# 基于改进集合卡尔曼滤波方法的目标运动轨迹多源异步数据融合方法研究

张泽群* 任文娟 付 琨 方继飞 张 跃
(中国科学院电子学研究所 北京 100190)
(中国科学院空间信息处理与应用系统技术重点实验室 北京 100190)

**摘 要**：该文构建了一个改进的多源异步观测数据情景下基于非线性运动学本构方程的集合卡尔曼滤波理论模型，该模型可以精确反演出目标运动状态参数(速度、加速度)以对目标后续运动进行预测。并基于集合卡尔曼滤波实现了多源观测数据融合，利用高精度观测数据修正低精度观测数据，修正后的数据精度可通过集合卡尔曼滤波提供的统计学信息进行标定，为非线性情形下目标轨迹多源异步数据融合问题提供了新的解决思路。

**关键词**：数据融合；目标轨迹分析；集合卡尔曼滤波
**中图分类号**：TP391 **文献标识码**：A **文章编号**：1009-5896(2018)09-2143-07
**DOI**: 10.11999/JEIT171115

# Research on Multi-source and Asynchronous Data Fusion of Target Trajectory Based on the Modified Ensemble Kalman Filter Method

ZHANG Zequn REN Wenjuan FU Kun FANG Jifei ZHANG Yue
(*Institute of Electronics*, *Chinese Academy of Sciences*, *Beijing* 100190, *China*)
(*Key Laboratory of Technology in Geo-spatial Information Processing and Application System*, *Chinese Academy of Science*, *Beijing* 100190, *China*)

**Abstract**: A modified Ensemble Kalman Filter (EnKF) theory model based on kinematic equations is proposed to realize the historical fitting analysis and trajectory prediction of the target trajectory in the multi-source observation data scenario. This model is applied to accurately calculate the target motion state parameters (velocity and acceleration), then the target's follow-up movement is predicted. The multi-source observation data fusion is realized by using the EnKF, which enables the low-precision observation data to be corrected by high-precision observation data, and the accuracy of the corrected data can be calibrated by the statistical information provided by the EnKF.

**Key words**: Data fusion; Target trajectory analysis; Ensemble Kalman Filter (EnKF)

## 1 引言

在目标追踪定位问题中，融合多传感器观测数据从而实现对目标更加精确的定位一直是研究的重点。不同的定位测量手段，为目标轨迹提供了不同时序和空间的观测点数据源，也导致了同一目标轨迹上各个定位信息的精确度存在高低差异。所以需要利用多源观测数据中不同时刻的高精度信息对低精度信息进行修正，即多源观测数据异步融合[1]。

现有的目标追踪定位方法包括：卡尔曼滤波方法[2]、扩展卡尔曼滤波方法[3]、粒子滤波方法[4]、马尔科夫链[5]等。卡尔曼滤波方法只有在系统参数较少时会达到较高的计算效率，另一方面，卡尔曼滤波方法是一种利用线性系统状态方程，通过系统输入输出观测数据，对系统状态进行最优估计的算法，使得其不能对非线性问题进行处理[6,7]。扩展卡尔曼滤波方法则只限于处理弱非线性和Jacobi矩阵可以定义的情形[8]。粒子滤波算法基于蒙特卡洛思想，利用粒子集的形式来表示概率，但需要大量样本进行计算[9]。马尔科夫链方法则将目标运动轨迹视为一个马尔科夫链，利用概率对移动轨迹进行定位，但是无法对目标运动状态进行表述[10]。Evensen[11]基于卡尔曼滤波方法提出了集合卡尔曼滤波方法(Ensemble Kalman Filter, EnKF)。集合

收稿日期：2017-11-28；改回日期：2018-05-25；网络出版：2018-07-12
*通信作者： 张泽群 zqzhang1@mail.ie.ac.cn

卡尔曼滤波方法是另一种卡尔曼滤波方法处理非线性问题的拓展[12]，在石油工业等领域中已有较多应用[13–15]。Cui等人[16]将集合卡尔曼滤波方法应用于多传感器目标跟踪问题，验证了集合卡尔曼滤波方法对目标跟踪结果明显优于扩展卡尔曼滤波方法，但由于集合卡尔曼滤波模型构建并不完善，不考虑运动目标速度与加速度共存情形，不能实现对目标运动加速度的精确反演，同时假设不同观测源的观测时间节点同步。Pornsarayouth等人[17]利用集合卡尔曼滤波方法处理非顺序测量问题，并验证了集合卡尔曼滤波方法在处理该类问题时要优于卡尔曼滤波、粒子滤波和扩展卡尔曼滤波方法，并较粒子滤波方法需要更少的样本数，但该研究假设目标运动为匀速运动，主要考虑如何将两组不同观测数据进行融合，并且没有实现对后续目标运动轨迹的预测。总体来说，集合卡尔曼滤波方法在目标轨迹分析中的应用研究还较为初步。

本文将考虑目标加速度与速度同时存在的情形，即考虑加速度和速度耦合情形，构建一个多源异步观测数据情景下基于非线性运动学本构方程的集合卡尔曼滤波理论模型。同时研究如何改进集合卡尔曼滤波方法以实现对目标运动轨迹多源观测数据进行自动历史拟合，通过轨迹数据反演目标的运动状态信息(速度、加速度)，并对后续运动状态进行预测，实现多源异步观测数据间的融合，提高低精度定位信息准确度。

## 2 模型构建

集合卡尔曼滤波方法主要分为两个步骤：预测步骤以及更新步骤。在预测步骤中，首先基于样本参数的先验信息，如概率密度分布函数，产生样本参数的集合，对模型未来变化进行预测。其中的每个样本参数都是一个模型状态向量的形式，这个状态向量包含了动态、静态参数和观测值。在更新步骤中，则通过比较预测步骤得到的预测值与实际观测数据之间的差别来修正参数样本集合中的状态向量。本节将对集合卡尔曼滤波进行改进，以使其可以处理多源异步数据融合问题。

### 2.1 样本参数集合

在集合卡尔曼滤波中，首先引入样本集合矩阵$\boldsymbol{Y}$，矩阵$\boldsymbol{Y}$的每一列都代表着样本集合中的每一个元素。所以，样本集合矩阵$\boldsymbol{Y}$的每一列都可以由一个状态向量$\boldsymbol{y}^j$定义，$j$为状态向量$\boldsymbol{y}^j$的标号，或者说是样本集合矩阵$\boldsymbol{Y}$的第$j$列。状态向量由动态参量$\boldsymbol{\eta}^j$和静态参量$\boldsymbol{r}^j$构成。

则此时，样本集合矩阵$\boldsymbol{Y}$可以表示为

$$\begin{aligned}\boldsymbol{Y}_i=\boldsymbol{Y}(t_i)&=(\boldsymbol{y}^1(t_i),\boldsymbol{y}^2(t_i),\cdots,\boldsymbol{y}^{\mathrm{Ne}}(t_i))\\&=\begin{pmatrix}\boldsymbol{\eta}^1(t_i)&\cdots&\boldsymbol{\eta}^{\mathrm{Ne}}(t_i)\\\boldsymbol{\gamma}^1(t_i)&\cdots&\boldsymbol{\gamma}^{\mathrm{Ne}}(t_i)\end{pmatrix}\end{aligned}\tag{1}$$

Ne是集合中所有样本实现的总个数。$<\boldsymbol{Y}(t_i)>$是储存样本集合矩阵的参数均值，定义如式(2)：

$$<\boldsymbol{Y}(t_i)>=\boldsymbol{Y}(t_i)\,\boldsymbol{I}_{\mathrm{Ne}}\tag{2}$$

这里，$\boldsymbol{I}_{\mathrm{Ne}}$为$\mathrm{Ne}\times\mathrm{Ne}$的矩阵，其每个元素都是$1/\mathrm{Ne}$。则样本参数矩阵中的扰动$\boldsymbol{Y}'$可表示为

$$\boldsymbol{Y}'(t_i)=\boldsymbol{Y}(t_i)-<\boldsymbol{Y}(t_i)>\tag{3}$$

故样本参数协方差$\boldsymbol{C}_{\mathrm{Y}}$形式为

$$\boldsymbol{C}_{\mathrm{Y}}(t_i)=\frac{\boldsymbol{Y}'(t_i)\,\boldsymbol{Y}'^{\mathrm{T}}(t_i)}{\mathrm{Ne}-1}\tag{4}$$

协方差$\boldsymbol{C}_{\mathrm{Y}}$可以表述样本参数集合的光滑性和波动程度。

### 2.2 构建多源观测参数集合

同时定义观测量向量$\boldsymbol{d}\in R^m$, $m$是观测数据的种类个数。为了匹配样本集合矩阵的维度，需要给观测量向量$\boldsymbol{d}$添加均值为0的误差扰动$\boldsymbol{\varepsilon}^j$。由于观测数值总是存在着系统误差，所以这一个误差扰动的添加符合实际情况。生成矩阵$\boldsymbol{D}$：

$$\boldsymbol{D}(t_i)=\left(\boldsymbol{d}^1(t_i),\boldsymbol{d}^2(t_i),\cdots,\boldsymbol{d}^{\mathrm{Ne}}(t_i)\right)\tag{5}$$

在这里，$\boldsymbol{D}$的每一列为$\boldsymbol{d}^j(t_i)$：

$$\boldsymbol{d}^j(t_i)=\boldsymbol{d}(t_i)+\boldsymbol{\varepsilon}_k^j,j=1,2,\cdots,\mathrm{Ne}\tag{6}$$

$\boldsymbol{d}(t_i)$为时刻$t_i$的观测值构成的向量。在多源观测数据情境下，需要根据不同的传感器精度，对不同时刻观测值添加不同大小的误差扰动。式(6)需要修改为

$$\boldsymbol{d}^j(t_i)=\boldsymbol{d}(t_i)+\boldsymbol{\varepsilon}_k^j(t_i),\ j=1,2,\cdots,\mathrm{Ne}\tag{7}$$

$\boldsymbol{\varepsilon}_k^j(t_i)$表示传感器$k$在时刻$t_i$的观测误差扰动。

误差扰动$\{\boldsymbol{\varepsilon}_k^j(t_i)\}$构成集合$\boldsymbol{E}_k$：

$$\boldsymbol{E}_k(t_i)=(\boldsymbol{\varepsilon}_k^1(t_i),\boldsymbol{\varepsilon}_k^2(t_i),\cdots,\boldsymbol{\varepsilon}_k^{\mathrm{Ne}}(t_i))\tag{8}$$

则来自传感器$k$的观测数据协方差可表示为

$$\boldsymbol{C}_{D,k}(t_i)=\frac{\boldsymbol{E}_k(t_i)\,\boldsymbol{E}_k^{\mathrm{T}}(t_i)}{\mathrm{Ne}-1}\tag{9}$$

### 2.3 更新步骤控制方程

在集合卡尔曼滤波算法更新步骤中，将更新后得到新的状态向量$\boldsymbol{y}_j^a$表示为

$$\boldsymbol{y}_j^a=\boldsymbol{y}_j'+\boldsymbol{C}_{\boldsymbol{Y}}\boldsymbol{H}^{\mathrm{T}}\left(\boldsymbol{H}\,\boldsymbol{C}_{\mathrm{Y}}\boldsymbol{H}^{\mathrm{T}}+\boldsymbol{C}_{\mathrm{D}}\right)^{-1}\boldsymbol{D}_j'\tag{10}$$

这里，$\boldsymbol{C}_{\mathrm{Y}}$与$\boldsymbol{C}_{\mathrm{D}}$为样本集合矩阵$\boldsymbol{Y}$和观测矩阵$\boldsymbol{D}$的协方差矩阵，$\boldsymbol{y}_j'$为当前时刻的状态向量预测值，$\boldsymbol{y}_j^a$为更新后的状态向量。$\boldsymbol{D}_j'$定义为

$$\boldsymbol{D}_j' = \boldsymbol{d}^j - \boldsymbol{H}\boldsymbol{y}_j' \tag{11}$$

在多源异步观测数据情景下，式(10)，式(11)应修改为

$$\boldsymbol{y}_j^a(t_i) = \boldsymbol{y}_j'(t_i) + \boldsymbol{C}_{\mathrm{Y}}(t_i)\,\boldsymbol{H}^{\mathrm{T}}(\boldsymbol{H}\boldsymbol{C}_{\mathrm{Y}}(t_i)\,\boldsymbol{H}^{\mathrm{T}} + \boldsymbol{C}_D(t_i))^{-1}\,\boldsymbol{D}_j'(t_i) \tag{12}$$

$$\boldsymbol{D}_j'(t_i) = \boldsymbol{d}^j(t_i) - \boldsymbol{H}\boldsymbol{y}_j'(t_i) \tag{13}$$

矩阵$\boldsymbol{H}$为模型参数状态向量$\boldsymbol{y}^j$与观测向量$\boldsymbol{d}^j$之间的映射矩阵。通常情况下，由于模型的非线性程度较强，在模型参数状态向量$\boldsymbol{y}^j$与观测向量$\boldsymbol{d}^j$之间并不存在线性映射关系。但是，当模型参数状态向量$\boldsymbol{y}_j'$中包含对观测数据的预测值时，映射矩阵的形式将非常简单，映射矩阵$\boldsymbol{H}$中的元素将只包括0和1：

$$\boldsymbol{H} = [\boldsymbol{O}|\boldsymbol{I}] \tag{14}$$

这里$\boldsymbol{I}$为$\boldsymbol{N}_d \times \boldsymbol{N}_d$的单位矩阵；$\boldsymbol{O}$为$\boldsymbol{N}_d \times (\boldsymbol{N}_y - \boldsymbol{N}_d)$的零矩阵。

### 2.4 非线性运动学控制方程预测步骤

本研究中，不假设目标运动为匀速运动，所以状态参数为目标位置、速度和加速度。在这里，定义时刻$t_n$集合卡尔曼滤波状态向量$\boldsymbol{y}_n^j$为

$$\boldsymbol{y}_n^j(t_n) = [\mathrm{xs}^j(t_n), \mathrm{ys}^j(t_n), \mathrm{xv}^j(t_n), \mathrm{yv}^j(t_n), \mathrm{xa}^j(t_n), \mathrm{ya}^j(t_n)] \tag{15}$$

同样令$\Delta t$表示时刻$t_{n-k}$与$t_n$的时间间隔，利用时刻$t_{n-k}$状态向量$\boldsymbol{y}_{n-k}^j$计算时刻$t_n$状态向量$\boldsymbol{y}_n^j$的预测值$\boldsymbol{y}_n^{j\prime}$，本文中刻画状态向量预测值：

$$\boldsymbol{y}_n^{j\prime}(t_n) = [\mathrm{xs}^{j\prime}(t_n), \mathrm{ys}^{j\prime}(t_n), \mathrm{xv}^{j\prime}(t_n), \mathrm{yv}^{j\prime}(t_n), \mathrm{xa}^{j\prime}(t_n), \mathrm{ya}^{j\prime}(t_n)] \tag{16}$$

运动本构方程如式(17)：

$$\left.\begin{aligned}
\mathrm{xs}^{j\prime}(t_n) &= \mathrm{xs}^j(t_{n-k}) + \mathrm{xv}^j(t_{n-k})\,\Delta t + 0.5\mathrm{xa}^j(t_{n-k})\,\Delta t^2\\
\mathrm{ys}^{j\prime}(t_n) &= \mathrm{ys}^j(t_{n-k}) + \mathrm{yv}^j(t_{n-k})\,\Delta t + 0.5\mathrm{xa}^j(t_{n-k})\,\Delta t^2\\
\mathrm{xv}^{j\prime}(t_n) &= \mathrm{xv}^j(t_{n-k}) + \mathrm{xa}^j(t_{n-k})\,\Delta t\\
\mathrm{yv}^{j\prime}(t_n) &= \mathrm{yv}^j(t_{n-k}) + \mathrm{ya}^j(t_{n-k})\,\Delta t\\
\mathrm{xa}^{j\prime}(t_n) &= \mathrm{xa}^j(t_{n-k})\\
\mathrm{ya}^{j\prime}(t_n) &= \mathrm{ya}^j(t_{n-k})
\end{aligned}\right\} \tag{17}$$

式(17)中加速度值预测值虽然暂定为上一时刻加速度值，但在集合卡尔曼滤波更新步骤中会对加速度进行更新，使其不断得到修正。在得到时刻$t_n$状态向量$\boldsymbol{y}_n^j$的预测值$\boldsymbol{y}_n^{j\prime}$后，就可以利用式(12)和时刻$t_n$的观测数据对进行$\boldsymbol{y}_n^{j\prime}$更新修正。随着各个时间步的观测数据不断进入集合卡尔曼滤波系统(历史拟合过程)，就可以对状态向量$\boldsymbol{y}_n^j$中的各个参数(速度、加速度)逐渐进行修正，最后使得反演得到的目标运动状态(速度、加速度)逐渐趋近于真实数值。至此，多源异步观测数据情景下，基于运动学本构方程的集合卡尔曼滤波模型构建完毕。在第3节中，将对本模型的适用性进行验证。

## 3　仿真实验及分析

本算例基于一个具有加速度的运动目标多源观测数据，数据点同样15个，目标轨迹观测值如表1所示，轨迹和各观测数据误差如图1所示。图1中各个点的观测误差均值为0，标准差大小对应于黑色线段长度，长度越大代表该点的观测标准差也越大，标准差相应有：2 km, 5 km, 8 km, 15 km(即观测数据具有4个不同的来源)。目标实际运动过程，按照 $V_{x,0} = 5$ km/h，$a_x = 0.2$ km/h$^2$，$V_{y,0} = 6$ km/h，$a_y = -0.2$ km/h$^2$做匀加速运动。在集合卡尔曼滤波中，每个观测数据添加均值为0及其对应标准差(2 km, 5 km, 8 km, 15 km)的误差扰动，以反映实际观测数据中的不确定性。$X$方向初始速度均值设置为9 km/h，标准差为5 km/h; $Y$方向初始速度均值设置为10 km/h，标准差为5 km/h; $X$方向初始加速度均值设置为0，标准差为0.25 km/h$^2$; $Y$方向初始加速度均值设置为0，标准差为0.25 km/h$^2$。集合卡尔曼滤波样本数Ne设置为100。

图2为依据100个初始速度、加速度猜测样本对目标运动轨迹的预测，可以看到未进行集合卡尔曼

**表 1　目标轨迹观测值**

| 时刻(h) | $X$轴(km) | $Y$轴(km) |
|---|---|---|
| 1 | 5.1 | 3.9 |
| 3 | 15.9 | 11.1 |
| 5 | 27.5 | 17.5 |
| 8 | 43.4 | 25.6 |
| 10 | 63.0 | 33.0 |
| 14 | 89.6 | 36.4 |
| 18 | 122.4 | 39.6 |
| 20 | 144.0 | 44.0 |
| 21 | 149.1 | 39.9 |
| 25 | 187.5 | 37.5 |
| 29 | 229.1 | 34.9 |
| 32 | 262.4 | 21.6 |
| 35 | 297.5 | 17.5 |
| 39 | 347.1 | 3.9 |
| 41 | 373.1 | –4.1 |

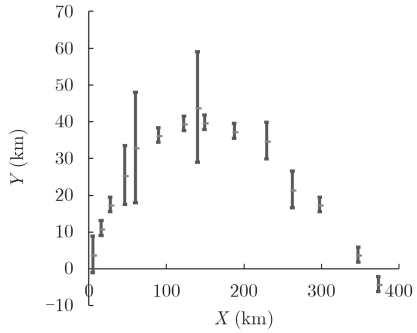


图 1 目标轨迹观测值和观测误差分布

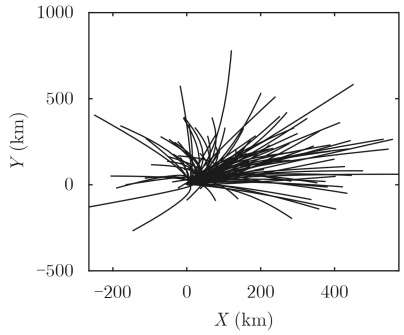


图 2 初始猜测值(速度、加速度)对目标轨迹的预测

滤波的目标预测轨迹分布较为离散，不能对实际运动状态进行刻画。图3为依据前13个目标观测数据进行集合卡尔曼滤波的计算结果，黑色曲线代表实际观测数据形成的轨迹，每个实际观测数据周围的黑色圆圈为100个集合卡尔曼滤波样本更新值。可以看到，与图2初始猜测计算出的经过集合卡尔曼滤波后图3中黑色点代表的集合卡尔曼滤波轨迹点已经收敛至观测点周围，但是在某些观测位置上还有一定的偏差，本文将利用图4对这一现象进行解释。

图4为集合卡尔曼滤波拟合结果100个样本的统计信息与实际多源观测数据统计信息对比。由于集合卡尔曼滤波利用了蒙特卡洛思想来产生随机样本，所以可以直接计算样本相应统计学信息(均值、方差等)。方块标记的虚线代表集合卡尔曼滤波拟合轨迹，线段的中点代表集合卡尔曼滤波100个样

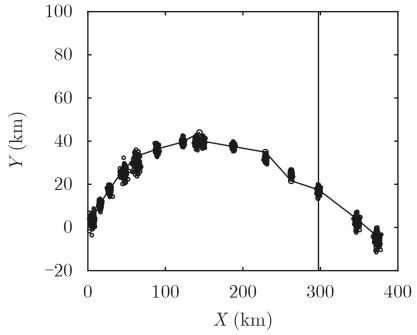


图 3 集合卡尔曼滤波实现目标轨迹的历史拟合

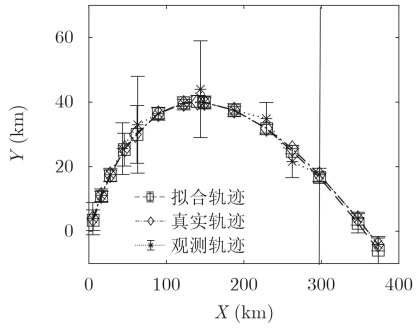


图 4 集合卡尔曼滤波实现目标轨迹的历史拟合

本的均值，线段长度与集合卡尔曼滤波更新结果标准差大小成正比；“*”标记的点状虚线代表多源观测数据，中点为观测数据位置，线段长度与标准差大小成正比。菱形标记的虚线为实际目标运动轨迹。可以从图4中看到，经过集合卡尔曼滤波更新后，集合卡尔曼滤波拟合轨迹代表的样本标准差较多源观测数据明显减小，尤其在几个观测误差较大的观测点位置(左起点4, 5, 8, 11, 12)，集合卡尔曼滤波结果不仅更加贴近实际目标运动轨迹，并且集合卡尔曼滤波更新后轨迹点位置标准差显著减小，也就意味着得到的更新结果定位精度更高。这是由于集合卡尔曼滤波每个时刻的样本更新值有两个来源：一个来源是基于上一时刻样本更新值通过集合卡尔曼滤波预测步骤得到的当前时刻预测值(式(17))；另一个来源为当前时刻的观测数据。当前后两个时刻的观测数据精度有所不同时，集合卡尔曼滤波的计算流程使得其可以利用高精度的观测数据对低精度的观测数据进行修正，实现不同观测数据源之间的信息融合，从而提高低精度观测数据的置信度，图4中的结果就是最有力的证明。同时，图3、图4中黑色竖线后的两个数据点是基于反演出的目标速度和加速度对其轨迹进行预测得到的结果，可以看到，经历两个时间步后，集合卡尔曼滤波轨迹预测值仍能将观测数据包含在分布范围内。这证明在多源异步观测数据情景下，本研究中构建的集合卡尔曼滤波模型可以利用历史拟合得到的运动参数对后续目标运动状态进行预测。

图5、图6为集合卡尔曼滤波$X$方向和$Y$方向的速度历史拟合结果。黑色曲线代表集合卡尔曼滤波中100个样本实现，100条曲线从初始步骤时较为离散的分布情况开始不断收敛。在第13个时间步得到$X$方向速度均值为11.95 km/h, $Y$方向速度均值为–3.03 km/h(该时刻实际$X$方向速度为12 km/h, $Y$方向速度为–3 km/h)。可以看到，在多源异步观测数据情况下，集合卡尔曼滤波进行历史拟合仍然可以非常精确地刻画目标运动速度。

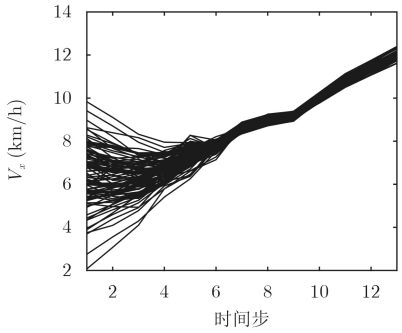


图 5 $X$方向速度集合卡尔曼滤波反演结果

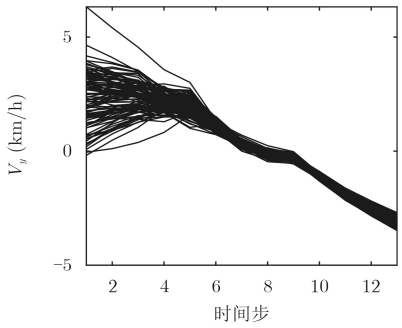


图 6 $Y$方向速度集合卡尔曼滤波反演结果

图7、图8为集合卡尔曼滤波$X$方向和$Y$方向的加速度历史拟合结果。可以看到，随着集合卡尔曼滤波的进行，图7、图8中的黑色曲线也逐渐从初始猜测时较为离散的状态不断收敛。在第13个时间步时，集合卡尔曼滤波得到的$X$方向和$Y$方向加速度均值分别为0.195 km/h$^2$和–0.203 km/h$^2$，而实际加速度值为0.2 km/h$^2$与–0.2 km/h$^2$。故可以得出结论：在多源异步观测数据情景下，集合卡尔曼滤波方法可以反演得到精确的目标运动加速度值。图9为本研究采用的基于改进集合卡尔曼滤波方法轨迹拟合结果与卡尔曼滤波、扩展卡尔曼滤波以及粒子滤波轨迹拟合结果的对比。可以从图9中看到，本研究构建的基于改进集合卡尔曼滤波方法轨迹拟合结果与实际轨迹最为接近，也验证了本研究构建的模型处理非线性运动问题的能力明显优于卡尔曼滤波等传统轨迹拟合方法。

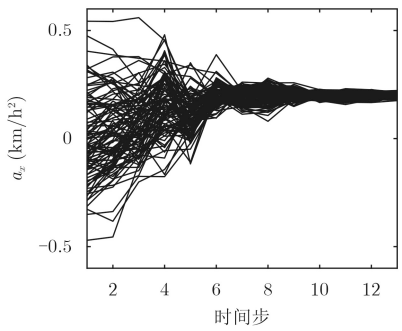


图 7 $X$方向加速度集合卡尔曼滤波反演结果

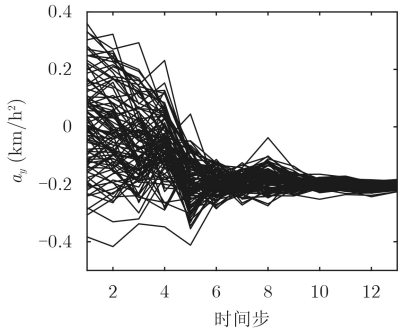


图 8 $Y$方向加速度集合卡尔曼滤波反演结果

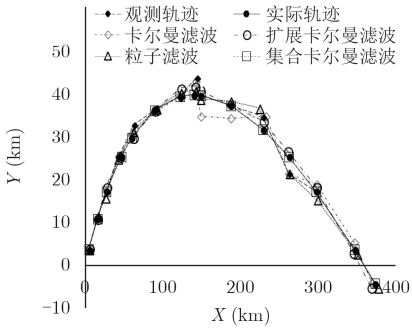


图 9 集合卡尔曼滤波运动拟合结果与卡尔曼滤波、扩展卡尔曼滤波和粒子滤波对比

## 4　结论

基于多源异步信息的目标轨迹分析问题一直是目标追踪研究领域的研究重点之一，本文利用集合卡尔曼滤波方法解决目标轨迹多源异步观测数据分析与预测问题，并构建了多源观测数据情景下基于非线性运动学本构方程的集合卡尔曼滤波理论模型。基于蒙特卡洛方法的集合卡尔曼滤波，通过在计算过程中为不同精度的观测数据添加不同的误差扰动，可以实现对目标不同观测数据源信息不确定性的统计学表述，实现不同精度的多源观测数据融合，并且相较卡尔曼滤波有可以处理强非线性问题的优势。本研究与现有的利用集合卡尔曼滤波方法分析目标运动研究不同之处在于：(1)不假设目标各观测时间间隔内做匀速运动，考虑加速度项的存在，通过对目标历史轨迹的拟合和运动本构方程，精确反演出目标运动状态参数(速度、加速度)；(2)考虑多源异步观测数据源，实现不同时刻不同观测数据源之间的融合。

同时，本文通过仿真分析，验证了改进后的集合卡尔曼滤波模型在多源异步观测数据情景下应用的可行性，并得到以下结论：(1)在多源异步观测数据情景下，可以利用集合卡尔曼滤波基于目标历史轨迹精确拟合目标运动状态参数(速度、加速度)，并对未来运动轨迹进行预测；(2)通过在计算过程中为不同精度的观测数据添加不同的误差扰

动，集合卡尔曼滤波方法可以实现多源异步观测数据不确定性的直接表述，并在参数拟合过程中考虑观测数据不确定性，参数拟合结果可以从统计学角度更加客观地表述目标实际情况；(3)集合卡尔曼滤波方法可以实现不同精度的多源异步观测数据融合，利用高精度的观测数据对低精度观测数据进行修正，提高低精度观测数据精度和置信度，轨迹拟合能力优于传统轨迹拟合方法。

本文构建了一个完善的多源异步观测数据情景下的目标轨迹数据融合模型，由于模型可以较为精确地刻画出运动状态参数(速度、加速度)，使得在后续新的研究中可以对目标运动状态参数(速度、加速度)的异常变化进行监控，对目标运动异常变化进行预警。

## 参 考 文 献


[1] 孙辉, 赵峰, 张峰云. 多传感器信息融合技术及其应用[J]. 海洋测绘, 2009, 29(5): 77–81. doi: 10.3969/j.issn.1671-3044.2009.05.023.
SUN Hui, ZHAO Feng, and ZHANG Fengyun. Multisensor information fusion technology and application[J]. *Hydrographic Surveying and Charting*, 2009, 29(5): 77–81. doi: 10.3969/j.issn.1671-3044.2009.05.023.

[2] 姜楷娜. 基于卡尔曼滤波的目标轨迹跟踪仿真研究[J]. 中国科技信息, 2017(17): 105–106. doi: 10.3969/j.issn.1001-8972.2017.17.036.
JIANG Kaina. Research on target tracking based on Kalman filter[J]. *Chian Science and Technology Information*, 2017(17): 105–106. doi: 10.3969/j.issn.1001-8972.2017.17.036.

[3] 王雪君, 孙进平, 张旭旺. 基于压缩感知的PD雷达序贯扩展卡尔曼滤波跟踪方法[J]. 信号处理, 2017, 33(4): 601–606. doi: 10.16798/j.issn.1003-0530.2017.04.022.
WANG Xuejun, SUN Jinping, and ZHANG Xuwang. Progressive Extended Kalman Filter Tracking Method Based on Compressive Sensing for PD Radar[J]. *Journal of Signal Processing*, 2017, 33(4): 601–606. doi: 10.16798/j.issn.1003-0530.2017.04.022.

[4] 刘晨光, 程丹松, 刘家锋, 等. 一种基于交互式粒子滤波器的视频中多目标跟踪算法[J]. 电子学报, 2011, 39(2): 260–267.
LIU Chenguang, CHENG Dansong, LIU Jiafeng, *et al.* A multi-target tracking algorithm in video based on interactive particle filter[J]. *Acta Electronica Sinica*, 2011, 39(2): 260–267.

[5] 陈思静, 张可. VANETs中的车辆移动规律性及轨迹预测研究[J]. 计算机工程与应用, 2016, 52(18): 139–143. doi: 10.3778/j.issn.1002-8331.1410-0313.
CHEN Sijing and ZHANG Ke. Research on vehicle movement regularity and trajectory prediction in VANETs[J]. *Computer Engineering and Applications*, 2016, 52(18): 139–143. doi: 10.3778/j.issn.1002-8331.1410-0313.

[6] 郭晓军, 万龙, 刘峰. 基于扩展卡尔曼滤波的空间小目标跟踪算法[J]. 电光与控制, 2016, 23(4): 57–61. doi: 10.3969/j.issn.1671-637X.2016.04.012.
GUO Xiaojun, WAN Long, and LIU Feng. An algorithm for small space target tracking based on extended Kalman filter[J]. *Electronics Optics & Control*, 2016, 23(4): 57–61. doi: 10.3969/j.issn.1671-637X.2016.04.012.

[7] GELB A and BOOKSX I. Applied optimal estimation[J]. *Proceedings of the IEEE*, 1974, 64(4): 574–575.

[8] 沈凯, 管雪元, 李文胜. 扩展卡尔曼滤波在组合导航中的应用[J]. 传感器与微系统, 2017, 36(8): 158–160. doi: 10.13873/J.1000-9787(2017)08-0158-03.
SHEN Kai, GUAN Xueyuan, and LI Wensheng. Application of EKF in integrated navigation system[J]. *Transducer and Microsystem Technologies*, 2017, 36(8): 158–160. doi: 10.13873/J.1000-9787(2017)08-0158-03.

[9] 程兰, 王志远, 陈杰, 等. 基于粒子滤波和滑动平均扩展卡尔曼滤波的多径估计算法[J]. 电子与信息学报, 2017, 39(3): 709–716. doi: 10.11999/JEIT160587.
CHENG Lan, WANG Zhiyuan, CHEN Jie, *et al.* An improved multipath estimation algorithm using particle filter and sliding average extended Kalman filter[J]. *Journal of Electronics & Information Technology*, 2017, 39(3): 709–716. doi: 10.11999/JEIT160587.

[10] 朱海东, 葛万成. 车联网中的异构网络融合机制研究[J]. 通信技术, 2017, 50(8): 1691–1695. doi: 10.3969/j.issn.1002-0802.2017.08.017.
ZHU Haidong and GE Wancheng. Heterogeneous network fusion mechanism in vehicle networks[J]. *Communications Technology*, 2017, 50(8): 1691–1695. doi: 10.3969/j.issn.1002-0802.2017.08.017.

[11] EVENSEN G. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics[J]. *Journal of Geophysical Research Oceans*, 1994, 99(C5): 10143–10162. doi: 10.1029/94JC00572.

[12] VERLAAN M and HEEMINK A W. Nonlinearity in data assimilation applications: A practical method for analysis[J]. *Monthly Weather Review*, 2001, 129(6): 1578–1589. doi: 10.1175/1520-0493(2001)129.

[13] ZHANG Zequn, LI Heng, and ZHANG Dongxiao. Water flooding performance prediction by multi-layer capacitance-resistive models combined with the ensemble Kalman filter[J]. *Journal of Petroleum Science & Engineering*, 2015,

127(1): 1–19. doi: 10.1016/j.petrol.2015.01.020.

[14] ZHANG Zequn, LI Heng, and ZHANG Dongxiao. Reservoir characterization and production optimization using the ensemble-based optimization method and multi-layer capacitance-resistive models[J]. *Journal of Petroleum Science & Engineering*, 2017, 156: 633–653. doi: 10.1016/j.petrol.2017.06.020.

[15] LIU Di, MISHRA A K, and YU Zhongbo. Evaluating uncertainties in multi-layer soil moisture estimation with support vector machines and ensemble Kalman filtering[J]. *Journal of Hydrology*, 2016, 538(1): 243–255. doi: 10.1016/j.jhydrol.2016.04.021.

[16] CUI Bo and ZHANG Jiashu. The improved ensemble Kalman filter for multisensor target tracking[C]. IEEE International Symposium on Information Science and Engineering, Shanghai, China, 2008: 263–265. doi: 10.1109/isise.2008.272.

[17] PORNSARAYOUTH S, WONGSAISUWAN M, and YAMAKITA M. An improvement of ensemble Kalman filter for OOSM tracking[J]. *IFAC Proceedings Volumes*, 2011, 44(1): 12003–12008. doi: 10.3182/20110828-6-it-1002.03399.

张泽群：男，1990 年生，助理研究员，研究方向为反问题、模型优化、地理空间信息挖掘.

任文娟：女，1982 年生，副研究员，研究方向为电子目标识别、数据挖掘.

付　琨：男，1976 年生，研究员，研究方向为计算机视觉与遥感图像理解、地理空间信息挖掘与可视化.

方继飞：男，1989 年生，工程师，研究方向为轨迹分析.

张　跃：男，1990 年生，助理研究员，研究方向为计算机视觉与遥感图像理解.