

基于时变转移概率矩阵的交互式 多模型粒子滤波算法

任泽民, 王忠华

(华东电子工程研究所, 合肥 230000)

摘要:现代雷达已具备多维度、全空域的探测与跟踪能力,随着空中目标机动性的增强以及电磁环境的复杂化,目标跟踪作为雷达的关键技术,其对跟踪精度和实时响应能力的要求不断提高,根据上述要求,文章围绕雷达目标跟踪中的滤波算法展开研究,针对传统交互式多模型算法在跟踪机动目标时精度低的问题,文章通过实时修正马尔科夫转移概率矩阵,实现了自适应交互式多模型粒子滤波,提升了匹配模型概率和模型切换响应速度;通过仿真分析对比,改进的算法在位置跟踪精度方面相较于常规算法提升了16.1%,在速度跟踪精度方面提升了26.8%,证明了改进算法在机动性适应方面的显著优势。

关键词:雷达; 目标跟踪; 马尔科夫转移概率矩阵; 自适应交互式多模型粒子滤波

Interacting Multiple Model Particle Filter Algorithm Based on Time-Varying Transition Probability Matrix

REN Zemin, WANG Zhonghua

(East China Research Institute of Electronic Engineering, Hefei 230000, China)

Abstract: Modern airborne radar systems have been equipped with multi-dimensional and full-airspace capabilities for detection and tracking. With the increasing maneuverability of airborne targets and the complexity of the electromagnetic environment, target tracking, as a key radar technology, is facing ever-growing demands for tracking accuracy and real-time response capability. In response to these challenges, filtering algorithms for air-to-air multi-target tracking in airborne radar systems are investigated in this thesis. To address the low tracking accuracy of traditional Interactive Multiple Model (IMM) algorithms for maneuvering targets, an Adaptive IMM Particle Filter is proposed by correcting the Markov transition probability matrix. Model matching and switching responsiveness are enhanced by the proposed method. Simulation results demonstrate that position tracking accuracy is improved by 16.1%, and velocity tracking accuracy is improved by 26.8%, compared to conventional approaches, highlighting its significant advantage in maneuverability adaptation.

Keywords: radar; target tracking; markov transition probability matrix; adaptive IMM particle filter

0 引言

随着航空航天技术的发展和环境的复杂多变,空中目标跟踪技术正经历着系统性革新^[1],在这个过程中机载雷达扮演着至关重要的角色。机载雷达通过天线发射电磁波对探测方向进行照射,如果探测方向出现目标或者是其它物体,部分电磁波在照射目标时被反射,反射

回的部分电磁波被雷达天线接收从而实现对目标信息的获取。通过对目标信息的处理从而为任务提供精确的位置和运动状态信息^[2]。

然而随着航空航天技术的发展,机动目标的运动特性、目标的机动性以及越来越复杂的空中环境^[3],传统的目标跟踪技术在目标机动性、跟踪精度和实时性等方面已无法满足对目标的跟踪。我们需要针对特定的目标

收稿日期:2025-12-02; 修回日期:2025-12-03。

作者简介:任泽民(1998-),男,硕士研究生,助理工程师。

引用格式:任泽民,王忠华. 基于时变转移概率矩阵的交互式多模型粒子滤波算法[J]. 计算机测量与控制,2025,33(12):321-328.

和环境提出新的目标跟踪技术，从而提升目标跟踪的精度与实时性，因此对目标跟踪新方向的研究具有学术和现实意义。

滤波跟踪是目标跟踪中的核心环节之一。滤波跟踪算法最早可追溯到最小二乘法^[4]。文献[5]提出了 Winner 滤波。Winner 滤波是一种基于最小均方误差(MMSE, minimum mean square error,)准则的滤波方法，是最小二乘法的一种推广，但是 Winner 滤波对计算资源的要求较高且对非高斯噪声和异常值较为敏感。

文献[6]将只适用静态估计问题的 Winner 滤波改进为适用动态系统状态估计的 Kalman 滤波算法，这一改进具有划时代意义。文献[7-8]将最初针对离散时间系统设计的 Kalman 滤波理论扩展至连续时间系统。通过严谨的数学推导分析了状态估计问题的统计特性，使得线性系统在连续时间域内的状态估计成为可能。文献[9]通过对非线性系统线性化并结合 Kalman 滤波理论进行状态估计，提出了扩展 Kalman 滤波(EKFextended Kalman filter)。

在 20 世纪末，经典的线性滤波虽然在高斯噪声下表现优异，但是在处理非线性非高斯问题时面临挑战，而改进的线性滤波(EKF、UKF)需要对系统模型进行线性化或者无迹变换，仍对分布形状和非线性程度有较高的要求。因此需要寻找一种无需对模型进行线性化处理，能够直接在复杂分布下进行估计的方法^[10-12]。文献[13]提出了粒子滤波(PF, particle filter)的概念，即序列重要性采样(SIS, sequential importance sampling)，解决了非线性非高斯状态估计的问题。

但是粒子滤波在处理高维非线性系统的过程中，大量粒子权重趋于零，即出现粒子退化现象^[14-15]。为解决这一问题，文献[16]提出了序列蒙特卡罗方法，正式将重采样机制引入粒子滤波，显著提高了算法的稳定性。文献[17-23]都是在粒子滤波的基础上进行改进，提升算法在跟踪目标时的稳定性以及准确性，从而提高在复杂系统中的应用。

在雷达目标跟踪系统中，提升跟踪精度和实时性始终是核心指标。然而随着目标机动性的增强以及跟踪环境的日益复杂，传统的跟踪方法面临着严峻的挑战。跟踪高机动目标需构建精确的运动模型，复杂环境需设计稳定的滤波算法。针对上述问题，本文研究了自适应交互式多模型粒子滤波算法。将交互式多模型与粒子滤波结合，并针对交互式多模型中固定马尔科夫矩阵的局限性，提出自适应马尔科夫矩阵，使模型转移概率自适应更新。改进的算法提高了当前最优模型的保持能力，提升了模型之间的转换速率，从而提高状态估计精度。最后通过仿真分析验证了算法的优越性。

1 IMMPF 算法

1.1 粒子滤波

粒子滤波(PF)是一种基于蒙特卡洛方法的非线性状态估计算法。该算法通过序贯重要性采样实现贝叶斯递推，然后通过重采样机制赋值高权重粒子和淘汰低权重粒子来缓解粒子退化问题。粒子滤波不依赖于系统状态的高斯分布和线性化假设，而且能够自适应地逼近任意形式的后验分布，因此在实际问题中具有较强的适应性。粒子滤波中的每个粒子代表系统状态空间中的一个可能状态，这些粒子和它们的权重共同描述了系统当前状态的概率分布。通过系统的动态模型对粒子进行预测并利用新的观测数据更新粒子的权重，可以反映每个粒子状态的可能性。

粒子滤波的算法流程为：

1) 粒子初始化：

根据先验概率密度函数 $p(x_0)$ 生成 N 个独立同分布的采样粒子 $\{x_x^i\}_{i=1}^N$ ，每一个粒子代表系统可能的状态，并根据粒子代表状态重要性赋予相应的权重。然后循环步骤 2) ~5)。

2) 状态转移：

根据状态转移函数预测每个粒子在下一时刻的状态，并生成新的粒子。这一步骤考虑了系统的动态特性和过程噪声以便更准确模拟状态随时间的变化：

$$x_k^i \sim p(x_k | x_{k-1}^i) \quad (1)$$

3) 权重计算：

根据观测似然函数计算各粒子的非归一化权值，然后对所有粒子权值进行归一化处理。粒子的权重反应该粒子状态与测量数据的匹配程度，即粒子权重越大，其与实际状态之间的相似性越高：

$$w_k^i = w_{k-1}^i p(z_k | x_k^i) \quad (2)$$

权值归一化：

$$\tilde{w}_k^i = \frac{w_k^i}{\sum_1^N w_k^i} \quad (3)$$

4) 重采样：

在粒子滤波的迭代过程中，重要性权值的方差呈现单调性递增特性，导致粒子集出现权值极化现象，即仅有极少数粒子保持显著权值，其余粒子权值趋近于零。这种退化现象使得计算资源集中消耗在无效粒子的状态更新上，降低算法效率。通过重采样机制，在维持粒子总数不变的前提下，依据权值比例对粒子进行选择性复制与淘汰，重构粒子集的概率质量分布。其中高权值粒子通过多重复制增强其表征能力，而权重低于阈值的粒子被剔除，使得计算资源集中于最有可能表征系统当前状态的粒子，提升粒子滤波算法的效率。

重采样算法为:

初始化累计分布函数 (CDF): $c_1 = 0$

For $i=2: N$

构造 CDF: $c_i = c_{i-1} + w_k^i$

从 CDF 的底部开始: $i=1$

采样起始点 $u_1 \sim \varphi[0, 1/N]$

End For

For $j=1: N$

沿 CDF 移动: $u_j = u_i + (j-1) / N$

While $u_j > c_i$

$I=i+1$

End While

赋值粒子: $x_k^j = x_k^i$

赋值权值: $w_k^j = 1/N$

End For

5) 状态估计:

通过加权平均所有粒子的状态, 得到最终的目标状态估计和对应协方差矩阵:

$$\hat{x}_k = \sum_i^N \tilde{w}_k^i x_k^i \quad (4)$$

$$P_k = \frac{1}{N} (x_k^i - \hat{x}_k) (x_k^i - \hat{x}_k)^T + P_{k-1} \quad (5)$$

最终, 通过循环得到每一时刻的目标状态估计和估计协方差矩阵。

1.2 交互式多模型

交互式多模型 (IMM) 是多模型算法中协作式多模型的一种, 由 H. A. P. Blom 和 Y. B. Shalom 提出。IMM 算法通过并行运行多个不同的运动模型, 利用贝叶斯滤波机制在不同模型之间进行信息交互, 其中每个模型独立预测目标状态。IMM 算法在每个时刻根据目标的运动情况调整各模型的权重, 使整个跟踪系统能够快速适应目标的机动变化。例如, 在目标匀速运动时恒速模型的权重较高, 而当目标突然加速或转向时系统会迅速增加恒加速度或恒转向模型的权重, 使得跟踪算法能准确预测目标的下一步位置。单一模型在目标运动模式发生突变时往往无法迅速调整, 这样会导致预测误差增大。而 IMM 能够在多个模型之间平滑过渡, 减少模型不匹配带来的误差从而提高跟踪精度。因此相比于单一模型滤波器, IMM 具有更高的鲁棒性和适应性。此外, IMM 通过交互更新机制优化计算过程使得即使在多模型并行运行的情况下, 计算复杂度仍然低于简单的多个独立滤波器并行执行的方式, 从而实现较高的计算效率。

IMM 算法将模型切换过程建模为隐马尔可夫 (Markov) 链, 其中不同的运动模型之间的转换由

Markov 转移矩阵控制。Markov 矩阵用于描述不同模型之间的转移概率, 其能够确保算法在不同运动模式之间进行合理的权重分配以适应目标的动态变化。Markov 矩阵假设在每一个扫描时间内目标以先验概率 $\pi_{j|i}$ 从运动模型 i 转移到运动模型 j , 对于所有的运动模型组合有 $\sum_{j=1}^r \pi_{j|i} = 1$ 。在状态估计过程中, 每个运动模型都会根据自身的运动假设进行预测, 然后将预测结果与实际观测值进行匹配。为了衡量模型对当前观测数据的适配程度, IMM 算法计算每个模型的似然函数并根据似然函数实时更新模型概率, 最终的状态估计并不是直接使用某个单一模型的结果, 而是采用加权平均的方法将所有模型的状态估计进行融合。这种融合方式既考虑了不同运动模型的多样性, 在确保能够覆盖目标可能的运动模式的同时又通过概率加权的方式增强估计的精确性和鲁棒性。在实际应用中, Markov 矩阵的设定通常基于对系统动态模式切换特性的先验知识或历史数据。例如: 对于机动目标, 不同模型之间的转移概率可能较高以反映目标的高动态性; 对于低机动或稳定运动目标, 较低的模型间转移概率使得算法更倾向于维持当前模型的状态。

Markov 矩阵一种常见的设定方式为:

$$\pi = \begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.2 & 0.7 & 0.1 \\ 0.1 & 0.2 & 0.7 \end{bmatrix} \quad (6)$$

第一行表示如果当前目标处于模型 1, 那么有 90% 的概率继续保持在模型 1, 5% 的概率转移到模型 2, 5% 的概率转移到模型 3。类似地, 其他行也遵循相同的逻辑。合理设定 Markov 矩阵可以提高算法在不同目标轨迹中的适应性, 使其既能保持平稳目标的连续性又能迅速响应机动目标的变化。

1.3 标准交互式多模型粒子滤波算法

标准的交互式多模型粒子滤波 (IMMPF, interacting multiple model particle filter) 算法流程如图 1 所示。

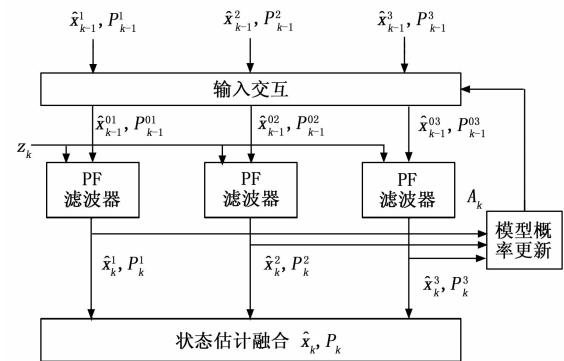


图 1 标准 IMMPF 算法流程图

IMMPF 算法步骤如下：

1) 输入交互：

在滤波状态估计的初始阶段，利用前一时刻的状态估计和协方差矩阵作为输入，结合各模型的先验概率，进行加权融合得到各模型的初始状态和协方差矩阵，作为滤波处理的输入：

$$\hat{\mathbf{x}}_{k-1}^{0j} = \sum_{i=1}^r \hat{\mathbf{x}}_{k-1}^i \mu_{k-1}^{ij} \quad (7)$$

$$\mathbf{P}_{k-1}^{0j} = \sum_{i=1}^r \mu_{k-1}^{ij} \{ \mathbf{P}_{k-1}^i + [\hat{\mathbf{x}}_{k-1}^i - \hat{\mathbf{x}}_{k-1}^{0j}] [\hat{\mathbf{x}}_{k-1}^i - \hat{\mathbf{x}}_{k-1}^{0j}]^T \} \quad (8)$$

$$\mu_{k-1}^{ij} = \frac{1}{c_{k-1}^j} \pi_{j|i} \mu_{k-1}^i \quad (9)$$

$$c_{k-1}^j = \sum_{i=1}^r \pi_{j|i} \mu_{k-1}^i \quad (10)$$

其中： $\hat{\mathbf{x}}_{k-1}^{0j}$ 表示模型 j 在 $k-1$ 时刻的混合状态向量估计值， $\hat{\mathbf{x}}_{k-1}^i$ 表示模型 j 在 $k-1$ 时刻经滤波得到的状态估计值， \mathbf{P}_{k-1}^{0j} 表示模型 j 在 $k-1$ 时刻的混合协方差矩阵， \mathbf{P}_{k-1}^i 表示模型 j 在 $k-1$ 时刻经滤波得到的协方差矩阵， μ_{k-1}^{ij} 表示 $k-1$ 时刻模型 i 转移到模型 j 的混合概率， μ_{k-1}^i 表示 $k-1$ 时刻目标处于模型 j 的概率， c_{k-1}^j 代表输入交互后目标处于模型 j 的概率， $\pi_{j|i}$ 表示转移概率矩阵中模型 i 转移到模型 j 的先验概率。

2) 模型滤波：

对输入交互得到的各运动模型混合状态向量和对应协方差矩阵进行粒子滤波，更新各运动模型滤波后的状态估计和对应协方差矩阵。

3) 模型概率更新：

在滤波器算法的多模型框架下，各运动模式对应的新息向量 $\tilde{\mathbf{y}}_k$ 及其协方差矩阵 \mathbf{S}_k 的计算方式为：

$$\tilde{\mathbf{y}}_k^i = \mathbf{z}_k^i - \mathbf{H}\hat{\mathbf{x}}_k^i \quad (11)$$

$$\mathbf{S}_k^i = \mathbf{H}\mathbf{P}_k^i\mathbf{H}^T + \mathbf{R} \quad (12)$$

各模型的似然函数计算为：

$$\Lambda_k^i = \frac{\exp[-(\tilde{\mathbf{y}}_k^i)(\mathbf{S}_k^i)\tilde{\mathbf{y}}_k^i/2]}{\sqrt{(2\pi)^M |\mathbf{S}_k^i|}} \quad (13)$$

式中， M 是测量模型的维数，各模型概率更新为：

$$\mu_k^i = \frac{\Lambda_k^i c_k^i}{\sum_1^r \Lambda_k^i c_k^i} \quad (14)$$

4) 估计融合：

在 IMM 算法的输出融合阶段，基于各模型的滤波结果和模型概率，通过加权融合得到全局状态估计及其协方差矩阵：

$$\hat{\mathbf{x}}_k = \sum_{i=1}^r \hat{\mathbf{x}}_k^i \mu_k^i \quad (15)$$

$$\mathbf{P}_k = \sum_{i=1}^r \mu_k^i \{ \mathbf{P}_k^i + [\hat{\mathbf{x}}_k^i - \hat{\mathbf{x}}_k] [\hat{\mathbf{x}}_k^i - \hat{\mathbf{x}}_k]^T \} \quad (16)$$

最终，通过循环加权融合得到每一时刻的目标状态估计和估计协方差矩阵。

2 自适应 IMMPF 算法

在标准的 IMM 算法中，依据经验或者物理运动特性设定的 Markov 矩阵一般是固定不变的。若采用固定的 Markov 矩阵，当实际系统的动态切换频率或模式与矩阵预设的转移概率不一致时，可能导致模型权重更新滞后或过度敏感。在复杂场景中固定矩阵包含大量低概率转移路径，使得大量计算资源浪费在对状态估计贡献微小的转移路径中从而导致效率下降。因此固定的矩阵在动态变化复杂或突发的场景中可能产生次优结果，需结合自适应调整或数据驱动方法优化。

2.1 模型概率变化率的 Markov 矩阵

文献 [24] 提出一种新的 Markov 矩阵校正方式，其定义参数：

$$\lambda_{ij} = \frac{1 + e^{-l}}{1 + l \exp\left(-\frac{\mu_k^j}{\mu_{k-1}^j} \frac{\mu_{k-1}^i}{\mu_k^i}\right)} \quad (17)$$

其中： l 为比例系数，设定 $0 < l \leq 1$ ，通常设定 $l = 1$ 。

因此修正后的 Markov 矩阵中的各元素为：

$$\hat{\pi}_{ij} = \lambda_{ij} \pi_{ij} \quad (18)$$

为使修正后的转移概率满足 Markov 矩阵从任一模型出发，切换到所有可能模型概率的总和为 1 的条件，即使每一行的元素之和必须等于 1，保证概率分布的完备性，进一步调整 Markov 矩阵中各转移概率为：

$$\pi_{ij} = \frac{\hat{\pi}_{ij}}{\sum_{j=1}^n \hat{\pi}_{ij}} \quad (19)$$

模型之间转换的判决依据如图 2 所示。

2.2 时变转移概率的 Markov 矩阵

理想情况下如果系统模型保持稳定，系统的估计状态只由匹配模型决定。但是在实际中，系统的估计状态是由各个模型的估计状态进行加权求和获得，因此非匹配模型的状态估计可被认为整体状态估计的噪声。本文利用历史波动信息来最小化非匹配模型概率，并提高匹配模型概率，从而优化状态估计的准确性。本文针对固定 Markov 矩阵出现的问题，定义调节因子为：

$$\begin{aligned} \beta_k &= \alpha \beta_{k-1} + (1 - \alpha) \Lambda_k \\ \beta_{k-1} &= \alpha \beta_{k-2} + (1 - \alpha) \Lambda_{k-1} \\ \beta_{k-2} &= \alpha \beta_{k-3} + (1 - \alpha) \Lambda_{k-2} \end{aligned} \quad (20)$$

其中： Λ_k 为 k 时刻的似然函数，最终可以将调节因子表示为似然函数的加权和：

$$\begin{aligned} \beta_k &= (1 - \alpha) \Lambda_k + (1 - \alpha) \alpha \Lambda_{k-1} + \\ &\quad (1 - \alpha) \alpha^2 \Lambda_{k-2} + \dots \end{aligned} \quad (21)$$

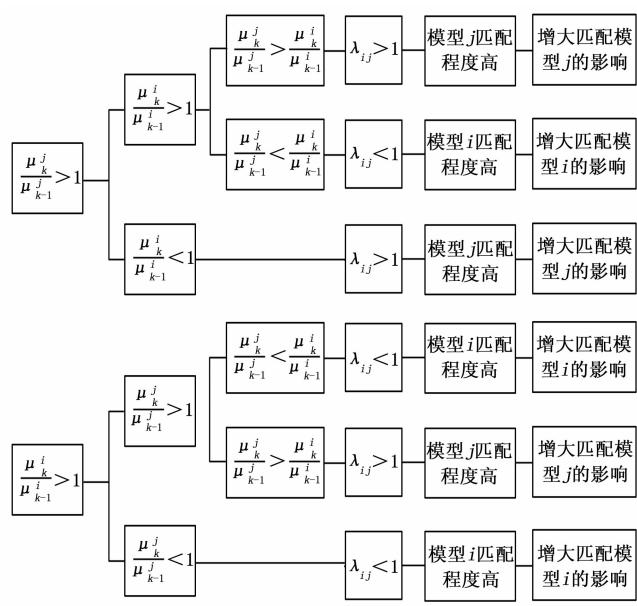


图 2 模型转换判决依据图

如果 $\alpha=0$, 则不反映过去的数据。因此如果根据过去时间的模型概率分配影响 α , β_k 可以近似表示如下:

$$\beta_k = \frac{1}{1-\alpha} \quad (22)$$

已知模型 j 的概率越高, 代表着该模型与机动目标模型的匹配程度越高。似然函数也代表模型为目标匹配模型的可能性, 而且其值相较于模型概率变化幅度更大, 更能反映出模型的变化趋势。因此将两时刻模型概率与似然函数乘积的差值对转移概率矩阵作时变处理。令 $\alpha=\mu_k^i\Lambda_k^i-\mu_{k-1}^i\Lambda_{k-1}^i$, 当 α 大于或等于 0, 说明该模型成为匹配模型的概率增大, 若其小于 0, 它会抑制当前值, 与过去模型概率相对立, 该模型为匹配模型的概率减小。但是当 α 趋近于 1 时, β_k 趋近无穷大, 导致转移概率矩阵发散, 而且在此定义下需满足 $-1<\alpha<1$ 。因此重新定义调节因子为:

$$\beta_k = \exp(\alpha) = \exp(\mu_k^i\Lambda_k^i - \mu_{k-1}^i\Lambda_{k-1}^i) \quad (23)$$

调节因子 β_k 保证了目标运动稳定时, 匹配目标运动模型的概率趋近于 1, 其他运动模型的概率趋近于 0, 使得作为噪声的非匹配模型的状态估计对匹配运动模型的影响忽略不计。但是由于指数函数的性质, 使得模型在切换时, 切换速度较慢, 导致切换时的误差增大, 因此需引入不同模型之间概率差 $\Delta\mu_k^{i,o}$, 对模型的变化做出快速反应。

假设 $k-1$ 时刻模型 i 为匹配模型, k 时刻模型 j 为匹配模型, 即两个时刻之间运动模式发生了切换, 使用前后两时刻不同模型之间的变化反映模型之间的切换。首先令前后两时刻不同模型之间概率差 $\Delta\mu_k^{i,o}$ 为:

$$\Delta\mu_k^{i,o} = \mu_k^i - \sum_{j=1}^n \mu_{k-1}^j, i \neq j \quad (24)$$

模型发生切换时分为两种情况: 当 k 时刻模型 i 为匹配模型, $k-1$ 时刻其它模型为匹配模型时, $\Delta\mu_k^{i,o}$ 的值趋近于 0; 当 k 时刻其它模型为匹配模型, $k-1$ 时刻模型 i 为匹配模型时, $\Delta\mu_k^{i,o}$ 的值趋近于 0。

模型不发生切换时, 即前后两时刻匹配模型未发生变化, 若前后两时刻模型 i 都为匹配模型, $\Delta\mu_k^{i,o}$ 的值趋近于 1; 若前后两时刻其它模型为匹配模型, $\Delta\mu_k^{i,o}$ 的值趋近于 -1, 集成调节因子 β_k 与模型之间概率差 $\Delta\mu_k^{i,o}$ 将 Markov 矩阵调整为:

$$\hat{\pi}_k^{ij} = (\beta_k^i - \Delta\mu_k^{i,o})\pi_{ij} \quad (25)$$

为验证更新后的 $\hat{\pi}_k^{ij}$ 是否满足 Markov 矩阵的性质, 从以下 4 个方面进行分析。

匹配模型不发生切换:

1) 模型 i 为匹配模型, 此时所有的 β_k 都趋近于 1, $\Delta\mu_k^{i,o}$ 也趋近于 1。

2) 其它模型为匹配模型, 此时所有的 β_k 都趋近于 1, $\Delta\mu_k^{i,o}$ 也趋近于 -1。

匹配模型发生切换:

1) $k-1$ 时刻其它模型为匹配模型, k 时刻模型 i 为匹配模型, 此时不同的 β_k 取值不同, 但是都 >0 , $\Delta\mu_k^{i,o}$ 趋近于 0。

2) $k-1$ 时刻模型 i 为匹配模型, k 时刻其它模型为匹配模型, 此时不同的 β_k 取值不同, 但是都 >0 , $\Delta\mu_k^{i,o}$ 趋近于 0。

为确保 Markov 矩阵中的元素满足 >0 的条件, 对调整后的 Markov 矩阵加设绝对值, 最终 Markov 矩阵更新为:

$$\hat{\pi}_k^{ij} = |\beta_k^i - \Delta\mu_k^{i,o}| \pi_{ij} \quad (26)$$

归一化:

$$\pi_{ij} = \frac{\hat{\pi}_{ij}}{\sum_j \hat{\pi}_{ij}} \quad (27)$$

改进的 IMMPF 算法流程如图 3 所示。

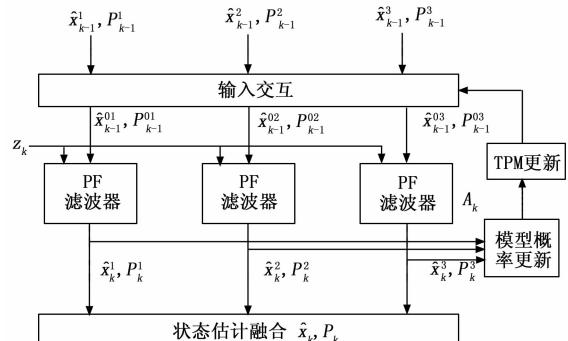


图 3 改进的 IMMPF 算法流程图

3 仿真分析

本文针对常规的 IMMPF、文献 [24] 中提到的基于模型概率变化的 IMMPF 算法以及本文改进的 IMMPF 算法进行了仿真验证。假设总跟踪时长为 500 s, 采样周期为 1 s, 雷达位于原点, 目标在二维平面某一范围内运动, 目标的初始位置 [10 000 m, 10 000 m], 目标的初始速度为 [80 m/s, 60 m/s]。目标的运动分为 5 个阶段, 如所示表 1。

表 1 目标运动模式

时间(t/s)	运动模型
1~100	匀速直线
201~200	右转弯
201~320	左转弯
321~400	匀速直线
401~500	左转弯

转弯阶段的角速度为 0.04 rad/s, 仿真采样点数为 500 个, 共进行 50 次蒙特卡洛实验。匀速运动、右转弯运动和左转弯运动模型的状态转移矩阵分别为:

$$F = e^{AT} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (28)$$

$$F = \begin{bmatrix} 1 & \frac{\sin\Omega T}{\Omega} & 0 & \frac{1-\cos\Omega T}{\Omega} & 0 \\ 0 & \cos\Omega T & 0 & \sin\Omega T & 0 \\ 0 & -\frac{1-\cos\Omega T}{\Omega} & 1 & \frac{\sin\Omega T}{\Omega} & 0 \\ 0 & -\sin\Omega T & 0 & \cos\Omega T & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (29)$$

$$F = \begin{bmatrix} 1 & \frac{\sin\Omega T}{\Omega} & 0 & -\frac{1-\cos\Omega T}{\Omega} & 0 \\ 0 & \cos\Omega T & 0 & -\sin\Omega T & 0 \\ 0 & \frac{1-\cos\Omega T}{\Omega} & 1 & \frac{\sin\Omega T}{\Omega} & 0 \\ 0 & \sin\Omega T & 0 & \cos\Omega T & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (30)$$

量测方程为非线性方程, 量测方程为:

$$h(x_k) = \begin{cases} \sqrt{(x_k - x_0)^2 + (y_k - y_0)^2} \\ \arctan\left(\frac{y_k - y_0}{x_k - x_0}\right) \end{cases} \quad (31)$$

过程噪声协方差矩阵值设置为 $Q = \text{diag} [100, 1, 100, 1]$, 量测噪声协方差矩阵值设置为 $R = \text{diag} [20^2, 0.01^2]$ 。运动模型的初始概率值为 $[1/3 \ 1/3 \ 1/3]$, Markov 转移概率矩阵初始值为:

$$\pi_{ij} = \begin{bmatrix} 0.95 & 0.025 & 0.025 \\ 0.025 & 0.95 & 0.025 \\ 0.025 & 0.025 & 0.95 \end{bmatrix} \quad (32)$$

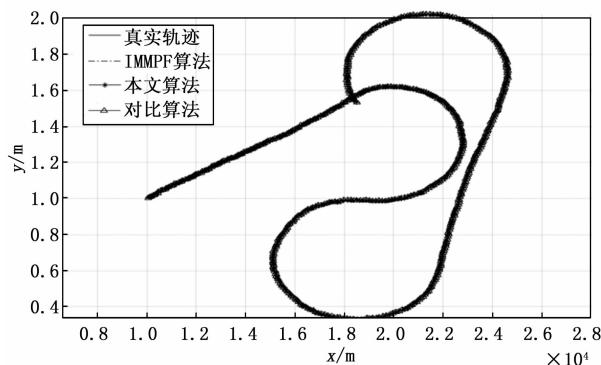


图 4 跟踪轨迹对比图

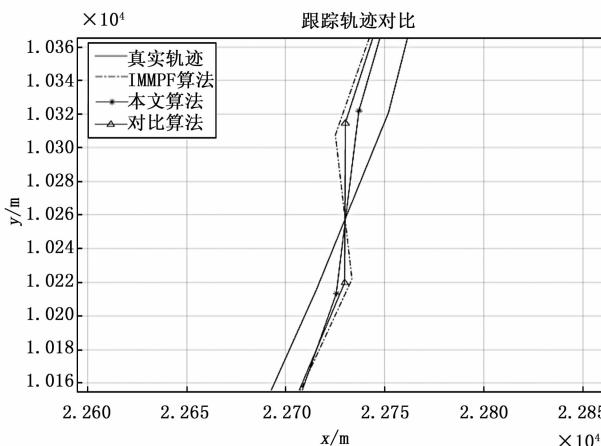
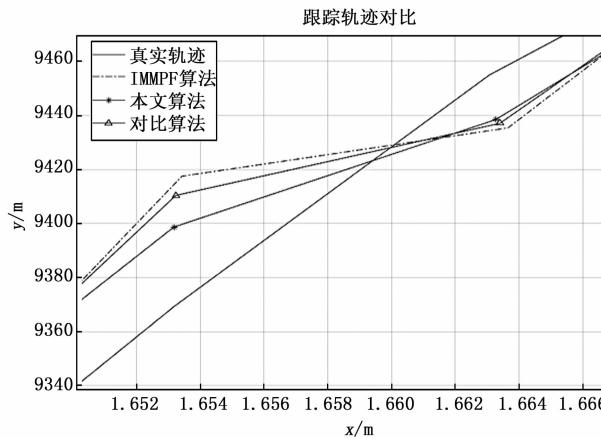


图 5 局部放大跟踪轨迹对比图

真实轨迹和各算法的预测轨迹如图 4 所示, 从图中可以看出各算法在整体性能上表现相似, 难以直观区分优劣性。但是从图 5 可以看出在目标运动状态发生转换的关键节点, 本文改进的 IMMPF 算法能更快捕捉目标的动态特性变化, 其预测滤波轨迹与真实轨迹接近程度优于其他两种对比方法, 展现出更强的跟踪精度。

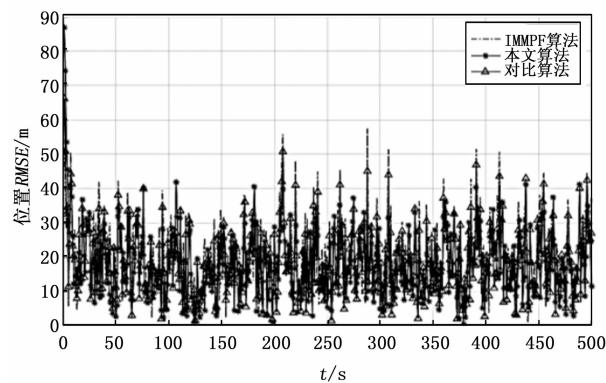


图 6 位置均方根误差对比图

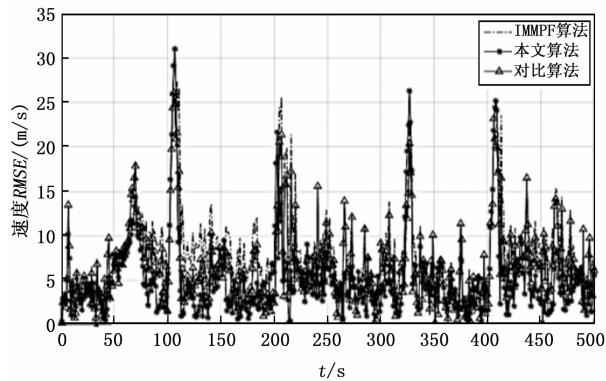


图 7 速度均方根误差对比图

图 6 为各算法的位置均方根误差对比, 从图中可以看出标准 IMMPF 算法的误差要普遍高于其余两种算法, 而本文改进的 IMMPF 算法在大多数时间区间内保持最低误差。图 7 为各算法的速度均方根误差对比, 从图中可以看出各算法在速度误差方面的变化趋势相似, 但是本文改进的 IMMPF 算法表现出更小的波动范围, 相比之下, 标准 IMMPF 算法速度误差变化幅度最大, 这一对比结果验证了本文改进的 IMMPF 算法在状态估计精度和稳定性方面的优势。

表 2 不同滤波算法的误差分析表

	标准 IMMPF	文献[24]算法	本文改进的 IMMPF
位置误差(m)	22.972 8	21.041 0	19.325 5
速度误差(m/s)	9.243 3	7.756 7	6.768 8

改进的 IMMPF 算法较标准 IMMPF 和文献 [24] 算法在位置误差上分别降低了 16.1% 和 8.2%, 表明其在位置估计精度上具有显著优势。在速度误差上分别降低了 26.8% 和 12.7%, 显示其在机动目标速度跟踪中的鲁棒性更强。

图 8 为各模型概率对比图, 从图中可以看处出本文提出的算法在目标处于特定运动模式时, 能够有效提升

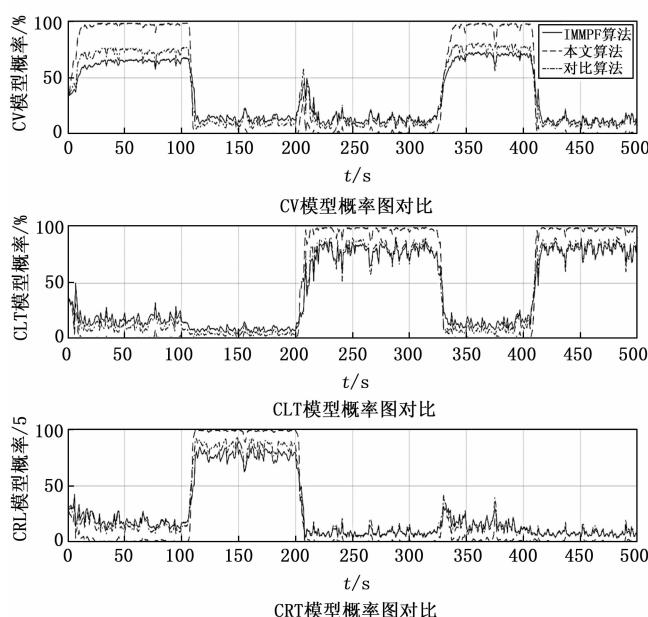


图 8 各模型概率对比图

当前匹配模型的概率, 使模型概率接近于 1, 并且降低其它模型概率, 以抑制对预测轨迹的干扰影响。与其它两种算法相比, 本文算法展现出更快的模型切换响应能力, 快速准确地匹配目标实时运动状态。

图 9 为本文算法的运动模型概率图, 从图中可以看出本文算法在运动模型匹配方面表现出良好的稳定性。当目标处于某一运动模式时, 对应模型的概率值在绝大多数区间内维持在 0.95 以上的高水平, 仅在少数时刻会发生匹配模型概率的短暂下降, 表明算法能有效识别当前运动模式, 验证了算法在模型选择方面的可靠性。

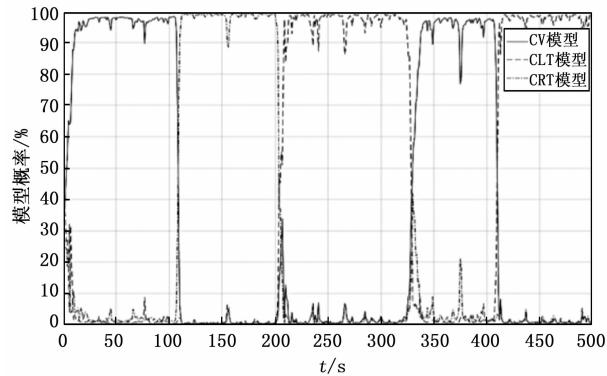


图 9 本文算法模型概率图

4 结束语

本文针对标准 IMMPF 算法中 Markov 矩阵固定不变而导致模型权重更新滞后或过度敏感的问题, 研究了已有的改进算法, 并提出一种新的 Markov 转移概率矩阵自适应交互式多模型粒子滤波算法。该算法通过引入调节因子保证目标在运动稳定时, 匹配目标运动模型的

概率趋近于 1, 其他运动模型的概率趋近于 0, 使得作为噪声的非匹配模型的状态估计对匹配运动模型的影响忽略不计; 引入模型之间概率差保证目标在切换运动模式时, 算法能更快的做出模型切换响应能力, 快速准确地匹配目标实时运动状态。通过仿真分析, 本文提出的IMMPF 算法相较于标准 IMMPF 和基于模型概率变化率的 IMMPF 算法, 具有更高的模型匹配概率和模型转换速率, 在位置误差上分别降低了 16.1% 和 8.2%, 在速度误差上分别降低了 26.8% 和 12.7%, 表明本文提出的 IMMPF 具有更高的跟踪精度。

参考文献:

- [1] 张朋友, 汪学刚. 雷达系统 第 3 版 [M]. 北京: 电子工业出版社, 2011.
- [2] 丁鹭飞, 耿富禄, 陈建春. 雷达原理 第 6 版 [M]. 北京: 电子工业出版社, 2020.
- [3] ZIKIDIS K, SKONDRA S A, TOKAS C. Low observable principles, stealth aircraft and anti-stealth technologies [J]. Journal of Computations & Modelling, 2014, 4 (1): 12–18.
- [4] 向 浩. 基于特征辅助的雷达多目标跟踪算法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2024.
- [5] 李盈萱. 机动目标运动建模与跟踪研究 [D]. 烟台: 烟台大学, 2023.
- [6] KALMAN R E. A new approach to linear filtering and prediction problems [J]. Journal of Fluids Engineering, 1960, 82 (1): 35–45.
- [7] KALMAN R E, BUCY R S. New results in linear filtering and prediction theory [J]. Journal of Fluids Engineering, 1961, 83 (1): 95–108.
- [8] DIVYA G N, RAO S K. Implementation of ensemble Kalman filter algorithm for underwater target tracking [J]. Journal of Control and Decision, 2024, 11 (3): 345–354.
- [9] JONDHALE S R, ATHAWALE S V, WAKCHAURE M A, et al. Application of extended Kalman filter for tracking of mobile target [J]. Turkish Online Journal of Qualitative Inquiry, 2021, 12 (6): 8925–8932.
- [10] 吕 旭, 胡柏青, 李开龙, 等. 非线性目标跟踪滤波算法的比较研究 [J]. 火力与指挥控制, 2021, 46 (4): 24–30.
- [11] YANG Y. Review of target tracking algorithms based on bayes filtering [C] //Proceedings of the 2022 3rd International Conference on Computer Science and Intelligent Communication, 2022: 3–13.
- [12] SANG H R, ZHENG R, CHENG H R, et al. A review of point target and extended target tracking algorithms [C] //2024 3rd International Conference on Image Processing and Media Computing (ICIPMC). IEEE, 2024: 335–346.
- [13] GORDON N J, SALMOND D J, SMITH S F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation [J]. IEE Proceedings F (Radar and Signal Processing), 1993, 140 (2): 107–113.
- [14] 罗伟丽, 周 芸, 张博龙. 非线性非高斯条件下基于粒子滤波的目标跟踪 [J]. 国外电子测量技术, 2021, 40 (7): 45–51.
- [15] 季陈倍, 田梦楚, 吴 云, 等. 基于粒子滤波的无人机实时在线目标跟踪算法研究 [J]. 智能物联技术, 2025, 57 (1): 13–20.
- [16] YLMAZ M K, BAYRAM H. Particle filter-based aerial tracking for moving targets [J]. Journal of Field Robotics, 2023, 40 (2): 368–392.
- [17] JOHANSEN A. A tutorial on particle filtering and smoothing: fifteen years later. [J]. The Oxford Handbook of Nonlinear Filtering, 2009, 7 (2): 103–109.
- [18] BI X J, PAN T W. Face tracking based on particle filter with differential evolution algorithm [J]. Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering), 2018, 11 (2): 211–216.
- [19] 林晓杰, 索继东. 基于自适应粒子群优化的粒子滤波跟踪算法 [J]. 现代电子技术, 2020, 43 (17): 11–15.
- [20] ZHOU N, LAU L, BAI R, et al. A genetic optimization resampling based particle filtering algorithm for indoor target tracking [J]. Remote Sensing, 2021, 13 (1): 132.
- [21] JAGAN B O L, RAO S K, JAHAN K. Unscented particle filter approach for underwater target tracking [J]. International Journal of e-Collaboration, 2021, 17 (4): 29–40.
- [22] LU X B, LI F, TANG J, et al. A new performance index for measuring the effect of single target tracking with Kalman particle filter [J]. International Journal of Modern Physics C: Computational Physics & Physical Computation, 2022, 33 (9): 1.
- [23] LIU Y J, CUI D W. Vehicle dynamics prediction via adaptive robust unscented particle filter [J]. Advances in Mechanical Engineering, 2023, 15 (5): 1–8.
- [24] 戴定成, 姚敏立, 蔡宗平, 等. 改进的马尔可夫参数自适应 IMM 算法 [J]. 电子学报, 2017, 45 (5): 1198–1205.