DOI: 10.7641/CTA.2015.40019

多步历史估计信息反馈多模型融合方法

申屠晗^{1†}, 薛安克¹, 骆吉安^{1,2}

(1. 杭州电子科技大学 通信信息传输与融合技术国防重点学科实验室, 浙江 杭州 310018;

2. 七一五研究所 声纳技术国防科技重点实验室, 浙江 杭州 310012)

摘要: 针对强机动和大观测误差下的目标跟踪问题, 传统低阶多模型融合方法存在估计精度较低、鲁棒性较差的 缺点; 高阶多模型融合方法面临计算量增大和保证实时性之间的矛盾. 为此本文针对一类多步稳健机动目标跟踪 问题提出一种基于历史估计信息反馈的多模型融合框架, 首先累积和反馈历史估计信息, 然后结合当前量测计算多 阶模型序列的似然函数, 最后得到贝叶斯后验融合结果. 同时结合粒子滤波构建了易于工程实现的粒子滤波历史反 馈多模型融合算法(PF-HFMM). 仿真表明, 与传统粒子滤波多模型算法相比, 本法显著提高了估计精度和鲁棒性. 关键词: 反馈融合; 多模型融合; 历史估计信息; 粒子滤波

中图分类号: TP273 文献标识码: A

Feedback multiple-stage historical estimating information multiple-model fusion method

SHEN Tu-han^{1†}, XUE An-ke¹, LUO Ji-an^{1,2}

(1. State Key Defense Laboratory of Information Transmission and Fusion Technology, Hangzhou Dianzi University,

Hangzhou Zhejiang 310018, China;

2. National Defense Science and Technology Key Laboratory of Sonar Technology,

715th Research Institute of China Shipbuilding Industry Corporation, Hangzhou Zhejiang 310012, China)

Abstract: When facing the target tracking problem with high maneuver as well as large observation error, traditional low order multiple-model fusion approach exposes the defects of degrading in estimating accuracy and robustness; high order multiple-model fusion approach confronts the dilemma between the increasing calculating assumption and the insurance of good real-time performance. To this end, we propose a multiple-model fusion scheme based on feeding back the historical estimating results to the problem of tracking a class of multiple-step robust maneuvering targets. First, we accumulate and feed back the historical estimation and the current observation, at last, obtain the Bayesian posterior fusion results. At the meanwhile, a particle filter historical feedback multiple-model (PF–HFMM) is constructed for the real application. The simulations show that, the proposed algorithm provides better results in fusion accuracy and robustness comparing to the traditional particle filter multiple model algorithm.

Key words: feedback fusion; multiple-model fusion; historical estimating information; particle filter

1 引言(Introduction)

在目标跟踪、系统监测、故障诊断等诸多信息融合领域,多模型融合方法(multiple-model methods, MM)是一种应用广泛的贝叶斯融合方法^[1-2].应用贝叶斯融合方法一般需要提供先验知识、模型和观测信息三大要素,但实际应用中模型信息不确定成为限制融合精度提高的一大瓶颈^[3].多模型融合方法正是针对模型不确定性所提出的,首先将目标系统建模成基

于多个模型假设的混合系统,然后进行并行贝叶斯滤 波,最后依据全概率定理对并行滤波结果进行融合^[3]. 理论上多模型融合方法在考虑完全假设树时具备最 优性;实际中考虑到计算规模的限制,学者们提出了 诸多次优方法,典型方法包括:1)静态多模型方法 (static MM, SMM)^[4];2) 广义伪贝叶斯方法(general pseudo Bayesian, GPB)^[1,5];3) 交互式多模型方法(interactive MM, IMM)^[6-7];4) 变结构多模型方法(varia-

Supported by National Natural Science Major Scientific Instrument Research Foundation of China (61427808), National Natural Science Foundation of China (61174024) and Opening Fund of Zhejiang Key Laboratory for Signal Processing (ZJKL-4-SP-OP2014-01).

收稿日期: 2014-01-09; 录用日期: 2014-09-25.

[†]通信作者. E-mail: hanshentu@hotmail.com; Tel.: +86 571-86873828.

国家自然科学基金重大仪器专项项目(61427808),国家自然科学基金项目(61174024),浙江省信号处理重点实验室开放基金项目(ZJKL-4-SP-OP2014-01)资助.

ble structure MM, VSMM)^[8-9], 等. 各类多模型方法 在不同情况下各具优势,例如: SMM计算简便适用于 弱机动目标等一些简单情况; GPB考虑了低阶马尔可 夫假设下全概率公式,因而适用于中等机动目标的跟 踪与估计; IMM的估计性能接近GPB2但计算规模接 近GPB1,费效比较高,适用范围类似于GPB方法; VSMM适用于高机动目标或大规模先验模型集的复 杂情况,通过在线辨识有效模型序列集达到控制计算 规模和提高融合精度的目的[4-9].为进一步提高多模 型方法的性能,学者们相继提出诸多改进算法,例如: 文献[10]针对复杂非线性情况将粒子滤波(particle filter, PF)引入多模型估计并结合IMM方法构建了PF-IMM方法,提高了多模型融合方法在非线性情况下的 估计性能; 文献[11]提出一种基于混合采样的多模型 粒子滤波算法,在基本保持融合性能的同时降低了计 算复杂度; 文献[12]提出一种在线辨识马尔可夫转移 概率矩阵的自适应交互式多模型算法,提高了系统的 收敛速度; 文献[13]提出一种最小熵反馈式变结构多 模型融合算法,利用在线反馈融合信息计算当前有效 模型序列集,提高了算法的估计精度和鲁棒性.

尽管学者们针对现有多模型融合方法的不足提出 诸多改进,但大多数都没有考虑如何有效利用历史估 计信息来提高算法性能.其原因是如果要考虑利用历 史估计信息则必须考虑高阶马尔可夫链,将使多模型 方法面临假设分支组合爆炸的困境.因此当目标突发 强机动,或者观测误差较大时,传统方法一般只能依 靠当前观测和上一周期的跟踪结果对目标模式和状 态进行跟踪估计,其估计精度和鲁棒性都受到较大限 制;如果直接考虑多阶模型序列则计算规模呈几何态 势增长.为此,本文首先在合理分析目标实际运动规 律的基础上提出一类"多步稳健"目标,并对其进行 数学描述;然后针对"多步稳健"目标提出一种基于 历史估计信息反馈的多模型融合框架(history feedback MM, HFMM). 首先对多步历史估计信息进 行在线积累和反馈,进而结合当前观测应用贝叶斯公 式得到所有可能的多阶多模型序列的似然函数;最后 在全概率公式下融合得到当前状态的后验估计结果. 同时,本文还结合粒子滤波器设计了易于工程实现的 粒子滤波历史反馈多模型融合算法(PF-HFMM).相 较于传统粒子滤波多模型算法(PF-IMM), 仿真实验 在两个不同场景下论证本法的优势.

2 问题描述(Problem formulation)

考虑如下目标系统:

$$x_k = f_{k-1,k}(x_{k-1}, m(k)) + v_k(m(k)), \qquad (1)$$

其中: $x_k 和 m(k)$ 分别表示系统在k时刻的状态向量和 有效模式(模型); $f_{k-1,k}(x_{k-1}, m(k))$ 表示系统从k-1到k时刻基于模型m(k)的状态转移函数; $v_k(m(k))$ 代 表未建模过程噪声, 一般假设 $v_k(m(k))$ 为高斯白噪 声. 假设模型m(k)取值于一个先验非空离散模型集 Ω = { m_1, m_2, \cdots, m_r }, 即 $m(k) \in \Omega$. 一般认为, 在两 个相继时刻目标系统的有效模型可以在属于 Ω 的不同 模型间进行动态切换, 因此可以将切换建模成马尔可 夫过程, 如果切换概率先验已知则进一步表示为

$$p_{i,j}(k) = p\{m(k) = m_j | m(k-1) = m_i\}.$$
 (2)

实际应用中,切换概率有时是完全已知的,而更多 情况下只知道很少甚至几乎不知道任何有关切换概 率的先验知识,本文仅考虑后者情况.

考虑如下观测模型:

$$z_k = g_k(x_k) + w_k, \tag{3}$$

其中: *z_k*表示*k*时刻的观测向量, *g_k*是该时刻的观测函数, *w_k*是零均值高斯白噪声.

多模型估计问题的目标就是基于先验知识和累积 到k时刻的全部观测值 $Z_k = \{z_1, z_2, \dots, z_k\}$ 得到目 标系统状态的后验估计 \hat{x}_k .

3 最优和传统次优融合方法(Optimal and traditional suboptimal fusion methods)

根据问题描述,将目标系统过程建模成马尔可夫 链. 在k时刻用m(k)表示系统有效模型,那么从0到k时刻,系统的有效模型序列可表示为 $M_l(k) = \{m(1), m(2), \cdots, m(k)\},$ 且这样的模型序列共存在 r^k 种不同的路径.因此,可利用全概率公式得到系统 的最优后验估计

$$\hat{x}_{k} = \sum_{l=1}^{r^{k}} \hat{x}_{l,k} p\{M_{l}(k) | Z_{k}\},$$
(4)

其中: r是先验模型数量, $\hat{x}_{l,k}$ 是基于模型序列 $M_l(k)$ 的后验估计, $p\{M_l(k)|Z_k\}$ 是该模型序列的后验概率. 具体来说, $\hat{x}_{l,k}$ 可以由模型序列匹配滤波器滤波得到, $p\{M_l(k)|Z_k\}$ 可利用贝叶斯公式递归算得

$$p\{M_{l}(k)|Z_{k}\} = \frac{1}{c}p\{z_{k}|M_{l}(k), Z_{k-1}\}p\{m(k)|M_{s}(k-1)\} \cdot p\{M_{s}(k-1)|Z_{k-1}\},$$
(5)

其中c是归一化常数.

式(4)-(5)给出了针对多模型估计问题的最优融 合框架.但在应用最优融合框架时显然至少存在如下 两点困境:1)最优方法要求考虑完全假设树,所以计 算规模将随模型序类阶数增加呈几何倍数增长;2)最 优方法要求批处理观测数据,属于离线计算方法,缺 乏实时性.因此,实际中一般不直接应用最优框架进 行融合估计.为此,不少学者提出各种次优实现算法. 经典算法包括GPB1算法、GPB2算法^[1]、IMM算 法^[6]等.GPB1算法只考虑一阶马尔可夫链,因此在每 一融合周期只需考虑一阶模型序列,而将更早的模型 序列做合并处理.相较于GPB1,GPB2算法则考虑了 二阶马尔可夫过程,因而在每一融合周期需考虑二阶 模型假设分支.IMM算法具有较高的费效比,因为该 算法是一种二阶近似算法,其计算规模接近GPB1.

讨论1 尽管在许多场景下应用经典算法(GPB, IMM等)能够得到不错的融合效果,但其中大多数都 不能克服"组合爆炸"困难,所以难以推广到高阶形 式.且在面对复杂问题时(如目标高机动或观测误差 较大等),经常存在如下矛盾:一方面,为提高精度需 要考虑模型序列的高阶形式;但另一方面,高阶形式 带来的计算规模往往呈几何级数增长.因此若要考虑 多阶模型序列,就必须解决计算规模爆炸的问题.

4 历史反馈多模型融合方法(History feedback multiple-model fusion approach)

为了在考虑高阶多模型序列的同时控制计算规模, 本文提出一种基于历史信息反馈的多模型融合方法. 为此需要解决两点问题:1)减少模型序列的组合数量; 2)实时反馈和利用历史估计信息对模型序列概率进 行估计.因此,首先提出一类"多步稳健"机动目标, 然后构造针对该类目标的反馈式融合框架,最后结合 粒子滤波器给出易于工程实现的PF-HFMM算法.

4.1 多步稳健机动目标(Multiple-step robust maneuvering target)

实际中,不同目标的机动模式特征,机动发生时间 和频率都各不相同,因此难以对所有机动特性一言以 蔽之.尽管如此,依然可以从逻辑上根据发生机动切 换的频率将机动目标分为两类.第一类目标机动模式 很不稳定,拥有很高的机动切换频率,即频繁改变其 机动模式,将这类目标称为"疯狂"目标.例如,做类 似布朗运动的目标即属于"疯狂"目标.欲对"疯 狂"目标进行融合估计,在理论和工程上都极具挑战, 本文暂不考虑.第二类目标虽然在机动模式特征和发 生机动的时间上各不相同,但共性是不频繁改变自身 的机动模式,换言之,当发生一次机动模式切换后,一 般会在一定时间内保持当前模式,将这类目标称为 "多步稳健"机动目标.下面通过定义进一步刻画一 类"*H*步稳健"机动目标的数学特性:

定义1 考虑任意H个相继离散时刻 $S = \{k - H + 1, k - H + 2, \dots, k\}, k \in \mathbb{N}, M(H)$ 是某个与S相对应的模型序列, $M(H) = \{m(k - H + 1), m(k - H + 2), \dots, m(k)\}$.用 $\delta(m(t)) \in \{0, 1\}, t \in S$ 表征模型m(t)在t时刻是否发生机动模式切换, $\delta(m(t)) = 1$ 表示发生机动模式切换, $\delta(m(t)) = 0$ 表示未发生机动模式切换.如果满足条件1,称M(H)是一个"H步稳健"模型序列.

条件1

s.t.
$$\delta(m(t_1)), \delta(m(t_2)) \in \{0, 1\},\$$

if
$$\delta(m(t_1)) = 1$$
, then $\delta(m(t_2)) = 0$,
 $t_1, t_2 \in S$,
 $t_1 \neq t_2$, (6)

定义2 针对问题描述中的机动目标,考虑任意 H个相继离散时刻 $S = \{k - H + 1, k - H + 2, \dots, k\}, k \in \mathbb{N}, 其所有 H 阶多模型序列可表示为 <math>M = \{M_{l,k}^{H}\}, l = 1, 2, \dots, r^{H}, r^{H} \rightarrow H$ 阶模型序列总数. 对任意 $M_{l,k}^{H} \in M,$ 若不是定义1所规定的"H步稳 健"多模型序列,则 $p(M_{l,k}^{H}) = 0,$ 并称该目标为"H 步稳健"目标.

4.2 历史反馈多模型融合框架 (History feedback multiple-model fusion scheme)

针对定义2中提出的"H步稳健"机动目标,对传统多模型序列集进行合理简化并通过历史估计信息的积累和反馈提出一种多模型融合框架.

根据定义1和2将式(4)做如下改写:

$$\hat{x}_{k}^{H} = \sum_{l=1}^{N(H)} \hat{x}_{l,k}^{H} p\{M_{l}^{H}(k) | Z_{k}\},$$
(7)

$$N(H) = r[(H-1)(r-1) + 1],$$
(8)

其中: N(H)是所有可能的H步稳健模型序列的个数, \hat{x}_{k}^{H} 是基于最近H周期信息目标在k时刻的状态估 计, $M_{l}^{H}(k) = \{m_{l}(k - H + 1), \cdots, m_{l}(k)\}$ 代表最 近H周期的稳健模型序列, $\hat{x}_{l,k}^{H}$ 是基于模型序列 $M_{l}^{H}(k)$ 目标在k时刻的状态估计.根据式(8)可知,相 较于H步完全假设树中的模型序列,稳健模型序列的 数量要少得多, 即 $N(H) << r^{H}$.

显然直接利用方程(7)可以设计批处理式的融合估 计方法. 尽管批处理方法理论上具有较高的估计精度, 但是由于要求批处理观测信息降低了算法的实时性. 为此,将对方程(7)进一步分析和改造以实现序贯处理 的融合估计方法.

为方便叙述,将"*H*步稳健"机动目标融合估计 问题重新整理如下:假设在k - 1时刻,最近的H - 1步历史估计{ $\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}$ }和先验模 型集 $\Omega = \{m_1, m_2, \cdots, m_r\}$ 已知,问题为如何结合 当前观测 z_k 对目标的当前状态进行估计.

针对上述问题将式(7)改写如下:

$$\hat{x}_{k}^{H} \approx \sum_{l=1}^{N(H)} \hat{x}_{l,k}^{H} p\{M_{l}^{H}(k)|z_{k}, \hat{x}_{k-H+1}^{H}, \\ \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}\}.$$
(9)

利用贝叶斯公式可以将*H*步模型序列的后验概率 计算如下:

$$p\{M_k^H | Z_k, \hat{x}_{k-H+1}^H, \hat{x}_{k-H+2}^H, \cdots, \hat{x}_{k-1}^H\} = p\{M_l^{H-1}(k-1), m_l(k) | z_k, \\ \hat{x}_{k-H+1}^H, \hat{x}_{k-H+2}^H, \cdots, \hat{x}_{k-1}^H\} =$$

$$\frac{1}{c}p\{z_{k}|M_{l}^{H-1}(k-1), m_{l}(k), \\
\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}\} \cdot \\
p\{M_{l}^{H-1}(k-1)|\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}\} = \\
\frac{1}{c}p\{z_{k}|m_{l}(k), \hat{x}_{k-1}^{H}\}p\{\hat{x}_{k-1}^{H}|m_{l}(k-1), \hat{x}_{k-2}^{H}\} \cdot \\
p\{M_{l}^{H-2}(k-2)|\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-2}^{H}\} = \\
\vdots \\
\frac{1}{c}p\{z_{k}|m_{l}(k), \hat{x}_{k-1}^{H}\}p\{\hat{x}_{k-1}^{H}|m_{l}(k-1), \hat{x}_{k-2}^{H}\} \cdots \\
p\{\hat{x}_{k-H+2}^{H}|m_{l}(k-H+2), \hat{x}_{k-H+1}^{H}\}, \quad (10)$$

c是归一化常数, $p\{z_k|m_l(k), \hat{x}_{k-1}^H\}$ 是模型相关似然 函数, $p\{\hat{x}_{k-i}^H|m_l(k-1), \hat{x}_{k-i-1}^H\}$, $i=1, \cdots, H-2$ 代 表两个相继历史时刻间的模型匹配概率.

构建HFMM融合方法框架(见图1):

1) 在k时刻的起始阶段,反馈积累最近H - 1时刻的状态估计结果 $\{\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}\}$ 和当前时刻的观测值 z_k ;

2) 然后将以最近H周期的累积信息反馈至模型
 序列概率估计模块,并根据式(10)计算所有可能的稳
 健模型序列的似然函数;

3) 进而将模型序列的概率估计结果反馈至多模型估计器并根据式(9)得到当前状态的估计结果;

4) 最后, 在输出当前状态估计结果的同时将其进行反馈作为*k* + 1时刻新的累积信息.



图 1 HFMM融合估计框架

Fig. 1 Fusion framework of HFMM

4.3 粒子滤波历史反馈多模型算法(PF-HFMM algorithm)

理论上将合适的滤波器嵌入上述HFMM框架便可 构造易于工程实现的HFMM算法.本文选择粒子滤 波器(PF)作为内嵌滤波算法是由于它具备以下优势: 1) PF适用于非线性非高斯系统^[14],所以适用面较宽; 2) PF通过粒子求和形式获得估计结果,方便表达为混 合估计的形式,所以适合于处理多模型估计中模型序列的假设分支与合并^[15].例如,针对"*H*步稳健"机动目标构建HFMM算法,需要每一融合估计周期考虑N(H) = r[(H-1)(r-1)+1]种不同的模型序列,所以一般需内嵌N(H)个并行滤波器.由于粒子滤波器可以表达成混合估计加权形式,所以只需内嵌一个滤波器即满足需求.具体来说,可通过粒子分组对每个模型序列下的后验分布做出独立估计,最后将所有模型序列下的估计加权融合即可.PF-HFMM算法具体实现如下:

k - 1时刻:

1) 积累最近H - 1个周期的融合估计结果 $\{\hat{x}_{k-H+1}^{H}, \hat{x}_{k-H+2}^{H}, \cdots, \hat{x}_{k-1}^{H}\}$ 和当前观测 z_{k} ;

2) 考虑N(H) = r[(H-1)(r-1)+1]个不同模 型序列 $\{M_l^H(k)\}, l = 1, \dots, N(H),$ 同时对每个模 型序列分配n个粒子, 共 $n \cdot N(H)$ 个粒子;

3) 确定k时刻滤波前 $n \cdot N(H)$ 个粒子的状态,如 果是初始周期则根据先验分布对粒子进行采样;如果 不是初始周期,则从上一个融合周期继承粒子状态 $\tilde{x}^{i}_{l,k-1}, i = 1, \dots, n, l = 1, \dots, N(H).$

k时刻:

1) 利用状态转移方程对每个粒子的状态进行一步预测:

$$\tilde{x}_{l,k}^{i} = f_{k,k-1}(\tilde{x}_{l,k-1}^{i}, m_{l}(k)) + v_{k}(m_{l}(k)), \quad (11)$$

其中m_l(k)是模型序列M^H_l(k)中最后一个模型.

2) 根据方程(10)可以计算每个粒子的权重 $w_{l,k}^i$, $i = 1, \dots, n, l = 1, \dots, N(H)$:

$$w_{l,k}^{i} \propto p\{z_{k}|m_{l}(k), \tilde{x}_{l,k}^{i}\}p\{\hat{x}_{k-1}^{H}|m_{l}(k-1), \hat{x}_{k-2}^{H}\}\cdots p\{\hat{x}_{k-H+2}^{H}|m_{l}(k-H+2), \hat{x}_{k-H+1}^{H}\},$$
(12)

$$p\{z_k|m_l(k), \tilde{x}_{l,k}^i\} = p\{z_k|\tilde{x}_{l,k}^i\},$$
(13)

$$p\{\hat{x}_{k-d}^{H}|m_{l}(k-1),\hat{x}_{k-d-1}^{H}\} = p\{\hat{x}_{k-d}^{H}|f_{k,k-1}(\hat{x}_{k-d-1}^{H},m_{l}(k)) + v_{k}(m_{l}(k))\}.$$
(14)

3) 归一化粒子权重:

$$\bar{w}_{l,k}^{i} = \frac{w_{l,k}^{i}}{\sum_{l=1}^{N(H)} \sum_{i=1}^{n} w_{l,k}^{i}}.$$
(15)

4) 融合得到当前状态估计结果:

$$\hat{x}_{k}^{H} = \sum_{l=1}^{N(H)} \sum_{i=1}^{n} \bar{w}_{l,k}^{i} \cdot \tilde{x}_{l,k}^{i}.$$
 (16)

5) 对当前粒子进行重要性重采样^[14]:

$$\{\hat{x}_{l,k}^i\} = \text{resample}\{\tilde{x}_{l,k}^i\},\$$

 $l = 1, \cdots, N(H), \ i = 1, \cdots, n, \ k = k+1.$

14

讨论 2 目前提出的HFMM方法还没有考虑不同 场景中H值(模型序列阶数)的设计问题.实际中可能 存在以下问题:一方面,若被跟踪目标足够稳健,适当 增大H值将有利于提高融合效果,但同时也带来更大 的计算负担;另一方面,若被跟踪目标欠稳健,过大的 H值反而可能降低融合鲁棒性.因此,未来工作可针 对不同场景下HFMM融合效果、鲁棒性和计算负担的 权衡问题研究H值的自适应优化机制.

5 仿真分析(Simulation analysis)

仿真分析将本文提出PF-HFMM算法与PF-IMM^[7,10]算法应用于两个不同稳健机动目标跟踪场景,进行500次蒙特卡洛仿真对比,两算法粒子数均为1600, PF-HFMM中H值为5.考虑跟踪二维笛卡儿坐标系下一高机动飞行目标,其运动方程如下:

$$x(k) = F \cdot x(k-1) + D \cdot a(k), \qquad (17)$$

其中: $x(k) = [x_p(k) x_v(k) y_p(k) y_v(k)]^T$ 表示k时 刻目标状态向量,各分量依次为目标在x与y坐标轴上 的位置与速度分量; $a(k) = [a_x(k) a_y(k)]^T$ 为k时刻 输入加速度模型矢量,其中分量表示x与y坐标轴上的 加速度分量, $a(k) \in \Omega$. 先验模型集 Ω 包括以下21个 模型,各模型用二维向量表示,各分量分别表示沿x与 y轴方向的加速度分量(m/s²):

$$m_{1} = \begin{bmatrix} 0 & 0 \end{bmatrix}^{\mathrm{T}}, \ m_{2,3} = \begin{bmatrix} 0 & \pm 10 \end{bmatrix}^{\mathrm{T}},$$
$$m_{4,5} = \begin{bmatrix} \pm 10 & 0 \end{bmatrix}^{\mathrm{T}}, \ m_{6-9} = \begin{bmatrix} \pm 10 & \pm 10 \end{bmatrix}^{\mathrm{T}},$$
$$m_{10,11} = \begin{bmatrix} 0 & \pm 20 \end{bmatrix}^{\mathrm{T}}, \ m_{12,13} = \begin{bmatrix} \pm 20 & 0 \end{bmatrix}^{\mathrm{T}},$$
$$m_{14-17} = \begin{bmatrix} \pm 20 & \pm 20 \end{bmatrix}^{\mathrm{T}},$$
$$m_{18,19} = \begin{bmatrix} 0 & \pm 40 \end{bmatrix}^{\mathrm{T}}, \ m_{29,21} = \begin{bmatrix} \pm 40 & 0 \end{bmatrix}^{\mathrm{T}}.$$

F与D为如下定常矩阵:

$$F = \begin{pmatrix} 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{pmatrix}, \ D = \begin{pmatrix} 1 & 0 \\ 0.5 & 0 \\ 0 & 1 \\ 0 & 0.5 \end{pmatrix},$$

其中T = 1s为系统采样周期.

系统观测方程如下:

$$Z(k) = Y(k) + W(k),$$
 (18)

其中: $Y(k) = [x_{p}^{o}(k) y_{p}^{o}(k)]^{T}$ 是传感器在k时刻对目标位置的观测, $W(k) = [w_{x}(k) w_{y}(k)]^{T}$ 为观测误差向量,各分量相互独立且为服从协方差矩阵为R的零均值高斯随机过程.

5.1 场景 1(Scenario 1)

考虑一稳健高机动目标,初始状态向量为

$$x(1) = [10^4 \text{ m } 150 \text{ m/s} 10^4 \text{ m } 250 \text{ m/s}]^{\mathrm{T}},$$

连续飞行150 s, 采样周期为1 s, 其间发生3次机动: 第1次发生于第31至第80 s为较弱机动, 加速度a(k)= $[10 \text{ m/s}^2 - 10 \text{ m/s}^2]$;第2次发生于第81至第119 s, 加速度 $a(k) = [-30 \text{ m/s}^2 30 \text{ m/s}^2]^T$ 为强机动;第3 次为较强机动,发生于第120 s至第150 s, 加速度a(k)= $[20 \text{ m/s}^2 20 \text{ m/s}^2]^T$,其余时间做匀速直线运动, 机 动切换时刻为第31 s, 81 s和120 s. 目标轨迹如图2所 示, 加速度绝对值变化如图3所示.





Fig. 3 The absolute value of the acceleration

场景1中主要考察目标机动模式切换对算法性能的影响,为此设定较小观测误差: $R = \text{diag}\{25^2 \text{ m}^2, 25^2 \text{ m}^2\}$,得到位置跟踪误差绝对值如图4所示,速度跟踪误差绝对值如图5所示.







16

图 5 速度跟踪误差绝对值比较 Fig. 5 Comparison of the absolute values of speed estimating error

对照图4和图3可知,当目标处于匀速直线运动(0s~30s)或者机动较弱时(31s~80s),本文提出的PF-HFMM算法和PF-IMM算法在位置跟踪精度上相近, PF-HFMM算法略有优势;当目标处于较强(120s~150s)和强机动时(81s~119s),PF-HFMM算法的位置跟踪精度明显高于PF-IMM算法,且机动越强优势越明显.图5表明,当目标处于匀速直线运动时,两算法的速度跟踪误差接近,当目标发生机动时PF-HFMM算法的速度跟踪误差小于PF-IMM算法,且机动越强PF-HFMM的优势越明显.

进一步分析实验结果:1)本文考虑的多阶稳健机 动目标,机动模式具有一定的历史延续性.传统 PF-IMM算法没有考虑累积和利用历史估计信息, 仅依靠 当前(一阶)估计信息判断各个模型的概率.当前估计 信息只能反映目标当前状态的估计结果,不能反映目 标的历史模式变化信息. 所以当目标处于强机动模式 时,受到算法本身估计精度的限制,传统PF-IMM算 法很难基于一阶估计信息对目标的真实模式做出准 确判断,从而估计性能下降.本文提出的PF-HFMM 算法,充分利用了历史估计信息来分析目标机动模式 的变化规律,提高了对目标真实模式的判别能力,从 而提升了算法的融合估计性能. 2) PF-HFMM算法的 核心是通过历史信息反馈来提高对目标真实模式的 估计能力,由于运动模式直接影响目标高阶运动特性 (速度、加速度),所以算法在提高速度估计精度方面的 优势更加明显(对比图4和图5).

5.2 场景 2(Scenario 2)

本场景中被跟踪目标运动特性与场景1中相同,不同点在于笔者进一步考察大观测误差对算法性能的影响.为此设定较大观测误差: $R = \text{diag}\{150^2 \text{ m}^2, 150^2 \text{ m}^2\}$,其标准差大小为场景1中标准差的6倍,且已达到并超过目标最大加速度的数量级.实验得到位置跟踪误差绝对值如图6所示,速度跟踪误差绝对值如图7所示.图6表明不管目标是否发生机动,PF-HFMM算法的位置估计精度都明显优于PF-IMM算

法.图7说明目标机动较弱时,两算法速度估计误差接 近,但目标机动变强时,PF-HFMM算法优势变明显. 进一步分析实验结果:1)场景2中,由于观测噪声水平 达到并超过目标加速度的数级,导致目标真实模式被 淹没于大噪声背景中,无论何种算法都较难对目标的 真实模式做出准确判断,所以相较于场景1中的结果 PF-HFMM在速度估计方面的优势被稍微弱化.尽管 如此,当目标发生强机动时,PF-HFMM算法在速度估 计精度方面依然保持明显优势.2)虽然场景2中很难 对目标的真实模式进行准确判断,PF-HFMM算法依 然可以通过反馈历史估计信息来分析目标的各种模 式序列在位置估计方面的质量,对高质量的模式序列 赋予更高的似然概率,提高PF-HFMM算法对大噪声 的抵抗能力,因此此场景中该算法的位置估计精度在 大多数时刻都高于传统PF-IMM算法.





综合两个场景的实验分析结果: PF-HFMM算法 比传统PF-IMM算法更适用于复杂环境下的稳健高机 动目标跟踪问题, 无论是目标处于强机动模式还是观 测误差较大的情况, PF-HFMM算法都表现出更高的 估计精度和更强的鲁棒性. 同时从表1可知, 由于利用 了多步历史信息, 本实验中的5阶PF-HFMM算法在 获得更高跟踪精度的同时将比传统低阶多模型算法 (PF-IMM)耗费稍大的计算量.

	表1	两算法相对运行时	间
Table 1	Relative	computing time of t	wo algorithms

算法	PF-IMM	PF-HFMM
相对运行时间	1	1.861

6 结论(Conclusions)

传统低阶多模型融合方法没有考虑累积和反馈利 用历史估计信息,因而在面对目标强机动和大观测误 差时存在估计精度下降和鲁棒性不足的问题.为此, 本文提出多阶稳健机动目标的概念,通过构建多步历 史信息反馈多模型融合估计方法(HFMM)有效解决了 历史估计信息的反馈利用问题,从而提升对当前机动 模式的估计精度,进一步在HFMM框架下提出PF-HFMM算法解决该方法的工程应用问题.仿真表明: 与传统PF-IMM算法相比,PF-HFMM算法融合估计 精度更高、鲁棒性更强.

参考文献(References):

- BAR-SHALOM Y, LI X R. Estimation and Tracking: Principles, Techniques, and Software [M]. Boston, MA: Artech House, 1998.
- [2] 鉴福升, 徐跃民, 阴泽杰. 改进的多模型粒子滤波机动目标跟踪算法 [J]. 控制理论与应用, 2010, 27(8): 1012 1016.
 (JIAN Fusheng, XU Yuemin, YIN Zejie. Enhanced multiple model particle filter for maneuvering target tracking [J]. Control Theory & Applications, 2010, 27(8): 1012 1016.)
- [3] LI X R, JILKOV V P. Survey of maneuvering target tracking-part V: multiple-model methods [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(4): 1255 – 1321.
- [4] LAINIOTIS D G. Optimal adaptive estimation: structure and parameter adaptation [J]. *IEEE Transactions on Automatic Control*, 1971, 16(2): 160 170.
- [5] JILKOV V P, LI X R. Online Bayesian estimation of transition probabilities for Markovian jump systems [J]. *IEEE Transactions on Signal Processing*, 2004, 52(6): 1620 – 1630.
- [6] QU H Q, PANG L P, LI S H. A novel interacting multiple model algorithm [J]. Signal Processing, 2009, 89(11): 2171 – 2177.
- [7] JO K, CHU K, SUNWOO M. Interacting multiple model filter-based sensor fusion of GPS with in-vehicle sensors for real-time vehicle

positioning [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(1): 329 – 343.

- [8] LI X R, BARSHALOM Y. Multiple-model estimation with variable structure [J]. *IEEE Transactions on Automatic Control*, 1996, 41(4): 478 – 493.
- [9] LI X R, JILKOV V P, RU J F. Multiple-model estimation with variable structure part VI: expected-mode augmentation [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(3): 853 – 867.
- [10] MCGINNITY S, IRWIN G W. Multiple model bootstrap filter for maneuvering target tracking [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(3): 1006 – 1012.
- [11] 王晓, 韩崇昭. 基于混合采样的多模型机动目标跟踪算法 [J]. 自动 化学报, 2012, 38(8): 1 – 5.
 (WANG Xiao, HAN Chongzhao. A multiple method filter for maneuvering target tracking based on composite sampling [J]. Acta Automatica Sinica, 2012, 38(8): 1 – 5.)
- [12] 黄鹤, 王小旭, 赵春晖, 等. 基于后验信息修正的自适应交互式多模型跟踪算法 [J]. 西北大学学报, 2011, 29(6): 829 833.
 (HUANG He, WANG Xiaoxu, ZHAO Chunhui, et al. A better adaptive IMM algorithm based on a posterior information modification [J]. Journal of Northwestern Polytechnical University, 2011, 29(6): 829 833.)
- [13] 申屠哈, 彭冬亮, 薛安克. 最小熵反馈式变结构多模型融合算法 [J]. 控制理论与应用, 2013, 30(3): 372 – 378.
 (SHEN Tuhan, PENG Dongliang, XUE Anke. Minimum entropy and feedback structure based algorithm for variable structure multi-model fusion [J]. Control Theory & Applications, 2013, 30(3): 372 – 378.)
- [14] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking [J]. *IEEE Transactions on Signal Processing*, 2002, 50(2): 174 – 188.
- [15] DOUCET A, GORDON N, KRISHNAMURTHY V. Particle filters for state estimation of jump Markov linear systems [J]. *IEEE Transactions on Signal Processing*, 2001, 49(3): 613 – 624.

作者简介:

申屠哈 (1984-), 男, 博士, 讲师, 目前研究方向为目标跟踪、反 馈融合、信息融合, E-mail: hanshentu@hotmail.com;

薛安克 (1957-), 男, 博士, 教授, 博士生导师, 目前研究方向为信息融合、鲁棒控制、优化调度, E-mail: akxue@hdu.edu.cn;

骆吉安 (1983-), 男, 博士, 讲师, 目前研究方向为目标定位、信息融合、信息处理, E-mail: luojian@hdu.edu.cn.