

改进的高斯粒子概率假设密度滤波算法

周承兴, 刘贵喜, 侯连勇, 钟兴质

(西安电子科技大学 自动控制系统, 陕西 西安 710071)

摘要: 高斯粒子概率假设密度滤波在预测和更新时需要进行粒子近似和重新采样, 这在一定程度上降低了算法的精度和实时性. 针对这一问题, 提出一种改进的高斯粒子概率假设密度滤波算法. 算法通过粒子的方式表示并传递目标的概率假设密度(PHD)预测值, 然后直接利用这些表征PHD预测值的粒子进行更新, 最后利用具有最大似然性的粒子将更新后的PHD表示为混合高斯形式. 仿真实验表明, 和高斯粒子概率假设密度滤波相比, 改进算法的多目标误差距离减少了约30%, 运行时间减少了约50%.

关键词: 多目标跟踪; 随机集; 概率假设密度; 混合高斯; 粒子近似

中图分类号: V249 **文献标识码:** A

Modified Gaussian particle probability hypothesis density filtering algorithm

ZHOU Cheng-xing, LIU Gui-xi, HOU Lian-yong, ZHONG Xing-zhi

(Department of Automation, Xidian University, Xi'an Shaanxi 710071, China)

Abstract: The Gaussian particle probability hypothesis density filter needs particle approximation and resampling in the prediction step and the update step; this lowers the accuracy and deteriorates the real-time performance of the algorithm to some extent. To solve this problem, a modified Gaussian particle probability hypothesis density filtering algorithm is proposed. This algorithm expresses and transfers the predicted probability hypothesis density (PHD) of targets in the form of particles, and then directly updates these particles representing the predicted PHD. Finally, the algorithm approximates the updated PHD into a Gaussian mixture function by using the particles with greatest likelihood. The simulation experiments show that the modified algorithm reduces the multi-target error distance by nearly 30% and cuts the running time by nearly 50% in comparison with Gaussian particle probability hypothesis density filter.

Key words: multiple target tracking; random sets; probability hypothesis density; Gaussian mixture function; particle approximation

1 引言(Introduction)

由于需要从不确定的测量值中估计多个目标的状态、处理未知且时变的目标个数和测量杂波等问题, 多目标跟踪在复杂程度上要远高于单目标跟踪. 传统多目标跟踪算法^[1,2]如联合概率数据关联^[1]、多假设跟踪^[2]等需要进行复杂的数据关联. 近几年出现的概率假设密度(probability hypothesis density, PHD)滤波^[3~8]方法无需进行数据关联, 已逐渐成为多目标跟踪领域的研究热点.

目前主流的PHD滤波主要分为两类: 一类是在线性高斯条件下得出的混合高斯概率假设密度滤波(Gaussian mixture probability hypothesis density filtering, GM-PHDF)^[4,5]; 另一类是在一般的非线性情况下, 结合蒙特卡罗方法得到的粒子概率假设密度滤波(particle PHDF)或序列蒙特卡罗概率假设密度

滤波(sequential Monte Carlo PHDF, SMC-PHDF)^[6]. 它们各有优缺点: GM-PHDF能简单快速的估计多目标状态, 但只适用于线性高斯情况; SMC-PHDF可以处理非线性非高斯情况下的多目标跟踪问题, 但是需要对大量粒子进行聚类 and 重采样.

高斯粒子概率假设密度滤波(Gaussian particle PHDF, GP-PHDF)^[7,8]充分结合了GM-PHDF和蒙特卡罗方法的优点, 通过粒子的方式将目标的PHD近似为混合高斯形式进行PHD滤波. 但该算法在滤波预测和更新时需要进行粒子近似和重新抽样, 同时, 提取目标状态的加权平均方式偏离了粒子权值的本质, 这些都在一定程度上影响了算法的精度和实时性.

本文针对GP-PHDF的上述不足, 提出一种改进的GP-PHDF算法(简称为MGP-PHDF). 改进算法以粒

子的方式表示和传递PHD预测值,然后直接利用这些表示PHD预测值的粒子进行PHD更新,最后利用具有最大似然性的粒子从各个混合高斯分量中提取目标状态,避免了在预测和更新时进行粒子近似和重新抽样,目标状态的提取也更符合粒子权值本质.仿真实验表明,和GP-PHDF相比,改进算法的多目标误差距离和运行时间分别减少了约30%和50%.

2 高斯粒子概率假设密度滤波(Gaussian particle probability hypothesis density filtering)

高斯粒子概率假设密度滤波(GP-PHDF)^[7,8]以粒子的方式将PHD近似为多个高斯分量进行滤波,既能够处理非线性问题,又不需要像粒子PHD那样对粒子进行聚类 and 重采样.

GP-PHDF将各时刻目标的PHD近似为混合高斯形式,其完整滤波过程分为两步^[7]:

1) GP-PHD预测.

从 $k-1$ 时刻得到的每个混合高斯分量中抽取 M 个粒子,再经动态方程传递这些粒子,然后利用蒙特卡罗方法将PHD预测值近似为混合高斯形式^[7].

2) GP-PHD更新.

在得到近似PHD预测值的混合高斯分量之后,利用这一结果从每个预测高斯分量中抽取 M 个粒子,并计算这些粒子的权值,然后通过PHD更新方程和加权平均的蒙特卡罗方式将目标的PHD值近似为混合高斯形式^[7].更详细的滤波过程可参考文献^[7].

3 改进的高斯粒子PHD算法(Modified Gaussian particle PHD algorithm)

针对GP-PHDF在预测和更新时进行粒子近似和再采样会在一定程度上加大算法的误差,还会浪费大量运算时间的不足,本文以粒子的形式表示和传递PHD预测值的分布,然后直接利用这些粒子进行更新,从而避免粒子近似和重新抽样.针对GP-PHDF通过粒子加权平均的方式提取各个高斯分量偏离了粒子权值本质的不足,本文利用最大似然方法由权值最大的粒子提取各高斯分量,相对加权平均更符合粒子权值的本质,可能产生的偏差更小.

通过上述改进得到本文算法:改进的高斯粒子PHD算法(MGP-PHDF).改进算法在滤波时采用如下非线性高斯动态模型和测量模型^[7]:

$$f_{k|k-1}(\mathbf{x}|\zeta) = N(\mathbf{x}; \varphi_{k-1}(\zeta), Q_{k-1}), \quad (1)$$

$$g_k(\mathbf{z}|\mathbf{x}) = N(\mathbf{z}; h_k(\mathbf{x}), R_k), \quad (2)$$

其中: $f_{k|k-1}$ 为单目标状态转移密度, g_k 为单目标似然函数, $N(\cdot; \mathbf{m}, P)$ 表示以 $\mathbf{m}$ 为均值, P 为协方差的的高斯分布, φ_{k-1} 为非线性状态转移方程, Q_{k-1} 为过

程噪声协方差, h_k 为非线性测量方程, R_k 为观测噪声协方差.

假设 $k-1$ 时刻目标PHD和 k 时刻的新目标PHD分别表示为如下形式^[7]:

$$v_{k-1}(\mathbf{x}) = \sum_{i=1}^{J_{k-1}} w_{k-1}^{(i)} N(\mathbf{x}; \mathbf{m}_{k-1}^{(i)}, P_{k-1}^{(i)}), \quad (3)$$

$$\gamma_k(\mathbf{x}) = \sum_{i=1}^{J_{\gamma,k}} w_{\gamma,k}^{(i)} N(\mathbf{x}; \mathbf{m}_{\gamma,k}^{(i)}, P_{\gamma,k}^{(i)}). \quad (4)$$

其中: J_{k-1} 表示 $k-1$ 时刻高斯分量个数, $w_{k-1}^{(i)}$ 表示第 i 个高斯分量的权值, $\mathbf{m}_{k-1}^{(i)}$ 和 $P_{k-1}^{(i)}$ 分别表示第 i 个高斯分量的均值和协方差, $J_{\gamma,k}$ 表示新生目标高斯分量个数, $w_{\gamma,k}^{(i)}$ 表示第 i 个新生目标高斯分量的权值, $\mathbf{m}_{\gamma,k}^{(i)}$ 和 $P_{\gamma,k}^{(i)}$ 分别表示第 i 个新生目标高斯分量的均值和协方差.

改进算法的一个完整滤波过程为:

1) 预测.

首先,从式(3)所表示的 $k-1$ 时刻的每个高斯分量采样 M 个粒子 $\mathbf{x}_{k-1}^{(i)(j)}, j=1, \dots, M$,再通过转移密度 $f_{k|k-1}(\cdot|\mathbf{x}_{k-1}^{(i)(j)})$ 传递得到预测粒子 $\mathbf{x}_{S,k|k-1}^{(i)(j)}$.然后,从式(4)所示的 k 时刻新生目标的各个高斯分量采样 M 个粒子 $\mathbf{x}_{\gamma,k}^{(i)(j)}, j=1, \dots, M$,综合这两部分粒子得到近似PHD预测值 $v_{k|k-1}$ 的粒子集:

$$\begin{aligned} \{\mathbf{x}_{k|k-1}^{(i)(j)}\}_{i=1}^{J_{k|k-1}} = \\ \{\mathbf{x}_{S,k|k-1}^{(i)(j)}\}_{i=1}^{J_{k-1}} \cup \{\mathbf{x}_{\gamma,k}^{(i)(j)}\}_{i=1}^{J_{\gamma,k}}, j=1, \dots, M. \end{aligned} \quad (5)$$

2) 更新.

在得到表示PHD预测值的粒子集后,通过更新步将PHD值近似为如下混合高斯形式:

$$\begin{aligned} v_k(\mathbf{x}) = & \sum_{\mathbf{z} \in Z_k} \sum_{i=1}^{J_{k|k-1}} w_{k|k-1}^{(i)}(\mathbf{z}) N(\mathbf{x}; \mathbf{m}_{k|k-1}^{(i)}, P_{k|k-1}^{(i)}) + \\ & [p_{S,k} \sum_{i=1}^{J_{k-1}} w_{k-1}^{(i)} N(\mathbf{x}; \mathbf{m}_{S,k|k-1}^{(i)}, P_{S,k|k-1}^{(i)}) + \\ & \gamma_k(\mathbf{x})] (1-p_{D,k}) = \sum_{i=1}^{J_k} w_k^{(i)} N(\mathbf{x}; \mathbf{m}_k^{(i)}, P_k^{(i)}), \end{aligned} \quad (6)$$

其中:

$$\mathbf{m}_{S,k|k-1}^{(i)} = \frac{1}{M} \sum_{j=1}^M \mathbf{x}_{S,k|k-1}^{(i)(j)}, \quad (7)$$

$$\begin{aligned} P_{S,k|k-1}^{(i)} = & \frac{1}{M} \sum_{j=1}^M (\mathbf{m}_{S,k|k-1}^{(i)} - \mathbf{x}_{S,k|k-1}^{(i)(j)}) \times \\ & (\mathbf{m}_{S,k|k-1}^{(i)} - \mathbf{x}_{S,k|k-1}^{(i)(j)})^T. \end{aligned} \quad (8)$$

对每个测量值 $\mathbf{z} \in Z_k$,按下式计算式(5)中每个预测粒子的权值:

$$\eta_{k,z}^{(i)(j)} = N(\mathbf{z}; h_k(\mathbf{x}_{k|k-1}^{(i)(j)}), R_k). \quad (9)$$

选择具有最大似然性(权值)的粒子 $\mathbf{x}_{k|k-1}^{(i)(j_0)}$ 及其对应

的权值 $\eta_{k,z}^{(i)(j_0)}$, 其中对每个固定 i 值:

$$j_0 = \arg \max \{ \eta_{k,z}^{(i)(j)} \}. \quad (10)$$

再利用所选择的粒子近似PHD更新值各高斯分量的均值、权值和协方差, 其计算公式如下:

$$\mathbf{m}_{k|k}^{(i)} = \mathbf{x}_{k|k-1}^{(i)(j_0)}, \quad (11)$$

$$w_{k|k}^{(i)} = \frac{p_{D,k} w_{k|k-1}^{(i)} \eta_{k,z}^{(i)(j_0)}}{\kappa_k(\mathbf{z}) + p_{D,k} \sum_{l=1}^{J_{k|k-1}} w_{k|k-1}^{(l)} \eta_{k,z}^{(l)(j_0)}}, \quad (12)$$

$$P_{k|k}^{(i)} = \frac{\sum_{j=1}^M \eta_{k,z}^{(i)(j)} (\mathbf{m}_{k|k}^{(i)} - \mathbf{x}_{k|k-1}^{(i)(j)}) (\mathbf{m}_{k|k}^{(i)} - \mathbf{x}_{k|k-1}^{(i)(j)})^T}{\sum_{j=1}^M \eta_{k,z}^{(i)(j)}}. \quad (13)$$

3) 估计目标个数和目标状态.

对混合高斯分量进行剪枝, 然后累加所有高斯分量的权值 $w_k^{(i)} (i = 1, \dots, J_k)$ 得到目标个数的估计值 N_k , 最后选择最大的前 N_k 个权值对应的高斯分量作为目标状态估计值.

假设对每个高斯分量采样的粒子数为 M , 由于GP-PHDF在预测和更新时需要进行粒子近似及重新抽样, 因此对每个高斯分量实际运算的粒子数为 $2M$, 而改进算法只需在预测步采样粒子, 对每个高斯分量实际运算的粒子数为 M . 因此, 从上述计算复杂度分析看出, 在不同的粒子数 M 的情况下, 改进算法均可以节省大约50%的运算时间.

4 仿真实验(Simulations)

4.1 仿真场景(Simulation environment)

仿真实验时长为40步, 每步一个时间单位(2 s), 采用多目标跟踪中经典的方位和距离跟踪模型^[6], 其中目标的运动模型为

$$\mathbf{x}_k = \begin{pmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{pmatrix} \mathbf{x}_{k-1} + \begin{pmatrix} \frac{T^2}{2} & 0 \\ T & 0 \\ 0 & \frac{T^2}{2} \\ 0 & T \end{pmatrix} \mathbf{w}_k, \quad (14)$$

其中: $\mathbf{x}_k = [x_p(k) \ x_v(k) \ y_p(k) \ y_v(k)]^T$ 为目标状态向量, 表示目标在 x, y 坐标方向的位置和速度, $\mathbf{w}_k$ 是零均值, 协方差为 $\text{diag}\{0.1, 0.1\}$ 的高斯白噪声. 采样周期 $T = 1$ (时间单位). 目标的测量方程为

$$\begin{cases} \vartheta_k = \arctan \frac{y_{p,k}}{x_{p,k} + 200} + v_{1,k}, \\ r_k = \left\| \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \mathbf{x}_k - \begin{pmatrix} -200 \\ 0 \end{pmatrix} \right\| + v_{2,k}. \end{cases} \quad (15)$$

其中: ϑ_k, r_k 分别表示目标的方位角和距传感器的距离. 测量噪声 $v_{1,k}, v_{2,k}$ 是零均值、方差分别是0.01和0.5的高斯白噪声.

测量空间内的杂波个数服从均值 $r = 3$ 的泊松分布, 杂波密度为: $\kappa_k(\mathbf{z}) = r/600\pi$. 检测概率 $p_{D,k} = 1$, 目标存活概率 $p_{S,k} = 1$, 不考虑目标衍生, 新生目标PHD为

$$\gamma_k(\mathbf{x}) = 0.1N([0, -4, 0, -4]^T, I) + 0.1N([0, -2, 0, -2]^T, I),$$

其中 I 表示单位矩阵. 每个高斯分量采样粒子数 $M = 70$.

4.2 仿真结果(Simulation result)

在上述仿真环境下, 分别利用两种算法对场景中的多个目标进行跟踪, 得到的跟踪轨迹和目标个数曲线如图1~3所示.




图1 x 方向的多目标跟踪轨迹

Fig. 1 Multi-target tracking trajectory in x coordinate




图2 y 方向的多目标跟踪轨迹

Fig. 2 Multi-target tracking trajectory in y coordinate




图3 目标个数估计

Fig. 3 Estimation of target number

从图3的目标个数估计曲线来看,两种算法均能对跟踪范围内出现的目标个数作出准确估计,但是从图1,2的多目标跟踪轨迹看出,和GP-PHDF相比,MGP-PHDF对目标轨迹的估计偏差更小.为了定量的比较两种算法的跟踪精度,采用Wasserstein距离^[6,9]来度量算法的跟踪误差.图4得到的是两种算法的多目标误差距离(Wasserstein距离)曲线.




图4 多目标跟踪误差

Fig. 4 Multi-target tracking error

从误差曲线可以更直观的看出,改进算法的跟踪误差比GP-PHDF更小,例如,在时间步8,16,24,32,改进算法和原有算法相比,误差分别减少了0.94 m, 0.75 m, 0.44 m, 0.31 m.为了从统计意义更合理的比较两种算法的性能,通过20次蒙特卡罗仿真比较两者在不同杂波密度下的平均运行时间和平均误差距离.其中平均误差距离按下式计算:

$$\bar{d} = \frac{1}{N_S N_T} \sum_{i=1}^{N_S} \sum_{j=1}^{N_T} d_{i,j}, \quad (16)$$

其中: $\bar{d}$ 为平均误差距离, $d_{i,j}$ 为第 i 次蒙特卡罗实验下第 j 时刻的Wasserstein距离, N_S 为蒙特卡罗仿真次数,实验中取20, N_T 为仿真步长,实验中为40.得到的结果如表1所示.表中: r 为杂波数均值, $\bar{t}$ 为平均运行时间, $\bar{d}$ 为平均误差距离.从表1结果可以看出,随着杂波密度的增大,两种算法的运算时间和误差距离均有一定程度的增加.但从横向来看,在不同杂波密度下,改进算法相对于GP-PHDF的运算时间更短,节省了约50%,误差距离更小,减少了约30%,且对不同环境具有一定的泛化能力.

表1 两种算法在不同杂波密度下的跟踪性能比较
Table 1 Tracking performance comparison of two algorithms under different clutter density

r	GP-PHDF		MGP-PHDF	
	$\bar{t}/s$	$\bar{d}/m$	$\bar{t}/s$	$\bar{d}/m$
1	56.23	5.36	26.84	3.92
3	65.74	5.87	32.63	4.16
5	78.15	6.12	36.29	4.45

5 结论(Conclusion)

本文针对高斯粒子PHD算法的一些不足,提出一种改进的高斯粒子PHD算法.改进算法以粒子的方式表示并传递PHD预测值,然后直接利用这些粒子进行PHD更新,最后采用最大似然方法提取混合高斯分量,使得改进算法的性能和高斯粒子PHD相比有两方面提高:1)多目标误差距离更小,精度更高.2)算法的运行时间更短,实时性更好.

参考文献(References):

- [1] 李晨, 韩崇昭, 徐林海, 等. 舰载红外警戒系统的单站多目标数据关联与滤波算法[J]. 控制理论与应用, 2008, 25(4): 733 – 737. (LI Chen, HAN Chongzhao, XU Linhai, et al. Data association and tracking algorithm for a shipborne infrared surveillance system[J]. *Control Theory & Applications*, 2008, 25(4): 733 – 737.)
- [2] BLACKMAN S S. Multiple hypothesis tracking for multiple target tracking[J]. *IEEE Aerospace and Electronic Systems Magazine*, 2004, 19(1): 5 – 18.
- [3] MAHLER R P S. Multitarget bayes filtering via first-order multitarget moments[J]. *IEEE Transactions on Aerospace and Electronic systems*, 2003, 39(4): 1152 – 1178.
- [4] VO BA-NGU, MA W K. The Gaussian mixture probability hypothesis density filter[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4091 – 4104.
- [5] PASHA S A, VO BA-NGU, TUAN H D, et al. A Gaussian Mixture PHD Filter for jump markov system models[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 45(3): 919 – 936.
- [6] VO BA-NGU, SINGH S, DOUCET A. Sequential monte carlo methods for multi-target filtering with random finite sets[J]. *IEEE Transactions on Aerospace and Electronic systems*, 2005, 41(4): 1224 – 1245.
- [7] CLARK D, VO BA-TUONG, VO BA-NGU. Gaussian particle implementations of probability hypothesis density filters[C] // *IEEE Aerospace Conference*. Montana, USA: AIAA Press, 2007: 1 – 11.
- [8] CLARK D, VO BA-TUONG, VO BA-NGU, et al. Gaussian mixture implementations of probability hypothesis density filters for non-linear dynamical models[C] // *The IET Seminar on Target tracking and Data Fusion: Algorithms and Applications*. Birmingham, UK: IET Press, 2008: 21 – 28.
- [9] HOFFMAN J R, MAHLER R P S. Multitarget miss distance via optimal assignment[J]. *IEEE Transactions on Systems, Man, and Cybernetics, part A: Systems and Humans*, 2004, 34(3): 327 – 336.

作者简介:

周承兴 (1987—), 男, 硕士研究生, 目主要研究方向为多目标跟踪、跟踪滤波和图像处理等, E-mail: xajdzcx@126.com;

刘贵喜 (1966—), 男, 博士, 教授, 博士生导师, 主要研究方向为多传感器信息融合、目标检测与跟踪、图像处理与机器视觉等, E-mail: gxliu@xidian.edu.cn;

侯连勇 (1987—), 男, 硕士研究生, 主要研究方向为图像处理、跟踪滤波和视频目标跟踪等, E-mail: hlypeter@163.com;

钟兴质 (1984—), 男, 硕士研究生, 主要研究方向为多传感器融合、跟踪滤波和图像处理等, E-mail: zhongxingzhi2007@163.com.