

基于粒子优化的多模型粒子滤波算法

刘先省¹, 胡振涛^{1,2}, 金 勇¹, 杨一平¹

(1. 河南大学智能技术与系统重点实验室, 河南开封 475001; 2. 西北工业大学控制与信息研究所, 陕西西安 710072)

摘 要: 针对模型信息引入粒子采样过程中导致用于逼近当前时刻真实状态与模型的粒子数减少问题, 本文给出了一种基于粒子优化的多模型粒子滤波算法. 在算法实现中, 对每个粒子运行一个扩展卡尔曼滤波器, 结合扩展卡尔曼滤波中预测更新机制实现最新量测信息的有效利用, 进而提升单个采样粒子对于真实系统状态和模型逼近的有效性. 理论分析和仿真结果表明: 新算法在系统状态估计的精度以及模型辨识的准确性方面均明显地优于交互式多模型粒子滤波算法和多模型粒子滤波算法.

关键词: 多模型粒子滤波; 交互式多模型; 扩展卡尔曼滤波, 模型辨识

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2010) 02-0301-06

A Novel Multiple Model Particle Filter Algorithm Based on Particle Optimization

LIU Xian-xing¹, HU Zhen-tao^{1,2}, JIN Yong¹, YANG Yi-ping¹

(1. Laboratory of Intelligent Technology and System, Henan University, Kaifeng, Henan 475001, China;

2. Institute of Control and Information, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

Abstract: For the adverse effect caused by the number decline of particles which are applied to implement the state estimation and model recognition, when model information is introduced into particle sampling process, a novel multiple model particle filter algorithm based on particle optimization is proposed. In the new algorithm, every particle is combined with extended Kalman filter, and the prediction and update mechanism of extended Kalman filter is used to realize the reasonable utilization of the latest observation information. The affectivity of single particle to approximate the real system state and model is improved. The theory analysis and simulation results show the new method outperform obviously the interacting multiple model particle filter and the standard multiple model particle filter in the filter precision of system state and the accuracy of model recognition.

Key words: multiple model particle filter; interacting multiple model; extended Kalman filter; model identification

1 引言

对于机动目标跟踪、故障检测和诊断等复杂系统, 系统建模通常采用多模型策略. 如何有效实现此类复杂系统中模型的准确辨识和状态的精确估计, 一直是国内外学者关注的焦点. 目前, 对于此类问题的解决方案, 主要是采用交互式多模型算法 (IMM)^[1,2]. IMM 采用一种“软切换”的机制, 滤波过程中保持模型集中所有模型同时并行工作, 通过计算模型概率来评估模型的权重, 并以此对模型的滤波输出进行综合. 在实际工程应用中表明, 对于具有高斯白噪声特性的线性系统, IMM 中子滤波器中卡尔曼滤波 (KF) 的采用, 在一定程度上能够补偿折中平衡过程所造成滤波精度的损失. 但当被估计系统具有强非线性、非高斯噪声特性时, 子滤波器中次优

滤波器的采用将进一步加大折中策略对于滤波估计的不利影响, 使得模型辨识的可靠性和状态估计的精度急剧下降^[3,4]. 近年来, 伴随着计算机性能的不断提升, 基于序贯重要性采样技术和递推贝叶斯理论的粒子滤波 (PF) 给出了一种处理非线性非高斯问题有效解决方法. 理论上可以获得被估计对象的最小方差估计, 并且不受系统非线性强度和噪声类型的约束, 因其自身具有的以上优点, 在信号处理、目标跟踪、故障诊断与图象处理等领域得到广泛应用^[5~7].

考虑到 IMM 和 PF 两者之间的互补性, 一些学者提出利用 PF 替换 IMM 中的次优滤波器, 以提升滤波估计精度, 然而随着状态维数和系统模型个数的增加, 这种简单结合无疑将带来计算量的急剧膨胀^[8~10]. 另外, 由于 PF 的预测更新过程不同于 KF, 其预测步骤利用重要

性采样实现,更新过程则基于重采样完成,导致无法精确计算 IMM 中模型概率更新过程中所需要的残差及其协方差,仅能依据求解算术均值的方式获取它们的近似解,易造成模型匹配的失败.依据 PF 利用随机采样策略实现滤波估计的特性,文献[11,12]中给出解决此类问题一种新的思路,即在粒子采样引入模型信息,在不增加采样粒子数目的前提下实现滤波过程中状态和模型的联合估计,以降低状态维数和系统模型个数增加对于计算量的不利影响.但这种粒子数目固定的方式,不可避免会导致用于当前时刻真实系统状态和模型的估计与辨识粒子数减少,降低估计精度和模型辨识的可靠性.针对以上问题,本文给出一种基于粒子优化的多模型粒子滤波算法(EMPF).对每个附带模型信息的采样粒子运行一个扩展卡尔曼滤波器(EKF),通过最新量测信息的合理利用实现对采样粒子的优化,进而增强采样粒子对于真实状态逼近的有效性.

2 多模型粒子滤波

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, r_{k-1}, \mathbf{u}_{k-1}) \quad (1)$$

$$\mathbf{z}_k = h(\mathbf{x}_k, r_k, \mathbf{v}_k) \quad (2)$$

其中 $\mathbf{x}_k \in R^n$ 为系统未知的状态向量, $\mathbf{z}_k \in R^m$ 为系统量测向量, k 表示采样时刻. \mathbf{w}_k 和 \mathbf{v}_k 表示方差分别为 Q_k 和 R_k 过程噪声和量测噪声,且满足相互独立的加性白噪声序列. f 和 h 分别表示系统状态演化函数与量测演化函数. r_k 表示未知的离散值模型状态,模型状态转移规律服从离散时间、齐次、有限状态的一阶 Markov 链,模型集 $L = \{1, 2, \dots, l\}$. 初始概率分布为 $\mu_a = P_r\{r_0 = a\}$, 转移概率为 $\pi_{ab} = P_r\{r_k = b | r_{k-1} = a\}$, 且 $\sum_{b=1}^l \pi_{ab} = 1, a, b \in L$. 转移概率矩阵为 $\Pi = [\pi_1, \pi_2, \dots, \pi_l]^T, \pi_a = [\pi_{a1}, \pi_{a2}, \dots, \pi_{al}]$. 在递推贝叶斯估计框架下,状态估计问题描述可归结为利用所有可能得到的量测序列 $\mathbf{z}_{1:k} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$ 递推地估计出当前时刻系统状态 \mathbf{x}_k 的后验概率分布 $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$. 由于 $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ 包括序贯估计的完全信息,进而可得到系统状态估计所需参数如均值,方差等信息. 针对粒子滤波依据随机采样策略实现系统状态估计的自身特点,可将模型信息引入进粒子的采样生成中,实现系统状态和模型状态的联合估计. 下面给出了多模型粒子滤波(MPF)的算法机理. 多模型粒子滤波利用附带模型状态信息的采样粒子完成对 $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ 的逼近,即

$$p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k}) \approx \frac{\sum_{i=1}^N \delta(\langle \mathbf{x}_k, r_k \rangle - \langle \mathbf{x}_k^i, r_k^i \rangle)}{N} \quad (3)$$

其中, $\delta(y)$ 是狄拉克函数,当 $y=0$ 时, $\delta(y)=1$, 否则 $\delta(y)=0$. $\langle \mathbf{x}_k^i, r_k^i \rangle$ 表示 k 时刻系统中附带模型状态信息的采样粒子,粒子数目 $i=1, 2, \dots, N, N \rightarrow \infty$, 通过

直接从后验概率分布中独立抽样得到. 然而,由于实际上 $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ 是未知的,上述过程一般很难实现. 为克服以上困难,常通过引入一个容易采样且接近后验概率分布的提议分布 $q(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$, 并从中抽取一组带权子样 $\{\langle \mathbf{x}_k^i, r_k^i \rangle, \omega_k^i\}_{i=1}^N$, 以此来近似后验概率分布,以上过程通常被称为重要性采样. 此时,采样粒子权重的数学表达式为

$$\omega_k^i \propto \frac{p(\mathbf{x}_k^i, r_k^i | \mathbf{z}_{1:k})}{q(\mathbf{x}_k^i, r_k^i | \mathbf{z}_{1:k})} \quad (4)$$

为进一步分析 $\{\langle \mathbf{x}_k^i, r_k^i \rangle\}_{i=1}^N$ 的采样过程,对提议分布 $q(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ 做如下分解

$$q(\mathbf{x}_k, r_k | \mathbf{z}_{1:k}) = q(\mathbf{x}_k, r_k | x_{k-1}, r_{k-1}, \mathbf{z}_{1:k}) q(\mathbf{x}_{k-1}, r_{k-1} | \mathbf{z}_{1:k-1}) \quad (5)$$

由上式可知, $\langle \mathbf{x}_k^i, r_k^i \rangle$ 生成实际是通过 $q(\mathbf{x}_k, r_k | x_{k-1}, r_{k-1}, \mathbf{z}_{1:k})$ 扩展从提议分布 $q(\mathbf{x}_{k-1}, r_{k-1} | \mathbf{z}_{1:k-1})$ 中采样的粒子 $\langle \mathbf{x}_{k-1}^i, r_{k-1}^i \rangle$ 实现. 为得到权重 ω_k^i 的递推方程,将 $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ 被分解为 $p(\mathbf{z}_k | x_k, r_k), p(\mathbf{x}_k, r_k | x_{k-1}, r_{k-1})$ 和 $p(x_{k-1}, r_{k-1} | \mathbf{z}_{1:k-1})$ $p(\mathbf{x}_k, r_k | \mathbf{z}_{1:k})$ $\propto p(\mathbf{z}_k | x_k, r_k) p(\mathbf{x}_k, r_k | x_{k-1}, r_{k-1}) p(x_{k-1}, r_{k-1} | \mathbf{z}_{1:k-1})$ (6)

在状态估计过程服从马尔可夫过程且与量测值是条件独立的假设条件下,结合式(4)、(5)和(6),则粒子权重的递推表达式为

$$\omega_k^i = \omega_{k-1}^i p(\mathbf{z}_k | \mathbf{x}_k^i, r_k^i) p(\mathbf{x}_k^i, r_k^i | \mathbf{x}_{k-1}^i, r_{k-1}^i) / q(\mathbf{x}_k^i, r_k^i | \mathbf{x}_{k-1}^i, r_{k-1}^i, \mathbf{z}_{1:k}) \quad (7)$$

在实际应用中,提议分布通常选取为先验状态转移概率的形式,即

$$q(\mathbf{x}_k^i, r_k^i | \mathbf{x}_{k-1}^i, r_{k-1}^i, \mathbf{z}_{1:k}) = p(\mathbf{x}_k^i, r_k^i | x_{k-1}^i, r_{k-1}^i) \quad (8)$$

将式(8)带入式(7)中,则粒子权重的表达式进一步简化为

$$\omega_k^i = \omega_{k-1}^i p(\mathbf{z}_k | x_k^i, r_k^i) \quad (9)$$

对 ω_k^i 进行归一化处理后得到归一化权 $\bar{\omega}_k^i$, 进而依据 $\bar{\omega}_k^i$ 实现重采样过程. 所谓重采样即在评估粒子权值后,维持粒子总数不变的条件下,删减权值低的粒子,复制权值高的粒子. 重采样后得到一组新的粒子集 $\{\langle \mathbf{x}_k^j, r_k^j \rangle, \bar{\omega}_k^j\}_{j=1}^N$, 依据蒙特卡罗仿真技术,最终状态估计结果可通过求解重采样后粒子算术平均值获得.

3 基于粒子优化的多模型粒子滤波算法

通过对上述 MPF 算法实现机理分析可知,MPF 在不增加系统中采样粒子数目的情况下,通过粒子采样过程中模型信息的引入,实现了被观测系统中目标运动状态和模型状态的联合估计. 相对于 IMM 和 PF 直接相结合的方式,采用的粒子数目仅仅是其实现过程中

所需粒子数的二分之一,同时简化了 IMM 中的模型交互过程,因此大大降低了计算复杂度.另外,考虑到 IMM 与 PF 结合的方式中,用于真实模型对于状态估计的粒子只占用了全部采样粒子的一半,造成采样粒子的利用效率较低,实际上是粒子退化现象的一种表现. MPF 虽然有效克服 IMM 中的缺陷,但在实时性要求较高,即粒子数目受限的场合,有限粒子数目在多个模型之间的分配容易造成用在估计当前时刻真实系统状态和模型状态的估计与辨识粒子数目的不足,从而导致状态估计精度和模型辨识可靠性的下降.直接增加粒子数目是一种直观的解决方法,但无疑将增加计算负担.考虑到通过当前时刻的量测信息能够实现对于采样粒子进一步的优化,通过 EKF 滤波器的引入,以下给出了一种基于粒子优化的多模型粒子滤波算法 (EMPF).

EMPF 算法的递推实现主要通过以下三个环节实现:当前时刻模型状态的采样、预测粒子的生成和更新、预测粒子的优化.首先,实现当前时刻模型状态的采样,其采样过程需要综合利用前一时刻粒子所蕴含的模型信息和模型转移概率所包含的先验信息共同实现.具体方法如下:已知 $r_{k-1}^i = a$, 表示 $k-1$ 时刻第 i 个粒子的模型状态为 a , 从 $[0,1]$ 均匀分布中采样 ϵ , 当满足 $\sum_{c=1}^{b-1} \pi_{a,c} < \epsilon \leq \sum_{c=1}^b \pi_{a,c}$, 则 $r_k^i = b$, 它表示 k 时刻第 i 个粒子的采样模型状态为 c . 在获得 k 时刻粒子的模型状态采样信息后,将其结合 $k-1$ 时刻的粒子,利用 EKF 一步预测生成预测粒子,并通过粒子滤波中的重采样步骤实现预测粒子的更新.预测粒子生成和更新的过程如下

$$\langle \mathbf{x}_{k/k-1}^i, \mathbf{r}_k^i \rangle = f(\mathbf{x}_{k-1/k-1}^i, \mathbf{r}_{k-1}^i, \mathbf{u}_{k-1}^i) \quad (10)$$

$$\Sigma_{k/k-1}^i = (\mathbf{F}_k^i) \Sigma_{k-1/k-1}^i (\mathbf{F}_k^i)^T \quad (11)$$

$$\mathbf{z}_{k/k-1}^i = \mathbf{H}_k^i \langle \mathbf{x}_{k/k-1}^i, \mathbf{r}_k^i \rangle \quad (12)$$

$$\tilde{\mathbf{z}}_{k/k-1}^i = \mathbf{z}_k - \mathbf{z}_{k/k-1}^i \quad (13)$$

$$\mathbf{S}_{k/k-1}^i = (\mathbf{H}_k^i) \Sigma_{k/k-1}^i (\mathbf{H}_k^i)^T + \mathbf{R}_k \quad (14)$$

式中 $\mathbf{F}_k^i = \partial f(\langle \mathbf{x}_{k-1/k-1}^i, \mathbf{r}_{k-1}^i \rangle) / \partial (\langle \mathbf{x}_{k-1/k-1}^i, \mathbf{r}_{k-1}^i \rangle)$, $\mathbf{H}_k^i = \partial h(\langle \mathbf{x}_{k/k-1}^i, \mathbf{r}_k^i \rangle) / \partial (\langle \mathbf{x}_{k/k-1}^i, \mathbf{r}_k^i \rangle)$, $\langle \mathbf{x}_{k/k-1}^i, \mathbf{r}_k^i \rangle$ 和 $\mathbf{z}_{k/k-1}^i$ 分别表示 k 时刻第 i 个预测粒子和粒子的量测预测值. $\Sigma_{k/k-1}^i$ 表示预测粒子估计误差协方差. $\tilde{\mathbf{z}}_{k/k-1}^i$ 和 $\mathbf{S}_{k/k-1}^i$ 分别表示第 i 个粒子残差向量及其协方差. 为实现重采样对于预测粒子的更新,依据式(9)实现粒子重要性权重的有效度量.由式(9)的表达形式可知,与标准粒子滤波中依据当前量测数据及量测精度实现粒子权重度量不同,由于预测粒子中所包含的信息量更加的丰富,因此,对于预测粒子权重度量过程充分考虑到粒子所蕴含的系统状态和模型状态模型信息.为实现对于系统中采用的所有粒子的整体评价,对 ω_k^i 进行归

一化处理,并归一化后权重 ω_k^i 为参数完成重采样过程,重采样后得到一组新的粒子集合 $\{\langle \mathbf{x}_{k/k-1}^j, \mathbf{r}_k^j \rangle\}_{j=1}^N$ 和相应 $\mathbf{z}_{k/k-1}^j$ 、 $\Sigma_{k/k-1}^j$ 、 $\tilde{\mathbf{z}}_{k/k-1}^j$ 和 $\mathbf{S}_{k/k-1}^j$. 基于不同的策略,目前常用的重采样方法主要有残差重采样,系统重采样以及多项式重采样^[13]. 重采样后包含权重大的粒子,即对于系统真实状态逼近程度高的粒子被有效复制,对于系统真实状态逼近程度低的粒子被删减.重采样过程不仅实现了预测粒子的更新,同时有效改善了粒子退化现象的影响.预测粒子的优化则依据 EKF 中的量测更新步骤实现.具体实现步骤如下

$$\Xi_k^j = \Sigma_{k/k-1}^j \mathbf{H}_k^j (\mathbf{S}_{k/k-1}^j)^{-1} \quad (15)$$

$$\langle \mathbf{x}_{k/k}^j, \mathbf{r}_k^j \rangle = \langle \mathbf{x}_{k/k-1}^j, \mathbf{r}_k^j \rangle + \Xi_k^j \tilde{\mathbf{z}}_{k/k-1}^j \quad (16)$$

$$\Sigma_{k/k}^j = \Sigma_{k/k-1}^j - \Xi_k^j \Sigma_{k/k-1}^j \quad (17)$$

其中, Ξ_k^j 为滤波增益矩阵,用于度量当前量测信息对于预测粒子的修正程度的大小, $\langle \mathbf{x}_{k/k}^j, \mathbf{r}_k^j \rangle$ 和 $\Sigma_{k/k}^j$ 分别表示当前时刻的采样粒子及其状态估计误差协方差.由于 $\langle \mathbf{x}_{k/k}^j, \mathbf{r}_k^j \rangle$ 的采样过程实现了对于当前量测信息的利用,从此提升了对于系统运动状态和模型状态的逼近程度.当前时刻系统运动状态的估计和模型状态辨识最终根据 Monte Carlo 仿真技术和概率最大化原则实现.

$$\hat{\mathbf{x}}_{k/k} = \Sigma_{j=1}^N \langle \mathbf{x}_{k/k}^j, \mathbf{r}_k^j \rangle / N \quad (18)$$

$$P(r_k = d) = \Sigma_{j=1}^N \delta(d - r_k^j) / N$$

$$d = 1, 2, \dots, l, k = 1, 2, \dots \quad (19)$$

其中, $P(r_k = d)$ 所体现的物理含义为模型 d 在 k 时刻为系统模型状态的概率.由式(19)获得每个模型概率后,当前时刻系统模型状态即选取模型状态集中概率值最大的模型状态.

4 仿真结果与分析

为验证本文提出算法的有效性,以下给出两个仿真算例.算例 1 中选用文献[10]和[5]采用的两种典型一维非线性系统模型.算例 2 中仿真背景设定为利用两坐标雷达的量测数据实现对于二维平面上机动目标跟踪,用以验证 EMPF 算法针对高维数、多模型和非线性系统状态估计及模型有效辨识的有效性.

例 1: 模型 1

$$x_{k+1} = 0.5x_k + \sin(0.04\pi k) + 1 + w_{1,k}, \quad y_k = \frac{x_k^2}{5} + v_k$$

模型 2

$$x_{k+1} = 0.5x_k + 25 \left[\frac{x_k}{(1+x_k^2)} \right] + 8\cos(1.2k) + w_{2,k}$$

$$y_k = \frac{x_k^2}{20} + v_k$$

模型 1 为一个非线性非高斯模型,模型 2 为一个单变量

非静态增长模型,该模型的特点是系统的非线性程度将随着采样步长逐步增强.系统过程噪声分别采用伽玛噪声和高斯噪声,其噪声统计特性满足 $u_{1,k} \sim ga(3, 2)$ 和 $u_{2,k} \sim N(0, 16)$. 量测噪声为高斯噪声,噪声统计特性满足 $v_k \sim N(0, 2.25)$. 采样周期 $t = 1s$, 模型转移概率 $\pi_{12} = \begin{bmatrix} 0.98 & 0.02 \\ 0.02 & 0.98 \end{bmatrix}$, 仿真时间为 40 拍, 粒子数分别取 200. 系统模型切换设置如下: 1~15 拍模型(1)作用, 16~30 拍模型(2)作用, 31~40 拍模型(1)作用.

图 1 中结果直观的给出了利用 MPF 和 EMPF 在实时辨别系统模型状态的结果, 根据概率最大化原则, EMPF 在给定的仿真场景中仅在模型 1 向模型 2 过度过程中的第 15 个采样时刻出现了模型状态的辨识错误. 而 MPF 在两次模型状态转移的过程中均出现了辨识错误, 并且在第二次出现错误后没有及时得到修正, 总共出现了 4 次模型状态的辨识错误. 图 2 则从模型状态概率意义下, 从细节上清晰给出了以上结果的差别.

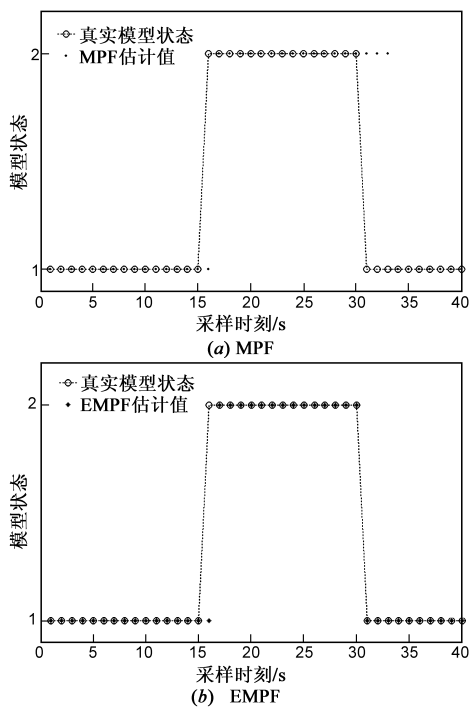


图1 模型状态

例 2: 利用两坐标雷达的量测数据实现对于 $X-Y$ 平面上运动目标的跟踪. 目标运动状态演化和量测演化方程如下

$$X_k = \begin{cases} F_1 * X_{k-1} + Gu_{1,k-1}, & 1 \leq k < 15 \\ F_k * X_{k-1} + Gu_{2,k-1}, & 15 \leq k < 30 \\ F_1 * X_{k-1} + Gu_{1,k-1}, & 30 \leq k \leq 40 \end{cases}$$

$$z_k = [\sqrt{x_k^2 + y_k^2} \quad \tan^{-1}(y_k/x_k)]^T + v_k$$

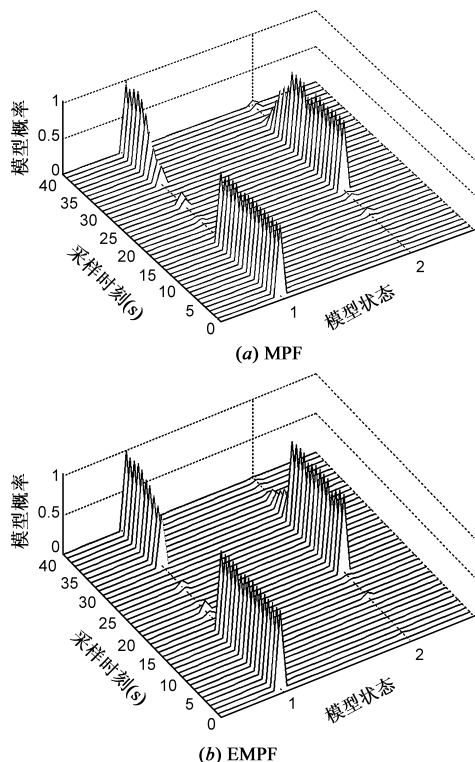


图2 模型状态概率

其中, $X_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, x_k, \dot{x}_k, y_k 和 \dot{y}_k 分别表示目标状态在 X 轴方向和 Y 轴方向的位置分量和速度分量.

$$F_1 = \begin{bmatrix} 1 & t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & t \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

$$F_2 = \begin{bmatrix} 1 & \sin(wt)/w & 0 & -(1 - \cos(wt))/w \\ 0 & \cos(wt) & 0 & -\sin(wt) \\ 0 & (1 - \cos(wt))/w & 1 & \sin(wt)/w \\ 0 & \sin(wt) & 0 & \cos(wt) \end{bmatrix}$$

为系统状态转移矩阵, 采样间隔 t 为 $1s$, 转弯角速度 $w = 0.2^\circ$. 系统过程噪声 $u_{1,k}$ 和 $u_{2,k}$ 为满足均值是零, 均方

根误差 $Q_{1,k}$ 和 $Q_{2,k}$ 的高斯白噪声, 其中 $Q_{1,k} = \frac{\sqrt{5}I}{5}$, $Q_{2,k}$

$= 0.2I$, $I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$, 过程噪声矩阵为 $G = \begin{bmatrix} 0 & 0 & t/2 & t \\ t/2 & t & 0 & 0 \end{bmatrix}^T$. 量测噪声向量 v_k 为满足均值是

零, 标准差为 $\begin{bmatrix} R_r & 0 \\ 0 & R_\theta \end{bmatrix}$ 的高斯白噪声, 其中径向距分量的噪声标准差 R_r 的值为 $0.1km$, 方位角分量的噪声标准差 R_θ 为 0.25° . 目标状态的初值 $X_0 = [3, 0.5, 4, 0.3]^T$.

采样粒子个数为 500, $\pi_{12} = \begin{bmatrix} 0.98 & 0.02 \\ 0.02 & 0.98 \end{bmatrix}$, $\mu_1 = 0.5$,

$\mu_2 = 0.5$. 仿真中对于算法滤波精度性能指标的评价采用均方根误差 (RMSE), 其数学表达式为 $RMSE = \{\sum_{\eta=1}^M (X_k - \hat{X}_{k/k, \eta})^2 / M\}^{1/2}$, 蒙特卡罗仿真次数 M 为 50, X_k 和 $\hat{X}_{k/k, \eta}$ 分别表示 k 时刻目标状态真值和第 η 次蒙特卡罗仿真中获得的估计值.

仿真中对比了 IMMPF、MPF、EMPF 等 3 种算法. 图 3 分别给出 50 次独立实验条件下目标在水平方向和竖直方向上状态估计均方根误差结果的比较, 由图 3 可知 EMPF 算法的滤波精度明显优于 IMMPF 和 MPF 算法. 考虑模型状态的正确辨识与目标状态估计是一种相互依存的关系, 这种关系体现仅仅在完成对模型正确辨识的条件下, 才可能保证对当时刻状态较好的估计; 而较好状态估计结果的获取, 又可进一步为下一时刻模型的辨识提供可靠保障. 因此 EMPF 所获得较好的状态估计效果必然建立在模型正确辨识的基础之上. 针对 IMMPF 和 MPF 滤波精度受限的原因在本文的引言中已经给予详细的分析, 这里就不再累述. 表 1 中数据给出了各滤波算法均方根误差的均值的结果, 定量给出了 3 种算法在滤波精度方面的差异.

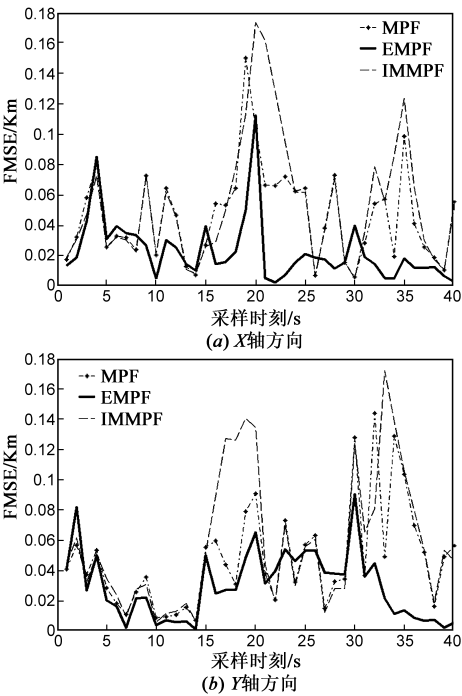


图3 位置分量的RMSE比较

表 1 基于 50 次独立仿真条件下算法目标位置分量 RMSE 的均值比较

	IMMPF	MPF	EMPF
水平方向	0.054002	0.047983	0.023027
竖直方向	0.058183	0.046263	0.029699

5 结论

在实际工程应用中, 由于被估计系统状态演化形式的复杂性, 传感器种类的多样性等因素, 系统一般采用为多模式的非线性模型. 由于传统 IMM 算法次优滤波器的采用常常无法满足滤波精度的需求. 利用 EKF 与 PF 自身特殊预测更新机制的有机结合, 本文给出了一种基于粒子优化的多模型粒子滤波算法. 由于采用了 PF 的框架, 因此算法具有较好地处理非线性非高斯问题的能力. 相对于 IMMPF, 避免了模型转移概率采用近似计算方式造成模型状态辨识的不稳定性的影响. 相对于 MPF, EMPF 通过最新量测信息的引入实现采样粒子的优化, 改善了采样粒子对于真实状态的逼近程度, 从而进一步提升了系统状态估计和模型状态辨识的准确性和可靠性.

参考文献:

[1] Li X R. Multiple-model estimation with variable structure—Part II: Model-set adaptation[J]. IEEE Trans on Automatic Control, 2000, 45(11): 2047 – 2060.

[2] Musicki D, Suvorova S. Tracking in clutter using IMM-IPDA-based algorithms [J]. IEEE Transactions on Aerospace and Electronic Systems, 2008, 44(1): 111 – 126.

[3] Mallick M, La Scala B F. IMM estimator for ground target tracking with variable measurement sampling intervals[A]. The 9th International Conference on Information Fusion [C]. Florence: IEEE press, 2006, 1 – 8.

[4] Kirubarajan T, Bar-Shalom Y. Kalman filter versus IMM estimator; when do we need the latter [J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1452 – 1457.

[5] 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.

[6] 张焱, 张志龙, 沈振康, 鹿小莺. 基于动态显著性特征的粒子滤波多目标跟踪算法[J]. 电子学报, 2008, 36(12): 2306 – 2311.

Zhang Yan; Zhang Zhi-long; Shen Zhen-kang; Lu Xiao-ying. The images tracking algorithm using particle filter based on dynamic salient features of targets[J]. Acta Electronica Sinica, 2008, 36(12): 2306 – 2311. (in Chinese)

[7] Cappe O, Godsill S J, Moulines E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE, 2007, 95(5): 899 – 924.

[8] Liu G X, Gao E K, Fan C Y. Multirate interacting multiple model algorithm combined with particle filter for nonlinear/non-Gaussian target tracking[A]. The 16th International Conference on Artificial Reality and Telexistence-Workshops [C].

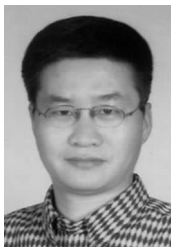
Hangzhou: IEEE press, 2006, 298 – 301.

- [9] Boers Y, Driessen J N. Interacting multiple model particle filter [J]. IEE Proceedings Radar Sonar Navigation, 2003, 150(5): 334 – 349.
- [10] LI Liang-qun, JI Hong-bing, LUO Jun-hui. The iterated extended Kalman particle filter [A]. IEEE International Symposium on Communications and Information Technology [C]. Adelaide: IEEE press, 2005, 1213 – 1216.
- [11] 杨小军, 潘泉, 张洪才. 基于 Monte Carlo 方法的自适应多模型诊断 [J]. 控制理论与应用, 2005, 22(5): 723 – 726.

(Yang Xiao-jun, Pan Quan, Zhong Hong-cai. Adaptive multi-model diagnosis using Monte Carlo method [J]. Control Theory & Applications, 2005, 22(5): 723 – 726. (in Chinese))

- [12] Driessen H, Boers Y. Efficient particle filter for jump Markov nonlinear systems [J]. IEE Proceedings Radar Sonar Navigation, 2005, 152(5): 323 – 326.
- [13] Ristic B, Arulampalam S. and Gordon N. Beyond the Kalman filter: particle filters for tracking applications [M]. Boston, London: Artech House Publishers, 2004.

作者简介:



刘先省 男, 1964 年出生于河南潢川县, 博士, 现为河南大学计算机与信息工程学院教授. 主要研究领域为多源信息融合、自适应数字波束形成和传感器网络等.

E-mail: liuxianxing@henu.edu.cn



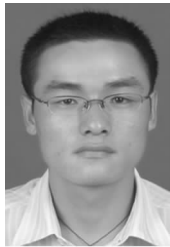
胡振涛 男, 1979 年出生于河南省永城市, 现为西北工业大学自动化学院博士研究生. 主要研究方向: 多源信息融合, 非线性滤波, 机动目标跟踪等.

E-mail: guchenshou@yahoo.com.cn



金 勇 男, 1972 年出生于河南省开封市, 博士生, 现为河南大学计算机与信息工程学院副教授, 主要研究方向: 信息融合, 阵列信号处理, 方位估计等.

E-mail: jy@henu.edu.cn



杨一平 男, 1981 年出生于山西省芮城县, 硕士, 现为河南大学智能技术与系统重点实验室讲师. 主要研究方向: 信息融合、传感器网络等.

E-mail: yangyp@henu.edu.cn