

文章编号: 1001-0920(2013)08-1226-05

基于STC-IMM结构的自适应多模型跟踪算法

周政, 刘进忙, 李振兴

(空军工程大学防空反导学院, 西安 710051)

摘要: 针对机动目标跟踪问题, 基于转换时间条件交互多模型(STC-IMM)结构, 提出一种转换概率自适应的STC-AIMM算法. 该算法根据滤波器收敛时间预设了模型转换时间条件, 保证了滤波器对目标后验状态的合理逼近, 同时通过模型转换概率的自适应算法实现了模型与目标运动模式的实时最优匹配. 理论和仿真分析结果表明: 相比交互多模型(IMM)算法和STC-IMM算法, 该算法能够发挥滤波器最优性能, 实现模型概率的优化分配, 对目标不同强度的机动具有良好的适应性、跟踪稳定性和更高的跟踪精度.

关键词: 机动目标跟踪; 多模型; 转换时间条件; 转换概率; 自适应估计

中图分类号: TP953

文献标志码: A

Adaptive multiple-model tracking algorithm based on STC-IMM structure

ZHOU Zheng, LIU Jin-mang, LI Zhen-xing

(Institute of Air Defense and Anti-missile, Air Force Engineering University, Xi'an 710051, China. Correspondent: ZHOU Zheng, E-mail: xmhs_01@163.com)

Abstract: An interacting multiple-model algorithm with switch time conditions based on adaptive transition probabilities is proposed for tracking maneuvering targets, which ensures that the filter approximates target posterior state reasonably by presetting switch time conditions of the model. The model can match the target motion well in real time by using transition probabilities adaption algorithm. The theoretic and simulation analysis show that the proposed algorithm can help the filter achieving optimal performance, make the model probability more reasonable and track the target more accurately than IMM and STC-IMM algorithms. At the same time, it performs well on the stability and adaption.

Key words: maneuvering target tracking; multiple-model; switch time conditions; transition probabilities; adaptive estimation

0 引言

机动目标跟踪问题是目标跟踪领域的一个难题, 目标机动方式和机动时间对于观测方的不确定性是影响机动目标跟踪精度的主要因素. 传统的单模型跟踪算法难以同时保证稳态跟踪精度和对目标机动的快速响应能力^[1]. 目前, 解决这一问题的主要方法是基于跳变Markov系统的多模型方法^[2], 其中交互多模型(IMM)方法因为在跟踪性能和计算量上获得了较好的平衡^[3-4]而被广泛应用. 然而, IMM算法中采用实时交互的状态合并方法, 各模型滤波过程中采用交互后的状态作为滤波初始状态, 滤波器收敛过程会受到其他模型滤波状态的干扰, 因此滤波算法并不能发挥最优性能.

基于semi-Markov过程的多模型方法考虑了模型的驻留, 更有利于滤波算法的收敛, 具有解决这一问题的潜力. 文献[5]和文献[6]分别提出了sojourn-time dependent Markov IMM(STDM-IMM)算法和semi-Markov IMM(SM-IMM)算法, 认为模型驻留时间服从某一随机分布, 但是算法仍然采用实时合并的方法减少模型假设, 限制了滤波算法性能的发挥; 文献[7]提出了LCMT算法, 采用滑窗修剪方法来减少模型假设, 但是相比SM-IMM算法, 该方法降低了多模型算法的跟踪精度.

2010年, Daniel等^[8]提出了转换时间条件交互多模型(STC-IMM)结构, 这种结构强制模型驻留固定的时间后再发生转换, 产生了模型驻留模式分支和模

收稿日期: 2012-03-19; 修回日期: 2012-09-17.

基金项目: 国家自然科学基金青年基金项目(61102109); 陕西省自然科学基金项目(2010JM8013).

作者简介: 周政(1985-), 男, 博士生, 从事目标跟踪技术的研究; 刘进忙(1958-), 男, 教授, 博士生导师, 从事雷达数据处理、多传感器信息融合等研究.

型转换模式分支, 其中模型驻留模式的出现有利于滤波算法免受其他模型状态的干扰, 实现对目标状态的最优估计. 但是STC-IMM算法中采用固定的模型转换概率, 限制了算法性能的发挥.

针对以上问题, 借鉴STC-IMM算法结构, 本文提出一种模型转换概率自适应多模型算法(STC-AIMM), 基于模式似然函数和权值给出了STC-IMM的模型转换概率计算方法, 从理论和仿真两个方面分析了该算法在目标跟踪中的应用优势.

1 STC-IMM 算法分析

STC-IMM算法中模型转换方式是在模型 j 转换到模型 i 后强制模型 i 驻留固定时间 $\beta^{ij}T_0$, 经过驻留时间后, 模型 i 才能发生模型转换. 图1是一个由两模型组成的STC-IMM结构图, 其中 $\beta^{12} = 2, \beta^{21} = 3$.




图1 STC-IMM 结构图

从图1可以看出, STC-IMM结构中模型出现了驻留模式和转换模式, 模式合并(图1标记处)仅发生在同一模型的最高级驻留模式和转换模式之间, 避免了不同模型状态在滤波过程中相互干扰, 从而使滤波器能够对目标状态进行最优近似. 在此基础上确定的模型似然函数也是比较合理的. STC-IMM算法模型模式(并行滤波器)的总数为

$$N = M + \sum_{i=1}^M \sum_{j=1, j \neq i}^M \beta^{ij}, \quad (1)$$

其中 M 是模型数量(转换模式数量).

STC-IMM算法包含两个重要的设计参数: 模型驻留时间和模型转换概率. 选取较小的 β^{ij} 可使算法在模型转换瞬间的鲁棒性更强^[8], 但是由于 β^{ij} 与模式状态合并时刻紧密相关(见图1), 如果状态合并发生在滤波器收敛之前, 则滤波器的性能会受到较大影响; 选取较大的 β^{ij} 不仅降低了算法模型转换瞬间的鲁棒性, 而且需要大量的滤波器并行工作, 增加了算法的计算量, 并且当 β^{ij} 大于滤波器收敛时间时, 对跟

踪性能的改善将很小^[8]. 模型的转换概率直接影响不同模型的权值分配, 理想的情况应是通过模型转换概率的调整增大匹配模型权重, 减小失配模型权重. 由于目标运动模式是时变的, 采用先验确定的模型转换概率显然会降低算法适应能力和跟踪精度.

本文在折衷选取 β^{ij} 兼顾模型匹配滤波器收敛时间和算法鲁棒性的同时, 采用模型转换概率自适应算法, 通过调整高低概率模型转换概率的方法来达到提高算法跟踪性能的目的.

2 基于STC-IMM结构的自适应多模型跟踪算法

假设模型的未知转换概率矩阵为 $\Pi = [\pi_1, \pi_2, \dots, \pi_M]^T$, 其中 $\pi_i = [\pi_{i1}, \pi_{i2}, \dots, \pi_{iM}]^T$ 且服从Dirichlet分布, 模型模式概率为

$$\mathbf{w}_k^{\text{mode}} = [w_k^{T_i}, w_k^{s_{ij}^1}, \dots, w_k^{s_{ij}^{\beta^{ij}}}]^T.$$

其中: T_i 和 s_{ij}^l 分别为模型 i 的转换模式和驻留模式, $w_k^{T_i} = P\{T_i(k) | \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\}$, $w_k^{s_{ij}^l} = P\{s_{ij}^l(k) | \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\}$, $\bar{\Pi}_{k-1}$ 为 $k-1$ 时刻 Π 的估计值, \mathbf{Z}^{k-1} 为 k 时刻以前的观测集合. 模型模式似然值为

$$\Lambda_k^{\text{mode}} = [\Lambda_k^{T_i}, \Lambda_k^{s_{ij}^1}, \dots, \Lambda_k^{s_{ij}^{\beta^{ij}}}]^T.$$

其中

$$\Lambda_k^{T_i} = p\{z_k | T_i(k), \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\},$$

$$\Lambda_k^{s_{ij}^l} = p\{z_k | s_{ij}^l(k), \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\}.$$

根据Bayesian全概率公式, 由模式概率和似然值得到模型的概率和似然值的计算公式为

$$w_k^i = \sum_{\text{mode}} (P\{i_k | \text{mode}(k), \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\} \times P\{\text{mode}(k) | \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\}) = w_k^{T_i} + \sum_{j=1, j \neq i}^M \sum_{l=1}^{\beta^{ij}} w_k^{s_{ij}^l}, \quad (2)$$

$$\Lambda_k^i = \sum_{\text{mode}} (p\{z_k | i_k, \text{mode}(k), \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\} \times P\{i_k, \text{mode}(k) | \bar{\Pi}_{k-1}, \mathbf{Z}^{k-1}\}) = \Lambda_k^{T_i} w_k^{T_i} + \sum_{j=1, j \neq i}^M \sum_{l=1}^{\beta^{ij}} \Lambda_k^{s_{ij}^l} w_k^{s_{ij}^l}. \quad (3)$$

由转换概率矩阵递推基本公式^[9]

$$p[\pi_i | \mathbf{Z}^k] = \{1 + \eta_i(k) [\Pi_i - \bar{\pi}_i(k-1)]^T \Lambda_k\} p[\pi_i | \mathbf{Z}^{k-1}], \quad (4)$$

可以得出

$$f[z_k | \pi_i] = p[z_k | \Pi_i, \mathbf{Z}^{k-1}] = \sum_{j=1}^M \pi_{ij} \tilde{g}_{ij}(k). \quad (5)$$

其中

$$\begin{aligned}\eta_i(k) &= \mathbf{w}_{k-1} / \mathbf{w}_{k-1}^T \bar{\mathbf{\Pi}}_{k-1} \mathbf{A}_k, \\ \mathbf{w}_k &= [w_k^1, w_k^2, \dots, w_k^M], \mathbf{A}_k = [A_k^1, A_k^2, \dots, A_k^M], \\ \tilde{g}_{ij}(k) &= 1 + \eta_i(k) [A_k^j - \bar{\pi}_i^T(k-1) \mathbf{A}_k].\end{aligned}$$

由于 π_i 服从 Dirichlet 分布, 由 Quasi-Bayesian 算法^[10] 可得模型转换概率自适应递推方法为

$$\bar{\pi}_{ij}(k) = \frac{1}{k + \alpha_i(0)} \alpha_{ij}(k). \quad (6)$$

其中

$$\begin{aligned}\alpha_{ij}(k) &= \alpha_{ij}(k-1) + \frac{\alpha_{ij}(k-1) \tilde{g}_{ij}(k)}{\sum_{j=1}^M \alpha_{ij}(k-1) \tilde{g}_{ij}(k)}, \\ \alpha_i(0) &= \sum_{j=1}^M \alpha_{ij}(0), \bar{\pi}_{ij}(0) = \frac{\alpha_{ij}(0)}{\sum_{j=1}^M \alpha_{ij}(0)}.\end{aligned}$$

综合以上推导, 可得基于 STC-IMM 结构的自适应多模型跟踪算法的计算公式及步骤如下.

1) 转换模式合并. 对于模型 i , k 时刻的最高级驻留模式 $s_{ij}^{\beta^{ij}}$ 将在 $k+1$ 时刻切换为转换模式 T_i , 类似于 IMM 算法的输入交互过程, 将 $k+1$ 时刻属于 T_i 模式的所有模式分支进行加权合并. 在合并过程中, 小概率模式对滤波器的性能影响很小, 因此可以设置概率门限对模式分支进行修剪. 门限的设置可根据实验确定: 分别选取每种模型对应的典型运动方式对算法进行测试, 选取模型概率最小值作为小概率门限, 即

$$\mathbf{x}_{k|k}^{(T_i)} = \mu_k^{T_i} \hat{\mathbf{x}}_{k|k}^{T_i} + \sum_{j=1, j \neq i}^M \mu_k^{j|i} \hat{\mathbf{x}}_{k|k}^{s_{ij}^{\beta^{ij}}}, \quad (7)$$

$$\begin{aligned}\mathbf{P}_{k|k}^{(T_i)} &= \mu_k^{T_i} [\mathbf{P}_{k|k}^{T_i} + (\hat{\mathbf{x}}_{k|k}^{T_i} - \mathbf{x}_{k|k}^{(T_i)}) (\cdot)^T] + \\ &\sum_{j=1, j \neq i}^M \mu_k^{j|i} [\mathbf{P}_{k|k}^{s_{ij}^{\beta^{ij}}} + (\hat{\mathbf{x}}_{k|k}^{s_{ij}^{\beta^{ij}}} - \mathbf{x}_{k|k}^{(T_i)}) (\cdot)^T].\end{aligned} \quad (8)$$

其中

$$\begin{aligned}\mu_k^{T_i} &= \frac{\pi_{ii} w_k^{T_i}}{\pi_{ii} w_k^{T_i} + \sum_{j=1, j \neq i}^M 1 \cdot w_k^{s_{ij}^{\beta^{ij}}}}, \\ \mu_k^{j|i} &= \frac{1 \cdot w_k^{s_{ij}^{\beta^{ij}}}}{\pi_{ii} w_k^{T_i} + \sum_{j=1, j \neq i}^M 1 \cdot w_k^{s_{ij}^{\beta^{ij}}}.\end{aligned}$$

2) 模式转换 (模式概率预测). 对于模型 i , 在各级驻留模式 s_{ij}^l ($l < \beta^{ij}$) 之间、最高级驻留模式 $s_{ij}^{\beta^{ij}}$ 与转换模式 T_i 之间是以概率 1 发生转换的; 转换模式 T_i 到模型 j 一级驻留模式 s_{ji}^1 ($i \neq j$) 则是以概率 π_{ij} 发生转换. 即有

$$w_{k+1|k}^{T_i} = \pi_{ii} w_k^{T_i} + \sum_{j=1, j \neq i}^M 1 \cdot w_k^{s_{ij}^{\beta^{ij}}},$$

$$\begin{aligned}w_{k+1|k}^{s_{ij}^1} &= \pi_{ji} w_k^{T_j}, \\ w_{k+1|k}^{s_{ij}^n} &= 1 \cdot w_k^{s_{ij}^{n-1}}, \quad n = 2, 3, \dots, \beta^{ij}.\end{aligned} \quad (9)$$

3) 模式滤波和模式似然值计算. 对每个模型 i 的 k 时刻转换模式 T_i ($w_k^{T_i} > \gamma$) 和驻留模式 s_{ij}^l ($w_k^{s_{ij}^l} > \gamma$) 进行滤波运算和似然值计算, 同时将低于概率门限 γ 的模式概率置零, 减少参与滤波和下一时刻模式合并运算的模式数量, 概率门限设置同步步骤 1). 模式似然值计算公式为

$$\begin{aligned}A_{k+1}^{T_i} &= p\{z_{k+1} | T_i(k), \bar{\mathbf{\Pi}}_k, \mathbf{Z}^k\} = \\ &N(v_{k+1}^{T_i}; \mathbf{0}, \mathbf{S}_{k+1}^{T_i}) \\ A_{k+1}^{s_{ij}^l} &= p\{z_{k+1} | s_{ij}^l(k+1), \bar{\mathbf{\Pi}}_k, \mathbf{Z}^k\} = \\ &N(v_{k+1}^{s_{ij}^l}; \mathbf{0}, \mathbf{S}_{k+1}^{s_{ij}^l}).\end{aligned} \quad (10)$$

其中: v 为滤波残差, \mathbf{S} 为残差协方差矩阵.

4) 模式概率更新. 根据模式预测概率和模式滤波后获得的似然值, 由 Bayesian 全概率公式得到 $k+1$ 时刻模式概率

$$\begin{aligned}w_{k+1}^{T_i} &= \frac{A_{k+1}^{T_i} w_{k+1|k}^{T_i}}{\sum_{i=1}^M \left(A_{k+1}^{T_i} w_{k+1|k}^{T_i} + \sum_{j=1, j \neq i}^M \sum_{l=1}^{\beta^{ij}} A_{k+1}^{s_{ij}^l} w_{k+1|k}^{s_{ij}^l} \right)}, \\ w_{k+1}^{s_{ij}^l} &= \frac{A_{k+1}^{s_{ij}^l} w_{k+1|k}^{s_{ij}^l}}{\sum_{i=1}^M \left(A_{k+1}^{T_i} w_{k+1|k}^{T_i} + \sum_{j=1, j \neq i}^M \sum_{l=1}^{\beta^{ij}} A_{k+1}^{s_{ij}^l} w_{k+1|k}^{s_{ij}^l} \right)}.\end{aligned} \quad (11)$$

5) 模型转换概率矩阵更新. 利用步骤 3)~步骤 4) 获得的模式似然值和模式概率计算出 $k+1$ 时刻模型似然值, 再将 k 时刻模型概率 w_k^i 和模型转换概率矩阵 $\bar{\mathbf{\Pi}}_k$ 代入式 (9) 便可计算出 $\bar{\mathbf{\Pi}}_{k+1}$.

6) 模式状态融合输出. 有

$$\begin{aligned}\hat{\mathbf{x}}_{k+1|k+1} &= \sum_{i=1}^M w_{k+1}^{T_i} \hat{\mathbf{x}}_{k+1|k+1}^{T_i} + \\ &\sum_{i=1}^M \sum_{j=1, j \neq i}^M \sum_{l=1}^{\beta^{ij}} w_{k+1}^{s_{ij}^l} \hat{\mathbf{x}}_{k+1|k+1}^{s_{ij}^l}.\end{aligned} \quad (12)$$

7) 循环步骤 1)~步骤 6) 可得目标各时刻状态估计.

从算法步骤 4) 和 5) 可以看出, 相比 IMM 算法, 由于模型模式的增加, 目标机动导致的模型似然值变化会引起模型概率较大幅度的更新调整, 保证了模型能够根据目标机动快速切换, 模型转换概率的自适应又保证了稳态跟踪情况下匹配模型获取较大的概率, 从而提高了稳态跟踪精度.

3 仿真分析

为了验证本文算法的实时性和有效性, 将本文算法 (STC-AIMM) 与 IMM 算法、STC-IMM 进行性能对比分析. 定义 k 时刻的位置均方根误差 (RMSE) 和采样时间内位置平均误差 Error 分别为

$$\text{RMSE}(k) = \left\{ \frac{1}{M} \sum_{i=1}^M \left\| \mathbf{x}_k^i - \hat{\mathbf{x}}_k^i \right\|_2^2 \right\}^{1/2},$$

$$\text{Error} = \frac{1}{N} \sum_{k=1}^N \text{RMSE}(k).$$

其中: M 为 Monte Carlo 仿真次数, \mathbf{x}_k^i 和 $\hat{\mathbf{x}}_k^i$ 分别为第 i 次 Monte Carlo 仿真的位置矢量真实值和估计值. 速度估计和加速度估计的均方根误差及采样时间内的平均误差采用相同的定义方式.

图 2 为目标运动情况. 目标初始状态 $X(0) = [2000 \text{ m}, 426 \text{ m/s}, 0 \text{ m/s}^2, 8000 \text{ m}, 0 \text{ m/s}, 0 \text{ m/s}^2]$, 运动过程历时 200 s, 其中第 31~85 s 目标作蛇形机动, 第 96~145 s 目标作俯冲拉起机动, 其余时间作匀速直线运动, 加速度变化规律如图 2(b) 所示.




图 2 目标运动轨迹及加速度变化规律

实验中采用匀加速 (CA) 模型、匀速 (CV) 模型和当前统计 (CS) 模型组成 CA-CS-CV 模型集. CA 和 CV 模型的状态噪声协方差系数均为 0.1, CS 模型的机动频率 $\alpha = 0.1$, 最大加速度 $a_{\pm \max} = \pm 80 \text{ m/s}^2$, 观测模型噪声均方差为 50 m. 本文算法和 STC-IMM 算法的驻留时间为 $\beta^{12} = 2, \beta^{13} = 2, \beta^{21} = 1, \beta^{23} = 1, \beta^{31} = 2, \beta^{32} = 2$. 小概率门限为 0.01, 各模型转换模式的先验概率均为 1/3, 驻留模式先验概率为 0, IMM 算法模型先验概率为 1/3. 3 种算法模型转换概率均为 $\pi_{ii} = 0.94, \pi_{ij} = 0.03 (i, j = 1, 2, 3, i \neq j)$. 雷达采样周期 $T_0 = 0.2 \text{ s}$, 实际观测噪声为高斯白噪声, 噪声均方差为 10 m, 进行 100 次 Monte Carlo 仿真实验.

图 3 为 3 种算法的目标状态估计实时误差, 表 1 和表 2 分别为 3 种算法在蛇形机动阶段和俯冲拉起机动阶段的状态估计平均误差. 从图 3 可以看出, 在目标蛇形机动阶段 (31~85 s), 本文算法在目标加速度连续快速大幅度阶跃变化情况下, 保持了较为稳定的位置峰值误差, 且能够快速收敛到较高的状态估计精度上, 这表明本文算法对于目标强机动具有较好的跟踪稳定性; 在目标俯冲拉起机动阶段 (95~145 s), 机

动强度降低, 本文算法峰值估计误差随之减小, 稳态跟踪精度明显提高, 表明本文算法对于不同强度的机动具有良好的适应性. 相比 IMM 算法和 STC-IMM 算法, 本文算法跟踪加速度阶跃变化的峰值误差与其相当, 但是本文算法的稳态跟踪误差明显小于 IMM 算法和 STC-IMM 算法. 从表 1 和表 2 也可以看出: 在目标不同机动强度情况下, 本文算法的平均跟踪误差均小于 IMM 算法和 STC-IMM 算法, 而在一般机动情况下算法优势更加显著. 在计算量上, 相比 IMM 算法, 本文算法和 STC-IMM 算法并行滤波器的数量增加了大约 3 倍, 但因实时修剪了小概率模式分支, 故计算量增加了大约 2 倍.




图 3 状态估计均方根误差

表 1 算法性能对比 1


算法类型	蛇形机动阶段跟踪平均误差			相对计算时间
	位置 /m	速度 /(m/s)	加速度 /(m/s ²)	
IMM	14.535	22.843	18.947	1.00
STC-IMM	14.687	22.819	18.778	3.06
STC-AIMM	14.524	22.243	18.071	3.31

表 2 算法性能对比 2


算法类型	俯冲拉起阶段跟踪平均误差			相对计算时间
	位置 /m	速度 /(m/s)	加速度 /(m/s ²)	
IMM	11.449	13.076	8.168	1.00
STC-IMM	11.424	12.979	8.026	2.92
STC-AIMM	9.974	10.526	6.357	3.10

图 4 是 3 种算法的模型在目标不同运动阶段的概率变化曲线. 从图 4 可以看出: 相比 IMM 算法和


STC-IMM 算法, 本文算法的模型概率变化对目标机动的反应更快, 模型切换更加匹配目标实际机动情况; 在目标稳定运动阶段, 匹配模型和非匹配模型概率差异更加明显, 从而确保了本文算法较好的机动响应能力和较高的稳态跟踪精度.



(a) IMM 算法模型在不同时刻的概率



(b) STC-IMM 算法模型在不同时刻的概率



(c) STC-AIMM 算法模型在不同时刻的概率

图 4 不同算法模型概率变化情况

4 结 论

针对交互多模型结构与自适应滤波算法性能发挥之间的矛盾, 通过对 STC-IMM 结构的分析, 本文提出了一种基于 STC-IMM 结构的模型转换概率自适应多模型算法, 利用 STC-IMM 结构有利于自适应滤波算法性能发挥的优点, 在模型驻留模式和转换模式基础上推导了模型转换概率自适应算法. 理论分析和仿真实验表明: 新算法最大限度地发挥了滤波器的性能, 而且模型切换对目标机动的反应更加快速, 模型概率分配更加合理, 具有良好的机动快速响应能力和较高的稳态跟踪精度. 针对 STC-IMM 的结构特点, 如

何将参数自适应模型与 STC-IMM 结构有机结合, 将是未来值得研究的问题.

参考文献(References)

- [1] Li X R, Jilkov V P. A survey of maneuvering target tracking, Part V: Multiple-model methods[J]. IEEE Trans on Aerospace and Electronic Systems, 2005, 41(4): 1254-1320.
- [2] 鉴福升, 徐跃民, 阴泽杰. 多模型粒子滤波跟踪算法研究[J]. 电子与信息学报, 2010, 32(6): 1271-1275.
(Jian F S, Xu Y M, Yin Z J. Research of multiple model particle filter tracking algorithms[J]. J of Electronics & Information Technology, 2010, 32(6): 1271-1275.)
- [3] Blom H A P, Bloem E A. Exact Bayesian and particle filtering of stochastic hybrid systems[J]. IEEE Trans on Aerospace and Electronic Systems, 2007, 43(1): 55-70.
- [4] Blom H, Bar-Shalom Y. The interacting multiple model algorithm for systems with Markovian switching coefficients[J]. IEEE Trans on Automatic Control, 1988, 33(3): 780-783.
- [5] Campo L, Mookerjee P, Bar-Shalom Y. State estimation for systems with sojourn-time-dependent Markov model switching[J]. IEEE Trans on Automatic Control, 1991, 36(2): 238-243.
- [6] Blom H. Hybrid state estimation for systems with semi-Markov switching coefficients[C]. Proc of Eur Control Conf. Grenoble, 1991: 1132-1137.
- [7] Petrov A I, Zubov A G. Estimation in nonlinear stochastic systems with sudden changes in structure, parameters and state coordinates[J]. Soviet J of Computer and Systems Sciences, 1991, 29(3): 9-28.
- [8] Svensson D, Svensson L. A new multiple model filter with switch time conditons[J]. IEEE Trans on Signal Processing, 2010, 58(1): 11-25.
- [9] Jilkov V P, Li X R. Online Bayesian estimation of transition probabilities for Markovian jump system[J]. IEEE Trans on Signal Processing, 2004, 52(6): 1620-1630.
- [10] Gauvain J L, Lee C H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains[J]. IEEE Trans on Speech Audio Processing, 1994, 2(2): 291-298.