

DOI:10.20079/j.issn.1001-893x.221206008

## 区间量测下自适应交互多模型箱粒子滤波机动目标跟踪\*

张俊根

(北方民族大学 电气信息工程学院, 银川 750021)

**摘要:**针对现有交互多模型箱粒子滤波(Interacting Multiple Model Box Particle Filter, IMMBPF)算法在区间量测目标跟踪过程中模型切换和跟踪精度方面的不足,结合自适应交互多模型算法,提出了一种自适应交互多模型箱粒子滤波(Adaptive IMMBPF, AIMMBPF)算法。该算法利用模型似然后验信息构建修正因子,并结合阈值对马尔可夫转移概率矩阵进行自适应修正,使得匹配模型的概率快速增大,并且可以减小非匹配模型的影响,即使在目标运动模型先验信息不足或者不准确情况下,也能对模型转移概率进行自适应更新。对于量测常受到未知分布和偏差的区间误差所影响而呈现区间形式的问题,将箱粒子代替普通粒子,拟合后验概率密度从而进行滤波。仿真结果表明,相比于原有算法,该算法在区间量测机动目标跟踪的应用中,拥有更优的模型匹配度和目标跟踪精度。

**关键词:**机动目标跟踪;箱粒子滤波;自适应交互多模型;区间量测;转移概率矩阵

开放科学(资源服务)标识码(OSID):



微信扫描二维码  
听独家语音释文  
与作者在线交流  
享本刊专属服务

中图分类号:TN953 文献标志码:A 文章编号:1001-893X(2024)04-0591-07

## An Adaptive IMMBPF Algorithm for Maneuvering Target Tracking with Interval Measurement

ZHANG Jungen

(School of Electrical and Information Engineering, North Minzu University, Yinchuan 750021, China)

**Abstract:** In order to solve the defect of model switching and tracking accuracy of the existing Interacting Multiple Model Box Particle Filter(IMMBPF) algorithm in interval measurement target tracking, combined with Adaptive Interacting Multiple Model(AIMM) algorithm, an adaptive IMMBPF(AIMMBPF) algorithm is proposed. The algorithm uses posteriori information of model likelihood to construct a coefficient and combines the threshold value to adaptively modify the Markov probability transition matrix, which makes the probability of the matching model increase rapidly, and can reduce the effects of the mismatched model. Even if the prior information of the target motion model is insufficient or inaccurate, the model transition probability can be updated adaptively. To solve the problem that the measurement is often affected by the interval error of unknown distribution and deviation and can be expressed in interval form, box particles are used instead of ordinary particles to fit a posterior probability density for filtering. The simulation results show that the adaptive IMMBPF algorithm has better model matching performance and target tracking accuracy than the original algorithms in the application of maneuvering target tracking with interval measurement.

**Key words:** maneuvering target tracking; box particle filter; adaptive interacting multiple model; interval measurement; probability transition matrix

\* 收稿日期:2022-12-06;修回日期:2023-01-14  
基金项目:宁夏自然科学基金资助项目(2021AAC03226)  
通信作者:张俊根 Email:zhang\_jungen@126.com

## 0 引言

目标跟踪是利用如雷达、红外等传感器获得目标的量测信息对目标状态进行估计,在军事和民用领域应用非常广泛<sup>[1-2]</sup>。

由于目标动态建模与量测建模坐标系转换过程中以及量测传感器自身物理特性造成模型的非线性问题,贝叶斯最优估计通常不能获得解析解。为此,相关学者在卡尔曼滤波基础上,提出了改进方法,如改进极性扩展卡尔曼滤波<sup>[3]</sup>、增广系综卡尔曼滤波<sup>[4]</sup>、无迹卡尔曼滤波<sup>[5]</sup>及伪线性卡尔曼滤波<sup>[6]</sup>等。当系统非线性、非高斯特性较强时,这类算法滤波性能急剧下降甚至会发散。粒子滤波(Particle Filter, PF)是一种基于蒙特卡罗积分的非线性、非高斯滤波器,具有更好的灵活性、更优的估计精度及更广的适用性,逐渐成为了研究目标跟踪问题的热点和有效方法<sup>[7]</sup>。粒子滤波的一个主要缺点是计算复杂度<sup>[8]</sup>,在实时目标跟踪的应用中有局限性。

对于机动目标跟踪,由于目标运动状态不单一且无法预测,结合交互多模型(Interacting Multiple Model, IMM)算法是常用的解决方法<sup>[9-10]</sup>。IMM 算法利用多个模型来适应机动目标的运动,通过马尔可夫转移概率矩阵实现模型间的转换。但是,传统的 IMM 算法是根据先验信息将转移概率矩阵设定为固定的主对角占优矩阵,不能依据后验信息对转移概率进行实时调整,将导致模型切换滞后。当先验信息不足或者不准确,使用固定的转移概率矩阵往往会导致目标状态估计不准确,滤波性能下降,甚至算法失效<sup>[11]</sup>。为此,许多学者提出了改进方法<sup>[12-15]</sup>。

在实际应用中,比如,在复杂分布系统和无线传感网络中,量测会受到未知分布的边界误差影响,使得该类非标准的量测呈现区间形式<sup>[16]</sup>。为解决区间量测条件下的机动目标跟踪问题,文献[17]提出了交互多模型箱粒子滤波(Interacting Multiple Model Box Particle Filter, IMMBPF)算法,改善了目标跟踪效率,但在目标跟踪过程中存在模型切换和跟踪精度方面的不足。因此,本文充分利用后验信息,对马尔可夫转移概率矩阵进行修正,提出一种自适应交互多模型箱粒子滤波(Adaptive Interacting Multiple Model Box Particle Filter, AIMMBPF)算法。仿真结果表明,该算法的模型匹配度更优,且目标跟踪精度比原有 IMMBPF 算法高。

## 1 问题描述

区间量测下多模型目标跟踪系统可以由一组状态方程和量测方程表示:

$$\mathbf{x}_{k+1} = \mathbf{F}_{m_k} \mathbf{x}_k + \mathbf{w}_{k, m_k} \quad (1)$$

$$[\mathbf{z}_k] = \mathbf{H}(\mathbf{x}_k) + \mathbf{v}_k \quad (2)$$

式中:  $\mathbf{x}_k = [x(k), \dot{x}(k), y(k), \dot{y}(k)]^T$  是  $k$  时刻目标状态,包含位置分量  $x(k), y(k)$ , 速度分量  $\dot{x}(k), \dot{y}(k)$ ;  $\mathbf{F}_{m_k}$  为对应于模型  $m_k$  的状态转移矩阵,  $m_k \in \{1, 2, \dots, M\}$ ,  $M$  表示模型数的最大值;  $\mathbf{w}_{k, m_k}$  是过程噪声,  $\mathbf{v}_k$  为量测噪声,假定  $\mathbf{w}_{k, m_k}$  和  $\mathbf{v}_k$  相互独立,  $\mathbf{w}_{k, m_k}$  服从均值为 0、协方差为  $\mathbf{Q}_{m_k}$  的高斯分布,  $\mathbf{v}_k$  服从均值为 0、协方差为  $\mathbf{R}_k$  的高斯分布;  $\mathbf{H}(\mathbf{x}_k)$  是量测函数;  $[\mathbf{z}_k]$  为区间量测,区间的定义如下:  $[\mathbf{z}] = [\underline{\mathbf{z}}, \bar{\mathbf{z}}]$ ,  $\underline{\mathbf{z}}$  和  $\bar{\mathbf{z}}$  分别为区间  $[\mathbf{z}]$  的下界和上界,即  $\underline{\mathbf{z}} \leq \mathbf{z} \leq \bar{\mathbf{z}}$ 。

IMM 算法中,利用  $M$  个模型对目标运动进行模拟,从  $k$  时刻的模型  $\alpha$  变换到  $k+1$  时刻的模型  $\beta$ ,可以建模为一个概率已知且时不变的马尔可夫链,即

$$\Pr\{m_{k+1} = \beta | m_k = \alpha\} = \pi_k^{\alpha\beta} \quad (3)$$

式中:  $\pi_k^{\alpha\beta}$  是模型转移概率,  $\alpha, \beta \in \{1, 2, \dots, M\}$ 。传统 IMM 算法是根据经验事先给定一个模型转移概率  $\pi_k^{\alpha\beta}$ ,它是固定值,不随时刻  $k$  而改变,这与目标实际的运动状态不相符,造成算法稳定性和跟踪精度不高。

## 2 基于自适应 IMMBPF 的目标跟踪算法

### 2.1 转移概率矩阵自适应更新策略

根据模型似然函数来实时计算转移概率矩阵并进行修正,可以充分利用模型的后验信息。假设模型转移概率初始值  $\pi_0^{\alpha\beta}$  已知,  $k$  时刻模型  $\alpha$  的似然函数为  $\Lambda_k^\alpha$ ,引入修正因子  $\lambda_k^{\alpha\beta}$ ,计算如下:

$$\lambda_k^{\alpha\beta} = \frac{\pi_k^{\beta\alpha} \cdot \Lambda_k^\beta}{\pi_k^{\alpha\beta} \cdot \Lambda_k^\alpha} \quad (4)$$

计算模型转移概率  $\pi_k^{\prime\alpha\beta}$ :

$$\pi_k^{\prime\alpha\beta} = \lambda_k^{\alpha\beta} \cdot \pi_k^{\alpha\beta} \quad (5)$$

当目标运动从不匹配模型转移到匹配模型时,模型转移概率会变得越来越大,同时当其转移到自身时,模型转移概率又变得越来越小,此时转移概率矩阵主对角线占优原则就不再成立<sup>[13]</sup>。为保证转移概率矩阵主对角元素占优,设置一个阈值  $\text{Th}$ ,对矩阵主对角元素进行判断。当  $\pi_k^{\prime\alpha\alpha} \geq \text{Th}$ ,即按

式(5)计算模型转移概率;当  $\pi_k^{\alpha\alpha} < \text{Th}$ , 需要结合该阈值进行修正。具体描述如下式所示:

$$\begin{cases} \pi_k^{\alpha\alpha} \geq \text{Th} \begin{cases} \pi_k^{\alpha\alpha} = \pi_k^{\alpha\alpha} \\ \pi_k^{\alpha\beta} = \pi_k^{\alpha\beta}, \alpha \neq \beta \end{cases} \\ \pi_k^{\alpha\alpha} < \text{Th} \begin{cases} \pi_k^{\alpha\alpha} = \text{Th} \\ \pi_k^{\alpha\beta} = (1 - \text{Th}) \frac{\pi_k^{\alpha\beta}}{1 - \pi_k^{\alpha\alpha}}, \alpha \neq \beta \end{cases} \end{cases} \quad (6)$$

经过验证可以看出,式(6)修正的转移概率矩阵仍然满足两个基本要求:

1) 矩阵每个元素作为概率值, 即有  $0 \leq \pi_k^{\alpha\beta} \leq 1$ ;

2) 矩阵的每一行元素是一个模型转移到所有模型的概率, 其和要等于 1, 即  $\sum_{\beta=1}^M \pi_k^{\alpha\beta} = 1$ 。

## 2.2 AIMMBPF 算法

本文提出的 AIMMBPF 算法是在 IMMBPF 算法<sup>[17]</sup>基础上增加了转移概率矩阵自适应更新步骤, 并做了相应计算式子上的改变, 主要包含以下 6 个迭代步骤: 箱粒子生成; 模型交互; 箱粒子滤波; 模型后验概率更新; 转移概率矩阵更新; 状态融合输出。

### 1) 箱粒子生成

利用  $k-1$  时刻的区间量测  $[\mathbf{z}_{k-1}]$ , 生成新生箱粒子。对于每一个  $[\mathbf{z}_{k-1}]$ , 新生箱粒子密度用一组均匀分布的概率密度函数的和来近似, 如下式所示:

$$\beta(\mathbf{x} | [\mathbf{z}_{k-1}]) \approx \frac{1}{N_b} \sum_{i_b=1}^{N_b} U_{[\mathbf{x}_{b,k-1}]}^{(i_b)}(\mathbf{x}) \quad (7)$$

式中:  $[\mathbf{x}_{b,k-1}]$  为新生箱粒子;  $N_b$  为新生箱粒子数的最大值;  $U_{[\mathbf{x}_{b,k-1}]}^{(i_b)}(\mathbf{x})$  是箱粒子  $[\mathbf{x}_{b,k-1}]$  上的均匀分布概率密度函数。

新生箱粒子由两部分组成: 位置分量  $[\mathbf{p}]$  和速度分量  $[\mathbf{u}]$ , 即  $[\mathbf{x}_{b,k-1}] = [[\mathbf{p}]^T, [\mathbf{u}]^T]^T$ ,  $[\mathbf{p}] = [H^{-1}]( [\mathbf{z}_{k-1}] )$ ,  $H^{-1}$  代表量测函数的反函数,  $[\mathbf{u}] \approx [\text{support}(p_0(u))]$  为包含先验值  $p_0(\mathbf{u})$  的均匀分布, 每个箱粒子的权值为  $1/N_b$ 。

在  $k-1$  时刻, 对应于  $\alpha$  模型的箱粒子集由新生箱粒子  $\{[\mathbf{x}_{\alpha,k-1}^{(i_b)}]\}_{i_b=1}^{N_b}$  和存活箱粒子  $\{[\mathbf{x}_{\alpha,k-1}^{(i_p)}]\}_{i_p=1}^{N_p}$  组成, 可表示为

$$\{[\mathbf{x}_{\alpha,k-1}^{(i)}]\}_{i=1}^N = \{[\mathbf{x}_{\alpha,k-1}^{(i_b)}]\}_{i_b=1}^{N_b} \cup \{[\mathbf{x}_{\alpha,k-1}^{(i_p)}]\}_{i_p=1}^{N_p} \quad (8)$$

式中:  $N_p$  为存活箱粒子的最大数;  $N$  为箱粒子总数,  $N = N_b + N_p$ 。

### 2) 模型交互

$k-1$  时刻, 计算  $\alpha$  模型转移到  $\beta$  模型的概率:

$$\mu_{\alpha|\beta,k-1|k-1} = \frac{1}{c_\beta} \pi_{k-1}^{\alpha\beta} \cdot \mu_{\alpha,k-1} \quad (9)$$

式中:  $c_\beta$  为归一化系数,  $c_\beta = \sum_{\alpha=1}^M \pi_{k-1}^{\alpha\beta} \cdot \mu_{\alpha,k-1}$ ;  $\mu_{\alpha,k-1}$  表示  $k-1$  时刻  $\alpha$  模型的概率。

通过下式计算, 得到模型  $\beta$  的交互箱粒子:

$$[\mathbf{x}_{\beta,k-1}^{(i)}] = \sum_{\alpha=1}^M \mu_{\alpha|\beta,k-1|k-1} \cdot [\mathbf{x}_{\alpha,k-1}^{(i)}] \quad (10)$$

式中:  $i = 1, 2, \dots, N$ 。

### 3) 箱粒子滤波

对于模型  $\alpha$ , 计算预测箱粒子为

$$[\mathbf{x}_{\alpha,k|k-1}^{(i)}] = \mathbf{F}_\alpha \cdot [\mathbf{x}_{\alpha,k-1}^{(i)}] + [\mathbf{w}_k] \quad (11)$$

预测区间量测为

$$[\mathbf{z}_{\alpha,k|k-1}^{(i)}] = H([\mathbf{x}_{\alpha,k|k-1}^{(i)}]) \quad (12)$$

利用区间压缩算法<sup>[17]</sup>, 将箱粒子的区域压缩在一个合适的范围, 可获得压缩后的箱粒子  $[\mathbf{x}'_{\alpha,k|k-1}^{(i)}]$  及区间量测  $[\mathbf{z}'_{\alpha,k|k-1}^{(i)}]$ 。

计算箱粒子的权值, 并进行归一化:

$$\omega_{\alpha,k|k-1}^{(i)} = \frac{|[\mathbf{z}_k] \cap [\mathbf{z}'_{\alpha,k|k-1}^{(i)}]|}{|[\mathbf{z}'_{\alpha,k|k-1}^{(i)}]|} \quad (13)$$

$$\bar{\omega}_{\alpha,k|k-1}^{(i)} = \frac{\omega_{\alpha,k|k-1}^{(i)}}{\sum_{i=1}^N \omega_{\alpha,k|k-1}^{(i)}} \quad (14)$$

利用随机子划分的方法, 对箱粒子  $\{[\mathbf{x}'_{\alpha,k|k-1}^{(i)}]\}_{i=1}^N$  进行重采样, 可以获得一组新的箱粒子集  $\{[\mathbf{x}_{\alpha,k|k}^{(i)}], \omega_{\alpha,k|k}^{(i)} = 1/N\}_{i=1}^N$ 。

计算  $\alpha$  模型的箱粒子滤波输出:

$$[\mathbf{x}_{\alpha,k|k}] = \frac{1}{N} \sum_{i=1}^N [\mathbf{x}_{\alpha,k|k}^{(i)}] \quad (15)$$

### 4) 模型后验概率更新

对于任一模型  $\alpha$ , 计算模型的似然函数为

$$\Lambda_k^\alpha = \frac{1}{N} \sum_{i=1}^N \omega_{\alpha,k|k-1}^{(i)} \quad (16)$$

更新模型后验概率为

$$\mu_{\alpha,k} = \frac{\Lambda_k^\alpha \sum_{\beta=1}^M \pi_{k-1}^{\beta\alpha} \mu_{\beta,k-1|k-1}}{\sum_{\alpha=1}^M \Lambda_k^\alpha \sum_{\beta=1}^M \pi_{k-1}^{\beta\alpha} \mu_{\beta,k-1|k-1}} \quad (17)$$

### 5) 转移概率矩阵更新

利用式(6), 对转移概率矩阵进行实时更新。

### 6) 状态融合输出

利用更新的模型后验概率, 对各模型滤波输出的区间中间值进行加权融合, 得到更新的目标状态:

$$\mathbf{x}_k = \sum_{\alpha=1}^M \mu_{\alpha,k} \cdot \text{mid}[\mathbf{x}_{\alpha,k|k}] \quad (18)$$

式中:  $\text{mid}[\mathbf{x}_{\alpha,k|k}]$  为区间  $[\mathbf{x}_{\alpha,k|k}]$  的中间值。

### 3 仿真实验与分析

为了验证所提出的 AIMMBPF 算法的性能,并与交互多模型粒子滤波(Interacting Multiple Model Particle Filter, IMMPF)算法和 IMMBPF 算法作对比。进行 100 次蒙特卡罗仿真实验,利用均方根误差(Root Mean Square Error, RMSE)评价算法的性能,定义如下:

$$E_{\text{RMS}}(k) = \left( \frac{1}{100} \sum_{l=1}^{100} [\|\mathbf{x}_k - \hat{\mathbf{x}}_k^l\|^2] \right)^{\frac{1}{2}} \quad (19)$$

式中:  $\mathbf{x}_k$  表示目标状态的真实值;  $\hat{\mathbf{x}}_k^l$  为第  $l$  次仿真中算法对目标状态的估计值。RMSE 的均值计算公式如下:

$$A_{\text{RMSE}} = \sum_{k=1}^{N_t} E_{\text{RMS}}(k) \quad (20)$$

式中:  $N_t$  表示目标跟踪总时间。

#### 3.1 仿真实验设置

系统模型由式(1)和式(2)描述,假设目标在二维平面上运动,目标初始位置为(100 m, 0 m),初始速度为(100 m/s, 80 m/s)。目标在 0~20 s 做匀速直线运动,在 21~40 s 做匀速右转弯运动,在 41~60 s 做匀速直线运动,在 61~80 s 做匀速左转弯运动,在 81~100 s 做匀速直线运动。

目标运动模型集选用以下 3 个模型:匀速直线 CV 模型、匀速右转弯 CT 模型和匀速左转弯 CT 模型。令  $m_k \in \{1, 2, 3\}$ , 分别表示以上 3 个模型,状态转移矩阵  $\mathbf{F}_{m_k}$  分别为

$$\mathbf{F}_1 = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (21)$$

$$\mathbf{F}_{2,3}(\zeta) = \begin{bmatrix} 1 & \frac{\sin(\zeta T)}{\zeta} & 0 & -\frac{1-\cos(\zeta T)}{\zeta} \\ 0 & \cos(\zeta T) & 0 & -\sin(\zeta T) \\ 0 & \frac{1-\cos(\zeta T)}{\zeta} & 1 & \frac{\sin(\zeta T)}{\zeta} \\ 0 & \sin(\zeta T) & 0 & \cos(\zeta T) \end{bmatrix} \quad (22)$$

式中:  $T$  为采样间隔,  $T = 1$  s;  $\zeta$  为转弯角速度,  $\zeta =$

5 °/s 表示左转弯,  $\zeta = -5$  °/s 表示右转弯。

3 个模型的过程噪声协方差矩阵  $\mathbf{Q}_{m_k}$  设为

$$\mathbf{Q}_{m_k} = \begin{bmatrix} 25 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 25 & 0 \\ 0 & 0 & 0 & 4 \end{bmatrix} \quad (23)$$

初始模型概率为  $\mu_{1,0} = \mu_{2,0} = \mu_{3,0} = 1/3$ , 模型转移概率矩阵初始值设为

$$\begin{bmatrix} \pi_0^{11} & \pi_0^{12} & \pi_0^{13} \\ \pi_0^{21} & \pi_0^{22} & \pi_0^{23} \\ \pi_0^{31} & \pi_0^{32} & \pi_0^{33} \end{bmatrix} = \begin{bmatrix} 0.7 & 0.15 & 0.15 \\ 0.15 & 0.7 & 0.15 \\ 0.15 & 0.15 & 0.7 \end{bmatrix} \quad (24)$$

量测函数  $H(\mathbf{x}_k)$  为

$$H(\mathbf{x}_k) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x}_k \quad (25)$$

量测噪声协方差矩阵如下:

$$\mathbf{R} = \begin{bmatrix} 400 & 0 \\ 0 & 400 \end{bmatrix} \quad (26)$$

区间量测长度设为 150 m, 新生箱粒子的速度分量服从均匀分布  $U[-150 \text{ m/s}, 150 \text{ m/s}]$ 。

IMMPF 的总粒子数为 1 500, 新生粒子数为 500。对于 IMMBPF 和 AIMMBPF 算法, 总箱粒子数为 60, 新生箱粒子数为 10。转移概率自适应更新阈值设为 0.9。本文所有实验都是在同一台电脑环境(CPU 型号为 i7-7500U, 内存为 4 GB)下通过 Matlab 实现的。

#### 3.2 算法性能对比

图 1 给出了某次实验中 3 种算法的目标跟踪轨迹对比, 可以看出, 本文提出的 AIMMBPF 算法、IMMPF 算法和 IMMBPF 算法都能实现对机动目标的有效跟踪。




图 1 3 种算法的目标跟踪轨迹对比

Fig. 1 Target tracking trajectories of three algorithms

经过 100 次蒙特卡罗实验后,得到了 3 种算法的位置均方根误差和速度均方根误差,分别如图 2 和图 3 所示。对图 2 和图 3 的数据进行分析,根据式(20),分别得到位置和速度估计的均方根误差的均值,如表 1 所示。




图 2 3 种算法的位置均方根误差  
Fig. 2 Position RMSE of three algorithms




图 3 3 种算法的速度均方根误差  
Fig. 3 Velocity RMSE of three algorithms

| 表 1 3 种算法的状态估计 ARMSE 对比                            |            |                |
|----------------------------------------------------|------------|----------------|
| Table 1 State estimation ARMSE of three algorithms |            |                |
| 算法                                                 | 位置 ARMSE/m | 速度 ARMSE/(m/s) |
| IMMPF                                              | 50.753 5   | 38.788 4       |
| IMMBPF                                             | 49.503 7   | 59.138 5       |
| AIMMBPF                                            | 44.288 8   | 32.779 8       |

从图 2、图 3 和表 1 可以看出,在位置跟踪方面,IMMPF 算法的误差最大,IMMBPF 算法次之,AIMMBPF 算法的误差最小。从 ARMSE 指标看,AIMMBPF 算法相比于 IMMPF 算法和 IMMBPF 算法的跟踪精度分别提升了 12.74% 和 10.53%。在速度跟踪方面,IMMBPF 算法的误差最大,主要是由于 IMMBPF 算法在压缩箱粒子时没有考虑目标速度分量,在模型匹配度不高的情况下速度跟踪劣势更加明显。AIMMBPF 算法由于模型转移概率能自适应

实时修正,模型匹配度更高,跟踪误差最小。相比于 IMMPF 算法和 IMMBPF 算法,AIMMBPF 算法的 ARMSE 分别减小了 15.49% 和 44.57%。

图 4~6 分别给出了 3 种算法的各模型概率,可以看出,本文提出的 AIMMBPF 算法能使系统迅速调整到匹配模型,且匹配模型的概率更加接近于 1,不匹配模型的概率更加接近于 0,而 IMMPF 算法和 IMMBPF 算法模型的切换及主次模型都不够分明。




图 4 IMMPF 算法的各模型概率  
Fig. 4 Model probability of IMMPF algorithm




图 5 IMMBPF 算法的各模型概率  
Fig. 5 Model probability of IMMBPF algorithm




图 6 AIMMBPF 算法的各模型概率  
Fig. 6 Model probability of AIMMBPF algorithm

本文利用运行时间来评价算法计算复杂度。不同算法执行一次完整的目标跟踪的运行时间如表 2

所示,可以看出,IMMPF 算法耗时最大,AIMMBPF 算法的运行时间约为 IMMPF 算法的 20%,由于增加了模型转移概率自适应修正计算步骤,比 IMMBPF 算法耗时略大。

表 2 3 种算法的运行时间对比  
Tab. 2 The running time of three algorithms

| 算法      | 运行时间/s    |
|---------|-----------|
| IMMPF   | 155.232 9 |
| IMMBPF  | 29.798 3  |
| AIMMBPF | 30.425 4  |

3.3 模型转移概率初始值对算法性能的影响

本节通过改变模型转移概率初始值来评价算法的性能。模型转移概率初始值是根据文献[12]的方法进行设计,即

$$\pi_0^{\alpha\beta} = \frac{1 - \pi_0^{\alpha\alpha}}{M - 1}, \alpha \neq \beta \quad (27)$$

仿真设定  $\pi_0^{\alpha\alpha}$  在 0.5~0.9 内均匀变化,步进为 0.05;其他实验参数保持一致。3 种算法的位置和速度 ARMSE 对比分别如图 7 和图 8 所示。




图 7 不同模型转移概率初始值下 3 种算法的位置 ARMSE  
Fig. 7 Position ARMSE of three algorithms under different model transition probability initial values




图 8 不同模型转移概率初始值下 3 种算法的速度 ARMSE  
Fig. 8 Velocity ARMSE of three algorithms under different model transition probability initial values

从图 7 和图 8 可以看出,当  $\pi_0^{\alpha\alpha} < 0.8$  时,相对于 IMMPF 算法和 IMMBPF 算法,AIMMBPF 算法的目标跟踪误差最小,而且对于较小的  $\pi_0^{\alpha\alpha}$ ,AIMMBPF 算法的跟踪精度优势更加明显。在  $\pi_0^{\alpha\alpha}$  从 0.5 变化到 0.9 的过程中,AIMMBPF 算法的跟踪误差都比较稳定,这说明 AIMMBPF 算法对模型转移概率初始值的要求不高,即使在目标运动模型先验信息不足或者不准确情况下也能对模型转移概率进行自适应更新,从而提高模型匹配度,最终提高了目标跟踪精度。

3.4 滤波初始误差对算法性能的影响

本节通过改变滤波初始误差来评价算法的性能。对目标初始状态  $x_1$  施加一个标准正态分布噪声:

$$x_1 + \varepsilon \cdot \text{diag}(80, 40, 80, 40) \cdot \text{randn}(4, 1) \quad (28)$$

式中:diag(·)表示对角矩阵;randn(·)表示标准正态分布; $\varepsilon$  是误差系数。仿真设定  $\varepsilon$  在 0~2 内均匀变化,步进为 0.2;其他参数不变。图 9 和图 10 分别给出了这 3 种算法的位置和速度 ARMSE 对比。




图 9 不同滤波初始误差下 3 种算法的位置 ARMSE  
Fig. 9 Position ARMSE of three algorithms under different initial filtering errors




图 10 不同滤波初始误差下 3 种算法的速度 ARMSE  
Fig. 10 Velocity ARMSE of three algorithms under different initial filtering errors

从图 9 和图 10 可以看出,这 3 种算法在不同滤波初始误差下,目标位置和速度估计误差变化都较小,跟踪精度都比较稳定,表明这些算法对滤波初始误差不敏感,基本不会受到滤波初始误差的影响。

#### 4 结束语

本文针对区间量测下的机动目标跟踪问题,在 IMMBPF 算法的基础上提出了一种自适应 IMMBPF 算法。该算法能够充分利用后验信息,对模型转移概率矩阵进行自适应更新,可以增大匹配模型的概率,同时减小非匹配模型的影响。仿真结果表明,本文提出的 AIMMBPF 算法相比于现有算法拥有更优的模型匹配度和目标跟踪精度。

下一步工作将重点研究模型集设计方法,将强跟踪修正输入估计模型与自适应交互多模型相结合,进一步提高目标跟踪精度。

#### 参考文献:

- [ 1 ] LI X H,ZHAO C X,LU X F,et al. Underwater bearings-only multitarget tracking based on modified PMHT in dense-cluttered environment[J]. IEEE Access,2019,7: 93678-93689.
- [ 2 ] 郑丹阳,曹林,王涛,等. 一种基于变分推断的雷达多目标跟踪 JPDA 算法[J]. 电讯技术,2021,61(12): 1540-1546.
- [ 3 ] JAWAHAR A, RAO S K. Modified polar extended Kalman filter(MPEKF) for bearings-only target tracking[J]. Indian Journal of Science and Technology,2016,26(9):1-5.
- [ 4 ] SUN T,XIN M. Bearings-only tracking using augmented ensemble Kalman filter[J]. IEEE Transactions on Control Systems Technology,2019,28(3):1009-1016.
- [ 5 ] LI L Q,WANG X L,LIU Z X,et al. Auxiliary truncated unscented Kalman filtering for bearings-only maneuvering target tracking[J]. Sensors,2017,17(5):1-14.
- [ 6 ] 郭戈,王兴凯,徐慧朴. 基于递归工具变量卡尔曼滤波算法的纯方位水下目标跟踪[J]. 控制与决策,2020,35(1):107-114.
- [ 7 ] 张宏伟. 双站纯方位空时软约束无迹粒子滤波算法[J]. 系统工程与电子技术,2023,45(5):1261-1269.
- [ 8 ] DAUM F. Nonlinear filters; beyond the Kalman filter[J]. IEEE Aerospace and Electronic Systems Magazine,2005,20(8):57-69.
- [ 9 ] LIM J,KIM H S,PARK H M. Interactive-multiple-model algorithm based on minimax particle filtering[J]. IEEE Signal Processing Letters,2020,27:36-40.
- [ 10 ] ZHANG H W,LI L Q,XIE W X. Constrained multiple model particle filtering for bearings-only maneuvering target tracking[J]. IEEE Access,2018,6:51721-51734.
- [ 11 ] 曾浩,母王强,杨顺平. 高机动目标跟踪 ATPM-IMM 算法[J]. 通信学报,2022,43(7):93-101.
- [ 12 ] 许登荣,程水英,包守亮. 自适应转移概率交互式多模型跟踪算法[J]. 电子学报,2017,45(9):2113-2120.
- [ 13 ] 叶瑾,许枫,杨娟,等. 一种改进的时变转移概率 AIMM 跟踪算法[J]. 应用声学,2020,39(2):246-252.
- [ 14 ] 周非,罗晓勇,刘云萍. 基于概率模型的实时修正 IMM 目标跟踪算法[J]. 计算机工程与应用,2020,56(21):85-92.
- [ 15 ] 王平波,刘杨. 基于改进自适应 IMM-UKF 算法的水下目标跟踪[J]. 电子与信息学报,2022,44(6):1999-2005.
- [ 16 ] 吴孙勇,张馨方,桂丛楠,等. 区间量测下基于无迹变换的伯努利粒子滤波算法[J]. 控制与决策,2017,32(8):1523-1527.
- [ 17 ] 张俊根. 基于 IMMBPF 的纯方位区间量测机动目标跟踪[J]. 控制工程,2022,29(12):2277-2283.

#### 作者简介:

张俊根 男,1979 年生于江西鹰潭,2011 年于西安电子科技大学获博士学位,现为讲师,主要研究方向为信号处理、目标跟踪等。