

# 具有状态相关转移阵的交互式多模型 贝努利滤波

张婉莹<sup>1,2</sup>, 杨峰<sup>1,2</sup>, 苏亚哲<sup>1,2</sup>, 么渲正<sup>1,2</sup>

1) 西北工业大学, 西安 710129; 2) 信息融合技术教育部重点实验室, 西安 710129

**摘要:** 对于机动目标的跟踪, 大多数基于贝叶斯理论的估计算法, 如交互式多模型贝努利滤波 (IMM Bernoulli Filter) 算法, 都假定模型转移概率保持不变。而实际系统中, 模型转移概率可能是与状态相关并随时间变化的。针对地面机动目标跟踪问题, 引入道路先验辅助信息对状态转移概率建立具有状态相关性的模型, 结合交互式多模型贝努利滤波算法, 实现目标跟踪。仿真结果表明, 提出的具有状态相关转移阵的交互式多模型贝努利滤波算法优于传统的模型转移概率恒定滤波算法。

**关键词:** 机动目标跟踪; 交互式多模型; 贝努利滤波

**中图分类号:** TP273 **文献标识码:** A

## IMM Bernoulli Filter with State-Dependent-Transition

Zhang Wanying<sup>1,2</sup>, Yang Feng<sup>1,2</sup>, Su Yazhe<sup>1,2</sup>, Yao Xuanzheng<sup>1,2</sup>

1) Northwestern Polytechnical University, Xi'an 710129;

2) Key Laboratory of Information Fusion Technology, Ministry of Education, Xi'an 710129

**Abstract:** For maneuvering target tracking, under the Bayesian theorem, most estimation algorithms, such as the interacting multiple model Bernoulli Filter (IMMBF), assume constant model transition probabilities. However, in practical systems, model transition probabilities may be related to the state and varies with time. For the problem of tracking ground maneuvering target, we introduce prior road information to establish a state-dependent-transition model for the model transition probability, and combine with IMMBF to achieve maneuvering target tracking. Simulation results show that the proposed state-dependent-transition IMMBF algorithm is better than traditional constant model transition probability algorithm.

**Key words:** maneuvering target tracking; IMM; Bernoulli Filter

## 引言

机动目标跟踪系统<sup>[1][2]</sup>作为目标跟踪中的重要组成部分, 一直受到人们的广泛关注。几乎所有的机动目标跟踪的方法都是基于模型的, 它们都假设目标运动及其观测可以通过某些已知的数学模型准确描述。目前普遍认为, 对于机动目标的跟踪, 最好的算法是交互式多模型(IMM)算法, 而当前对机动目标跟踪的算法研究也主要集中于此。IMM算法<sup>[3]</sup>首先是由 H.A.P.Blom 在 1984 年提出的, 它使用多个不同的运动模型分别匹配目标的不同运动状态。Munir A.和 Atherton D.P.<sup>[4]</sup>提出自适应 IMM 算法(AIMM), 它利用模式的状态相关性对模型进行修正, 使模型与目标运动模式相匹配, 提高了跟踪性能。Li X. R.<sup>[5]</sup>和 Kirubarajan<sup>[6]</sup>等人直接对 IMM 算法改进, 考虑在不同时刻选用不同模型集的变结

构交互式多模型 (VS-IMM) 算法, 对于机动变化复杂的目标, VS-IMM 算法的估计性能要优于固定结构的 IMM 算法。

通常情况下, IMM 算法中的模型转移概率矩阵被设定为与时间无关的常数。然而, 由于实际的环境特性复杂多变, 真实系统的模型切换概率很难在长时间内保持恒定不变, 即模型转移概率可能是与状态相关并随时间变化的。如飞机的软着陆问题、网络控制系统中出现的时延和随机丢包问题、系统工程中存在的组件故障率问题等。一方面, 考虑到客观因素本身的不确定性, 即每一时刻的模型切换概率并不是确定给出的, 并不能用特定的常数值来描述。另一方面, 当系统状态落入某一个连续状态空间的子集中时, 系统将发生模态切换, 这个子集也可被认为是某种约束条件。此时, 模型转移概率是与系统状态相关的, 并不是相互独立的。

因此, 如何对模型转移概率矩阵进行有效合理

地建模，将是一个关键问题。本文以地面机动目标跟踪为应用背景，通过引入道路先验辅助信息对模型转移概率进行建模，结合交互式多模型贝努利滤波算法实现机动目标跟踪。仿真结果表明，本文所提出的转移概率状态相关交互式多模型贝努利滤波器能够提高跟踪性能，具有一定的可行性和有效性。

## 1. 贝努利滤波器

贝努利滤波是随机集理论框架下贝叶斯滤波的一种，目前主要应用于目标跟踪，传感器网络，虚拟跟踪和雷达监控等方面<sup>[8]</sup>。 $k$ 时刻的贝努利随机有限集可以完全用两个变量来描述，分别是目标存在概率 $q_k$ 和目标状态的后验概率密度 $s_k(x)$ 。贝努利滤波器包括预测和更新两步。

预测步为：

$$q_{k|k-1} = p_b(1 - q_{k-1|k-1}) + p_s q_{k-1|k-1}$$

$$s_{k|k-1} = \frac{p_b(1 - q_{k-1|k-1})b_{k|k-1}(x)}{q_{k|k-1}} + \frac{p_s q_{k-1|k-1} \int f_{k|k-1}(x|x')s_{k-1|k-1}(x')dx'}{q_{k|k-1}}$$

其中， $p_b$ 表示目标新生概率， $p_s$ 表示目标存活概率， $b_{k|k-1}$ 表示 $k-1$ 时刻新生目标的概率密度， $f_{k|k-1}$ 表示单个目标的状态转移概率密度。更新步为：

$$q_{k|k} = \frac{1 - \Delta_k}{1 - q_{k|k-1}\Delta_k} q_{k|k-1}$$

$$s_{k|k}(x) = \frac{1 - p_d + p_d \sum_{z \in Z_k} \frac{g_k(z|x)}{\lambda c(z)}}{1 - \Delta_k} s_{k|k-1}(x)$$

$$\Delta_k = p_d \left( 1 - \sum_{z \in Z_k} \frac{\int g_k(z|x)s_{k|k-1}(x)dx}{\lambda c(z)} \right)$$

其中， $p_d$ 是目标检测概率， $g_k(z|x)$ 是单目标似然函数， $C(z)$ 表示杂波分布函数， $\lambda$ 为平均杂波个数。

## 2. 具有状态相关模型转移阵的交互式多模型贝努利滤波器

### 2.1 状态相关模型转移阵的建模

以地面机动目标跟踪为例，考虑到可以提前获取道路信息，首先建立一个典型的道路目标运动模型，如下图1所示：




图1 典型道路目标运动模型

其中，红色所示曲线为目标真实的运动轨迹，黑色实线为道路中心线，虚线内表示道路宽度信息， $T$ 点为转弯点，目标在 $T$ 点开始机动。假定目标为道路目标，即不考虑非道路目标模型。目标运动模型包含匀速直线运动（CV）模型和匀速率转弯运动（CT）模型两种模型。假设 $y_k$ 代表 $k$ 时刻目标的位置， $T$ 点的位置为 $y_t$ 。如果目标严格地按照道路方向运行，即当到达 $T$ 点（ $y_k - y_t = 0$ ）时开始转弯，运动模式将从CV模型切换为CT模型。但是在大多数实际情况中，由于一些因素，比如驾驶员的主观性，外部干扰等，可能会在距转弯点 $T$ 一定距离的时候就开始进行转弯。这种不确定性不同于估计目标位置中的不确定性（比如目标动态方程和雷达量测的准确度），为了描述这种不确定性，我们将模型转移概率建模为一个随机事件，且它具有以 $y_k - y_t$ 为条件的发生概率<sup>[7]</sup>。假设我们能够以系统状态 $x_k$ 来表示目标位置 $y_k = Lx_k$ ，其中 $L$ 是常矩阵，那么，条件模型转移概率就可以被建模为函数 $g(Lx_k - y_t)$ ，即：

$$\pi_{ij}(y_k) = g_{ij}(y_k - y_t)$$

其中 $i, j \in M$ 且 $i \neq j$ ， $g_{ij} : R^q \rightarrow [0, 1]$ ， $\mu_{ij} \in R^q$

为一个常向量。

在一般的机动目标跟踪中，当目标即将到达机动位置 $y_t$ 时，模型转移概率 $\pi_{ij}(x)$  ( $i \neq j$ )将逐渐增大，

并且达到峰值，之后随着远离机动点模型转移概率逐渐减小，符合图 2 所示规律。




图 2 转移概率实际变化规律

当满足条件  $y_k = \mu_{ij}$  时，条件模型转移概率达到峰值，并且随着  $y_k$  远离  $\mu_{ij}$  而逐渐变小。为此，我们采用一个多变量高斯概率密度函数来定义函数  $g_{ij}$ ，如下所示：

$$\begin{aligned} \pi_{ij}(y_k) &= \pi_{ij}^{\min} + a_{ij} N_q(y_k - \mu_{ij}; \Sigma_{ij}) \\ &= \pi_{ij}^{\min} + a_{ij} N_q(y_k; \mu_{ij}, \Sigma_{ij}) \end{aligned}$$

其中  $a_{ij}$  是标量常量； $\Sigma_{ij}$  是一个  $q \times q$  的对称正定矩阵；函数  $N_q(y; \mu, \Sigma)$  表示一个  $q$  维的多变量高斯概率密度函数，且具有均值  $\mu$  和方差  $\Sigma$ ，如下式所示：

$$N_q(y; \mu, \Sigma) = \frac{1}{(2\pi)^{q/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(y - \mu)^T \Sigma^{-1} (y - \mu)\right)$$

对于所有  $i, j = 1, \dots, m$ ，满足条件  $\pi_{ij} \geq 0$  且  $\sum_{j=1}^m \pi_{ij} = 1$ ， $\pi_{ij}(x_k)$  可写为：

$$\pi_{ij}(y_k) = \pi_{ij}^{\min} + \frac{a_{ij}}{(2\pi)^{q/2} |\Sigma_{ij}|^{1/2}} \exp\left(-\frac{1}{2}(y_k - \mu_{ij})^T \Sigma_{ij}^{-1} (y_k - \mu_{ij})\right)$$

并且设定

$$\pi_{ii} = 1 - \sum_{j=1, j \neq i}^m \pi_{ij}$$

考虑图 1 所示例子，目标从 CV 模型切换到 CT 模型的转移概率  $\pi_{12}(x)$  可由 (2) 式表示为：

$$\pi_{12}(x_k) = \pi_{12}^{\min} + a_{12} N_2(L_{12} x_k - y_T; 0, \Sigma_{12})$$

其中

$$L_{12} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad \Sigma_{12} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

常量  $\pi_{12}^{\min}$  和  $a_{12}$  均为设计的参数，此处我们设定  $\pi_{12}^{\min} = 0.025$  和  $a_{12} = 0.7 |2\pi \Sigma_{12}|^{1/2}$ 。需要注意的是，常量  $\pi_{12}^{\min}$  用来对目标可能在距离点  $T$  有一定距离的地方发生转弯的概率进行建模表征；常量  $a_{12}$  用来对目标沿着道路运动的概率进行建模[7]。

接着考虑目标从 CT 模型切换到 CV 模型的转移概率  $\pi_{21}(x)$ ，依照经验我们知道，当目标速度方向与道路方向重合时，目标将从 CT 模型切换到 CV 模型，如图 3 中所示：




图 3 目标速度方向和道路方向描述

其中， $\alpha_d$  代表道路与水平线夹角， $\alpha_i$  代表目标速度方向与水平线夹角，且规定逆时针方向为正方向。当目标速度方向  $\alpha_i$  与  $\alpha_d$  越来越接近时，模型转移概率  $\pi_{21}(x)$  将越来越大，当满足条件  $\Delta\alpha = \alpha_d - \alpha_i = 0$  时，转移概率  $\pi_{21}(x)$  达到最大值，之后将逐渐减小。为此，我们可依据此规律将  $\Delta\alpha$  建模为一个高斯分布。当角度之差  $\Delta\alpha$  较小时，可按如下近似

$$\Delta\alpha = \sin^{-1} \frac{V_{\perp}}{V} \approx \frac{V_{\perp}}{V}$$

其中  $V$  表示目标速度， $V_{\perp}$  表示目标垂直于道路的速度分量。由图 3 所示的几何关系可推导出  $V_{\perp}$  表达式如下：

$$V_{\perp} = \sin(\alpha_d) \dot{\xi} - \cos(\alpha_d) \dot{\eta}$$

为此，我们将角度之差  $\Delta\alpha$  近似为  $\Delta\alpha = L_{21} x$ ，其中

$$L_{21} = \begin{bmatrix} 0 & \frac{\sin(\alpha_d)}{V_0} & 0 & -\frac{\cos(\alpha_d)}{V_0} \end{bmatrix}$$

设定  $V_0 = 30m/s$  为目标额定速率，那么条件模型转移概率  $\pi_{21}(x)$  可建模为：

$$\pi_{21}(x_k) = \pi_{21}^{\min} + a_{21}N_1(L_{21}x_k; 0, \Sigma_{21})$$

其中设定  $\pi_{21}^{\min} = 0.025$ ， $a_{21} = 0.7 |2\pi\Sigma_{21}|^{1/2}$  和  $\Sigma_{21} = [(5\text{deg})^2]$ 。并且可以容易得到  $\pi_{11}(x)$  和  $\pi_{22}(x)$  分别如下：

$$\begin{aligned}\pi_{11}(x) &= 1 - \pi_{12}(x) \\ \pi_{22}(x) &= 1 - \pi_{21}(x)\end{aligned}$$

## 2.2. 具有状态相关模型转移阵的交互式多模型贝努利滤波器

记  $k$  时刻单个机动目标的运动状态为  $x_k \in R^n$ ，传感器量测为  $z_k \in R^m$ ，运动模型为  $\theta_k$ ，且在固定模型空间  $M = \{1, 2, \dots, m\}$  内取值。 $k-1$ 时刻模型  $i$  跳变到  $k$  时刻模型  $j$  的概率为

$$\pi_{ij} = P\{\theta_k = j | \theta_{k-1} = i\}$$

其中， $i, j \in M$  且  $\sum_{j=1}^m \pi_{ij} = 1$ 。

交互式多模型贝努利滤波算法在一般情况下没有解析解，需要在满足如下线性高斯假设的条件下得到解析解<sup>[9]</sup>。

假设 1. 目标运动模型和传感器测量模型均为线性高斯，即

$$f_{k|k-1}(x_k | x_{k-1}, \theta_{k-1}) = N(x_k; F_k(\theta_k)x_{k-1}, Q_k(\theta_k))$$

$$g_k(z_k | x_k, \theta_k) = N(z_k; H_k(\theta_k)x_k, R_k(\theta_k))$$

其中， $N(\cdot; m, p)$  为高斯分布的概率密度函数，均值为  $m$ ，协方差为  $p$ ； $F_k(\theta_k), Q_k(\theta_k)$  分别表示模型  $\theta_k$  的运动状态转移矩阵，过程噪声协方差矩阵； $H_k(\theta_k), R_k(\theta_k)$  分别为模型  $\theta_k$  的观测矩阵和测量噪声协方差矩阵。

假设 2. 目标存活概率和检测概率与目标状态无关，即

$$P_{s,k}(x_{k-1}, \theta_{k-1}) = P_{s,k}(\theta_{k-1})$$

$$P_{d,k}(x_k, \theta_k) = P_{d,k}(\theta_k)$$

假设 3. 模型条件化的新生目标状态向量概率

密度函数  $b_{k|k-1}(x_k, \theta_k)$  服从高斯混合分布，即

$$b_{k|k-1}(x_k, \theta_k) = \sum_{j=1}^{J_{\Gamma,k}^{(\theta_k)}} w_{\Gamma,k|k-1}^{(j)} N(x_k; m_{\Gamma,k|k-1}^{(j)}(\theta_k), P_{\Gamma,k|k-1}^{(j)}(\theta_k))$$

下面给出模型切换概率状态相关的交互式多模型高斯混合贝努利滤波算法主要步骤：

第一步：计算模型概率

若  $k-1$  时刻目标的后验概率密度为

$$\begin{aligned}s_{k-1}(x_{k-1}, \theta_{k-1}) &= \sum_{i=1}^{N_{k-1}^{(\theta_{k-1})}} w_{k-1}^{(i)}(\theta_{k-1}) \\ &\dots N(x_{k-1}; m_{k-1}^{(i)}(\theta_{k-1}), P_{k-1}^{(i)}(\theta_{k-1}))\end{aligned}$$

通过公式 (11) 和公式 (15) 计算模型转移概率  $\pi(\theta_k | \theta_{k-1})$ 。

第二步：混合步

$k-1$ 时刻目标的运动模型概率为  $\mu_{k-1}(\theta_{k-1})$ 。则经模型交互后的混合概率为

$$\mu_{k-1|\theta_{k-1}} = \frac{\pi(\theta_k | \theta_{k-1}) \mu_{k-1}(\theta_{k-1})}{\sum_{\theta_{k-1}} \pi(\theta_k | \theta_{k-1}) \mu_{k-1}(\theta_{k-1})}$$

第三步：预测步

$$q_{k|k-1} = p_b(1 - q_{k-1})$$

$$+ p_s q_{k-1} \sum_{\theta_{k-1} \in M} \sum_{i=1}^{N_{k-1}^{(\theta_{k-1})}} \mu_{k-1}(\theta_{k-1}) w_{k-1}^{(i)}(\theta_{k-1})$$

$$\begin{aligned}s_{k|k-1}(x_k, \theta_k) &= \frac{p_b(1 - q_{k-1})}{[p_b(1 - q_{k-1}) + p_s q_{k-1}] \mu_{k|k-1}(\theta_k)} b_{k|k-1}(x_k, \theta_k) \\ &+ \frac{p_s q_{k-1}}{[p_b(1 - q_{k-1}) + p_s q_{k-1}] \mu_{k|k-1}(\theta_k)} \sum_{\theta_{k-1}=1}^M \sum_{i=1}^{N_{k-1}^{(\theta_{k-1})}} w_{k-1}^{(i)}(\theta_{k-1}) \\ &\dots N(x_k; m_{k|k-1}^{(i)}(\theta_k | \theta_{k-1}), P_{k|k-1}^{(i)}(\theta_k | \theta_{k-1}))\end{aligned}$$

其中，

$$w_{k|k-1}^{(i)}(\theta_k | \theta_{k-1}) = p_s \pi(\theta_k | \theta_{k-1}) w_{k-1}^{(i)}(\theta_{k-1})$$

$$m_{k|k-1}^{(i)}(\theta_k | \theta_{k-1}) = F_k(\theta_k) m_{k-1}^{(i)}(\theta_{k-1})$$

$$P_{k|k-1}^{(i)}(\theta_k | \theta_{k-1}) = F_k(\theta_k) P_{k-1}^{(i)}(\theta_{k-1}) (F_k(\theta_k))^T + Q_k(\theta_k)$$

第四步：更新步

假设  $k$  时刻预测目标概率密度为混合高斯形式：

$$\begin{aligned}s_{k|k-1}(x_k, \theta_k) &= \sum_{i=1}^{N_{k|k-1}^{(\theta_k)}} w_{k|k-1}^{(i)}(\theta_k) \\ &\dots N(x_k; m_{k|k-1}^{(i)}(\theta_k), P_{k|k-1}^{(i)}(\theta_k))\end{aligned}$$

则

$$q_{k|k} = \frac{q_{k|k-1} \sum_{\theta_k} \mu_{k|k-1}(\theta_k) \ell(\theta_k)}{(1-q_{k|k-1}) + q_{k|k-1} \sum_{\theta_k} \mu_{k|k-1}(\theta_k) \ell(\theta_k)}$$

$$s_{k|k}(x_k, \theta_k) = \frac{1}{\Delta_k} \frac{q_{k|k-1} \mu_{k|k-1}(\theta_k) G_{k|k}(x_k, \theta_k)}{\mu_k(\theta_k) (1-q_{k|k-1}) + q_{k|k-1} \sum_{\theta_k \in M} \mu_{k|k-1}(\theta_k) \ell(\theta_k)}$$

其中,

$$G_{k|k}(x_k, \theta_k) = (1-p_d) s_{k|k-1}(x_k, \theta_k) + p_d \left[ \sum_{z \in Z_k} \sum_{i=1}^{N_{k|k}^{(i)}} \frac{w_{k|k}^{(i)}(\theta_k) l_k^{(i)}(z, \theta_k)}{\lambda c(z)} N(x_k; m_{k|k}^{(i)}(\theta_k), P_{k|k}^{(i)}(\theta_k)) \right]$$

$$\Delta_k = \frac{q_{k|k-1} \sum_{\theta_k \in M} \mu_{k|k-1}(\theta_k) \ell(\theta_k)}{(1-q_{k|k-1}) + q_{k|k-1} \sum_{\theta_k \in M} \mu_{k|k-1}(\theta_k) \ell(\theta_k)}$$

$$\ell(\theta_k) = 1 - p_d + p_d \sum_{z \in Z_k} \sum_{i=1}^{N_{k|k-1}^{(i)}} \frac{w_{k|k-1}^{(i)}(\theta_k) l_k^{(i)}(z, \theta_k)}{\lambda c(z)}$$

$$l_k^{(i)}(z, \theta_k) = N(z; H_k m_{k|k-1}^{(i)}(\theta_k), R_k + H_k P_{k|k-1}^{(i)}(\theta_k) H_k^T)$$

$$m_{k|k}^{(i)}(\theta_k) = m_{k|k-1}^{(i)}(\theta_k) + K_{k|k-1}^{(i)}(\theta_k) (z - H_k m_{k|k-1}^{(i)}(\theta_k))$$

$$P_{k|k}^{(i)}(\theta_k) = (I - K_{k|k}^{(i)}(\theta_k) H_k) P_{k|k-1}^{(i)}(\theta_k)$$

$$K_{k|k-1}^{(i)}(\theta_k) = P_{k|k-1}^{(i)}(\theta_k) H_k^T (H_k P_{k|k-1}^{(i)}(\theta_k) H_k^T + R_k)^{-1}$$

第四步: 模型概率更新步

通过计算模型后验概率

$$\mu_k(\theta_k) = \frac{\mu_{k|k-1}(\theta_k) \ell(\theta_k)}{\sum_{\theta_k=1}^M \mu_{k|k-1}(\theta_k) \ell(\theta_k)}$$

第五步: 状态估计

依据模型概率对状态进行加权, 计算状态估计值

$$\hat{x}_k = \sum_{\theta_k} \mu_k(\theta_k) x_{k|k}(\theta_k)$$

### 3 仿真分析

对地机动目标跟踪系统中, 考虑到目标将沿道路方向运动。目标运动模型如下: 首先沿道路做匀速直线运动 (CV), 到达转弯处时, 目标将切换为匀速率转弯运动 (CT), 之后将继续做匀速直线运动 (CV)。为此我们将目标动态系统建模为具有两

个模态 (CV 和 CT) 的马尔可夫切换系统。令目标状态为  $x = [\xi \ \dot{\xi} \ \eta \ \dot{\eta}]^T$ , 其中  $(\xi, \eta)$  为笛卡尔坐标系下的目标位置,  $(\dot{\xi}, \dot{\eta})$  为目标速度。

目标运动模型如下式给定:

(1) CV 模型:

$$x_{k+1} = \begin{bmatrix} 1 & T_s & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T_s \\ 0 & 0 & 0 & 1 \end{bmatrix} x_k + \begin{bmatrix} T_s^2/2 & 0 \\ T_s & 0 \\ 0 & T_s^2/2 \\ 0 & T_s \end{bmatrix} w_k$$

(2) CT 模型:

$$x_{k+1} = \begin{bmatrix} 1 & \frac{\sin(\omega T_s)}{\omega} & 0 & \frac{1 - \cos(\omega T_s)}{\omega} \\ 0 & \cos(\omega T_s) & 0 & -\sin(\omega T_s) \\ 0 & \frac{1 - \cos(\omega T_s)}{\omega} & 1 & \frac{\sin(\omega T_s)}{\omega} \\ 0 & \sin(\omega T_s) & 0 & \cos(\omega T_s) \end{bmatrix} x_k + \begin{bmatrix} T_s^2/2 & 0 \\ T_s & 0 \\ 0 & T_s^2/2 \\ 0 & T_s \end{bmatrix} w_k$$

其中,  $T_s$  为采样时 NRDB, tEKF 均值的高斯白噪声,

且 CV 模型和 CT 模型的协方差分别为

$$E[ww^T] = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \text{ 和 } E[ww^T] = \begin{bmatrix} 5 & 0 \\ 0 & 5 \end{bmatrix}$$

采样时间间隔  $T_s = 1s$ , 目标初始位置为  $x_0 = (50m, 30m/s, 50m, 0)^T$ , 在采样时间  $0 < k \leq 15$  区间内, 目标进行 CV 运动; 当  $15 < k \leq 30$  时, 目标进行转弯运动, 即进入 CT 模型; 当  $30 < k \leq 50$  时, 目标又切换为 CV 运动模型。设定目标即将开始转弯处的位置为  $y_r = (500m, 50m)^T$ , 量测噪声的协方差矩阵为  $R = \text{diag}([10, 10])m^2$ , CT 模型的转弯角速率  $\omega = 3 \text{ deg/s}$ , 初始模型概率取  $\mu_0^1 = 0.9$  和  $\mu_0^2 = 0.1$ , 滤波器初始状态设定为  $\hat{x}_{00} = x_0 + (5m, 1m/s, 5m, 0.1m/s)^T$ , 其中第二项为随机选取参数, 对应的初始协方差为  $P_0 = \text{diag}([1, 1, 1, 1])$ 。

为了验证具有状态相关的模型转移矩阵的算法的有效性, 我们将本算法与模型转移矩阵恒定的 IMM 贝努利滤波算法进行对比, 并且转移概率矩阵

分别选取以下两种情况进行对比：

$$\Pi_1 = \begin{bmatrix} \pi_{11} & \pi_{12} \\ \pi_{21} & \pi_{22} \end{bmatrix} = \begin{bmatrix} 0.75 & 0.25 \\ 0.25 & 0.75 \end{bmatrix}$$

$$\Pi_2 = \begin{bmatrix} \pi_{11} & \pi_{12} \\ \pi_{21} & \pi_{22} \end{bmatrix} = \begin{bmatrix} 0.95 & 0.05 \\ 0.05 & 0.95 \end{bmatrix}$$




图 4 XY 轴位置估计 RMSE 曲线




图 5 位置估计 RMSE 曲线图




图 6 XY 速度估计 RMSE 曲线图




图 7 速度估计 RMSE 曲线图

实验中进行了 100 次蒙特卡洛仿真，图 4-图 7 分别给出了转移概率恒定不变和转移概率与状态相关的估计位置和速度 RMSE 曲线图。由仿真图可以直观地看出，与模型转移概率恒定不变的情况相比，转移概率状态相关算法可以获得更高的估计精度，位置估计精度在模型切换处也优于转移概率恒定情况的跟踪精度。结果显示，本算法通过结合地面道路信息对转移概率矩阵进行建模，具有一定的有效性和可行性，可以提高跟踪性能。

## 结论

本文针对模型转移概率与状态相关情况下的状态估计问题，以对地道路机动目标跟踪为应用背景，首先通过引入道路辅助信息，对模型转移概率进行了合理有效的建模；并设计出了具有状态相关模型转移矩阵的交互式多模型贝努利滤波器；最后，与模型转移矩阵恒定情况下的交互式多模型贝努利滤波算法进行了仿真对比。仿真结果表明，具有状态相关模型转移矩阵的贝努利滤波器能够有效地改善跟踪精度，优于传统的模型转移矩阵恒定的交互式多模型贝努利滤波器。

## 参考文献

- [1] 潘泉,梁彦,杨峰,程咏梅. 现代目标跟踪与信息融合[M], 北京: 国防工业出版社,2009.
- [2] 韩崇昭,朱红艳,段战胜等. 多源信息融合(第二版)[M], 北京: 清华大学出版社, 2010.

- [3] H. A. P. Blom, An Efficient Filter for Abruptly Changing Systems [C]. *Proceedings of 23<sup>rd</sup> Conference on Decision and Control*.1984: 656-658.
- [3] H. A. P. Blom., E. A. Bloem, Exact Bayesian and particle filtering of stochastic hybrid systems [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(1), 55-70.
- [4] A. Munit, D.P. Atherton, Maneuvering Target Tracking Using an Adaptive Interacting Multiple Model Algorithm [C]. *Proceedings of American Control Conference*.1994, 2.1324-1328.
- [5] X.R Li., Y Bar-Shalom. Multiple Model Estimation with Variable Structure [J]. *IEEE Transactions on American Control*, 1996, 24(1):478-493.
- [6] T. Kirubarajan, Y. Bar-Shalom, P. Pattipatik, I. Kadar, Ground Target Tracking with Variable Structure IMM Estimator [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(1): 26-44.
- [7] C. E. Seah, I. Hwang, State estimation for stochastic linear hybrid systems with continuous-state-dependent transitions: an IMM approach [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 45(1), 376-392.
- [8] B. Ristic, Vo. B T, Vo. B N, et al. A tutorial on Bernoulli filters: theory, implementation and applications [J]. *Signal Processing*, IEEE Transactions on, 2013, 61(13): 3406-3430
- [9] 连峰, 韩崇昭, 李晨. 多模型 GM-CBMeMBer 滤波器及航迹形成 [J]. *自动化学报*. 2014, 40(2).
- [10] X.R. Li, V. P. Jilkov, Survey of Maneuvering Target Tracking. Part V: Multiple-Model Methods [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(4).
- [11] 杨威, 基于有限集统计学理论的机动目标联合检测、跟踪与分类技术研究 [D]. 2012.

作者简介:

张婉莹 (1993-), 女, 陕西西安, 硕士, 信息融合, 目标跟踪与识别。

E-mail:zhangwanying0418@163.com

基金项目:

国家自然科学基金(61135001,61374159,61374203)