

基于 DSMT 与粒子滤波的多传感器融合

夏建明^{a,b}, 杨俊安^{a,b}, 张 琼^{a,b}

(解放军电子工程学院 a. 信息系; b. 安徽省电子制约技术重点实验室, 合肥 230037)

摘 要: 为实现多传感器对机动目标状态的跟踪, 提出一种基于 DSMT 与粒子滤波的多传感器融合算法。在各传感器利用粒子滤波方法处理观测数据的基础上, 运用 DSMT 作为融合工具, 将观测数据转化为辨识框架内的元素及其 mass 值, 得到最终融合结果。实验结果表明, 该方法可减小距离误差, 提高跟踪精度, 且运算复杂度能满足在线实时融合的要求。

关键词: DSMT 技术; 粒子滤波; 贝叶斯融合规则; 卡尔曼融合规则; 目标跟踪

Multi-sensor Fusion Based on DSMT and Particle Filtering

XIA Jian-ming^{a,b}, YANG Jun-an^{a,b}, ZHANG Qiong^{a,b}

(a. Department of Information; b. Key Laboratory of Electronic Restriction Technology of Anhui Province, PLA Electronic Engineering Institute, Hefei 230037, China)

【Abstract】 To realize multi-sensor tracking for maneuvering target state, this paper presents a multi-sensor fusion algorithm based on DSMT and particle filtering. On the basis of observation data which is delivered by multi-sensor and filtered by particle filters. It chooses DSMT as the combining tool. The observation data is transformed into the elements and masses of the frame of discernment, and gets the finally result. Experimental results show that this algorithm can reduce distance error and improve tracking accuracy, and the appropriate computational complexity can satisfy the demand of fusing on-line.

【Key words】 DSMT technology; particle filtering; Bayesian fusion rule; Kalman fusion rule; target tracking

1 概述

在状态估计和目标跟踪过程中, 传感器观测方程通常是非线性的, 拓展卡尔曼滤波器等传统滤波器试图用线性化方法去解决该难题, 效果并不理想, Unscented 卡尔曼滤波器能较好估计状态的均值及方差, 但不适用于一般情况下的非高斯分布情况^[1]。而粒子滤波技术作为一种基于贝叶斯理论和蒙特卡罗方法的近似算法, 由于其过程本身不依赖于系统的线性程度和噪声的高斯性, 适用于难以线性化和高斯近似处理的情况, 因此近年来被广泛应用。在解决复杂问题时, 单个传感器通常不能提供有关隐藏状态的足够信息, 这就需要融合若干传感器的测量信息 $z_{k,f}$ ($k=1, 2, \dots, n$), 已有经典融合方法有加权平均、最小二乘法、最小一乘估计^[2]、卡尔曼滤波、贝叶斯方法等, 其中, 加权平均法是最简单和直观的方法, 其调整和设定权系数的工作量大且具有一定主观性。卡尔曼滤波方法是融合第 1 级的动态冗余数据方法, 可以提供统计意义上的最优融合^[3], 但对于融合粒子滤波器结果而言, 只是在粒子云整体特征上进行融合, 云内部相关粒子的权值没有考虑。Dezert J 和 Smarandache F 于 2000 年提出一种通用有效的崭新信息融合算法 DSMT(Dezert-Smarandache Theory), 由于其能处理多源信息的模糊性、不确定性和高度冲突性, 在提出后一直受到关注。该证据理论计算思路与粒子滤波的思想(用带有归一化权重的粒子集表征状态)相似, 使其能作为一种决策层的融合方法适用于像素层。本文将粒子滤波方法作为观测站的跟踪方法, 以 DSMT 为融合手段, 构造一种新的多传感器融合方法, 应用于目标跟踪中, 最后用仿真实验证明方法的有效性。

2 相关理论

2.1 DSMT 基本理论

2.1.1 重要定义

定义 1 (超幂集) 对于辨识框架 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ 中的元素, 通过 “ \cup ” 和 “ \cap ” 运算形成符合以下规则的集合, 称为超幂集 D^Θ ^[4]:

- (1) $\emptyset, \theta_1, \theta_2, \dots, \theta_n \in D^\Theta$;
- (2) 如果 $A, B \in D^\Theta$, 则 $A \cap B \in D^\Theta$ 且 $A \cup B \in D^\Theta$;
- (3) 除了由(1)、(2)获得的元素外, D^Θ 不包含其他元素。

定义 2 设 Θ 为辨识框架, Θ 上的广义基本置信分配 (Generalized Basic Belief Assignment, GBBA) 即 mass 函数, 定义为 $m(\cdot): D^\Theta \rightarrow [0, 1]$, 若满足下列条件^[4], 则 $m(A)$ 称为 mass 函数, 表示证据支持命题 A 发生的程度:

- (1) $m(\emptyset) = 0$;
- (2) $\sum_{A \in D^\Theta} m(A) = 1$ 。

2.1.2 重要公式

在辨识框架 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ 上, k 2 个独立证据源的 free-DSMT 模型 $M^f(\Theta)$ 的组合规则为^[4]:

$$m_{M^f(\Theta)}(A) \triangleq [m_1 \oplus m_2 \oplus \dots \oplus m_k](A) = \sum_{\substack{X_1, X_2, \dots, X_k \in D^\Theta \\ (X_1 \cap X_2 \cap \dots \cap X_k) = A}} \prod_{i=1}^k m_i(X_i) \quad (1)$$

基金项目: 国家自然科学基金资助项目(60872113)

作者简介: 夏建明(1982-), 男, 硕士研究生, 主研方向: 信号分析, 机器学习; 杨俊安, 教授、博士、博士生导师; 张 琼, 硕士研究生
收稿日期: 2010-04-22 **E-mail:** bushixiaohui@tom.com

2.2 基本粒子滤波理论

时变问题的一般动态状态空间模型分为系统状态转移模型 $p(x_k/x_{k-1})$ 和量测模型 $p(z_k/x_k)$ ，其中， $x_k \in R^{n_x}$ 代表系统在时间 k 的状态变量； $z_k \in R^{n_z}$ 为系统在时间 k 的观测值。

系统状态转移模型为：

$$x_k = f_k(x_{k-1}, \omega_k) \leftrightarrow p(x_k | x_{k-1}) \quad (2)$$

量测模型为：

$$z_k = h_k(x_k, \nu_k) \leftrightarrow p(z_k | x_k) \quad (3)$$

所获信息为：

$$\begin{cases} D_k = (z_1, z_2, \dots, z_k) \\ p(x_0) \end{cases} \quad (4)$$

其中， $z_k \in R^{n_z}$ 表示输出观测值； $x_k \in R^{n_x}$ 为系统的状态变量； $\omega_k \in R^{n_\omega}$ 、 $\nu_k \in R^{n_\nu}$ 分别为过程噪声和量测噪声， ω_k 和 ν_k 是相互独立的协方差分别为 Q_{ω_k} 和 R_{ν_k} 的零均值加性噪声（一般情况下认为其是高斯白噪声）； $f: R^{n_x} \times R^{n_\omega} \rightarrow R^{n_x}$ 、 $h: R^{n_x} \times R^{n_\nu} \rightarrow R^{n_z}$ 为有界非线性函数^[5]。

量测信息与隐藏状态关系由概率密度 $p(z_{k,t} | x_k)$ 表示。而一般很难获得状态转移概率密度 $p(x_t | x_{t-1})$ 及后验概率密度 $p(x_t | z_t)$ 的解析表示，只能考虑近似获得。粒子滤波的基本思想是：首先依据系统状态向量的经验条件分布在状态空间产生一组随机样本的集合（粒子）；然后根据观测量不断调整粒子的权重和位置，修正最初的经验条件分布。用由粒子及其权重组成的离散随机测量近似相关的概率分布，并且根据算法递推更新离散随机测度。当样本容量很大时，这种蒙特卡罗描述近似于状态变量真实的后验概率密度函数。

3 基于 DSMT 与粒子滤波的多传感器融合算法

DSMT 方法是对离散化的辨识框架内的元素 mass 值进行一系列的运算，需要将各传感器的相应数据转化为框架内的元素及其 mass 值，具体构造的 DSMT 融合算法步骤如下：

传感器数目 n 、粒子数 N 、状态数 n_k

步骤 1 for $k=1:n$

传感器 k 依据初始先验分布 $p(x_0)$ 产生样本，所有粒子权值为 $1/N$

end；

步骤 2 时刻 t ，for $k=1:n$

传感器 k ，对应正确的观测模型进行滤波处理，得到粒子云、权值 $\{\hat{x}_{k,t}^i, \hat{w}_{k,t}^i | i=1, 2, \dots, N\}$

end；

步骤 3 计算各粒子云方差，对权值进行加权处理，浓缩粒子云（去除重复项，汇聚权值），得到新的粒子云、权值 $\{\hat{x}_{k,t}^i, \hat{w}_{k,t}^i | i=1, 2, \dots, \hat{N}_k\}$ ；

步骤 4 for $k=1:n$

for $j=1:n$

if $j \neq k$

将粒子云 $j(\{\hat{x}_{j,t}^i, \hat{w}_{j,t}^i | i=1, 2, \dots, \hat{N}_j\})$ 中的粒子填入粒子云 $k(\{\hat{x}_{k,t}^i, \hat{w}_{k,t}^i | i=1, 2, \dots, \hat{N}_k\})$ ，根据 $\hat{x}_{j,t}^i$ 与 $\hat{x}_{k,t}^i$ 大小及权值 $\hat{w}_{k,t}^i$ 得到 $\hat{x}_{j,t}^i$ 新的权值，并进行归一化得到新的粒子云 k

end

end

end；

步骤 5 以各新粒子云为辨识框架，其中的粒子为元素，

新的权值为其 mass 函数值，对 n 个粒子云进行 DSMT 融合得到最终粒子云：

$$\{\hat{x}_{ds,t}^i, \hat{w}_{ds,t}^i | i=1, 2, \dots, \hat{N}_{ds}\}$$

$$\hat{X} \approx \sum_{i=1}^{\hat{N}_{ds}} \hat{x}_{ds,t}^i \times \hat{w}_{ds,t}^i ;$$

步骤 6 各传感器重采样， $t=t+1$ ，转到步骤 2。

4 仿真实验

为验证算法的应用效果，本文分 2 个实验进行说明：

(1) 贝叶斯方法、卡尔曼方法与本文算法效果的对比；(2) 在多传感器的目标跟踪信息融合上的运用。

4.1 高斯分布融合实验

由文献[6]可知， $p(x | z_1, z_2) \propto \frac{p(x | z_1) \times p(x | z_2)}{p(x)}$ ，假设先

验分布 $p(x)$ 统一，则：

$$p_{\text{Bayes}}(x | z_1, z_2) \propto p(x | z_1) \times p(x | z_2) \quad (5)$$

$$\text{设 } p_1(x) = \frac{1}{\sigma_1 \sqrt{2\pi}} e^{-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2}}、p_2(x) = \frac{1}{\sigma_2 \sqrt{2\pi}} e^{-\frac{(x-\bar{x}_2)^2}{2\sigma_2^2}}，\text{得到：}$$

$$p_{\text{Bayes}}(x) = \frac{1}{\sigma_{\text{Bayes}} \sqrt{2\pi}} e^{-\frac{(x-\bar{x}_{\text{Bayes}})^2}{2\sigma_{\text{Bayes}}^2}}$$

$$\text{其中，} \sigma_{\text{Bayes}}^2 = \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 + \sigma_2^2}；\bar{x}_{\text{Bayes}} = \sigma_{\text{Bayes}}^2 \left(\frac{\bar{x}_1}{\sigma_1^2} + \frac{\bar{x}_2}{\sigma_2^2} \right)。$$

上文即贝叶斯融合方法的原理，也是文献[3]提出的卡尔曼融合改进方法。

场景 1

2 个粒子滤波器结果相同，模糊程度不同。

设某变量 t 时刻状态为 0，其后验概率密度服从 $N(0,1)$ 分布，2 个滤波器粒子数相同，滤波器 1 结果为 $N(1,1.1)$ ，滤波器 2 结果为 $N(1,1.8)$ 。粒子数分别取 200、5 000。仿真结果见表 1。

表 1 仿真结果对比 1

指标	粒子数	真实分布	滤波器 1	滤波器 2	卡尔曼方法	贝叶斯方法	本文方法
均值	200	0	0.989 94	0.996 73	0.994 87	0.991 81	0.990 65
方差	200	1	1.087 00	1.797 00	0.928 06	0.928 06	0.623 51
均值	5 000	0	1.007 70	1.048 80	1.037 60	1.019 00	1.010 20
方差	5 000	1	1.109 00	1.802 00	0.945 95	0.945 95	0.461 90

由表 1 可知，当 2 个滤波器均值相同、方差不同时，本文方法融合后方差最小，效果较标准卡尔曼滤波、贝叶斯方法更优。文献[7]指出，在不丧失粒子多样性的前提下，均值越接近真实值、方差越小、粒子云越收敛，则样本的代表性越好、运算效率越高。本文方法结果随着粒子数增加更优，而其余 2 种方法效果基本不变。

场景 2

2 个粒子滤波结果互相矛盾，模糊程度相同。

设某变量 t 时刻状态为 0，后验概率密度服从 $N(0,1)$ 分布，2 个滤波器粒子数相同，滤波器 1 结果为 $N(1,1.8)$ ，滤波器 2 结果为 $N(3,1.8)$ 。粒子数分别取 200、5 000。仿真结果见表 2。

表 2 仿真结果对比 2

指标	粒子数	真实分布	滤波器 1	滤波器 2	卡尔曼方法	贝叶斯方法	本文方法
均值	200	0	1.010 8	2.983 0	1.997 2	1.996 5	2.008 20
方差	200	1	1.800 0	1.800 4	1.268 9	1.268 9	0.901 96
均值	5 000	0	0.970 4	3.001 0	1.992 6	1.979 1	1.978 00
方差	5 000	1	1.803 0	1.815 0	1.279 3	1.279 3	0.703 30

由表 2 可知，2 个结果矛盾模糊程度相同的滤波器融合时，卡尔曼方法和贝叶斯方法结果很接近，而本文方法的融

合结果方差更小，效果最好。

场景 3

2 个粒子滤波器结果互相矛盾，模糊程度不同。

设某变量 t 时刻状态为 0，其后验概率密度服从 $N(0,1)$ 分布，2 个滤波器粒子数相同，滤波器 1 结果服从 $N(1,1.1)$ ，滤波器 2 为 $N(3,1.8)$ 。粒子数分别取 200、5 000。仿真结果见表 3。

表 3 仿真结果对比 3

指标	粒子数	真实分布	滤波器 1	滤波器 2	卡尔曼方法	贝叶斯方法	本文方法
均值	200	0	0.993 89	2.988 80	2.454 00	1.528 70	1.153 00
方差	200	1	1.092 00	1.806 00	0.932 01	0.932 01	0.825 12
均值	5 000	0	1.004 50	3.025 30	2.490 00	1.539 80	1.126 00
方差	5 000	1	1.098 00	1.803 00	0.930 67	0.930 67	0.667 93

由表 3 可知，本文方法融合结果较标准卡尔曼滤波、贝叶斯方法均值更接近变量真实值，方差更小。由此可知，在多个滤波器结果之间处于矛盾、模糊程度不同的多种情况下，本文方法融合得到的结果均能更好地向正确的滤波器结果收敛、方差减小、样本更具有代表性，同时模糊程度随着粒子数的增加更低，标准卡尔曼滤波、贝叶斯方法则效果不变。

4.2 目标跟踪实验

该实验初始条件如下：

系统模型为：

$$x_t = x_{t-1} + v_{t-1}T + \frac{1}{2}a_{t-1}T^2 + \omega_t \quad \omega_t \sim N(0,0.5), T=1 \text{ s}$$

其中， $v_{t-1} = \sin(\beta\pi(t-1))$ ； $a_{t-1} = v_{t-1}' = \beta\pi\cos(\beta\pi(t-1))$ ； $\beta=0.4$ 。

$x(0)=10$ 采用 2 个传感器，其观测模型分别为：

$$z_{1,t} = \begin{cases} x_t + v_{1,0,t} & v_{1,0,t} \sim u([-20,20]), c_{1,t} = 0 \\ \frac{(x_t - 3)^2}{5} + v_{1,1,t} & v_{1,1,t} \sim N(0,1), c_{1,t} = 1 \\ \frac{x_t^2}{5} + v_{1,2,t} & v_{1,2,t} \sim N(0,3), c_{1,t} = 2 \end{cases}$$
$$z_{2,t} = \begin{cases} x_t + v_{2,0,t} & v_{2,0,t} \sim u([-20,20]), c_{2,t} = 0 \\ \frac{(x_t - 5)^2}{4} + v_{2,1,t} & v_{2,1,t} \sim N(0,1), c_{2,t} = 1 \end{cases}$$

其中， $u([-20,20])$ 为平均分布，持续时间 100 s，粒子数均为 200。2 个传感器观测模型中正常状态都是非线性观测模型，状态不恒定，其时间分布为：

$$\begin{aligned} t \sim (0 \ 20] \quad c_{1,t} &= 1, \quad c_{2,t} = 1 \\ t \sim (20 \ 40] \quad c_{1,t} &= 1, \quad c_{2,t} = 0 \\ t \sim (40 \ 90] \quad c_{1,t} &= 2, \quad c_{2,t} = 1 \\ t \sim (90 \ 100] \quad c_{1,t} &= 0, \quad c_{2,t} = 1 \end{aligned}$$

仿真过程如下：

在 100 s 时间内，传感器 1、传感器 2 按照状态分布来变换观测模型，分别用 DSmT 融合、卡尔曼融合 2 种方法来融合结果。当某传感器状态为 0 时，2 种方法停止融合，结果取自另一传感器。

表 4 是蒙特卡洛 100 次，不同时间段内 2 个传感器以及 2 种方法的平均误差。

表 4 各时间段的融合 RMSE 比较

结果来源	1 s~20 s	21 s~40 s	41 s~90 s	91 s~100 s	m
传感器 1	0.221 3	0.129 9	0.382 8	3.315 60	1.247 0
传感器 2	0.177 8	1.782 9	0.185 7	0.190 24	0.814 2
本文方法	0.110 7	0.129 9	0.172 9	0.190 24	0.156 2
卡尔曼方法	0.190 4	0.129 9	0.311 6	0.190 24	0.250 6

各方法的轨迹跟踪、本文方法与卡尔曼方法的融合

RMSE 对比、融合时间对比见图 1~图 3。




图 1 2 种方法的融合轨迹对比




图 2 2 种方法的融合 RMSE 对比




图 3 2 种方法的融合时间对比

仿真结果表明：

(1) 卡尔曼滤波在 2 个传感器方差差别不大的时间段融合效果一般(见图 1 及图 3 中 $t \sim (40 \ 90]$ ，而本文方法效果在各时间段普遍好于卡尔曼方法，相对卡尔曼方法；在 $t \sim (0 \ 20]$ 时误差减少 41.9%； $t \sim (40 \ 90]$ 误差减少 44.5%，总平均误差减少 37.7%； $t \sim (20 \ 40] \cup (80 \ 100]$ 没有融合，结果取自同一传感器。

(2) 由于方法本质区别，本文方法融合时间要比卡尔曼方法长，前者时间随着粒子数增加快速增加，后者基本不变。但在一般应用中不需要大量的粒子数即可达到要求，在目标跟踪实验中，相对于一般应用如声纳探测(观测间隔时间 1 s~3 s)，约占观测间隔时间的 0.68%~2.04%，本文方法平均在每个时间点耗费时间为 20.4 ms，可以满足实际应用中实时融合的要求。

5 结束语

为提高多传感器融合结果的精度，本文将融合算法 DSmT 同粒子滤波理论相结合，提出一种新的多传感器数据融合方法，并运用到目标跟踪中。通过 2 个实验证明，本方法在多传感器数据融合中具有良好的性能。(下转第 184 页)