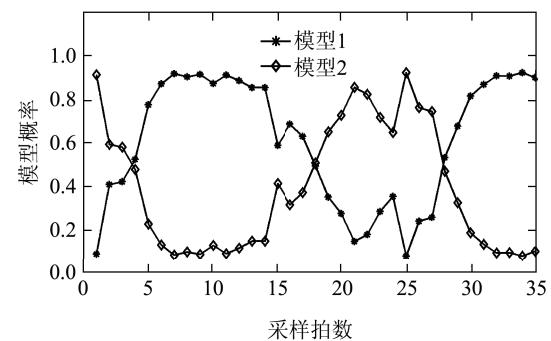


图 3 IMM-EKF 模型概率

Fig. 3 Model probability based on IMM-UKF

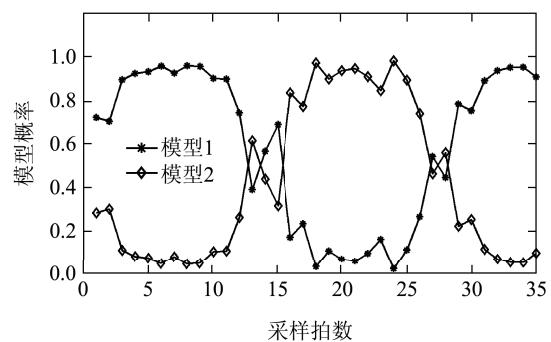


图 4 IMM-EnKF 模型概率

Fig. 4 Model probability based on IMM-EnKF

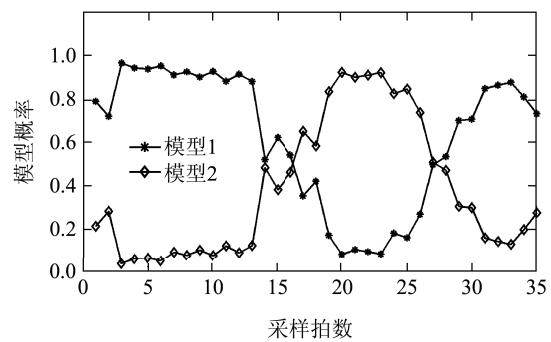


图 5 IMM-PF 模型概率

Fig. 5 Model probability based on IMM-PF

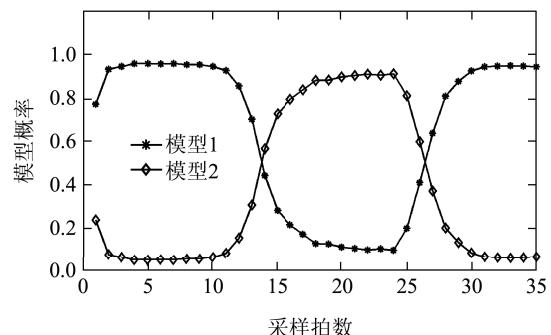


图 6 IMM-IEnKF 模型概率

Fig. 6 Model probability based on IMM-IEnKF

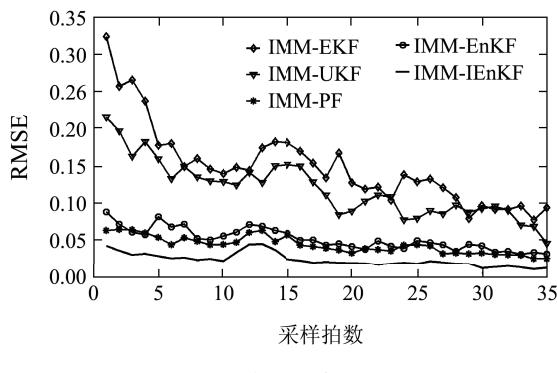


图7 水平方向位置

Fig. 7 Position estimation in horizontal direction

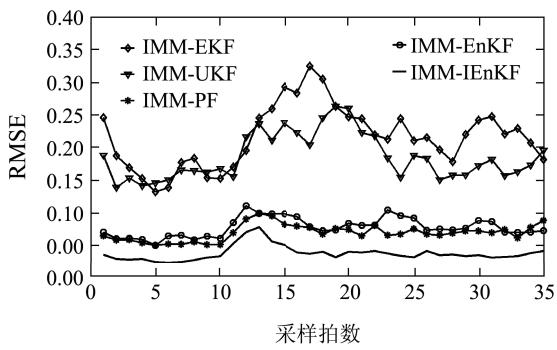


图8 竖直方向位置

Fig. 8 Position estimation in vertical direction

值得注意的是: IMM-IEnKF滤波精度优于IMM-PF, 而IMM-PF精度与IMM-EnKF相接近, 但IMM-EnKF算法耗时仅是IMM-PF的29. IMM-IEnKF算法耗时相对于IMM-EnKF增加了59%, 然而, 滤波精度同样提升了50%左右。分析其原因在于: IEnKF中通过引入量测迭代更新策略实现对EnKF的滤波估计精度的进一步改善。考虑到粒子数目与采样型滤波精度具有近似正相关的特性, 由以上仿真结果可知: 当在粒子数目相同条件下, IMM-EnKF和IMM-IEnKF的滤波精度和实时性必然将均优于IMM-PF; IMM-IEnKF滤波精度将优于IMM-EnKF, 实时性则次于IMM-EnKF。因此, 在实时性要求较高场合, 可以选择IMM-EnKF; 而在滤波精度优先的场合, 可以选择IMM-IEnKF。为进一步定量分析以上5种算法滤波精度和实时性方面具体差异, 表1给出50次独立仿真条件下RMSE的均值以及平均运行时间比较, 其数据信息同样验证了以上结果分析。

由于IEnKF采用了随机性采样处理方式, 其采样粒子数目将直接影响IMM-IEnKF滤波性能。为验证采样粒子数目对算法精度和实时性的影响, 表2中定量给出了粒子数目分别取100, 200, 500, 1000以及5000条件下IMM-IEnKF的RMSE均值以及平均运行时间的信息。从表2中数据可知: 随着采样粒子数目增加IMM-IEnKF滤波精度将得到逐渐改善, 但并不服从严格的线性关系。当粒子数目100增加500过程中, IMM-

IEnKF精度改善比较明显; 而当粒子数目进一步增加时, 从500增加到5000过程中, 滤波精度提升效果有限。以上结论为实际应用中兼顾算法滤波精度和实时性两个滤波器关键指标参数, 有效发挥IMM-IEnKF性能提供了一定参考价值。

表1 基于50次独立仿真条件下RMSE均值以及平均运行时间比较

Table 1 The mean of RMSE and time-consuming under 50 independent simulations

算法	水平方向/km	竖直方向/km	耗时/s
IMM-EKF	0.1525	0.2330	0.0040
IMM-UKF	0.1158	0.1782	0.0102
IMM-EnKF	0.0519	0.0784	0.2934
IMM-PF	0.0454	0.0693	1.0136
IMM-IEnKF	0.0231	0.0357	0.4651

表2 粒子数目不同取值下IMM-IEnKF的RMSE均值以及平均运行时间比较

Table 2 The mean of RMSE and time-consuming in condition of different particles numbers

粒子数	水平方向/km	竖直方向/km	耗时/s
100	0.2124	0.3486	0.1015
200	0.0827	1.0239	0.1923
500	0.0231	0.0357	0.4651
1000	0.0192	0.0224	0.9428
5000	0.0176	0.0208	4.6822

## 5 总结(Conclusions)

机动目标跟踪一直是目标跟踪领域研究的热点。针对此类问题的处理, 本文提出了一种基于量测迭代更新EnKF的机动目标跟踪算法。近年来提出的EnKF给出了解决非线性系统估计问题一种有效处理方法, 在EnKF框架下, 文中通过量测迭代更新环节的引入进一步改善了其滤波精度。IMM利用多个与系统模型相匹配的滤波器并行处理结果的综合, 能够较好地处理系统结构和参数不确定或变化问题。新算法通过IEnKF和IMM的动态结合实现机动目标运动模式和状态的有效辨识和估计。仿真结果验证了算法有效性。

## 参考文献

- [1] MAHLER R P S. *Statistical Multisource-multitarget Information Fusion* [M]. Boston: Artech House Publishers, 2007.
- [2] LI W L, JIA Y M. Consensus-based distributed multiple model UKF for jump Markov nonlinear systems [J]. *IEEE Transactions on Automatic Control*, 2012, 57(1): 227 – 233.
- [3] JIAN L, LI X R, JILKOV V P, et al. Second-order Markov chain based multiple-model algorithm for maneuvering target tracking [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2013, 49(1): 3 – 19.

- [4] NADARAJAH N, THARMARASA R, MCDONALD M, et al. IMM forward filtering and backward smoothing for maneuvering target tracking [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(3): 2673 – 2678.
- [5] 彭冬亮, 郭云飞, 薛安克. 三维高速机动目标跟踪交互式多模型算法 [J]. 控制理论与应用, 2008, 25(5): 831 – 836.  
(PENG Donglang, GUO Yunfei, XUE Anke. An interacting multiple model algorithm for a 3D high maneuvering target tracking [J]. *Control Theory & Applications*, 2008, 25(5): 831 – 836.)
- [6] HAMMES U, ZOUBIR A M. Robust MT tracking based on M-estimation and interacting multiple model algorithm [J]. *IEEE Transactions on Signal Processing*, 2011, 59(7): 3398 – 3409.
- [7] BILIK I, TABRIKIAN J. Maneuvering target tracking in the presence of glint using the nonlinear Gaussian mixture Kalman filter [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2010, 46(1): 246 – 262.
- [8] FOO P H, NG G W. Combining the interacting multiple model method with particle filters for maneuvering target tracking [J]. *IET Radar, Sonar and Navigation*, 2011, 5(3): 234 – 255.
- [9] KAI X, WEI C L, LIU L D. Robust extended Kalman filtering for nonlinear systems with stochastic uncertainties [J]. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 2010, 40(2): 399 – 405.
- [10] GUSTAFSSON F, HENDEBY G. Some relations between extended and unscented Kalman filters [J]. *IEEE Transactions on Signal Processing*, 2012, 60(2): 545 – 555.
- [11] DUNIK J, SIMANDL M, STRAKA O. Unscented Kalman filter: aspects and adaptive setting of scaling parameter [J]. *IEEE Transactions on Automatic Control*, 2012, 57(9): 2411 – 2416.
- [12] DINI D H, MANDICD P, JULIER S J. A widely linear complex unscented Kalman filter [J]. *IEEE Signal Processing Letters*, 2011, 18(11): 623 – 626.
- [13] WANG Y F, SUN F C, ZHANG Y A, et al. Central difference particle filter applied to transfer alignment for SINS on missiles [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(1): 375 – 387.
- [14] ARASARATNAM I, HAYKIN S, HURD T R. Cubature Kalman filtering for continuous-discrete systems: theory and simulations [J]. *IEEE Transactions on Signal Processing*, 2010, 58(10): 4977 – 4993.
- [15] KARLSSON R. *Particle filter for positioning and tracking applications* [D]. Linkoping: Linkoping University, 2005.
- [16] CAPPE O, GODSILL S J, MOULINES E. An overview of existing methods and recent advances in sequential Monte Carlo [J]. *Proceedings of the IEEE*, 2007, 95(5): 899 – 924.
- [17] EVENSEN G. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics [J]. *Geophys*, 1994, 99(5): 143 – 162.
- [18] GILLIJNS S, MENDOZA O B, CHANDRASEKAR J, et al. What is the ensemble Kalman filter and how well does it work [C] // *American Control Conference*. Minneapolis: IEEE, 2006: 4448 – 4453.
- [19] EVENSEN G. The ensemble Kalman filter for combined state and parameter estimation [J]. *IEEE Control Systems*, 2009, 29(3): 83 – 104.
- [20] CHANG L, HU B, CHANG G, et al. Marginalised iterated unscented Kalman filter [J]. *IET Control Theory and Applications*, 2012, 6(6): 847 – 85.

### 作者简介:

- 胡振涛 (1979–), 男, 副教授, 博士, 主要从事复杂系统建模与估计、多源信息融合、非线性滤波的研究, E-mail: hzt@henu.edu.cn;
- 张 勇 (1979–), 男, 工程师, 主要从事数据融合、数据挖掘的研究, E-mail: zhangyong@henu.edu.cn;
- 刘先省 (1964–), 男, 教授, 博士, 主要从事多源信息融合、多传感器管理的研究, E-mail: liuxxhd@126.com.