

多模型粒子滤波跟踪算法研究

鉴福升^{①②③} 徐跃民^② 阴泽杰^①

^①(中国科学技术大学近代物理系 合肥 230026)

^②(中国科学院空间科学与应用研究中心 北京 100190)

^③(中国人民解放军 92323 部队 青岛 266003)

摘要: 针对机动目标跟踪问题, 该文设计了一种改进的多模型粒子滤波(EMMPF)算法。与传统的多模型粒子滤波(MMPF)算法按照模型概率分配粒子数不同, 该算法可根据用户定义的准则灵活控制各个模型的粒子数, 且无需对模型间的粒子进行交互。模型估计和状态估计分开计算, 并用模型似然函数更新模型后验概率。与MMPF进行的仿真比较表明, 该算法能用较少的粒子数获得更好的滤波性能。

关键词: 机动目标跟踪; 多模型; 粒子滤波; 粒子数

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2010)06-1271-06

DOI: 10.3724/SP.J.1146.2009.00853

Research of Multiple Model Particle Filter Tracking Algorithms

Jian Fu-sheng^{①②③} Xu Yue-min^② Yin Ze-jie^①

^①(University of Science and Technology of China, Hefei 230026, China)

^②(Center for Space Science and Applied Research, CAS, Beijing 100190, China)

^③(Unit 92323 of PLA, Qingdao 266003, China)

Abstract: An Enhanced Multiple Model Particle Filter(EMMPF) algorithm is presented for maneuvering target tracking. Rather than allocating the particles to the various modes according to mode probabilities as the MMPF, the new algorithm proposes an approach which enables the user to control the number of particles in a certain mode flexibly without interaction between particles of different mode. The estimations of mode and state are calculated respectively, and the posterior probability of each model is updated with the model likelihood function. It is demonstrated that the new algorithm can achieve better performance with less particles, compared with MMPF.

Key words: Maneuvering target tracking; Multiple model; Particle filter; Number of particles

1 引言

目标跟踪过程中, 所采用的运动模型只有与目标运动形式相匹配, 跟踪精度才比较理想。但是, 机动目标的运动形式不可能始终被单一的运动模型所表征。解决目标运动形式不确定的主要方法是基于跳跃马尔可夫系统(Jump Markov systems, JMS)的多模型滤波算法^[1-3]。其中交互多模型(IMM)方法由于在跟踪性能和计算量上获得了较好的平衡, 因此被广泛应用。然而, IMM算法中, 即使上一时刻每个模型的状态后验概率密度为高斯分布, 交互后的概率密度仍为高斯和(非高斯)的形式, 不能用标准的卡尔曼滤波方法进行滤波。其后验概率密度通常是用高斯分布的一阶矩和二阶矩来近似, 这在系统模型高度非线性时难以取得好的滤波效果。

粒子滤波算法不受非线性、非高斯问题限制,

因此可以对 IMM 中的后验概率密度进行更精确的描述。文献[4]开始把多模型与粒子滤波相结合提出了多模型粒子滤波(Multiple Model Particle Filter, MMPF), 但因为将模型索引引入状态维, 导致各模型中粒子数与模型概率成比例, 模型概率非常低的粒子数则极少, 过少的粒子不能足够近似条件模型后验概率, 降低了多模型的跟踪性能。Driessen^[5]等利用 IMM 算法思想对 MMPF 改进, 但由于使用各模型的粒子权值总和去更新模型后验概率, 在模型粒子数量差别较大时会使模型切换变得难以执行。注意到 IMMPF 算法^[6,7]中由于粒子的数量没有参与模型的切换, 所以允许对模型粒子数量进行控制, 但是每次递推各模型间的粒子都要进行交互, 存在计算量过大的缺点。基于以上问题, 本文根据文献[6-8]的思想, 提出一种改进的多模型滤波算法(Enhanced MMPF, EMMPF), 并从理论推导和仿真验证两个角度论述了新算法在机动目标跟踪中的应用优势。

2009-06-05 收到, 2009-09-07 改回

通信作者: 鉴福升 jianfusheng@gmail.com

2 系统模型与 MMPF 算法

考虑下述随机混合系统:

$$\begin{cases} \mathbf{x}_k = f(r_k, \mathbf{x}_{k-1}) + \mathbf{v}_{k-1}(r_k) \\ \mathbf{z}_k = h(r_k, \mathbf{x}_k) + \mathbf{w}_k \end{cases} \quad (1)$$

其中 \mathbf{x}_k , \mathbf{z}_k 分别是 k 时刻系统的状态和量测向量, $\mathbf{v}(r_k)$, \mathbf{w}_k 代表互不相关的零均值高斯噪声, 方差分别为 $Q(r_k)$, R 。 r_k 代表系统在 k 时刻的模型索引, 模型转移概率由一阶马尔可夫链表示:

$$P\{r_k = j | r_{k-1} = i\} = \Pi_{ij}, \quad i, j = 1, \dots, M \quad (2)$$

其中 M 是模型总数。

MMPF 是单模型粒子滤波的扩展应用。它基于贝叶斯方法, 用扩维的粒子群去近似概率密度, 而不是仅仅用一阶矩和二阶矩去匹配模型的后验概率密度, 其过程可简述如下:

首先由马尔可夫转移概率和 $k-1$ 时刻的后验概率密度 $p(\mathbf{x}_{k-1}, r_{k-1} | Z_{k-1})$ 计算 k 时刻的初始概率密度

$$p(\mathbf{x}_{k-1}, r_k = j | Z_{k-1}) = \sum_{i=1}^M \Pi_{ij} p(\mathbf{x}_{k-1}, r_{k-1} = i | Z_{k-1}) \quad (3)$$

其中 $Z_{k-1} = \{\mathbf{z}_1, \dots, \mathbf{z}_{k-1}\}$ 表示直到 $k-1$ 时刻的量测序列, $j = 1, \dots, M$ 。

然后通过各模型的状态方程预测 k 时刻的先验概率密度

$$p(\mathbf{x}_k, r_k | Z_{k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k) p(\mathbf{x}_{k-1}, r_k | Z_{k-1}) d\mathbf{x}_{k-1} \quad (4)$$

其中 $p(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k)$ 由模型 r_k 的状态方程和过程噪声的统计特性决定。

最后, 得到 k 时刻量测后, 通过贝叶斯公式更新得到后验概率密度

$$p(\mathbf{x}_k, r_k | Z_k) = \frac{p(\mathbf{z}_k | \mathbf{x}_k, r_k) p(\mathbf{x}_k, r_k | Z_{k-1})}{p(\mathbf{z}_k | Z_{k-1})} \quad (5)$$

其中 $p(\mathbf{z}_k | \mathbf{x}_k, r_k)$ 是似然函数, 取决于量测方程和量测噪声的统计特性。由于在求得状态预测值后, 量测值与系统模型无关, 因此 $p(\mathbf{z}_k | \mathbf{x}_k, r_k) = p(\mathbf{z}_k | \mathbf{x}_k)$ 。

分母 $p(\mathbf{z}_k | Z_{k-1}) = \sum_{j=1}^M \int p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k, r_k = j | Z_{k-1}) d\mathbf{x}_k$ 。

3 EMMPF 算法设计

MMPF 算法对粒子群进行扩维, 粒子总数是固定的, 但各模型的粒子数按模型概率分布自动调整。因为在预测更新之后通过统一归一化的权值对粒子群进行重采样, 状态估计和模型估计同步进行, 所以状态的滤波输出值可由全体粒子的状态算术平均值求出。但由于模型的粒子数量与模型概率成比例, 若某一模型概率很小, 其粒子数量也相应很少, 一

方面难以充分近似该模型的概率密度, 降低了滤波性能, 甚至在重采样后该模型的粒子数为零, 失去了多模型的特点; 另一方面在目标发生机动时, 模型无法及时切换, 容易导致滤波发散。虽然可以通过扩大粒子总数来增加小概率模型的粒子数, 但会使计算量太大。为此, 本文提出了一种包含两次重采样的改进的多模型粒子滤波(EMMPF)算法, 将各模型的粒子数相对固定, 把模型估计和状态估计分开进行, 并对各模型粒子的权单独归一化, 利用模型的似然函数更新模型的后验概率, 从而解决了上述问题, 用相对较少的粒子总数获得了对机动目标较好的滤波性能。

3.1 递推过程

由于各模型的粒子数固定, 不再与模型概率直接相关, 因此模型概率需单独计算, 对后验概率密度可分两步求解, 即

$$p(\mathbf{x}_k, r_k | Z_k) = P(r_k | Z_k) p(\mathbf{x}_k | r_k, Z_k) \quad (6)$$

其中 $P(r_k | Z_k)$ 为模型 r_k 的后验概率, $p(\mathbf{x}_k | r_k, Z_k)$ 为状态 \mathbf{x}_k 的模型条件后验概率密度(本文用大写字母 P 表示模型的概率分布, 用小写字母 p 表示状态的概率密度)。

假设已知 $k-1$ 时刻的模型后验概率 $P(r_{k-1} | Z_{k-1})$ 及各模型的状态后验概率密度 $p(\mathbf{x}_{k-1} | r_{k-1}, Z_{k-1})$, 为求得 k 时刻的后验概率密度 $p(\mathbf{x}_k, r_k | Z_k)$, 有以下递推过程:

(1)混合阶段 利用马尔可夫转移概率矩阵和模型后验概率 $P(r_{k-1} | Z_{k-1})$ 计算 k 时刻模型先验概率

$$P(r_k | Z_{k-1}) = \sum_{r_{k-1}=1}^M P(r_k | r_{k-1}) P(r_{k-1} | Z_{k-1}) \quad (7)$$

接着计算模型混合概率

$$P(r_{k-1} | r_k, Z_{k-1}) = \frac{P(r_k | r_{k-1}) P(r_{k-1} | Z_{k-1})}{P(r_k | Z_{k-1})} \quad (8)$$

由 $k-1$ 时刻的模型条件后验概率密度 $p(\mathbf{x}_{k-1} | r_{k-1}, Z_{k-1})$ 计算 k 时刻的模型条件初始概率密度

$$\begin{aligned} & p(\mathbf{x}_{k-1} | r_k, Z_{k-1}) \\ &= \sum_{r_{k-1}=1}^M P(r_{k-1} | r_k, Z_{k-1}) p(\mathbf{x}_{k-1} | r_{k-1}, Z_{k-1}) \quad (9) \end{aligned}$$

(2)预测阶段 得到初始概率密度后, 按照各模型对应的状态方程进行状态预测, 得到 k 时刻的模型条件先验概率密度

$$p(\mathbf{x}_k | r_k, Z_{k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k) p(\mathbf{x}_{k-1} | r_k, Z_{k-1}) d\mathbf{x}_{k-1} \quad (10)$$

(3)更新阶段 获得 k 时刻的量测值 \mathbf{z}_k 后, 计算模型后验概率

$$P(r_k | Z_k) = \frac{p(\mathbf{z}_k | r_k, Z_{k-1})P(r_k | Z_{k-1})}{p(\mathbf{z}_k | Z_{k-1})} \quad (11)$$

其中 $p(\mathbf{z}_k | r_k, Z_{k-1}) = \int p(\mathbf{z}_k | r_k, \mathbf{x}_k)p(\mathbf{x}_k | r_k, Z_{k-1})d\mathbf{x}_k$ 为模型的似然函数, $p(\mathbf{z}_k | Z_{k-1}) = \sum_{r_k=1}^M p(\mathbf{z}_k | r_k, Z_{k-1})P(r_k | Z_{k-1})$ 为归一化量。

同时计算出 k 时刻的模型条件后验概率密度

$$p(\mathbf{x}_k | r_k, Z_k) = \frac{p(\mathbf{z}_k | \mathbf{x}_k, r_k)p(\mathbf{x}_k | r_k, Z_{k-1})}{p(\mathbf{z}_k | r_k, Z_{k-1})} \quad (12)$$

最后由式(6)得到 $p(\mathbf{x}_k, r_k | Z_k)$ 。

3.2 算法步骤

由递推过程可以看出, 该算法在混合阶段既不像 IMMPF 算法那样对各模型的粒子进行交互计算, 也不像 MMPF 算法那样通过马尔可夫转移概率对各模型粒子进行重新分配, 而是按照模型混合概率在上一时刻各模型滤波得到的后验粒子群中进行重采样, 重建当前时刻各模型的初始粒子群。比方说, 我们使用两个模型对跟踪目标进行滤波, 模型 1 固定有 N_1 个粒子, 模型 2 固定有 N_2 个粒子。假定混合阶段计算出的 k 时刻模型混合概率矩阵为 $[0.8, 0.1; 0.2, 0.9]$, 即 k 时刻模型 1 的粒子分别有 80% 和 20% 的概率来自 $k-1$ 时刻模型 1 和模型 2 的粒子群, 而模型 2 的粒子分别有 10% 和 90% 的概率来自 $k-1$ 时刻模型 1 和模型 2 的粒子群。要获得 k 时刻模型 1 的初始粒子群 $\{\tilde{\mathbf{x}}_{k/k-1}^{n,1}\}_{n=1,\dots,N_1}$, 首先通过概率采样确定这 N_1 个粒子 $k-1$ 时刻的模型索引 $\{r_{k-1}^n\}_{n=1,\dots,N_1}$, 即它们分别来自上一时刻哪个模型的粒子群, 然后在对应粒子群中抽取粒子。同样方法得到 k 时刻模型 2 的初始粒子群 $\{\tilde{\mathbf{x}}_{k/k-1}^{n,2}\}_{n=1,\dots,N_2}$ 。

这一过程称之为对粒子群的第 1 次重采样。各模型的初始粒子群经预测成为 k 时刻的先验粒子群, 按模型各自计算归一化权值后进行第 2 次重采样, 得到 k 时刻各模型的后验粒子群。模型的概率由模型的似然函数计算得出, 既避免了小概率模型粒子数过少的情况, 也没有改变模型的马尔可夫性质。算法步骤可描述如下:

(1) 计算各模型的先验概率和混合概率 由式(7), 式(8)分别得到模型先验概率 $P(r_k | Z_{k-1})$ 和混合概率 $u_{ij} = P(r_{k-1} = i | r_k = j, Z_{k-1})$ 。

(2) 获取各模型的初始粒子群 $\{\tilde{\mathbf{x}}_{k/k-1}^{n,j}\}_{n=1,\dots,N_j}$, $j = 1, \dots, M$, 其中 n 是粒子序号, N_j 是模型 j 的粒子数。

首先用类似于 bootstrap 滤波器中重采样的方式^[4,9], 从 u_{ij} 中抽取 N_j 个模型索引 $\{r_{k-1}^n\}_{n=1,\dots,N_j}$, 其

伪代码可表示为

```

FOR  $j = 1 : M$ 
   $c(1, j) = u_{1j}$ 
  FOR  $i = 1 : M - 1$ 
     $c(i + 1, j) = c(i, j) + u_{(i+1)j}$  // 模型混合概率累加
  END FOR
  FOR  $n = 1 : N_j$ 
    抽取  $u_n$  //  $u_n$  服从从区间  $(0, 1]$  上的均匀分布
     $m(n, j) = 1$ 
    WHILE  $c(m, j) \leq u_n$ 
       $m(n, j) = m(n, j) + 1$ 
    END WHILE
    //  $m(n, j)$  是要分配给模型  $j$  的第  $n$  个粒子的模型索引
  END FOR
END FOR

```

然后按照模型索引 r_{k-1}^n 从上一时刻对应的后验粒子群中随机抽取状态粒子给模型 j 。也就是说, 如果 $r_{k-1}^n = i$, 就从 $k-1$ 时刻模型 i 的后验粒子群 $\{\mathbf{x}_{k-1/k-1}^{n,i}\}_{n=1,\dots,N_i}$ 中随机抽取一个粒子。如此进行 N_j 次, 就得到了 k 时刻模型 j 的初始粒子群 $\{\tilde{\mathbf{x}}_{k/k-1}^{n,j}\}_{n=1,\dots,N_j}$ 。

如果模型 i 的粒子数 N_i 较少, 而需要从中抽取的次数较多, 会造成其粒子被多次采样, 影响了粒子的多样性。这时可通过对 $k-1$ 时刻模型 i 的估计值 $\tilde{\mathbf{x}}_{k-1/k-1}^i$ 加噪声粗糙的办法^[10]多生成一些粒子, 扩大采样时的选择面。

(3) 各个模型条件滤波 从模型 j 的过程噪声 \mathbf{v}_{k-1} 中得到 N_j 个抽样值 $\{v_{k-1}^{n,j}\}_{n=1,\dots,N_j}$, 由状态方程得到模型 j 的先验粒子群 $\{\mathbf{x}_{k/k-1}^{n,j}\}_{n=1,\dots,N_j}$

$$\mathbf{x}_{k/k-1}^{n,j} = f(r_k = j, \tilde{\mathbf{x}}_{k/k-1}^{n,j}) + v_{k-1}^{n,j} \quad (13)$$

得到量测 \mathbf{z}_k 后, 计算各粒子的残差(新息)

$$\mathbf{e}_k^{n,j} = \mathbf{z}_k - \mathbf{z}_{k/k-1}^{n,j} = \mathbf{z}_k - h(\mathbf{x}_{k/k-1}^{n,j}) \quad (14)$$

其中 $\mathbf{z}_{k/k-1}^{n,j} = h(\mathbf{x}_{k/k-1}^{n,j})$ 是粒子的预测量测。由于量测噪声是高斯噪声, 残差符合均值为 0, 方差为 R 的正态分布, 于是可求粒子权值

$$q_k^{n,j} = p(\mathbf{z}_k | \mathbf{x}_{k/k-1}^{n,j}) = N(\mathbf{e}_k^{n,j}; 0, R) \quad (15)$$

以及归一化的粒子权值

$$\tilde{q}_k^{n,j} = q_k^{n,j} / \sum_{n=1}^{N_j} q_k^{n,j} \quad (16)$$

利用文献[9]的重采样算法, 对粒子群 $\{\mathbf{x}_{k/k-1}^{n,j}\}_{n=1,\dots,N_j}$ 进行 N_j 次重采样, 复制权值较大的 $\mathbf{x}_{k/k-1}^{n,j}$, 舍弃权值较小的 $\mathbf{x}_{k/k-1}^{n,j}$, 得到 k 时刻模型 j 的后验粒子群 $\{\mathbf{x}_{k/k}^{n,j}\}_{n=1,\dots,N_j}$, 粒子权值均为 $1/N_j$, 从而求得模型 j 的状态估计

$$\hat{\mathbf{x}}_{k/k}^j = \frac{1}{N_j} \sum_{n=1}^{N_j} \mathbf{x}_{k/k}^{n,j} \quad (17)$$

(4)模型概率更新 模型 j 的新息协方差

$$S_k^j = R + \frac{1}{N_j} \sum_{n=1}^{N_j} [\hat{\mathbf{z}}_{k/k-1}^{n,j} - \hat{\mathbf{z}}_{k/k-1}^j][\hat{\mathbf{z}}_{k/k-1}^{n,j} - \hat{\mathbf{z}}_{k/k-1}^j]^T \quad (18)$$

其中 $\hat{\mathbf{z}}_{k/k-1}^j = \frac{1}{N_j} \sum_{n=1}^{N_j} \hat{\mathbf{z}}_{k/k-1}^{n,j}$ 为模型 j 对应的预测量测。

模型似然函数

$$A_k^j = \frac{1}{N_j} \sum_{n=1}^{N_j} N(\mathbf{e}_k^{n,j}; 0, S_k^j) \quad (19)$$

利用模型的似然函数更新模型概率

$$P(r_k = j | Z_k) = \frac{A_k^j P(r_k = j | Z_{k-1})}{\sum_{j=1}^M A_k^j P(r_k = j | Z_{k-1})} \quad (20)$$

(5)输出系统状态估计

$$\hat{\mathbf{x}}_{k/k} = \sum_{j=1}^M P(r_k = j | Z_k) \hat{\mathbf{x}}_{k/k}^j \quad (21)$$

3.3 粒子数控制说明

由于粒子数量不参与模型切换,模型概率用模型的似然函数进行更新,所以各个模型粒子数量可以独立控制,不影响模型的正常切换。本文仿真中采用一个简单的方式选取各模型的粒子数:对非线性较强的模型用较多的粒子,以便更好地近似其状态的后验概率密度,保证跟踪精度;而对机动小的模型用较少的粒子,不影响跟踪精度,但是可以减少计算量。

4 仿真

设目标运动场景为:初始位置(74,30) km,初始速度(-283, -63) m/s,在 0-20 s, 40-60 s, 80-100 s 时间范围做匀速运动,在 20-40 s 之间做 2 g 转弯,60-80 s 做 3 g 转弯,运动持续时间共 100 s。

采用匀速(CV)模型和扩维转弯(ACT)模型^[1]对 MMPF、EMMPF 算法进行仿真比较。CV 模型状态向量 $\mathbf{x}_k = [x_k, y_k, \dot{x}_k, \dot{y}_k]^T$, ACT 模型状态向量 $\mathbf{x}_k = [x_k, y_k, \dot{x}_k, \dot{y}_k, \omega_k]^T$ 。过程噪声方差分别为 $Q_{CV} = 25 \text{ m}^2/\text{s}^4$ 、 $Q_{ACT} = 400 \text{ m}^2/\text{s}^4$ 。转弯率变化范围为 $[2, 6](^\circ/\text{s})$ 。两模型的初始概率分别为 0.8, 0.2。马尔可夫一步转移概率矩阵 $[0.9, 0.1; 0.02, 0.98]$ 。

雷达量测得到距离和方位。 $h(\mathbf{x}_k) = [\sqrt{x_k^2 + y_k^2}, \tan^{-1}(y_k/x_k)]^T$, 距离量测标准差为 15 m, 方位量测标准差为 2 mrad。3 dB 波束宽度 B 取 2° , 采样间隔为 $T = 1.2 \text{ s}$ 。仿真过程中,目标真实位置与波

束指向误差超过 $B/2$, 或与预测点距离误差大于 600 m, 均认为不能产生有效量测,连续 5 次不能产生有效量测就认为跟踪失败。仿真 100 次,只计算没有发生失跟时的结果。

首先比较粒子总数相同时两种算法的滤波精度。两种算法都使用 600 个粒子,其中 EMMPF 算法 CV 模型固定 200 个粒子,ACT 模型固定 400 个粒子,而 MMPF 算法各模型的粒子数与模型概率相关,其变化情况如图 1 所示。跟踪过程中位置和速度误差的比较结果如图 2 所示。




图 1 MMPF 跟踪过程中粒子数变化情况

由图 2 可以看出,在第 60 s 之前,目标只在 20-40 s 间做小的机动,因而两算法精度近似。但 60 s 后,目标做 3 g 转弯,EMMPF 算法的位置误差开始明显小于 MMPF 算法,特别是在第 80 s 目标再次转为匀速运动之后。从图 1 可知,这是由于此时 MMPF 算法对目标的机动没有做出及时的响应所致。速度误差也有类似的比较结果。

模型未能及时切换不仅会使滤波精度下降,跟踪误差变大,而且会导致失跟。我们发现在 100 次仿真中 MMPF 出现了 39 次失跟,而 EMMPF 没有失跟发生。由于 EMMPF 算法的粒子数不受模型概率变化的影响,不会出现某一模型粒子数过少的情况,因而其跟踪性能整体好于 MMPF。

如果维持 EMMPF 粒子数不变,而把 MMPF 粒子总数增加到 1600,仿真比较结果如图 3 所示。可见 EMMPF 的整体跟踪精度仍然略好于 MMPF,但所用粒子数却不到 MMPF 算法的一半。

5 结束语

本文所提出的改进的多模型粒子滤波新算法能对各模型粒子数独立灵活控制,克服了 MMPF 算法小概率模型粒子数过少、近似性不好、难以及时切换的不足,用较少的粒子总数就可获得较理想的跟踪性能。在实际的机动目标跟踪中,往往采用多模型方法,因此这种对各模型粒子数独立控制的 EMMPF 算法有着广泛的应用前景。出于算法的简

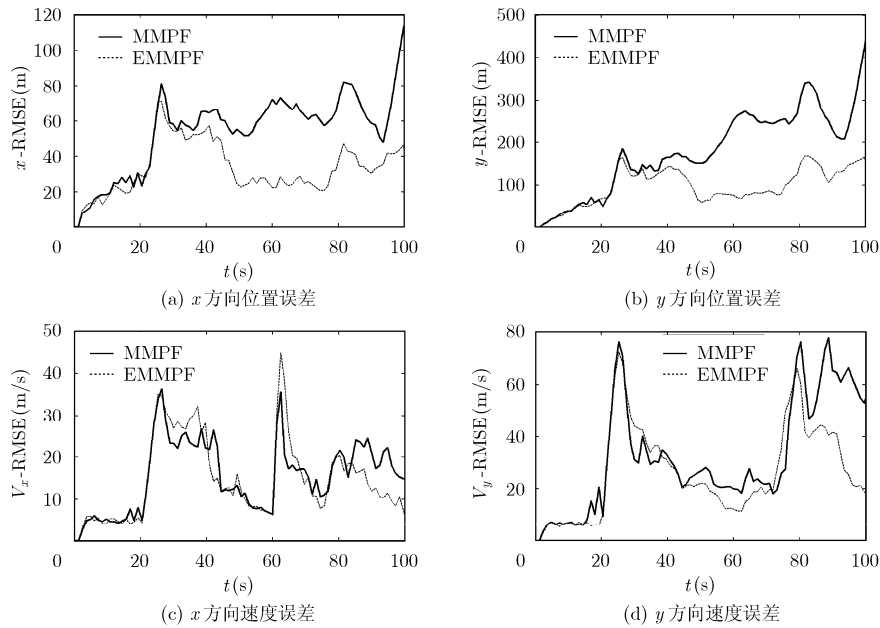


图 2 粒子数相同时两种算法的位置与速度误差比较

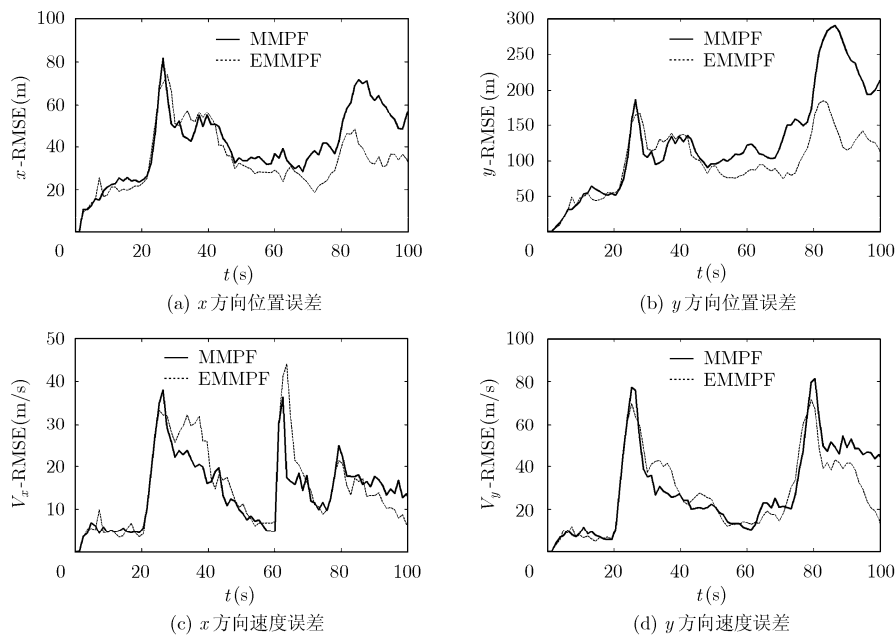


图 3 粒子数不同时两种算法的位置与速度误差比较

便, 本文采取了固定各模型粒子数的策略。实际上各模型粒子数量也可以根据滤波精度等因素自适应调整, 所以这种算法的优势还存在进一步研究与发掘的空间。

参考文献

- [1] Blackman S S and Popoli R. Design and Analysis of Modern Tracking System [M]. Norwood MA: Artech House, 1999: 221-252.
- [2] Blom H A P and Bloem E A. Exact Bayesian and particle filtering of stochastic hybrid systems[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(1): 55-70.
- [3] Liang Yan, Wang Zeng-fu, and Cheng Yong-mei, et al. Estimation of Markov jump systems with mode observation one-step lagged to state measurement [C]. The 10th International Conference on Information Fusion, Québec City, Canada, 9-12 July 2007: 1-6.
- [4] Mcginnity S and Irwin G W. Multiple model bootstrap filter for maneuvering target tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(3): 1006-1012.
- [5] Driessen H and Boers Y. Efficient particle filter for jump Markov nonlinear systems[J]. *IEE Proceedings: Radar, Sonar*

- and Navigation*, 2005, 152(5): 323-326.
- [6] Yacine M and Mohand S D. Genetic algorithm combined to IMM approach for tracking highly maneuvering targets[J]. *IAENG International Journal of Computer Science*, 2008, 35(1): 41-46.
- [7] 刘贵喜, 高恩克, 范春宇. 改进的交互式多模型粒子滤波跟踪算法. 电子与信息学报[J], 2007, 29(12): 2810-2813.
Liu Gui-xi, Gao En-ke, and Fan Chun-yu. Tracking algorithms based on improved interacting multiple model particle filter. *Journal of Electronics & Information Technology*, 2007, 29(12): 2810-2813.
- [8] Doucet A, Gordon N, and Krishnamurthy V. Particle filters for state estimation of jump Markov linear systems[J]. *IEEE Transactions on Signal Processing*, 2001, 49(3): 613-624.
- [9] Caron F, Davy M, and Duflos E, *et al.* Particle filtering for multisensor data fusion with switching observation models: Application to land vehicle positioning[J]. *IEEE Transactions on Signal Processing*, 2007, 55(6): 2703-2719.
- [10] Fredrik G, Niclas B, and Urban F, *et al.* Particle filters for positioning, navigation and tracking[J]. *IEEE Transactions on Signal Processing*, 2002, 50(2): 425-437.
- 鉴福升: 男, 1973 年生, 博士生, 研究方向为雷达信号与数据处理.
- 徐跃民: 男, 1959 年生, 研究员, 研究方向为信号与数据处理、空间等离子体等.
- 阴泽杰: 男, 1956 年生, 教授, 博士生导师, 研究方向为物理电子学、计算机技术应用等.