第 31 卷第 11 期
2014 年 11 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 31 No. 11
Nov. 2014

DOI: 10.7641/CTA.2014.40362

联合模糊聚类和拟蒙特卡罗重采样的群目标跟踪算法

李振兴[†], 刘进忙, 李　超, 白东颖, 郭相科

(空军工程大学 防空反导学院, 陕西 西安 710051)

摘要: 联合概率数据关联粒子滤波(joint probabilistic data association-particle filter, JPDA–PF)算法常被用来解决群目标跟踪中的数据关联和非线性滤波问题. 针对算法的数据关联时间较长以及样本枯竭问题, 本文阐述了一种利用模糊聚类和拟蒙特卡罗重采样的群目标跟踪算法. 首先, 在群演化网络模型的基础上, 采用最大熵模糊聚类法来完成群内个体目标和量测之间的数据关联, 利用模糊隶属度来构建互联概率矩阵. 其次, 在目标状态样本的重采样的过程中, 利用随机化拟蒙特卡罗序列映射到拟复制样本的子空间上, 提高样本的多样性, 抑制样本枯竭的出现. 仿真实验结果表明, 与JPDA–PF算法相比, 本文算法能有效估计群内目标状态和群结构, 并具有更优的估计性能.

关键词: 群目标; 跟踪; 滤波; 模糊聚类; 拟蒙特卡罗; 重采样; 数据关联

中图分类号: TN953　　　**文献标识码**: A

Group targets tracking algorithm by combination of fuzzy clustering and Quasi-Monte Carlo resampling method

LI Zhen-xing[†], LIU Jin-mang, LI Chao, BAI Dong-ying, GUO Xiang-ke

(Air and Missile Defense College, Air Force Engineering University, Xi'an Shaanxi 710051, China)

Abstract: Joint probabilistic data association-particle filter (JPDA–PF) algorithm was always used to solve the data association and nonlinear filtering problem. Aiming at the high computational complexity in data association and the sample impoverishment problem in resampling step, an improved algorithm by combination of fuzzy clustering and Quasi-Monte Carlo resampling method was proposed for group targets tracking in this paper. First, based on the group evolving network model, the maximum entropy fuzzy clustering was used to achieve the data association between group individual targets and measurements, and the association probability matrix was constructed by the fuzzy membership degree. Then, the randomized Quasi-Monte Carlo points were transformed into some independent sub-spaces of planned duplicate particles to improve the diversity of samples and prevent the occurrence of sample impoverishment. The computer simulations showed that compared the JPDA–PF algorithm, our proposed algorithm can estimate group targets state and group structure effectively, and obtain the better estimation performance.

Key words: group targets; tracking; filter; fuzzy clustering; Quasi-Monte Carlo; resampling; data association

1　引言(Introduction)

在多目标编队跟踪、海面目标监控等许多跟踪场景内, 跟踪对象通常由一系列具有类似运动方式的空间临近目标组成, 人们将此类问题归纳成群目标跟踪问题[1]. 尽管群内的个体目标可以在一定范围内展现出独立的运动方式, 但是由于群目标是作为一个整体来运动, 因此群内目标需要保持运动同步, 而且必须防止彼此碰撞. 因此, 群目标跟踪方法不同于常见的多目标跟踪方法. 常见的多目标跟踪算法的跟踪主体主要是个体目标, 而群跟踪算法还需要对群目标运动特性进行分析和建模, 从而获得更好的群跟踪效果.

在群模型的建立方面, 文献[2]提出了协同群跟踪模型, 通过利用斥力模型来建立群内目标之间的相互作用. 文献[3]提出了粒子模型, 文献[4]提出了群首领跟随模型. 文献[5]提出一种利用网络图形的形式来联合估计群结构和群状态, 将群内目标与群内周围其它目标联系起来, 从而更加准确刻画出群的内在关系. 它采用了联合概率数据关联粒子滤波(joint probabilistic data association-particle filter, JPDA–PF)算法来处理数据关联和非线性滤波问题, 取得了较好的效果. 但是还存在两个方面的问题: 1) 文章采用的JPDA方法过程比较复杂, 但是当群内关联目标的数目较多时,

收稿日期: 2014−04−24; 录用日期: 2014−08−26.
[†]通信作者. E-mail: lzxing1988@163.com; Tel.: +86 18291883590.
基金项目: 国家自然科学青年基金资助项目(61102109); 航空科学基金资助项目(20120196003); 空军工程大学防空反导学院“研究生科技创新基金”资助项目(HX1112).

将会导致确认矩阵拆分出现组合爆炸; 2) 为了抑制粒子退化现象, 文章采用传统的重采样方法进行粒子选择. 而这容易导致出现粒子枯竭问题, 在一定程度上影响了算法的估计精度和运算效率. 针对降低JPDA算法复杂度问题, 文献[6–7] 提出了不同次优算法来减少关联假设数目. 文献[8]提出最大熵模糊聚类(maximum entropy fuzzy clustering, MEF)法, 通过使目标函数最小化, 将量测数据分别划分到以目标预测位置为中心的类中. 针对抑制粒子枯竭问题, 常用方法包括正则化PF算法和马尔科夫链蒙特卡罗–粒子滤波(MCMC–PF)算法[9–10], 但两者运算量都较大. 文献[11]提出一种快速拟蒙特卡罗(Quasi-Monte Carlo, QMC)粒子滤波方法, 通过将生成的随机化QMC序列映射到以大权重粒子为核心的子空间上, 避免了直接对采样空间进行预测, 有效抑制样本枯竭, 并能获得高于蒙特卡罗方法的估计精度.

因此, 在文献[5]的基础上, 本文着眼于解决这两个问题, 提出一种改进的群目标跟踪算法. 首先, 通过利用群演化网络模型估计群结构, 在第2层群结构基础上采用最大熵模糊聚类法对目标和观测数据进行关联, 利用模糊隶属度来重建群内目标的联合关联概率矩阵. 其次, 在目标状态粒子的重采样过程中, 利用随机化QMC序列映射到拟复制样本的子空间上, 有效抑制样本枯竭问题. 仿真实验结果验证了本文算法的有效性.

2 群演化网络模型(Group evolving network models)

假设N个目标构成顶点集$\{v_1,\cdots,v_N\}$, v_i对应着目标i的状态和方差, $E(i,j)=(v_i,v_j)$来代表顶点v_i和v_j间的关系. 因此, 群结构可以表示为$\boldsymbol{G}=(\{v_1,\cdots,v_N\},E)$. 文献[5]提出采用马氏距离判别准则, 通过计算不同目标间的距离和速度的马氏距离, 来判断是否属于同一子群. 因此, 还可以用$\boldsymbol{G}_t=\{\boldsymbol{g}_1,\cdots,\boldsymbol{g}_{n_\mathrm{G}}\}$来描述群的整体网络结构, 其中$\boldsymbol{g}_i$代表第$i$个子群, n_G为$\boldsymbol{G}$内子群个数. 因此, 它的目的是更新$\boldsymbol{G}_t=f(\boldsymbol{G}_{t-1},\boldsymbol{X}_t)$, 其中$\boldsymbol{X}_t=\{\boldsymbol{x}_{t,1},\cdots,\boldsymbol{x}_{t,N}\}$代表所有目标的状态向量, f代表群网络结构的演化模型. 它可表示为[5]

$$\begin{cases} t=0,\ \boldsymbol{G}_0=f_\mathrm{I}(\boldsymbol{X}_0),\\ t>0,\ \boldsymbol{G}_t=f_\mathrm{NS}\circ f_\mathrm{NI}\circ f_\mathrm{EU}(\boldsymbol{G}_{t-1},\boldsymbol{X}_t), \end{cases} \tag{1}$$

其中: f_I为群起始模型, f_EU为边的更新模型, f_NI为顶点合并模型, f_NS为顶点消除模型.

2.1 群的起始模型(Group initialization model)

本文跟踪是在文献[12]的目标检测技术基础上进行的, 即在$t=0$时目标的数目和状态都是已知的. 假设N个目标的顶点集为$\{v_1,\cdots,v_N\}$, 计算v_i和$v_j(i,j=1,\cdots N;i\neq j)$间的马氏距离$d_{i,j}$. 若$d_{i,j}<\varepsilon$, 则$(v_i,v_j)\in E$, 其中$\varepsilon$为预设门限. 因此, 利用模型$f_\mathrm{I}$可以获得初始时刻的群结构$\boldsymbol{G}_0=(\{v_1,\cdots,v_N\},E_0)$.

2.2 边的更新模型(Edge updating model)

首先, 构建第2层群结构$\boldsymbol{G}'$. 令$\boldsymbol{g}$的质心状态$\boldsymbol{O}^{\boldsymbol{g}}=(1/n_\mathbf{g})\sum\limits_{v_i\in\boldsymbol{g}}\boldsymbol{x}_i^{\boldsymbol{g}}$和平均协方差矩阵$\boldsymbol{P}^{\boldsymbol{g}}=(1/n_\mathbf{g})\sum\limits_{v_i\in\boldsymbol{g}}\boldsymbol{P}_i^{\boldsymbol{g}}$, 其中$n_{\boldsymbol{g}}$为$\boldsymbol{g}$的目标个数. 再利用$n_\mathrm{G}$个子群质心构成顶点集$\{v'_1,\cdots,v'_{n_\mathrm{G}}\}$, 计算$v'_i$和$v'_j(i,j=1,\cdots n_\mathrm{G};i\neq j)$的马氏距离$d'_{i,j}$. 若$d'_{i,j}<\varepsilon'$, 则$(v'_i,v'_j)\in E'$, 其中$\varepsilon'(\varepsilon'\gg\varepsilon)$为预设门限. 此时可得$\boldsymbol{G}'=(\{v'_1,\cdots,v'_{n_{\mathrm{G}'}}\},E')$. 接着, 在对$\boldsymbol{g}_i(i=1,\cdots N)$内目标进行边更新的同时,在$E'$内找出$(v'_i,v'_j)$, 并对$\boldsymbol{g}_i$和$\boldsymbol{g}_j$内目标间进行边更新. 最后, 依此类推, 直到循环更新结束.

2.3 顶点合并模型(Node incorporation model)

首先, 计算新顶点v_new和v'_i间的马氏距离$d''_{\mathrm{new},i}$. 若$d''_{\mathrm{new},i}<\varepsilon''$, 则将$v_\mathrm{new}$与$\boldsymbol{g}_i$内目标进行边更新, 其中$\varepsilon''(\varepsilon''\ll\varepsilon')$为预设门限. 接着, 在$E'$中找出$(v'_i,v'_j)$, 并将$v_\mathrm{new}$和$\boldsymbol{g}_j$内目标进行边更新. 最后, 按照这种方法, 直到循环更新结束.

2.4 顶点消除模型(Node suppression model)

如果在一段时间内获取的量测中不包含顶点v_old的任何信息, 就从顶点集中消除v_old, 并删除所有与v_old相关的边.

3 群目标跟踪算法(Group targets tracking algorithm)

3.1 后验概率密度模型(Posterior probability density model)

设t时刻目标的状态向量为$\boldsymbol{x}_{t,i}=(x_{t,i},\dot{x}_{t,i},y_{t,i},\dot{y}_{t,i})^\mathrm{T}$, 即代表$x$轴和$y$轴的位置和速度. $\boldsymbol{g}$用一个随机有限集来建模[4], 即$\boldsymbol{X}_t^{\boldsymbol{g}}=\{\boldsymbol{x}_{t,1}^{\boldsymbol{g}},\cdots,\boldsymbol{x}_{t,n_\mathrm{g}}^{\boldsymbol{g}}\}$. 因此, 整体群结构为$\boldsymbol{G}=\{\boldsymbol{g}_1,\cdots,\boldsymbol{g}_{n_\mathrm{G}}\}$, 对应的目标联合状态向量$\boldsymbol{X}_t=\{\boldsymbol{X}_t^{\boldsymbol{g}_1},\cdots,\boldsymbol{X}_t^{\boldsymbol{g}_{n_\mathrm{G}}}\}$. 记$t$时刻量测为$\boldsymbol{z}_t$, 起始到$t$时刻的全部量测集为$\boldsymbol{Z}_{1:t}$, 因此, 后验概率密度$p(\boldsymbol{X}_t,\boldsymbol{G}_t|\boldsymbol{Z}_{1:t})$为

$$p(\boldsymbol{X}_t,\boldsymbol{G}_t|\boldsymbol{Z}_{1:t})=\frac{p(\boldsymbol{z}_t|\boldsymbol{X}_t,\boldsymbol{G}_t)\times p(\boldsymbol{X}_t,\boldsymbol{G}_t|\boldsymbol{Z}_{1:t-1})}{p(\boldsymbol{z}_t|\boldsymbol{Z}_{1:t-1})}, \tag{2}$$

$$\begin{aligned}&p(\boldsymbol{X}_t,\boldsymbol{G}_t|\boldsymbol{Z}_{1:t-1})=\\&p(\boldsymbol{G}_t|\boldsymbol{X}_t,\boldsymbol{Z}_{1:t-1})\times p(\boldsymbol{X}_t|\boldsymbol{Z}_{1:t-1})=\\&\int p(\boldsymbol{G}_t|\boldsymbol{X}_t,\boldsymbol{G}_{t-1})\times p(\boldsymbol{X}_t|\boldsymbol{X}_{t-1},\boldsymbol{G}_{t-1})\times\\&p(\boldsymbol{X}_{t-1},\boldsymbol{G}_{t-1}|\boldsymbol{Z}_{1:t-1})\mathrm{d}\boldsymbol{X}_{t-1}\mathrm{d}\boldsymbol{G}_{t-1},\end{aligned} \tag{3}$$

其中$p(\boldsymbol{G}_t|\boldsymbol{X}_t,\boldsymbol{G}_{t-1})$是利用第2节的更新方法来计算. 此外, 在假设不同子群相互间独立的前提下可得

$$p(\boldsymbol{X}_t|\boldsymbol{X}_{t-1},\boldsymbol{G}_{t-1})=\prod_{\boldsymbol{g}_i\in\boldsymbol{G}_{t-1}}p(\boldsymbol{X}_t^{\boldsymbol{g}_i}|\boldsymbol{X}_{t-1}^{\boldsymbol{g}_i}).\quad(4)$$

在计算$p(\boldsymbol{z}_t|\boldsymbol{X}_t,\boldsymbol{G}_t)$时, 主要采用JPDA算法[12]来解决量测起源的不确定性问题. 文献[5]为了减少数据关联假设的数目, 提出在第2层群结构$\boldsymbol{G}'$框架内, 只对同属E'的子群内目标间进行数据关联. 令$\boldsymbol{G}'=\{\boldsymbol{g}'_1,\cdots,\boldsymbol{g}'_{n'_{\rm G}}\}$, 则JPDA的门处理过程主要在$\boldsymbol{g}'_i(i=1,\cdots,n_{\rm G'})$内进行, 此时可得

$$p(\boldsymbol{z}_t|\boldsymbol{X}_t,\boldsymbol{G}_t)=p(\boldsymbol{z}_t|\boldsymbol{X}_t,\boldsymbol{G}_t,\boldsymbol{G}'_t)=\prod_{i=1,\cdots,n_{\rm G'}}p(\boldsymbol{z}_t^{\boldsymbol{g}'_i}|\boldsymbol{X}_{t-1}^{\boldsymbol{g}'_i}).\quad(5)$$

3.2 个体目标运动模型和观测模型(Dynamic model and observation model of individual target)

1) 群内个体目标的运动模型.

参照文献[5,13]的模型设置, 采用CV模型对群内个体目标的运动情况进行建模. 在二维平面内, 第$i(i=1,2,\cdots,N)$个目标的状态更新方程为

$$\boldsymbol{x}_{t,i}=f(\boldsymbol{x}_{t-1,i},\boldsymbol{v}_{t-1})=F\boldsymbol{x}_{t-1,i}+\boldsymbol{v}_{t-1},\quad(6)$$

式中: $F=\mathrm{diag}\{F_1,F_1\}$, $F_1=\begin{bmatrix}1&T\\0&1\end{bmatrix}$; 过程噪声$\boldsymbol{v}_{t-1}\sim\mathcal{N}(0,Q)$, 即均值为0; 协方差为$Q$的高斯白噪声. 为了覆盖更多的运动模式, 设置$p(\boldsymbol{v}_{t-1})=\alpha\mathcal{N}(0,Q_1)+(1-\alpha)\mathcal{N}(0,Q_2)$, $\alpha\in[0,1]$这里将群的共同信息运用到状态更新方程中. 记$\boldsymbol{x}_{t,i}^{\boldsymbol{g}}\in\boldsymbol{X}_t^{\boldsymbol{g}}=\{\boldsymbol{x}_{t,1}^{\boldsymbol{g}},\cdots,\boldsymbol{x}_{t,n_{\rm g}}^{\boldsymbol{g}}\}$, 则可得

$$\boldsymbol{x}_{t,i}^{\boldsymbol{g}}=\boldsymbol{x}_{t-1,i}^{\boldsymbol{g}}+\frac{1}{n_{\rm g}}\cdot\sum_{l=1}^{n_{\rm g}}(B\boldsymbol{x}_{t-1,l}^{\boldsymbol{g}})+\boldsymbol{v}_{t-1},\quad(7)$$

其中: $B=\mathrm{diag}\{B_1,B_1\}$, $B_1=\begin{bmatrix}0&T\\0&0\end{bmatrix}$.

2) 观测模型.

令量测空间$\mathcal{Z}\subseteq\mathbb{R}^{n_z}$, 则$t$时刻获得的量测$\boldsymbol{z}_{t,j}(j=1,2,\cdots,M_t)$可以用下式表示:

$$\boldsymbol{z}_{t,j}=\begin{cases}h(\boldsymbol{x}_{t,i})+\boldsymbol{w}_{t,i},\ r_j=i,\\u_t,\ r_j=0,\end{cases}\quad(8)$$

其中: 量测函数$h(\boldsymbol{x}_{t,i})$为非线性函数, 量测噪声$\boldsymbol{w}_{t,i}\sim\mathcal{N}(0,R)$, u_t为量测空间中的杂波. $r_j=i$表示量测j来源于目标i, $r_j=0$表示量测j来源于杂波. 量测函数$h(\boldsymbol{x}_{t,i})$定义为

$$h(\boldsymbol{x}_{t,i})=(\sqrt{x_{t,i}^2+y_{t,i}^2},\ \arctan\frac{y_{t,i}}{x_{t,i}})^{\rm T}.\quad(9)$$

而在$\boldsymbol{g}'_i$内进行门处理过程, 需要确认目标i的有效量测$\boldsymbol{z}_{t,j}$, 即

$$\{\boldsymbol{z}_{t,j}:g_i^2(\boldsymbol{z}_{t,j})\leqslant\xi,j=1,2,\cdots,M_t\},\quad(10)$$

其中: $g_i^2(\boldsymbol{z}_{t,j})=[\boldsymbol{z}_{t,j}-\mu_{\boldsymbol{z}_{t,i}}]^{\rm T}\Sigma_{\boldsymbol{z}_{t,i}}^{-1}[\boldsymbol{z}_{t,j}-\mu_{\boldsymbol{z}_{t,i}}]$, ξ为预设阈值, $\mu_{\boldsymbol{z}_{t,i}}=\sum_{n=1}^{N_{\rm p}}w_{t,i}^{(n)}\boldsymbol{z}_{t,i}^{(n)}$, $\Sigma_{\boldsymbol{z}_{t,i}}=\Sigma_0+\sum_{n=1}^{N_{\rm p}}w_{t,i}^{(n)}[\boldsymbol{z}_{t,i}^{(n)}-\mu_{\boldsymbol{z}_{t,i}}][\boldsymbol{z}_{t,i}^{(n)}-\mu_{\boldsymbol{z}_{t,i}}]^{\rm T}$,其中: Σ_0表示传感器的量测协方差矩阵, $\boldsymbol{z}_{t,i}^{(n)}$为$t$时刻第$i$个目标第$n$个粒子的预测量测, 即$\boldsymbol{z}_{t,i}^{(n)}=h(\boldsymbol{x}_{t,i}^{(n)})$, $N_{\rm p}$为采样粒子总数.

3.3 最大熵模糊聚类数据关联(Maximum entropy fuzzy clustering data association)

假设k时刻观测数据集为$\{\boldsymbol{z}_{t,j},j=1,2,\cdots M_t\}$, M_t为量测个数, 目标聚类中心(即目标的预测状态)为$\{\boldsymbol{x}_{t|t-1,i},i=1,2,\cdots,N\}$, N为聚类中心个数. 聚类过程可以描述为以下优化过程[8]:

首先, 建立相应的代价函数为

$$E_t=\sum_{j=1}^{M_t}\sum_{i=1}^{N}[\mu_{ji}\cdot d(\boldsymbol{z}_{t,j},\boldsymbol{x}_{t|t-1,i})],\quad(11)$$

其中: $d(\boldsymbol{z}_{t,j},\boldsymbol{x}_{t|t-1,i})$为量测$\boldsymbol{z}_{t,j}$与目标$\boldsymbol{x}_{t|t-1,i}$之间的欧氏距离, μ_{ji}为对应的隶属度, 且服从如下的约束条件:

$$\sum_{i=1}^{N}\mu_{ji}=1,\ \forall\mu_{ji}\in[0,1].\quad(12)$$

为了最小无偏地描述数据点和类中心的隶属度, 采用最大熵原理定义目标函数为

$$\begin{aligned}J=&-\sum_{j=1}^{M_t}\sum_{i=1}^{N}(\mu_{ji}\ln\mu_{ji})-\\&\sum_{j=1}^{M_t}\alpha_j\sum_{i=1}^{N}(\mu_{ji}\cdot d(\boldsymbol{z}_{t,j},\boldsymbol{x}_{t,i}))+\\&\sum_{j=1}^{M_t}\lambda_j(\sum_{i=1}^{N}\mu_{ji}-1),\end{aligned}\quad(13)$$

其中λ_j和α_j为拉格朗日乘子, 最大化上式可计算出隶属度μ_{ji}为

$$\mu_{ji}=\frac{\exp(-\alpha_j\cdot d(\boldsymbol{z}_{t,j},\boldsymbol{x}_{t|t-1,i}))}{\sum_{i=1}^{N}\exp(-\alpha_j\cdot d(\boldsymbol{z}_{t,j},\boldsymbol{x}_{t|t-1,i}))},\quad(14)$$

为了提高α_j估计精度, 在计算杂波密度时, 可以对历次扫描落入波门内的测量数进行平均, 即用平均杂波密度$\overline{\lambda}$来计算

$$\overline{\lambda}=\frac{1}{V_t\cdot t}\sum_{l=1}^{t}M_l,\quad(15)$$

其中: M_l是l时刻落入波门内的测量数, V_t是确认区域体积. 由于JPDA需要构建关联概率矩阵, 为了区别原有的关联概率矩阵$\{\beta_{ji}\}_{i=1,\cdots,N,j=1,\cdots,M_t}$, 设量测与目标之间的关联概率矩阵为

$$\gamma=\{\gamma_{ji}\}=\begin{pmatrix}\gamma_{11}&\cdots&\gamma_{1N}\\\vdots&\ddots&\vdots\\\gamma_{M_t1}&\cdots&\gamma_{M_tN}\end{pmatrix},\quad(16)$$

其中γ_{ji}为$\boldsymbol{z}_{t,j}$和第i个目标间的关联概率, 且

$$\gamma_{ji}=\begin{cases}\mu_{ji}, & \text{当}\boldsymbol{z}_{t,j}\text{和第}i\text{个目标的有效观测},\\ 0, & \text{其他}.\end{cases} \tag{17}$$

当$\boldsymbol{z}_{t,j}$与多个目标关联, 通常需对γ做不确定性处理, 具体为

$$\gamma_{ji}=\begin{cases}\gamma_{ji}, & \text{当}\gamma_{ji}=\max\limits_{m=1:M_t}\gamma_{mi},\\ \min\limits_{i\in\Omega}\{\gamma_{ji}\}, & \text{其他},\end{cases} \tag{18}$$

其中Ω表示与$\boldsymbol{z}_{t,j}$关联的所有目标集合. 因此, 可用γ_{ji}来代替目标与量测的关联概率β_{ji}.

3.4 QMC重采样步骤(QMC resampling step)

QMC方法[11,14]通过生成的低差异性的确定序列(如Halton序列[15]), 从而能比MC采样产生的伪随机序列散布得更加均匀, 因而可以改善采样样本的质量. 为了降低采样的计算量, 本文在拟复制的大权重粒子的子空间内生成随机化QMC序列, 来代替传统的直接复制大权重粒子的方法. 它的主要步骤是:

步骤 1 确定样本的拟复制数目. 假设样本总数为$N_{\rm p}$, 根据t时刻样本$\{\boldsymbol{x}_t^{(L)}\}_{L=1}^{N_{\rm p}}$对应的权重$\{w_t^{(L)}\}_{L=1}^{N_{\rm p}}$, 确定每个样本拟复制的数目$\{n_t^{(L)}\}_{L=1}^{N_{\rm p}}$;

步骤 2 构造采样子空间. 设S为拟复制个数不为零的样本集合, 样本数为N_1, s为剩余样本集合, 样本数为N_2, 则$N_{\rm p}=N_1+N_2$. 令样本的维数为d, S包含的样本为$S_i=\{\boldsymbol{x}_i,w_i,n_i\}_{i=1}^{N_1}$, n_i为拟复制的数目. 因此, 以x_i为核心, 构造N_1个d维子空间$\{[\boldsymbol{x}_i-0.5\varDelta, \boldsymbol{x}_i+0.5\varDelta]\}_{i=1}^{N_1}$, 其中$\varDelta$为子空间的容量, 在不同维上的$\varDelta$可以按照实际的测量精度来分别设置.

步骤 3 样本生成及权重分配. 针对S中的x_i, 首先平均分配粒子权重$\{w_i(j)=1/n_i\}_{j=1}^{n_i}$, 接着生成长度为$n_i-1$的随机化QMC点集, 再将点集投影到$x_i$的子空间中, 得到$\{\boldsymbol{x}_i(j)\}_{j=1}^{n_i-1}$. 为了确保子代的加权估计与父代保持一致, 有$\boldsymbol{x}_i(n_i)=n_i\times\boldsymbol{x}_i-\sum\limits_{j=1}^{n_i-1}\boldsymbol{x}_i(j)$. 此外, 在不同维上需要采用不同的序列间隔来抽取Halton序列.

图1给出了一次仿真实验中3种算法针对所有目标的平均有效样本容量的对比结果. 从结果中可知, 本文算法能够保持较高的有效样本容量, 没有出现粒子枯竭现象. 这是由于本文的PF–MEF–QMC算法在每次样本更新后都执行重采样过程以减轻样本退化, 再执行QMC采样以抑制样本枯竭的出现. 而文献[5]采用的标准PF算法, 是通过采用传统重采样方法来提高有效样本容量. 而传统重采样后的样本会在子空间内出现聚集, 一旦状态估计误差变大, 会使得样本在后续递推过程中逐渐无法充分描述后验概率密度函数, 并最终导致某些时刻出现粒子枯竭现象, 进一步增大状态的估计误差.

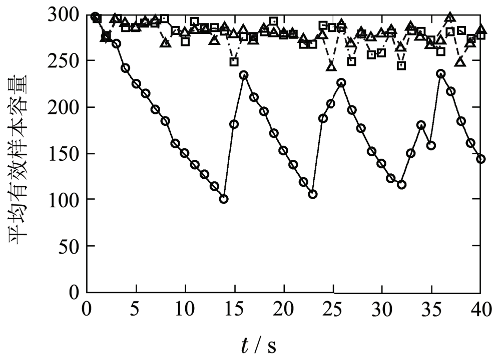

图 1 平均有效样本容量对比结果

Fig. 1 Results comparison of average effective sample size

3.5 本文算法流程(Proposed algorithm process)

按照群结构的确定性更新和不确定性估计分别设计两种算法, 记为PF–MEF–QMC1和PF–MEF–QMC2. 其中, PF–MEF–QMC1是通过$\boldsymbol{G}_t=f(\boldsymbol{G}_{t-1},\boldsymbol{X}_t)$来更新群结构, 而PF–MEF–QMC2算法是将$\boldsymbol{G}_t$作为目标状态的一部分, 形成扩展状态$(\boldsymbol{X}_t,\boldsymbol{G}_t)$, 即利用群目标的联合采样粒子包含的目标状态信息来估计出相应的群结构, 再把粒子的权重作为该群结构出现的概率. 下面分别对两种算法进行阐述:

1) 基于PF–MEF–QMC1的群跟踪算法流程.

具体步骤如算法1所示, 假设t时刻个体目标的总数为N, 采样的粒子数为$N_{\rm p}$. 在步骤1内, 首先, 以子群为单位来进行时间更新, 并将目标状态的先验概率作为重要性密度函数, 在步骤2内, 先按照式(5)和MEF–JPDA算法计算粒子权重, 其中MEF–JPDA算法步骤见算法2. 然后, 对权重进行归一化处理. 接着按照群演化模型理论, 利用粒子$\boldsymbol{X}_t^{(L)}$中对应的部分和权重来估计目标$\hat{\boldsymbol{X}}_t$和$\boldsymbol{G}_t$. 在步骤3内, 执行QMC重采样步骤.

算法 1 基于PF–MEF–QMC1的群跟踪算法.

输入: $\boldsymbol{G}_{t-1}$, $\{\boldsymbol{X}_{t-1}^{(L)},w_{t-1}^{(L)}\}_{L=1}^{N_{\rm p}}$, $\boldsymbol{z}_t$.

步骤 1 预测步. 从重要性分布$q_{\boldsymbol{g}_i}(\boldsymbol{X}_t^{\boldsymbol{g}_i}|\boldsymbol{X}_{0:t-1}^{\boldsymbol{g}_i,(L)},\boldsymbol{z}_{0:t-1})$中抽取样本$\boldsymbol{X}_t^{\boldsymbol{g}_i,(L)}$.

步骤 2 更新步.

1) 样本权重计算: 按照式(10)确认目标的有效量测, 接着按照式(5)和MEF–JPDA算法来计算样本权重, 并对权重进行归一化;

2) 目标状态估计: 利用状态抽样样本和权重估计$\hat{\boldsymbol{x}}_{t,i}(i=1,\cdots,N)$, 并最终得到$\hat{\boldsymbol{X}}_t=\{\hat{\boldsymbol{x}}_{t,i}\}_{i=1}^N$;

3) 更新群结构: $\boldsymbol{G}_t=f(\boldsymbol{G}_{t-1},\hat{\boldsymbol{X}}_t)$.

步骤 3 重采样. 执行QMC重采样步骤.

输出: $\hat{\boldsymbol{X}}_t$, $\{\boldsymbol{X}_t^{(L)},w_t^{(L)}\}_{L=1}^{N_{\rm p}}$, $\boldsymbol{G}_t$.

算法 2 MEF–JPDA算法.

步骤 1 隶属度. 根据式(11)–(15), 计算隶属度μ_{ji}, 其中$\boldsymbol{x}_{t|t-1,i}$表示粒子的预测状态均值;

步骤 2 关联矩阵. 根据式(16)–(18), 重建目标关联矩阵$\gamma=\{\gamma_{ji}\}$, 并做不确定性处理;

步骤 3 样本权重.

计算$L_{\boldsymbol{x}_{t,i}^{(L)}}=\sum_{j=0}^{M_k}\beta_{i,j}p(z_{t,j}|\boldsymbol{x}_{t,i}^{(L)})$, 再利用$\omega_{t,i}^{(L)}=w_{t-1,i}^{(L)}\cdot L_{\boldsymbol{x}_{t,i}^{(L)}}$计算样本权重. 其中, 目标与量测的边缘关联概率$\beta_{i,j}$利用$\gamma_{ji}$来代替.

2) 基于PF–MEF–QMC2的群跟踪算法.

该算法处理的样本是群目标的联合采样粒子, 并在第2层群结构的基础上完成粒子的采样. 同时利用每个联合采样粒子完成群结构的采样, 群结构采样的重要性密度函数$Q(\boldsymbol{G}_t|\boldsymbol{X}_{0:t}^{(L)},\boldsymbol{G}_{t-1}^{(L)})=p(\boldsymbol{G}_t|\boldsymbol{X}_t,\boldsymbol{G}_{t-1})$. 在采用MEF–JPDA算法计算粒子权重后, 先利用$\boldsymbol{X}_t^{(L)}$和$w_t^{(L)}$估计目标状态$\hat{\boldsymbol{X}}_t$, 再利用群结构样本$\boldsymbol{G}_t^{(L)}$和对应的权重, 估计群结构和出现概率$\{\boldsymbol{G}_{t,l},p_{t,l}\}_{j=1}^{N_{\boldsymbol{G}}}$. 其中: $N_{\rm G}$代表群结构种类, $\boldsymbol{G}_{t,l}$代表t时刻第l类群结构, $p_{t,l}$代表$\boldsymbol{G}_{t,l}$出现的概率.

算法 3 基于PF–MEF–QMC2的群跟踪算法.

输入: $\boldsymbol{G}_{t-1},\{\boldsymbol{X}_{t-1}^{(L)},w_{t-1}^{(L)}\}_{L=1}^{N_{\rm P}},\boldsymbol{z}_t$.

步骤 1 预测步. 从重要性分布$q_{\boldsymbol{g}_i}(\boldsymbol{X}_t^{\boldsymbol{g}_i}|\boldsymbol{X}_{0:t-1}^{\boldsymbol{g}_i,(L)},\boldsymbol{z}_{0:t-1})$中抽取样本$\boldsymbol{X}_t^{\boldsymbol{g}_i,(L)}$, 从重要性分布$Q(\boldsymbol{G}_t|\boldsymbol{X}_{0:t}^{(L)},\boldsymbol{G}_{t-1}^{(L)})$中抽取群结构的样本$\boldsymbol{G}_t^{(L)}$.

步骤 2 更新步.

1) 样本权重计算. 按照式(10)确认目标的有效量测, 接着按照式(5)和MEF–JPDA算法来计算样本权重, 并对权重进行归一化;

2) 目标状态估计. 利用状态抽样样本和权重估计$\hat{\boldsymbol{x}}_{t,i}(i=1,\cdots,N)$, 并最终得到$\hat{\boldsymbol{X}}_t=\{\hat{\boldsymbol{x}}_{t,i}\}_{i=1}^{N}$;

3) 更新群结构. 利用群结构抽样样本$\boldsymbol{G}_t^{(L)}$和对应权重, 估计不同群结构的概率.

步骤 3 重采样. 执行QMC重采样步骤.

输出: $\hat{\boldsymbol{X}}_t,\{\boldsymbol{X}_t^{(L)},w_t^{(L)}\}_{L=1}^{N_{\rm P}},\{\boldsymbol{G}_{t,l},p_{t,l}\}_{j=1}^{N_{\boldsymbol{G}}}$.

4 仿真结果(Simulation results)

4.1 仿真场景和群结构设计(Simulation scenario and group structure design)

参照文献[5]的仿真设置, 设计了一个二维群目标交叉运动的跟踪场景, 其中一共包括两个子群, 每个子群内包括两个目标. 假设4个目标均作匀速直线运动, 初始状态分别为

$$\boldsymbol{x}_0^1=(15\ {\rm km},-0.21\ {\rm km/s},4.9\ {\rm km},0.21\ {\rm km/s}),$$
$$\boldsymbol{x}_0^2=(15\ {\rm km},-0.21\ {\rm km/s},4.8\ {\rm km},0.21\ {\rm km/s}),$$
$$\boldsymbol{x}_0^3=(15\ {\rm km},-0.22\ {\rm km/s},9.1\ {\rm km},-0.2\ {\rm km/s}),$$
$$\boldsymbol{x}_0^4=(15\ {\rm km},-0.22\ {\rm km/s},9.2\ {\rm km},-0.2\ {\rm km/s}).$$

总的仿真时长为40 s, 假定杂波数服从参数$\lambda=2$的泊松分布, 它们在以目标量测预测值为中心的椭球区域内均匀分布. 传感器的位置为[0 m, 0 m], 传感器的测距误差$\sigma_{\rm r}=60$ m, 测角误差$\sigma_\theta=0.01$ rad, 检测概率为$P_{\rm d}=0.98$, 门概率$P_{\rm G}=0.9997$, $\xi=16$, 常量$\eta=0.01$. 划分子群的马氏距离门限中$\varepsilon_{\rm position}=200$ m , 速度门限为$\varepsilon_{\rm velocity}=20$ m/s, 给子群质心划分群的门限$\varepsilon'_{\rm position}=4\varepsilon_{\rm position}$. 本文设置了仿真场景中可能出现的4种群结构, 具体如表1所示.

表1 群结构匹配库

Table 1 Matching base of group structure

群结构索引	子群结构划分
1	$\boldsymbol{g}_1=\{1,2\},\boldsymbol{g}_2=\{3,4\}$
2	$\boldsymbol{g}_1=\{1\},\boldsymbol{g}_2=\{2\},\boldsymbol{g}_3=\{3,4\}$
3	$\boldsymbol{g}_1=\{1,2\},\boldsymbol{g}_2=\{3\},\boldsymbol{g}_3=\{4\}$
4	$\boldsymbol{g}_1=\{1\},\boldsymbol{g}_2=\{2\},\boldsymbol{g}_3=\{3\},\boldsymbol{g}_4=\{4\}$

4.2 仿真结果分析(Simulation results analysis)

按照前述的算法步骤, 通过50次蒙特卡罗仿真实验, 得到的仿真结果如图2–6及表2所示. 其中图1, 图2分别给出粒子数为300时, 本文的两种PF–MEF–QMC算法和文献[5]的PF–JPDA算法的位置和速度估计的均方根误差[11](root mean square error, RMSE)比较, 表2给出了3种算法的估计性能对比. 从结果中可知, 两种PF–MEF–QMC算法的跟踪性能要优于文献[5]算法, 它们对位置和速度的平均均方根误差, 以及估计中的顶峰误差都要低于文献[5]算法.

图4给出了当杂波数服从参数$\lambda=2$的泊松分布时, 3种算法在不同粒子数下对目标位置和速度的平均均方根误差对比. 从仿真结果可知, 随着粒子数增加, 3种算法对目标位置和速度的估计精度都相应提高, 而当粒子数增加到一定程度后, 算法的估计精度逐渐趋于平稳. 3种算法相互之间对比可知, PF–MEF–QMC算法估计精度要高于PF–JPDA算法.

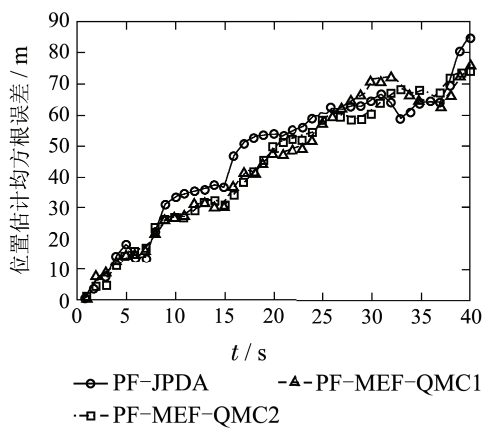

图 2 位置估计均方根误差

Fig. 2 RMSE of position estimation

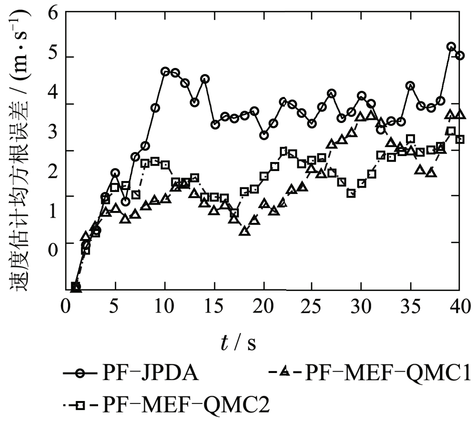

图 3 速度估计均方根误差

Fig. 3 RMSE of velocity estimation

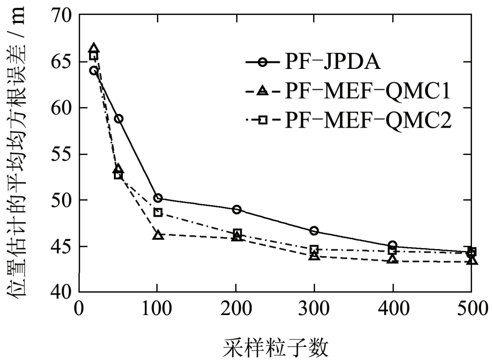

(a) 位置估计的平均均方根误差

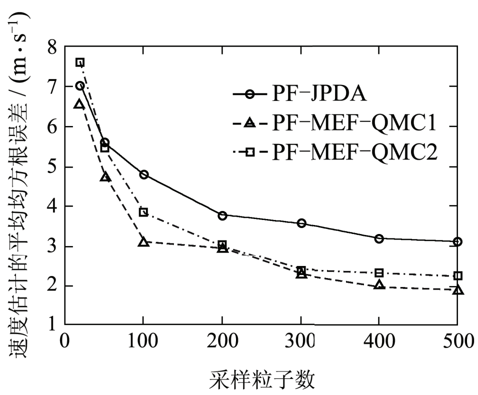

(b) 速度估计的平均均方根误差

图4 不同采样粒子数的结果比较

Fig. 4 Results comparison with different number of particles

本文测试算法的PC机平台是3.10 GHz Inter(R) Core(TM) i3－2100, RAM 2.00 GB, MATLAB (R2010b). 图5给出了3种算法在不同数目粒子下的平均单次运行时间对比, 从结果中可知, PF–MEF–QMC1算法是平均单次运行时间最少, 主要是由于该算法中利用最大熵模糊聚类得到的模糊隶属度来替代目标的关联概率, 提高了算法的运算效率. PF–MEF–QMC2算法的平均单次运行时间随着粒子数的增加而逐渐增大, 这是由于该算法需要估计群目标的每个联合采样粒子的群结构及对应发生的概率. 图6给出了PF–MEF–QMC2算法估计的群结构, 从图中可知, 该算法能较好地估计出各种群结构出现的概率, 从而能更加深入地揭示出群结构的内在变化趋势.

表2 采样粒子数为300时的算法性能比较

Table 2 Comparison of the three algorithms with 300 particles

算法类型	位置平均 RMSE/ m	速度平均 RMSE/ $(\mathrm{m\cdot s^{-1}})$	位置峰值 误差/ m	速度峰值 误差/ $(\mathrm{m\cdot s^{-1}})$
文献[5]方法	46.61	3.56	84.97	5.21
本文方法1	43.97	2.27	75.27	3.74
本文方法2	43.74	2.39	74.09	3.36

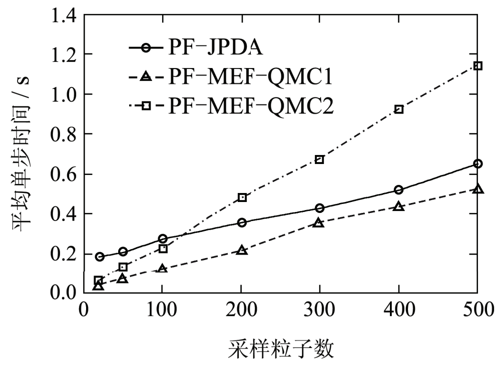

图5 不同采样粒子数下平均单次运行时间

Fig. 5 Computation time for per scan with different number of particles

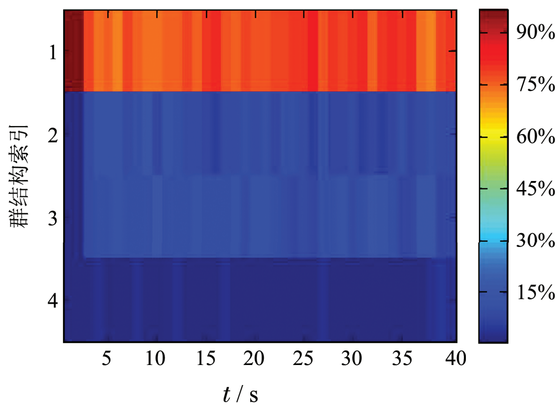

图6 群结构出现概率估计

Fig. 6 Occurrence probability estimation of group structure

5 结论(Conclusions)

针对原有群目标跟踪算法中数据关联和样本枯竭问题, 本文提出了基于模糊聚类和QMC重采样的群跟踪算法. 按照群结构的估计方式, 在此基础上分别设计了两种PF–MEF–QMC算法. 仿真实验结果表明, PF–MEF–QMC算法能在更高的运算效率的基础上,

获得比PF–JPDA算法更高的估计精度. 其中, PF–MEF–QMC1算法具有更少的计算量, 而PF–MEF–QMC2算法能更好地揭示出群结构的内在变化趋势.

参考文献(References):

[1] MIHAYLOVA L, CARMI A Y, SEPTIER F. Overview of Bayesian sequential Monte Carlo methods for group and extended object tracking [J]. *Digital Signal Processing*, 2014, 25(2): 1 – 16.

[2] PANG S K, LI J, GODSILL S J. Detection and tracking of coordinated groups [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, 47(1): 472 – 501.

[3] HELBING D. Traffic and related self-driven many-particle systems [J]. *Reviews of Modern Physics*, 2002, 73(4): 1067 – 1141.

[4] MAHLER R. *Statistical Multisource-Multitarget Information Fusion* [M]. Boston: Artech House, 2007.

[5] GNING A, MIHAYLOVA L, MASKELL S. Group object structure and state estimation with evolving networks and Monte Carlo methods [J]. *IEEE Transactions on Signal Processing*, 2011, 59(4): 1383 – 1395.

[6] MOURAD O, JORIS D S. Hybrid fuzzy probabilistic data association filter and joint probabilistic data association filter [J]. *Information Sciences*, 2002, 142(1/4): 195 – 226.

[7] LIU P X, Meng M Q. Online data-driven fuzzy clustering with applications to real-time robotic tracking [J]. *IEEE Transactions on Fuzzy Systems*, 2004, 12(4): 516 – 523.

[8] LI L Q, JI H B, GAO X B. Maximum entropy fuzzy clustering with application to real-time target tracking [J]. *Signal Processing*, 2006, 86(11): 3432 – 3447.

[9] 朱志宇. 粒子滤波算法及其应用 [M]. 北京: 科学出版社, 2010.
(ZHU Zhiyu. *Particle Filter Algorithm and Its Application* [M]. Beijing: Science Press, 2010.)

[10] 杨小军, 潘泉, 王睿. 粒子滤波进展与展望 [J]. 控制理论与应用, 2006, 23(2): 261 – 267.
(YANG Xiaojun, PAN Quan, WANG Rui. Development and prospect of particle filtering [J]. *Control Theory & Applications*, 2006, 23(2): 261 – 267.)

[11] 赵玲玲, 马培军. 一种快速准蒙特卡罗粒子滤波算法 [J].自动化学报, 2010, 36(9): 1351 – 1356.
(ZHAO Lingling, MA Peijun. A fast Quasi-Monte-Carlo based particle filter algorithm [J]. *Acta Automatica sinica*, 2010, 36(9): 1351 – 1356.)

[12] BLACKMAN S, POPOLI R. *Design and Analysis of Modern Tracking Systems* [M]. Boston: Artech House Radar Library, 1999.

[13] LI X R, JILKOV V. A survey of maneuvering target tracking part I: dynamic models [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1333 – 1364.

[14] GUO D, WANG X D. Quasi-Monte Carlo filtering in nonlinear dynamic systems [J]. *IEEE Transactions on Signal Processing*, 2006, 54(6): 2087 – 2098.

[15] WANG X, HICKMELL F. Randomized halton sequences [J]. *Mathematical and Computer Modeling*, 2000, 32(7): 887 – 899.

作者简介:

李振兴 (1988–), 男, 博士研究生, 主要研究方向为群目标跟踪、密集多目标分辨算法研究, E-mail: lzxing1988@163.com;

刘进忙 (1958–), 男, 教授, 博士生导师, 主要研究方向为目标信息融合、分坐标处理技术研究, E-mail: liujinmang1@163.com;

李　超 (1990–), 男, 硕士研究生, 主要研究方向为目标跟踪, E-mail: lichao19900929@163.com;

白东颖 (1982–), 女, 讲师, 主要研究方向为智能信息处理, E-mail: dybai@hotmail.com;

郭相科 (1980–), 男, 讲师, 主要研究方向为智能信息处理, E-mail: guosyanyu@163.com.