

# 基于广义 UT 变换的交互式多模型粒子滤波算法

胡振涛, 潘 泉, 杨 峰

(西北工业大学自动化学院, 陕西西安 710072)

**摘 要:** 针对粒子滤波中重采样过程与优化提议分布的处理方式导致的粒子溃退和算法实时性下降问题, 通过广义 UT 变换原理和卡尔曼滤波预测更新机制的引入, 实现当前量测信息对于状态估计结果的直接优化, 给出了一种基于广义 UT 变换的粒子滤波算法. 另外, 将改进后算法与交互式多模型相结合, 进而提出了一种基于广义 UT 变换的交互式多模型粒子滤波算法. 理论分析和仿真结果表明: 新算法在计算复杂度方面与标准粒子滤波相近, 在滤波精度方面优于标准粒子滤波及其改进算法.

**关键词:** 混合系统; 粒子滤波; 交互式多模式; 广义 UT 变换

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112 (2010) 06-1443-06

## Interacting Multiple Model Particle Filtering Algorithm Based on Generalized Unscented Transformation

HU Zhen-tao, PAN Quan, YANG Feng

(College of Automation, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

**Abstract:** To solve the particles impoverishment and the real-time decline caused by re-sampling and the proposal distribution optimization, a novel particle filtering algorithm based on generalized unscented transformation is proposed. The generalized unscented transform and the one-step state prediction and observation update of Kalman filter are introduced to realize the optimization of state estimation by the latest observation information. Then, by means of combining the improved algorithm with interacting multiple model, the interacting multiple model particle filtering algorithm based on generalized unscented transformation is proposed. The theoretical analysis and experimental results show that the new algorithm is close to the standard particle filter in computational complexity and superior to the standard particle filter and its improved algorithms in precision.

**Key words:** hybrid system; particle filtering; interacting multiple model; generalized unscented transformation

### 1 引言

在复杂混合系统的建模中, 考虑到状态演化形式的多样性和环境的复杂性, 建立其能够包含各种情况的全局统计模型是不现实的, 一般采用多模型算法. 在此类方法中, 以交互式多模型算法 (IMM) 较为优越, 它采用一种模型“软切换”机制, 实现模型可靠辨识和状态有效估计之间的平衡<sup>[1,2]</sup>. 对于线性系统, IMM 中子滤波器通常采用卡尔曼滤波 (KF), 在一定程度上补偿了折中平衡过程所带来滤波精度的损失. 然而, 对于非线性系统, 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, 导致滤波精度的下降<sup>[3]</sup>. 近年来, 伴随着计算机性能不断提升, 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. 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, 并取得较好的估计结果<sup>[4,5]</sup>.

在粒子滤波中一个普遍存在的问题就是粒子退化现象, 其实质是随着迭代次数增加, 滤波器中用以逼近后验概率分布采样粒子有效性减弱的表现<sup>[6,7]</sup>. 针对粒子退化现象的解决, 目前主要有两种思路: 重采样和提议分布优选. 重采样过程的引入一定程度上抑制了粒子退化现象, 但同时也造成了粒子枯竭问题. 一般在重采样过程后引入 MCMC (Markov Chain Monte Carlo) 移动处理, 使得粒子集趋于平稳分布, 实现粒子间相关性的减弱和粒子多样性的增强, 然而算法实现过程需要完成三次粒子采样和粒子权重的度量, 严重增加了计算复杂度<sup>[8,9]</sup>. 提议分布优选的目标在于利用当前量测信息实现提议分布进一步逼近后验概率密度, 从而提升单个采样粒子的有效性, 具体实现算法如: PFEKF、PFIEK、PFUKF 和 PFGHF 等<sup>[7,10,11]</sup>. 由于此类算法需要对每个粒

子都运行一个次优滤波器,无疑将造成算法计算量的急剧膨胀,尤其当被估计系统状态的维数较高时,这种影响更为显著.另外,次优滤波器一般受限于系统非线性强度和噪声为高斯的假设,其滤波精度和实际应用对象有着密切的关系,造成改进后算法缺乏应用的普适性.针对以上问题,本文首先依据 UT 变换的基本原理,通过卡尔曼滤波预测更新机制引入,构建了广义 UT 变换粒子滤波方法(UTPF),新算法同时兼顾了实时性和滤波估计精度的改善;其次,将 UTPF 算法应用于 IMM 算法框架,最终给出了一种针对复杂混合系统状态估计的广义 UT 变换交互式多模型粒子滤波算法(IMM-UTPF).

## 2 粒子滤波

### 2.1 模型切换的混合系统建模

考虑以下具有模型切换的混合系统

$$m_k \sim p(m_k | m_{k-1}) \quad (1)$$

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, m_k, \mathbf{u}_k) \quad (2)$$

$$\mathbf{z}_k = h(\mathbf{x}_k, m_k, \mathbf{v}_k) \quad (3)$$

其中  $\mathbf{x}_k \in R^n$  为未知的连续值系统状态,  $m_k$  为未知的离散值模型状态,  $\mathbf{z}_k \in R^m$  为系统量测. 设过程噪声  $\mathbf{u}_k$  和量测噪声  $\mathbf{v}_k$  为相互独立的白噪声序列. 模型状态  $m_k$  服从离散时间、齐次、有限状态的一阶 Markov 链. 状态空间为  $D = \{1, 2, \dots, d\}$ , 初始概率分布为  $P_a = P_m \{m_0 = a\}$ ,  $a \in D$ , 转移概率为  $\Pi_{ab} = P_m \{m_{k+1} = b | m_k = a\}$ ,  $a, b \in D$ , 转移概率矩阵为  $\Pi = [\Pi_1, \Pi_2, \dots, \Pi_d]^T$ ,  $\Pi_a = [\Pi_{a1}, \Pi_{a2}, \dots, \Pi_{ad}]$ , 且  $\sum_{b=1}^d \Pi_{ab} = 1$ . 设直到  $k$  时刻时量测累积集合  $\mathbf{z}_{1:k} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$ .

### 2.2 粒子滤波

粒子滤波主要通过序贯重要性采样和重采样两个步骤实现,首先从某个易于采样且接近后验概率分布的提议分布  $q(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})$  中抽取附带权重粒子  $\{\mathbf{x}_k^i, \omega_k^i\}_{i=1}^N$ , 实现状态估计的一步预测;其次,对  $\omega_k^i$  完成归一化处理,并依据归一化后权重  $\tilde{\omega}_k^i$  完成状态估计的更新. 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  $\{\mathbf{x}_k^j, \omega_k^j\}_{j=1}^N$ , 最终状态的后验概率分布逼近为

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) \approx \sum_{j=1}^N \tilde{\omega}_k^j \delta(\mathbf{x}_k - \mathbf{x}_k^j) / N \quad (4)$$

其中,  $\delta(\mathbf{y})$  是狄拉克函数, 当  $\mathbf{y} = \mathbf{0}$  时,  $\delta(\mathbf{y}) = 1$ , 否则  $\delta(\mathbf{y}) = 0$ . 由于  $p(\mathbf{x}_k | \mathbf{z}_{1:k})$  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. 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

$$q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k}) = p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i) \quad (5)$$

则粒子权重的递推表达式为

$$\omega_k^i = \omega_{k-1}^i p(\mathbf{z}_k | \mathbf{x}_k^i) \quad (6)$$

## 3 基于 UT 变换的粒子滤波算法

对于标准粒子滤波算法研究发现, 限制其滤波精度提升的关键在于当前时刻粒子采样过程中缺乏对于最新量测信息的合理利用, 从而减弱了采样粒子对真实状态逼近的有效性. 目前, 常用解决方法主要通过引入次优滤波实现提议分布的优选, 采用优化采样粒子为核心的思想, 此类方法的缺陷在于引入了较大计算负担, 同时造成改进后算法缺乏应用的普适性. 基于以上分析, 以下给出了一种广义 UT 变换粒子滤波方法, 算法以直接优化状态估计为目标, 同时兼顾对粒子枯竭问题的解决.

### 3.1 广义 UT 变换

UT 变换基于近似非线性函数的概率密度分布逼近其函数更容易思想, 利用一组附带权重的 Sigma 点集直接通过非线性变换逼近后验概率分布, 其基本原理如图 1 所示.




图1 UT变换原理图

根据该原理英国学者 Julier S J, Uhlmann J K 等基于卡尔曼滤波框架设计了 UKF 滤波器<sup>[12]</sup>. 考虑到粒子滤波采用随机性采样策略, 其附带权重的采样粒子集本身就是对于概率密度分布特性的一种体现, 对采样粒子集的粒子直接进行非线性变换即能够完成对于后验概率分布的有效逼近, 这种随机性采样粒子通过非线性变换实现非线性函数分布逼近的方式称之广义 UT 变换.

### 3.2 广义 UT 变换粒子滤波算法

卡尔曼滤波是一种基于递推 Bayesian 原理的状态估计器. 在滤波器的实现过程中, 同时进行状态估计和状态估计协方差的更新. 首先, 通过先验建模信息实现对于状态的一步预测; 其次, 通过状态估计协方差的更新实现对于状态预测的评价, 并确定滤波增益的大小, 进而完成对最新量测信息的有效利用和状态预测的更新. EKF、IEKF、UKF 和 GHF 等均采用了卡尔曼滤波的算法机理. 针对粒子滤波中采样粒子缺乏对于最新量测信息利用而造成的滤波精度受限问题, UTPF 算法引入卡尔曼滤波中一步预测和量测更新的机理, 在广义 UT

变换的基础上,实现粒子滤波与卡尔曼滤波两种不同算法机理动态的有机结合.下面具体分析 UTPF 算法的具体构建过程.

首先,基于广义 UT 变换的思想和先验模型信息实现粒子在提议分布中的采样,并利用式(6)实现对于粒子权重的度量,进而依据采样粒子和归一化后的粒子权重计算状态和量测的一步预测值:

$$\mathbf{x}_{k/k-1}^i = f(\mathbf{x}_{k-1}^i) + \mathbf{u}_{k-1}^i \quad (7)$$

$$\hat{\mathbf{x}}_{k/k-1} = \sum_{i=1}^N \tilde{\omega}_k^i \mathbf{x}_{k/k-1}^i \quad (8)$$

$$\mathbf{z}_{k/k-1}^i = h(\mathbf{x}_{k/k-1}^i) \quad (9)$$

$$\hat{\mathbf{z}}_{k/k-1} = \sum_{i=1}^N \tilde{\omega}_k^i \mathbf{z}_{k/k-1}^i \quad (10)$$

$$\boldsymbol{\varepsilon}_k = \mathbf{z}_k - \hat{\mathbf{z}}_{k/k-1} \quad (11)$$

其中,  $\mathbf{x}_{k/k-1}^i$  和  $\mathbf{z}_{k/k-1}^i$  分别表示粒子状态和粒子量测的一步预测值,  $\tilde{\omega}_k^i$  表示预测粒子的归一化权重,  $\hat{\mathbf{x}}_{k/k-1}$  和  $\hat{\mathbf{z}}_{k/k-1}$  分别表示系统状态和量测的一步预测值,  $\boldsymbol{\varepsilon}_k$  表示残差向量. 为构建滤波增益阵  $\mathbf{K}$ , 需要进一步计算状态的预测误差协方差  $\mathbf{P}_{k/k-1}$ 、状态与量测的预测误差协方差  $\mathbf{P}_{xz}$ 、残差协方差  $\mathbf{S}_k$  [13]:

$$\mathbf{P}_{k/k-1} = \sum_{i=1}^N \tilde{\omega}_k^i [\mathbf{x}_{k/k-1}^i - \hat{\mathbf{x}}_{k/k-1}][\mathbf{x}_{k/k-1}^i - \hat{\mathbf{x}}_{k/k-1}]^T \quad (12)$$

$$\mathbf{P}_{xz} = \sum_{i=1}^N \tilde{\omega}_k^i [\mathbf{x}_{k/k-1}^i - \hat{\mathbf{x}}_{k/k-1}][\mathbf{z}_{k/k-1}^i - \hat{\mathbf{z}}_{k/k-1}]^T \quad (13)$$

$$\mathbf{S}_k = \sum_{i=1}^N \tilde{\omega}_k^i [\mathbf{z}_{k/k-1}^i - \hat{\mathbf{z}}_{k/k-1}][\mathbf{z}_{k/k-1}^i - \hat{\mathbf{z}}_{k/k-1}]^T + \mathbf{R}_k \quad (14)$$

$$\mathbf{K} = \mathbf{P}_{xz} (\mathbf{S}_k)^{-1} \quad (15)$$

根据公式(12)至公式(15)得到滤波增益矩阵  $\mathbf{K}$ . 考虑到粒子滤波过程中粒子退化现象的改善及有效粒子利用效率的提升,在此引入重采样过程,实现粒子滤波框架意义下的状态更新.

$$\bar{\mathbf{x}}_{k/k} = \sum_{j=1}^N \mathbf{x}_{k/k}^j / N \quad (16)$$

其中,粒子集  $\{\mathbf{x}_{k/k}^j\}_{j=1}^N$  为对  $\{\mathbf{x}_{k/k-1}^i\}_{i=1}^N$  进行重采样得到的新粒子集,  $\bar{\mathbf{x}}_{k/k}$  表示基于重采样技术得到的状态估计的更新结果.在此基础上,利用增益阵  $\mathbf{K}$  实现卡尔曼滤波框架意义下的状态更新,通过最新量测信息的利用实现对于  $\bar{\mathbf{x}}_{k/k}$  的修正.

$$\hat{\mathbf{x}}_{k/k} = \bar{\mathbf{x}}_{k/k} + \mathbf{K}\boldsymbol{\varepsilon}_k \quad (17)$$

$$\mathbf{P}_{k/k} = \mathbf{P}_{k/k-1} - \mathbf{K}(\mathbf{S}_k)^{-1}\mathbf{K}^T \quad (18)$$

$\hat{\mathbf{x}}_{k/k}$  和  $\mathbf{P}_{k/k}$  分别表示  $k$  时刻滤波估计值和估计误差协方差.为改善重采样过程引入导致的粒子枯竭问题,依据  $\hat{\mathbf{x}}_{k/k}$  和  $\mathbf{P}_{k/k}$  实现粒子多样性的增强,具体实现形式如下:

$$\begin{cases} \mathbf{x}_k^i = \mathbf{x}_k^i & , e_j < \zeta \\ \mathbf{x}_k^i = (\mathbf{x}_k^i + \hat{\mathbf{x}}_{k/k} + \sqrt{\mathbf{P}_{k/k}}) / 2 & , e_j \geq \zeta \end{cases} \quad (19)$$

$e_j \sim u[0,1]$  为服从 0 至 1 区间均匀分布的随机数,  $\zeta$  为转移控制因子,且  $\zeta \in [0,1]$ ,其大小影响着重采样后粒子多样性的改善程度.另外,由公式(19)表达形式可知:这种粒子多样性方式的增强模式,能够有效地提取和利用重采样后粒子和当前估计结果中蕴含的冗余和互补信息.

#### 4 广义 UT 变换交互式多模型粒子滤波算法

为实现对于具有多模型特点的复杂混合系统的状态估计,将 UTPF 算法与 IMM 有机的结合,以进一步提升 IMM 中子滤波器对于非线性系统的状态估计精度. IMM 的实现思想在于保持系统中所有模型并行滤波,并用计算的概率权值对这些模型输出进行综合,主要分为输入交互、模型滤波、模型概率更新和估计综合四个环节 [14]. IMM-UTPF 与已有 IMM-PF 算法相比不同之处在于模型滤波阶段用 UTPF 算法替代 PF 算法,采用伪代码的形式,以下给出 IMM-UTPF 算法实现步骤:

已知  $k-1$  时刻各模型的概率  $\mu_{k-1}^a$  及采用不同模型的粒子  $\{\mathbf{x}_{k-1}^{a,i}\}_{i=1}^N, a=1,2,\dots,d$ .

(1) 输入交互

模型预测概率:

$$\bar{\mu}_{k-1}^a = \sum_{b=1}^d \prod_{ba} \mu_{k-1}^b, b=1,2,\dots,d$$

模型的混合概率:  $\mu_{b/a} = \prod_{ba} \mu_{k-1}^b / \bar{\mu}_{k-1}^a$

对模型粒子混合状态估计:

$$\bar{\mathbf{x}}_{k-1}^{a,i} = \sum_{b=1}^d \mathbf{x}_{k-1}^{b,i} \mu_{b/a}$$

(2) 模型滤波

以模型交互后得到的粒子集  $\{\bar{\mathbf{x}}_{k-1}^{a,i}\}_{i=1}^N$ , 作为模型在  $k-1$  时刻的粒子,并利用 UTPF 算法得到  $k$  时刻模型的状态估计值  $\hat{\mathbf{x}}_{k/k}^a$  和粒子集  $\{\mathbf{x}_{k/k}^{a,j}\}_{j=1}^N$ , 以及模型概率更新阶段所需残差  $\boldsymbol{\varepsilon}_k^a$  和残差协方差  $\mathbf{S}_k^a$ .

(3) 模型概率更新

模型似然函数:

$$\Lambda_a = (2\pi)^{-1} |\mathbf{S}_k^a|^{-1/2} \exp\left(-\frac{1}{2}(\boldsymbol{\varepsilon}_k^a)^T (\mathbf{S}_k^a)^{-1} (\boldsymbol{\varepsilon}_k^a)\right)$$

模型概率:  $\mu_k^a = \bar{\mu}_k^a \Lambda_a / \sum_{b=1}^d \bar{\mu}_k^b \Lambda_b$

(4) 输出交互

状态估计:  $\hat{\mathbf{X}}_{k/k} = \sum_{a=1}^d \hat{\mathbf{x}}_{k/k}^a \mu_k^a$ .

#### 5 仿真结果与分析

仿真实验中给出了两组仿真算例.算例一在单模

型的意义下,验证了 UTPF 算法在提升滤波精度方面的优势,同时给出与传统的提议分布优化方法在实时性方面的比较结果.仿真中分别选用了文献[11]和文献[7]中采用的两种典型非线性非高斯模型.算例二则验证了 IMM-UTPF 算法针对高维数、多模型非线性系统状态估计的有效性.

### 例 1 模型 1

$$x_{k+1} = 0.5x_k + \sin(0.04\pi k) + 1 + u_{1,k}$$

$$y_k = \begin{cases} x_k^2/5 + v_{1,k}, & 1 < k \leq 30 \\ x_k/2 - 2 + v_{1,k}, & k > 30 \end{cases}$$

### 模型 2

$$x_{k+1} = 0.5x_k + 25[x_k/(1+x_k^2)] + 8\cos[1.2(k-1)] + u_{2,k}$$

$$y_k = x_k^2/20 + v_{2,k}$$

模型 1 为一个分段非线性系统模型,且系统过程噪声  $u_{1,k}$  为伽玛噪声,其噪声统计特性满足  $Ga(3,2)$ ,量测噪声  $v_{1,k}$  为高斯噪声,噪声统计特性满足  $N(0,0.00001)$ ,仿真步数  $T1$  为 60s.模型 2 为一个典型非线性增长系统模型,系统的非线性程度将随着采样步长逐步增强.模型中系统过程噪声  $u_{2,k}$  采用高斯噪声,噪声统计特性满足  $N(0,10)$ ,量测噪声  $v_{2,k}$  采用高斯噪声,噪声统计特性满足  $N(0,4)$ ,仿真步数  $T2$  为 40s.蒙特卡罗仿真次数  $M$  为 50,采样粒子个数  $N$  为 300.其数学表达式为  $RMSE = \{\sum_{num=1}^M (\mathbf{x}_k - \hat{\mathbf{X}}_{k/k,num})^2/M\}^{1/2}$ ,  $\mathbf{x}_k$  和  $\hat{\mathbf{X}}_{k/k,num}$  分别表示系统的状态真值和第  $num$  次蒙特卡罗仿真中  $k$  时刻的状态估计值.针对以上两种模型,仿真中对比 EKF、UKF、PF、PFMC、PFEKF、PFIEKF、PFEKFMC、PFUKF、PFUKFMC 及 UTPF 等 10 种算法的滤波估计结果,表 1 中数据定量给出了各滤波算法均方根误差的均值和方差及平均运行时间的对比结果.

表 1 基于 50 次独立仿真条件下算法平均运行时间以及 RMSE 的均值和方差比较

|         | 模型 1     |          | Time/s  |
|---------|----------|----------|---------|
|         | 均值       | 方差       |         |
| EKF     | 0.277590 | 0.106060 | -----   |
| UKF     | 0.219220 | 0.069065 | -----   |
| PF      | 0.356100 | 0.086690 | 2.98070 |
| PFMC    | 0.338720 | 0.080888 | 6.52680 |
| PFEKF   | 0.238640 | 0.082786 | 6.66500 |
| PFIEKF  | 0.055452 | 0.004671 | 8.06310 |
| PFEKFMC | 0.243260 | 0.086826 | 14.0760 |
| PFUKF   | 0.067329 | 0.018750 | 21.5082 |
| PFUKFMC | 0.068142 | 0.018785 | 44.0774 |
| UTPF    | 0.040938 | 0.004516 | 3.52470 |

表 2 基于 50 次独立仿真条件下算法平均运行时间以及 RMSE 的均值和方差比较

|         | 均值      | 模型 2    |         |
|---------|---------|---------|---------|
|         |         | 方差      | Time/s  |
| EKF     | 14.0327 | 41.7777 | -----   |
| UKF     | 9.12420 | 6.62090 | -----   |
| PF      | 4.23210 | 4.91050 | 0.92600 |
| PFMC    | 4.21720 | 4.94070 | 1.97860 |
| PFEKF   | 11.5443 | 20.7218 | 3.82970 |
| PFIEKF  | 12.4944 | 34.5110 | 4.55410 |
| PFEKFMC | 11.4907 | 18.2063 | 8.03760 |
| PFUKF   | 8.99390 | 11.3464 | 7.52130 |
| PFUKFMC | 10.1374 | 12.9695 | 15.7537 |
| UTPF    | 4.17070 | 4.78890 | 1.26780 |

通过分析表 1 和表 2 中给出的仿真数据可知:在弱非线性、非高斯噪声情况下,采用次优滤波优化提议分布的方式在一定程度上提升了改进后算法的滤波精度,但是代价是算法的实时性能的急剧下降,而相比较 UTPF 算法具有兼顾算法精度和实时性能改善的优势.在强非线性、非高斯噪声情况下,采用次优滤波优化提议分布的方式,其结果不仅没有提升改进后算法的滤波精度,反而导致算法滤波精度和实时性能的下降.分析主要原因就在于次优滤波器本身缺乏对于模型 2 中强非线性的有效处理能力,这种缺陷清晰地体现在表征 EKF 和 UKF 滤波精度的数据中,进而导致修正后提议分布相对于真实后验分布偏差的进一步扩大,减弱采样粒子对于真实状态逼近的有效性.UTPF 采用直接优化状态估计结果,避免了传统的优化采样粒子方法带来的缺点,且保障了算法的实时性.

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

$$\mathbf{X}_k = \begin{cases} \mathbf{F}_1 * \mathbf{X}_{k-1} + \mathbf{\Gamma} \mathbf{u}_{1,k-1} & , 1 \leq k \leq 68 \\ \mathbf{F}_2 * \mathbf{X}_{k-1} + \mathbf{\Gamma} \mathbf{u}_{2,k-1} & , 68 < k \leq 257 \\ \mathbf{F}_1 * \mathbf{X}_{k-1} + \mathbf{\Gamma} \mathbf{u}_{1,k-1} & , 257 < k \leq 324 \end{cases}$$

$$\mathbf{z}_k = \left[ \text{sqrt}(x_k^2 + y_k^2) \quad \tan^{-1}\left(\frac{y_k}{x_k}\right) \right]^T + \mathbf{v}_k$$

其中,  $\mathbf{X}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$ ,  $x_k, \dot{x}_k, y_k$  和  $\dot{y}_k$  分别表示目标状态在水平和垂直方向的位置分量和速度分量,

$$\mathbf{F}_1 = \begin{bmatrix} 1 & t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & t & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{F}_2 = \begin{bmatrix} 1 & \sin(ut)/w & 0 & \frac{-(1-\cos(ut))}{w} \\ 0 & \cos(ut) & 0 & -\sin(ut) \\ 0 & (1-\cos(ut))/w & 1 & \sin(ut)/w \\ 0 & \sin(ut) & 0 & \cos(ut) \end{bmatrix}$$

为系统状态转移矩阵,仿真采样间隔  $t = 1s$ ,转弯角速度  $w = -0.9566^\circ$ ,系统噪声矩阵为  $\mathbf{\Gamma} = \begin{bmatrix} 0 & 0 & t/2 & t \\ t/2 & t & 0 & 0 \end{bmatrix}^T$ .系统过程噪声  $u_{1,k}$  和  $u_{2,k}$  分别为均值是零,标准差是

$\mathbf{Q}_{1,k} = 0.2\mathbf{I}$  和  $\mathbf{Q}_{2,k} = \mathbf{Q}_{1,k}$  的高斯白噪声,  $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ . 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  $R_r = 0.2\text{km}$ , 方位角分量的噪声标准差  $R_\theta = 0.3^\circ$ . 目标状态的初值  $\mathbf{X}_0 = [5, 0.3, 43, 0]^T$ , Monte Carlo 仿真次数循环数  $M$  取为 50 次, 在每次 Monte Carlo 循环中仿真步数  $T$  为 324s, 采样粒子个数  $N$  为 500. 仿真中对比了 IMM-EKF、IMM-UKF、IMM-PF、IMM-PFMC、IMM-PFEKF、IMM-PFUKF 及 IMM-UTPF 的状态估计效果.




图2 水平方向位置估计的RMSE比较

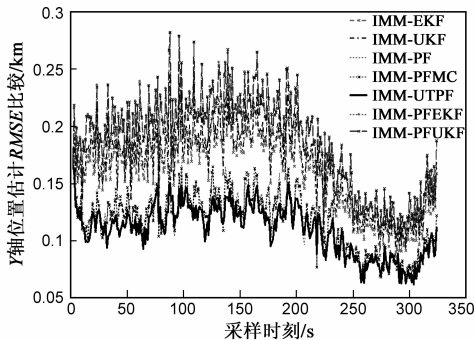


图3 垂直方向位置估计的RMSE比较

表3 基于 50 次独立仿真条件下算法平均运行时间以及 RMSE 的均值比较

|           | 均值 (km) |        | Time/s   |
|-----------|---------|--------|----------|
|           | X 轴     | Y 轴    |          |
| IMM-EKF   | 0.1703  | 0.1607 | -----    |
| IMM-UKF   | 0.1764  | 0.1662 | -----    |
| IMM-PF    | 0.1230  | 0.1180 | 64.6575  |
| IMM-PFMC  | 0.1221  | 0.1179 | 166.1140 |
| IMM-PFEKF | 0.2004  | 0.1864 | 112.0157 |
| IMM-PFUKF | 0.2006  | 0.1867 | 205.5134 |
| IMM-UTPF  | 0.1138  | 0.1104 | 69.0869  |

图 2 和图 3 分别给出了 50 次独立实验条件下算法状态估计的均方根误差比较;表 3 中数据定量给出了各滤波算法均方根误差的均值及平均运行时间的对比结果.从以上仿真结果可以清晰的看出:针对多模式、高维数、非线性系统的状态估计,IMM-PF 的滤波精度优于

IMM-EKF 和 IMM-UKF. IMM-PFMC 算法通过改善粒子多样性进一步提升了 IMM-PF 滤波精度,但代价是算法实时性的急剧恶化,在相同仿真环境下耗时接近 IMM-PF 算法的三倍.在被比较的 7 种算法中 IMM-PFEKF 和 IMM-PFUKF 无论从滤波精度以及实时性方面表现都非常差,造成这种结果的原因实际上与例 1 中导致模型 2 中滤波效果下降的原因相同.而本文给出算法在滤波精度方面明显均优于其它的 6 种算法,在算法实时性方面也优于 IMM-PFMC、IMM-PFEKF 和 IMM-PFUKF,且相对于 IMM-PF 的计算量仅有较少的增加.

## 6 结论

近年来,随着感知手段的日益丰富、感知任务的日益复杂精细、感知对象的日益多样,使得被估计系统越来越呈现出不确定、多模态、多尺度、高维数、非线性等复杂系统特征.系统中这些新特点的出现,进一步对估计理论发展和应用提出了更加严峻的挑战.针对具有以上特点复杂系统的状态估计问题,本文给出了一种基于广义 UT 变换的交互式粒子滤波算法.相对现有的处理方法,新算法具有以下优势:首先,IMM-UTPF 算法采用 IMM 与 PF 相结合算法框架,保留了解决多模态、非线性和非高斯问题的优点.其次,利用卡尔曼滤波量测更新原理实现针对状态估计的直接优化,避免了传统优化采样粒子方式造成的计算量急剧膨胀问题,以及外界扰动对于粒子权重有效度量造成不利影响,同时增强了算法的普适性.另外,基于状态估计改善重采样后粒子多样性的方法,建立在对于当前时刻状态估计和采样粒子中蕴含信息的充分提取和利用的基础上,具有物理意义明确,工程实现简单的优点.

## 参考文献:

- [1] Rapoport I, Oshman Y. Efficient fault tolerant estimation using the IMM methodology [J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(2): 492 - 508.
- [2] Sathyan T, Sinha A, Kirubarajan T. Passive geolocation and tracking of an unknown number of emitters [J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(3): 740 - 750.
- [3] Blom H A P, Bloem E A. Exact Bayesian and particle filtering of stochastic hybrid systems [J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(1): 55 - 70.
- [4] Boers Y, Driessen J N. Interacting multiple model particle filter [J]. IEE Proceedings Radar Sonar Navigation, 2003, 150(5): 334 - 349.
- [5] Morelande M R, Challa S. Maneuvering target tracking in clutter using particle filters [J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(1): 252 - 270.

- [6] 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.
- [7] 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.
- [8] Bolic M, Djuric P M, Hong S J. Re-sampling algorithms and architectures for distributed particle filters[J]. IEEE Transactions on Signal Processing, 2005, 53(7): 2442 – 2450.
- [9] Ristic B, Arulampalam M S, Gordon N. Beyond the Kalman Filter: Particle Filters for Tracking Applications[M]. Boston: Artech House Publishers, 2004. 87 – 101.
- [10] Der Merwe R V, Doucet A, N De Freitas, et al. The Unscented Particle Filter[R]. Cambridge: Cambridge University Press, 2001.
- [11] 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]. Beijing, China: IEEE Press, 2005. 1213 – 1216.
- [12] Julier S J, Uhlmann J K, Durrant-Whyte H F. A new approach for the nonlinear transformation of means and covariances in filters and estimators [J]. IEEE Transactions on Automatic Control, 2000, 45(3): 477 – 482.
- [13] 何友, 修建娟, 张晶炜, 等. 雷达数据处理及应用[M]. 北京: 电子工业出版社, 2006. 23, 47 – 48.

HE You, Xiu Jian-juan, Zhang Jing-wei, et al. Radar Data Processing with Application[M]. Bei Jing: Publishing House of Electronics Industry, 2006. 23, 47 – 48. (in Chinese)

- [14] Bar-Shalom Y, Chen Hui-min. IMM estimator with out-of-sequence measurements [J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(1): 90 – 98.

#### 作者简介:



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生研究生, 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



潘泉 男, 1961 年出生于上海市, 现为西北工业大学自动化学院教授, 博士生导师. 主要研究方向: 动态系统建模、多目标跟踪与识别、信息融合等.

E-mail: quanpan@nwpu.edu.cn

杨峰 男, 1977 年出生于陕西省西安市, 现为西北工业大学自动化学院讲师, 博士. 主要研究方向: 信息融合, 目标检测、跟踪与识别, C4ISR 建模与仿真等. E-mail: yangfeng@nwpu.edu.cn

