

区间量测下基于无迹变换的伯努利粒子滤波算法

吴孙勇^{1,2†}, 张馨方¹, 桂丛楠³, 蔡如华¹, 孙希延²

(1. 桂林电子科技大学 数学与计算科学学院, 广西 桂林 541004; 2. 广西精密导航技术与应用
重点实验室, 广西 桂林 541004; 3. 中国电子科技集团公司第五十四研究所, 石家庄 050081)

摘要: 针对区间量测下目标的实时检测与跟踪问题, 提出基于无迹变换的伯努利粒子滤波算法 (Bernoulli-Upf). 该算法在伯努利粒子滤波算法 (Bernoulli-pf) 的基础上融合无迹卡尔曼滤波 (UKF), 融合后的算法在预测步骤产生持续存活粒子时, 充分考虑到当前时刻的量测, 从而引导粒子向高似然区域移动, 使得粒子分布更加接近真实状态的后验分布. 仿真实验表明, Bernoulli-Upf 算法的估计精度优于 Bernoulli-pf 算法.

关键词: 目标跟踪; 区间量测; 伯努利滤波; 无迹卡尔曼滤波; 粒子滤波

中图分类号: TP391

文献标志码: A

Bernoulli particle filter algorithm based on unscented transformation in interval measurement

WU Sun-yong^{1,2†}, ZHANG Xin-fang¹, GUI Cong-nan³, CAI Ru-hua¹, SUN Xi-yan²

(1. School of Mathematics and Computational Science, Guilin University of Electronic Technology, Guilin 541004, China; 2. Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin 541004, China; 3. The 54th Research Institute of CETC, Shijiazhuang 050081, China)

Abstract: An improved Bernoulli particle filter algorithm based on unscented transformation is proposed for target detection and tracking in the interval measurement. Under the theory framework of the particle filter, an algorithm which combines the particle filter with the unscented Kalman filter (UKF) is presented. When persistent particles are calculated during the predicted measure by using the algorithm, the persistent particles are most likely to be in the region of high likelihood based on the current measurement, which makes the particles distribution more approach to the true posterior distribution of the state. Simulation results show that the tracking error of the improved Bernoulli particle filter is less than the original algorithm.

Keywords: target tracking; interval measurement; Bernoulli filter; unscented Kalman filter; particle filter

0 引言

目标跟踪技术已广泛地应用于军事和民事领域, 尤其是基于随机有限集 (RFS)^[1] 理论的目标跟踪算法备受国内外学者的关注. 21 世纪初, Ristic 等^[2] 基于伯努利随机有限集理论, 提出了标准量测模型下的伯努利滤波, 同时给出了滤波的两种实现方式: 粒子滤波实现 (即伯努利粒子滤波)、高斯和实现 (即伯努利高斯和滤波). 但在实际应用中, 标准的量测模型有时不能满足现实需求, 例如: 在复杂分布系统和无线传感网络中, 虽然由传感器检报出来的是一个点量测值, 但实际的量测会受未知分布的边界误差影响, 使

得该类非标准的量测需要用区间形式表示^[3]. 区间量测弥补了标准量测模型的不足, 将标准量测模型中仅受随机噪声影响的点量测用区间量测表示, 不仅可以解决跟踪过程中监视区域内目标出现和消失的问题, 还可以解决由随机不确定性、集合论不确定性和数据融合 3 种不确定源下所影响的非标准量测问题^[4-5]. 因此, Arulampalam 等在随机有限集理论的基础上提出了不精确量测模型下的伯努利滤波, 用于解决区间量测下的目标检测和跟踪问题, 同时应用粒子滤波对其进行实现, 称为区间量测下的伯努利粒子滤波算法^[6-8]. 该算法仅将系统状态转移概率密度作为

收稿日期: 2016-05-26; 修回日期: 2016-12-03.

基金项目: 国家自然科学基金项目 (61261033, 61561016, 61362005); 广西自然科学基金项目 (2014GXNSFAA118352, 2014GXNSFBA118280, 2016GXNSFAA380073); 广西精密导航技术与应用重点实验室基金项目 (DH201502); 广西高校数据分析与计算重点实验室开放基金项目; 广西密码学与信息安全重点实验室研究课题 (GCIS201611).

作者简介: 吴孙勇 (1981-), 男, 副教授, 博士, 从事微弱目标检测与跟踪、阵列信号处理、粒子滤波等研究; 张馨方 (1991-), 女, 硕士生, 从事微弱目标检测与跟踪、粒子滤波的研究.

†通讯作者. E-mail: wusunyong121991@163.com

重要性密度函数,没有考虑最新得到的量测信息,忽略了量测值对于状态估计的修正作用,使得粒子严重依赖模型^[9],导致通过重要性密度函数抽取的样本与真实后验概率密度函数产生的样本存在一定的偏差,这种滤波算法存在估计精度不高、粒子退化等问题。

本文在区间量测下伯努利粒子滤波算法的基础上,提出一种基于无迹变换的伯努利粒子滤波算法.该算法的核心思想是在预测阶段,利用当前时刻量测信息和无迹卡尔曼滤波(UKF)^[10-11]产生持续存活粒子,此时重要性密度函数的选取不再是简单的转移方程,而是用带有当前时刻量测信息的无迹变换代替,从而引导粒子向高似然区域移动,使得粒子的分布更接近目标状态真实的后验概率分布,很大程度上改善了粒子退化和估计精度不高的问题.同时为了验证算法的稳定性,选取不同噪声的协方差进行仿真实验.仿真实验表明,Bernoulli-Upf算法能够提高滤波估计的精度。

1 问题描述

目标的随机集包含了目标状态的所有信息,如目标的运动、属性、产生和消失等.假定在 t_k 时刻的目标状态定义为伯努利随机有限集(RFS)并用 X_k 表示.有限集中元素的性质可用Mahler的有限集统计(FISST)表示^[12].伯努利随机有限集的有限集统计概率密度定义为

$$f(X) = \begin{cases} 1 - q, & X = \emptyset; \\ q \cdot s(x), & X = \{x\}; \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

其中: q 为该有限集元素 x 存在的概率, $s(x)$ 为该元素的概率密度函数, $1 - q$ 为没有目标的概率。

目标状态模型通过转移密度 $\Phi_{k+1|k} = (X|X')$ 表示, X' 和 X 分别表示 k 和 $k + 1$ 时刻状态的伯努利随机有限集, $\Phi_{k+1|k} = (X|X')$ 定义为

$$\Phi_{k+1|k}(X|X') = \begin{cases} 1 - p_B, & X' = \emptyset, X = \emptyset; \\ p_B \cdot b_{k+1|k}(x), & X' = \emptyset, X = \{x\}; \\ 1 - p_s(x'), & X' = \{x\}, X = \emptyset; \\ p_s(x') \cdot \pi_{k+1|k}(x|x'), & X' = \{x\}, X = \{x\}. \end{cases} \quad (2)$$

其中: $p_B \triangleq p_{B,k+1|k}$ 为 k 时刻到 $k + 1$ 时刻新生目标的概率; $b_{k+1|k}(x)$ 为 k 时刻到 $k + 1$ 时刻新生目标的空间分布; $p_s(x') \triangleq p_{s,k+1|k}(x')$ 为目标状态 x' 从 k 时刻到 $k + 1$ 时刻持续存活的概率; $\pi_{k+1|k}(x|x')$ 为目标的转移密度。

由于传感器存在漏检和虚警问题,传感器反馈出以区间形式表示的量测.假设在 k 时刻获得 m_k 个区

间量测 $[z]_{k,1}, \dots, [z]_{k,m_k}$,则区间量测通过如下有限集合表示:

$$\Upsilon_k = \{[z]_{k,1}, \dots, [z]_{k,m_k}\} \in F(\mathcal{I}Z). \quad (3)$$

其中: $[z]_{k,m_k}$ 为 k 时刻第 m_k 个量测; $\mathcal{I}Z$ 为量测空间 Z 所有闭区间组成的集合; $F(\mathcal{I}Z)$ 为 $\mathcal{I}Z$ 有限子集组成的空间, Υ_k 为 k 时刻所有量测信息构成的集合。

伯努利滤波的目的是利用量测 $\Upsilon_{1:k}$ 序贯地估计状态的后验概率密度函数 $f_{k|k}(X|\Upsilon_{1:k})$,从而根据所得概率密度递归地估计目标状态, $\Upsilon_{1:k} = (\Upsilon_1, \Upsilon_2, \dots, \Upsilon_k)$ 表示1到 k 时刻的量测集合. $f_{k|k}(X|\Upsilon_{1:k})$ 通过预测和更新步骤传递下去,且完全通过存在概率 $q_{k|k} = Pr\{X_k = 1|\Upsilon_{1:k}\}$ 和 $X_k = \{x\}$ 的空间后验概率密度函数 $s_{k|k} = p(x_k|\Upsilon_{1:k})$ 来刻画.因此,伯努利滤波的实质是通过预测、更新递归地传递 $q_{k|k}$ 和 $s_{k|k}(x)$ 。

2 区间量测下的伯努利粒子滤波改进算法

2.1 Bernoulli-Upf算法的基本思想

无迹卡尔曼滤波(UKF)是常用的次优非线性滤波,该方法在无迹变换的基础上发展起来.无迹变换的基本思想是,在原先状态分布中按照一定规则选取一些采样点,使这些点的均值和协方差等于原状态分布的均值和协方差,再将这此点代入非线性函数中,相应得到非线性函数点集,通过该点集求取变换后的均值和协方差.由于这些点在变换的过程中不仅利用了状态变量间的转移概率关系,同时也充分利用了当前时刻的量测信息,得到的重要性密度函数与真实状态的概率密度函数会有更大的重叠部分,会引导粒子向更高似然区域移动.本文在文献[8]伯努利粒子滤波算法的框架上融合了无迹卡尔曼滤波(UKF),利用UKF算法对持续存活的粒子进行预测.对于用区间表示的量测,为实现UKF算法,需要对UKF的输入量测作预处理,要将区间量测转换成点量测,并将当前时刻的量测考虑进去,使用UKF算法取代原有算法中的转移方程,得到下一时刻持续存活粒子。

2.2 Bernoulli-Upf算法的滤波实现

基于以上分析,给出伯努利粒子滤波与UKF融合后的改进算法.首先引入 k 时刻状态向量 X_k ,并将其后验概率密度用存在概率 $q_{k|k}$ 和一组带权的粒子集合 $\{w_k^i, x_k^i\}_{i=1}^N$ 刻画.同时又已知 k 时刻和 $k + 1$ 时刻的量测集合 Υ_k 和 Υ_{k+1} ,则融入UKF预测持续存活粒子的伯努利粒子滤波改进算法的一次迭代运算步骤如下。

Step 1 初始化.已知 k 时刻的后验概率密度,用一组带权的粒子集合表示 $\{w_k^i, x_k^i\}_{i=1}^N$.

Step 2 预测(时间更新).

Step 2.1:根据式(4)计算存在概率 $q_{k+1|k}$,有

$$q_{k+1|k} = p_B \cdot (1 - q_{k|k}) + p_s \cdot q_{k|k}. \quad (4)$$

Step 2.2: 预测 $k + 1$ 时刻持续存活粒子. 需对持续存活粒子和新生粒子进行预测, 本文采用 UKF 算法对持续存活粒子进行预测. 已知 k 时刻得到的粒子集合为 $\{w_k^i, x_k^i\}_{i=1}^N$, 当粒子传递到 $k + 1$ 时刻时, 用 UKF 算法取代状态转移方程, 即利用 UKF 算法对持续存活粒子进行采样. 在 UKF 算法的基础上完成对持续存活粒子的预测, 进而得到持续存活粒子集合 $\{x_{p,k+1|k}^i\}_{i=1}^N$. 下面给出利用 UKF 对持续存活粒子预测的一次迭代运算步骤.

Step 2.2.1: 计算 $x_{p,k}^n$ 的 σ 点 $\chi_{p,k}^{(i)} (i = 1, 2, \dots, 2m)$, 即

$$\begin{cases} \chi_{p,k}^{(0)} = x_{p,k}^n; \\ \chi_{p,k}^{(i)} = x_{p,k}^n + (\sqrt{m + \lambda P_k^n}), i = 1, 2, \dots, m; \\ \chi_{p,k}^{(i)} = x_{p,k}^n - (\sqrt{m + \lambda P_k^n}), i = m + 1, \dots, 2m. \end{cases} \quad (5)$$

$$\begin{cases} \omega_0^b = \lambda / (m + \lambda); \\ \omega_0^c = \lambda / (m + \lambda) + (1 - \alpha^2 + \beta); \\ \omega_i^{(b)} = \omega_i^{(c)} = 0.5 / (m + \lambda), i = 1, 2, \dots, 2m. \end{cases} \quad (6)$$

其中: m 为状态向量的维数 (本文 $m = 4$); $\lambda = \alpha^2(m + \kappa) - m$, α 决定 σ 点的散布程度, 一般取一个较小的正数 (本文取值为 0.01), κ 取值为 1; β 为 x 的分布信息 (本文取值为 1); $(\sqrt{(m + \lambda)P_k^n})_i$ 为矩阵平方根的第 i 列; $\omega_i^{(b)}$ 为一阶统计特征的权系数, $\omega_i^{(c)}$ 为二阶统计特征的权系数.

Step 2.2.2: 状态 $\chi_{p,k}^{(i)}$ 的提前预测为

$$\begin{cases} \chi_{p,k+1|k}^{(i)} = f_k(\chi_{p,k}^{(i)}), i = 1, 2, \dots, 2m; \\ \hat{x}_{p,k+1|k} = \sum_{i=0}^{2m} \omega_i^{(b)} \chi_{p,k+1|k}^{(i)}; \\ P_{p,k+1|k} = Q_k + \sum_{i=0}^{2m} \omega_i^{(c)} (\chi_{p,k+1|k}^{(i)} - \hat{x}_{p,k+1|k}) \times (\chi_{p,k+1|k}^{(i)} - \hat{x}_{p,k+1|k})^T. \end{cases} \quad (7)$$

Step 2.2.3: 量测的提前预测为

$$\hat{z}_{k+1|k} = \sum_{i=0}^{2m} \omega_i^{(b)} h_{k+1}(\chi_{p,k+1|k}^{(i)}). \quad (8)$$

Step 2.2.4: 在获得新的量测 $[z_{k+1}]$ 后进行滤波, 有

$$\begin{cases} \hat{x}_{p,k+1|k+1} = \hat{x}_{p,k+1|k} + K_k(z_{k+1} - \hat{z}_{k+1|k}), \\ P_{p,k+1|k+1} = P_{p,k+1|k} - K_k S_k K_k^T. \end{cases} \quad (9)$$

其中

$$\begin{aligned} K_k &= P_{xz} S_k^{-1}, S_k = R_k P_{zz}, \\ P_{xz} &= \sum_{i=0}^{2m} \omega_i^{(c)} (\chi_{p,k+1|k}^{(i)} - \hat{x}_{p,k+1|k}) \times \\ &\quad (h_{k+1}(\chi_{p,k+1|k}^{(i)}) - \hat{z}_{k+1|k})^T, \\ P_{zz} &= \sum_{i=0}^{2m} \omega_i^{(c)} (h_{k+1}(\chi_{p,k+1|k}^{(i)}) - \hat{z}_{k+1|k}) \times \end{aligned}$$

$$(h_{k+1}(\chi_{p,k+1|k}^{(i)}) - \hat{z}_{k+1|k})^T. \quad (10)$$

Step 2.3: 预测 $k + 1$ 时刻新生粒子. 预测的新生密度表示为

$$b_{k|k+1}(x) = \int \pi_{k+1|k}(x|x') b_k(x') dx'. \quad (11)$$

通过 k 时刻的量测集合自适应得到新生密度^[8], 有

$$b_k(x') \approx \frac{1}{|\mathcal{Y}_k|} \sum_{[z] \in \mathcal{Y}_k} \beta_k(x|[z]). \quad (12)$$

式 (12) 中的每个 $\beta_k(x|[z])$ 密度可以通过使用区间量测 $[z] \in \mathcal{Y}_k$ 按照如下方式构造:

$$\beta_k(x|[z]) \approx \frac{1}{N_b} \sum_{j=1}^{N_b} \delta_{x_{b,k}^j}(x). \quad (13)$$

其中: $x_{b,k}^j$ 为目标状态的新生粒子, δ 为狄利克雷函数. 式 (13) 表明新生密度可以用 N_b 个均值为 $1/N_b$ 的粒子 $\{x_{b,k}^j\}_{j=1}^{N_b}$ 和替代. 假设 $\{x_{b,k}^j\}$ 由量测分量 p 和未被量测到的分量 u 两部分构成, 即 $x = [p^T, u^T]^T, j = 1, 2, \dots, N_b$ 构成. 对于量测分量, 可以通过量测函数的反函数获得, 即 $p_{b,k}^j = h_k^{-1}(z^j)$; 对于未被量测分量, 可以通过已知先验分布采样 N_b 次获得 $\{u_{b,k}^j\}_{j=1}^{N_b}$. 最后产生的新生粒子集合为

$$\{x_{b,k}^j\}_{j=1}^{N_b} = [(p_{b,k}^j)^T, (u_{b,k}^j)^T]^T.$$

Step 2.4: 根据式 (14) 和 (15) 计算粒子的权重

$$w_{p,k+1}^i = p_s q_{k|k} w_{p,k}^i / q_{k+1|k}, i = 1, 2, \dots, N; \quad (14)$$

$$w_{b,k+1}^i = p_B (1 - q_{k|k}) w_{b,k}^i / q_{k+1|k}, i = 1, 2, \dots, N_b. \quad (15)$$

将 k 时刻预测得到的带权粒子集合表示为

$$\begin{aligned} \{w_{k+1|k}^i, x_{k+1|k}^i\}_{i=1}^{N'} = \\ \{w_{b,k+1}^i, x_{b,k+1}^i\}_{i=1}^{N_b} \cup \{w_{p,k+1}^i, x_{p,k+1}^i\}_{i=1}^N, \end{aligned} \quad (16)$$

其中 $N' = N + N_b$.

综上可得预测概率密度函数为

$$p(x_{k+1|k}|Z_k) \approx \sum_{i=1}^{N'} w_{k+1|k}^i \delta_{x_{k+1|k}^i}(x). \quad (17)$$

Step 3 更新.

Step 3.1: 对于由预测步骤得到的每一个粒子 $\{x_{k+1|k}^i\}_{i=1}^{N'}$ 和 $k + 1$ 时刻获得的每一个量测 $[z] \in \mathcal{Y}_{k+1}$, 根据式 (18) 计算似然函数

$$\begin{aligned} g_{k+1}([z]|x_{k+1|k}^i) &= \Pr\{h_{k+1}(x_{k+1|k}^i) + v \in [z]\} = \\ &= \int_{[z]} p_v(z - h_{k+1}(x_{k+1|k}^i)) dz. \end{aligned} \quad (18)$$

Step 3.2: 根据式 (19) 和 (20) 更新存在概率 $q_{k+1|k+1}$, 有

$$q_{k+1|k+1} = \frac{1 - \Delta_{k+1}}{1 - \Delta_{k+1} \cdot q_{k+1|k}}, \quad (19)$$

$$\Delta_{k+1} = P_D \left(1 - \sum_{[z] \in \Upsilon_{k+1}} \frac{\int g_{k+1}([z]|x_{k+1|k}^i) S_{k+1|k}(x_{k+1|k}^i) dx_{k+1|k}^i}{\lambda c[z]} \right). \quad (20)$$

Step 3.3: 根据式(21)和(22)计算权重以及权重归一化

$$\tilde{w}_{k+1}^i = \frac{1 - p_D + p_D \sum_{[z] \in \Upsilon_{k+1}} \frac{g_{k+1}([z]|x_{k+1|k}^i)}{\lambda c[z]}}{1 - \Delta_{k+1}}, \quad (21)$$

$$w_{k+1}^i = \tilde{w}_{k+1}^i / \sum_{i=1}^{N'} \tilde{w}_{k+1}^i. \quad (22)$$

Step 4 重采样.

从所获得的带权粒子集合 $\{w_{k+1}^i, x_{k+1|k}^i\}_{i=1}^{N'}$ 中重采样 N 次得到相等权重的粒子集合 $\{w_{k+1}^i = 1/N, x_{k+1}^i\}_{i=1}^N$. 通过重采样得到的粒子集计算出后验概率密度函数

$$s_{k+1}(x) \approx \sum_{i=1}^{N'} w_{k+1}^i \delta_{x_{k+1}^i}(x). \quad (23)$$

Bernoulli-Upf算法流程如下:

$$\{ \{x_{k+1}^i, w_{k+1}^i\}_{i=1}^N; q_{k+1|k+1} \} = \text{Bernoulli-Upf}[\{x_k^i, w_k^i\}_{i=1}^N; q_{k|k}; \Upsilon_{k+1}].$$

Step 1 预测.

Step 1.1: 由式(4)预测存在概率 $q_{k+1|k}$;

Step 1.2: 根据式(5)~(10), 利用UKF算法预测 $k+1$ 时刻持续存活粒子集合 $x_{p,k+1}^i$;

Step 1.3: 由式(11)~(13), 预测 $k+1$ 时刻持续新生粒子集合 $x_{b,k+1}^i$;

Step 1.4: 合并新生和持续存活粒子集合

$$\{w_{k+1|k}^i, x_{k+1|k}^i\}_{i=1}^{N'} = \{w_{b,k+1}^i, x_{b,k+1}^i\}_{i=1}^{N_b} \cup \{w_{p,k+1}^i, x_{p,k+1}^i\}_{i=1}^N.$$

Step 2 更新.

Step 2.1: 根据式(18)计算似然函数 $g_{k+1}([z]|x_{k+1|k}^i)$;

Step 2.2: 根据式(19)和(20)更新存在概率 $q_{k+1|k+1}$;

Step 2.3: 根据式(21)更新权重 \tilde{w}_{k+1}^i ;

Step 2.4: 根据式(22)归一化权重 w_{k+1}^i .

Step 3 重采样. 采样得到相等权重的粒子集合 $\{w_{k+1}^i = 1/N, x_{k+1}^i\}_{i=1}^N = \text{重采样}\{w_{k+1}^i, x_{k+1|k}^i\}_{i=1}^{N'}$.

3 仿真分析

仿真一个二维空间里匀速运动的目标, 目标的状态向量为 $x = [x \ \dot{x} \ y \ \dot{y}]^T$, 其中 (x, y) 和 (\dot{x}, \dot{y}) 分

别表示目标的位置和速度分量. 目标是根据方程 $x = Gx' + Q$ 移动, 其中

$$G = I_2 \otimes \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad (24)$$

$$Q = I_2 \otimes \begin{bmatrix} T^3/3 & T^2/2 \\ T^2/2 & T \end{bmatrix} \cdot \bar{w}, \quad (25)$$

\otimes 为 Kronecker 积, \bar{w} 为过程噪声强度. 目标的初始位置和速度为 (550 m, 330 m) 和 (-5 m/s, -8.5 m/s), 且在 $k=3$ 时刻出现, 在 $k=54$ 时刻消失. 仿真跟踪 60 个时刻, 量测函数 $h_k(x)$ 定义为

$$h_k(x) = \left[\sqrt{x^2 + y^2}, \frac{x\dot{x} + y\dot{y}}{\sqrt{x^2 + y^2}}, \arctan(y/x) \right]^T. \quad (26)$$

$h_k(x)$ 中的 3 项分别表示距离、距离变化率和方位角. 量测噪声是零均值高斯白噪声, 具有协方差 $R = \text{diag}(\sigma_r^2, \sigma_{\dot{r}}^2, \sigma_\theta^2)$. 传感器提供的区间量测长度为 $\Delta = [\Delta_r, \Delta_{\dot{r}}, \Delta_\theta]^T$. 其中: $\Delta_r = 70$ m, $\Delta_{\dot{r}} = 1$ m/s, $\Delta_\theta = 5^\circ$. 由于传感器存在偏差, 向量 $h_k(x) + v_k$ 不一定是量测区间的中心, 所以在 k 时刻的量测值被定义为有偏差量测, 表示为

$$[z]_k = \left[h_k(x) + v_k - \frac{3}{4}\Delta, h_k(x) + v_k + \frac{1}{4}\Delta \right]. \quad (27)$$

目标的检测概率 $p_D = 0.95$, 在每一时刻平均虚警数服从 $\lambda = 5$ 的泊松分布. 假设对于任何区间量测虚警概率 $c[z]$ 都为常量. 新生概率 $P_B = 0.01$, 持续存活概率 $P_B = 0.98$. 对于新生粒子的产生, 令状态向量中的量测分量 $P = [x, y]^T$, 未被量测到的分量 $u = [\dot{x}, \dot{y}]^T$, 服从先验为 (-15 m/s, 15 m/s) 的均匀分布. 持续存活粒子数目 $N_p = 500$, 新生粒子数 $n_0 = 500$.

下面就 Bernoulli-pf 和 Bernoulli-Upf 算法进行仿真实验. 粒子个数选取为 1000, 进行 50 次蒙特卡罗仿真统计得到实验结果. 图 1 为区间量测环境下, Bernoulli-Upf 直观实现图, 其中小正方形表示传感器, 周围不规则的四边形表示该传感器收集的区间量测, 一系列的黑点表示目标使用区间量测的跟踪轨迹. 图 1 可以直观地表述目标在区间量测下的跟踪过程. 图 2 为量测噪声的协方差分量分别为 $\Delta_r = 2.5$ m, $\Delta_{\dot{r}} = 0.01$ m/s 和 $\Delta_\theta = 0.25^\circ$ 的两种算法的存在概率估计结果. 由图 2 可见, 两种方法的检测概率

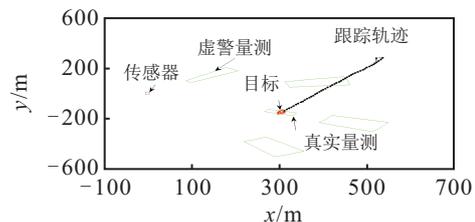


图 1 区间量测环境下 Bernoulli-Upf 算法直观实现

估计效果类似, 都有较高的检测概率, 表明在大部分时刻目标是可以被检测到的. 图3为Bernoulli-Upf算法的目标运动轨迹跟踪图. 由图3可见, Bernoulli-Upf算法可以很好地跟上待跟踪目标.

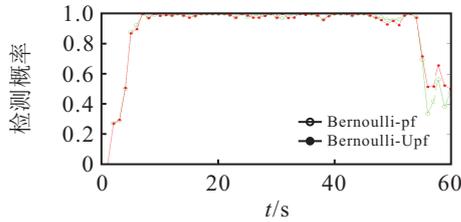


图2 目标存在概率估计

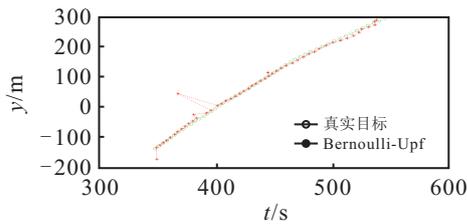
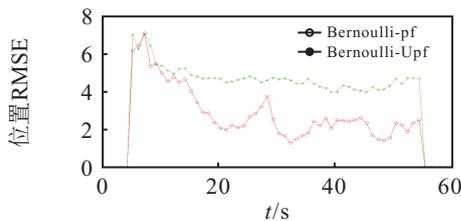
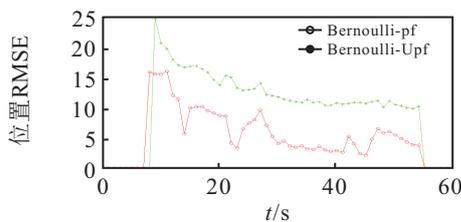


图3 改进算法的目标运动轨迹跟踪

图4为两种算法目标位置估计的均方根误差. 仿真结果表明, Bernoulli-pf在预测持续存活粒子时, 采用转移先验作为建议分布函数, 没有考虑最新量测信息, 因而其估计误差大于 Bernoulli-Upf. 针对不同量测噪声的协方差给出了两组仿真实验结果. 在量测噪声协方差 $R = \text{diag}[\sigma_r^2, \sigma_r^2, \sigma_\theta^2]^T$ 相对较大的情况下, 虽然两种算法的位置估计均方根误差都有所增大, 即两种算法的估计性能都有所下降, 但是 Bernoulli-Upf算法位置估计的均方根误差要小于 Bernoulli-pf算法的跟踪误差, 表明改进算法的跟踪性能较 Bernoulli-pf算法性能更优.



(a) $\Delta_r=2.5\text{m}, \Delta_r=0.01\text{m/s}, \Delta_\theta=0.25^\circ$



(b) $\Delta_r=2.8\text{m}, \Delta_r=0.02\text{m/s}, \Delta_\theta=1^\circ$

图4 目标位置估计的均方根误差

4 结 论

本文提出了一种基于粒子滤波与UKF融合的区间量测下的伯努利滤波改进算法. 基于当前时刻的

量测, 利用UKF算法对预测过程中的持续存活粒子进行预测, 使得该算法能够很好地利用量测带来的新息, 从而使粒子的分布更接近于状态的后验概率分布. 仿真结果表明, 无论对于量测噪声协方差较小还是相对较大的条件下, 大部分时刻改进后的算法具有更高的跟踪精度. 用两种不同噪声的协方差进行实验, 表明改进后的算法不但具有良好的跟踪性能, 同时也具有很好的稳定性.

参考文献 (References)

- [1] Ristic B. Particle filter for random set model[M]. London: Artech House, 2013: 15-18.
- [2] Ristic B, Vo B T, Vo B N, et al. A tutorial Bernoulli filter theory, implementation and application[J]. IEEE Trans on Signal Processing, 2013, 61(13): 3406-3430.
- [3] Combettes P L. Foundations of set theoretic estimation[J]. Proc of the IEEE, 1993, 81(2): 182-208.
- [4] Smets P. Imperfect information: Imprecision and uncertainty[C]. Uncertainty Management in Information Systems. New York: Springer, 1997: 225-254.
- [5] Milanese M, Vicino A. Optimal estimation theory for dynamic systems with set membership uncertainty[J]. Automatica, 1991, 27(6): 997-1009.
- [6] Arulampalam S, Maskell S, Gordon N, et al. A tutorial on particle filter for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Trans on Signal Processing, 2002, 50(2): 174-188.
- [7] Ristic B, Arulampalam S, Gordon N. Beyond the Kalman filter: filter for tracking applications[M]. London: Artech House, 2004: 35-69.
- [8] Gning A, Ristic B, Mihaylova L. Bernoulli particle/box particle filter for detection and tracking in the presence of triple measurement uncertainty[J]. IEEE Trans on Signal Processing, 2012, 60(5): 2138-2151.
- [9] Li Peng, Cui Hu-tao, Cui Pingyuan. UPF based autonomous navigation scheme for deep space probe[J]. J of Systems Engineering and Electronics, 2008, 19(3): 529-536.
- [10] Julier S J. The scaled unscented transform[C]. Proc of the American Control Conf. Anchorage, 2002, 6: 4555-4559.
- [11] 吴孙勇, 廖桂生, 杨志伟, 等. 基于粒子滤波的检测前跟踪改进算法[J]. 控制与决策, 2010, 25(12): 1884-1887.
(Wu S Y, Liao G S, Yang Z W, et al. Improved track-before-detect algorithm based on particle filter[J]. Control and Decision, 2010, 25(12): 1884-1887.)
- [12] Mahler R. Statistical multi-target information fusion[M]. London: Artech House, 2007: 487-488.
- [13] Ristic B. Bayesian estimation with imprecise likelihoods: Random set approach[J]. IEEE Signal Processing Letters, 2011, 18(7): 359-398.