

## 基于增强的粒子滤波算法的医学图像动态轮廓跟踪新方法

### 1 引言

心脏、血管等器官的形变运动研究属于非刚性运动估计与跟踪问题，其主要特点在于不具有刚体运动的规律性和可描述性。经典的统计模型、参数模型等方法对这一类问题的解决存在许多缺陷。解决运动状态估计的方法一般依赖于目标的形状、灰度、梯度流场、光流场，以及各种局部的空间和时间约束。就参数和几何方法而言，它是利用动态轮廓线模型、样条模型、网格模型，在有限差分法和有限元法的支持下动态逼近目标所描述的一类方法；就统计方法而言，重点是以Markov随机场为前提的系列优化估计方法，主要研究热点在于：贝叶斯滤波[1][2]；动态蒙特卡罗方法[3][4]（包括Gibbs算法、Metropolis算法）；卡尔曼滤波法（包括扩展卡尔曼滤波EKF、无迹卡尔曼滤波UKF[5]）以及顺序蒙特卡罗方法[6][7][8] [又称粒子滤波(PF)]、基于采样重要性的重采样滤波或蒙特卡罗滤波。上述方法中PF对于解决或优化状态估计和运动跟踪问题具有很好的针对性，它的主要特点在于：它是一种按照状态到达的时间段顺序进行概率递归计算的顺序蒙特卡罗概率跟踪方法，又称“概率浓缩”算法；在已知非线性、非高斯状态转移方程和各个时间步的观测值前提下，递归计算各个时间步的状态值。直接将经典PF算法用于感兴趣区(ROI)轮廓跟踪时面临的主要问题是：(1)经典PF算法重要密度(ID)的选择只依赖于状态先验；(2)经典PF算法没有考虑似然估计问题。

针对上述问题本文提供了较好的解决方案：首先，提出更优的ID计算方法；其次通过建立贝叶斯似然估计模型来提高运动跟踪的准确度；最后，依据帧间的轮廓相似性和剃度矢量流连续性，通过该增强的粒子滤波算法完成动态轮廓跟踪。

### 2 PF原理与背景介绍

PF算法的主要特点是：针对序列图像 $I(x, t)$ ， $x \in D \subset \mathbb{R}^{M \times N}$ ， $t \in \{1, 2, \dots, T\}$ ，其中 $x$ 代表像素的位置、 $t$ 代表时间顺序，初始点 $x_0$ 给定后，后续状态 $x_t$  ( $t=1, \dots, T$ ) 可通过计算后验密度 $p(X|Y) \propto p(X|Y)p(X)$  得到（其中 $X$ 代表状态序列、 $Y$ 代表测量序列）。该算法依据了概率递归计算原理，其实状态 $X$ 在逐帧的顺序计算过程中被分解为一簇加权粒子 $\{(x_t^i, w_t^i) | i=1, \dots, N_s\}$ ，其中点集 $\{(x_{0:t}^i, i=1, \dots, N_s)\}$ 依次对应权集 $\{(w_t^i, i=1, \dots, N_s)\}$ ，权集是归一化的： $\sum_i w_t^i = 1$ 。PF算法主要思想是通过加权的后验样本“粒子簇”来表示所需的后验密度函数 $p(X|Y)$ 并通过这些样本和权对 $p(X|Y)$ 进行估算。

如果将时间 $t$ 的后验概率 $p(x_{0:t} | y_{1:t})$ 近似表示为：

$$p(x_{0:t} | y_{1:t}) \approx \sum_{i=1}^{N_s} w_t^i \delta(x_{0:t} - x_{0:t}^i) \quad (1)$$

随后可以得到后验密度的离散权值估计，粒子便按照重要性采样原理[7]进行更新。进一步，第 $i$ 个粒子的归一化权写为：

$$w_t^i \propto \frac{p(x_{0:t}^i | y_{1:t})}{q(x_{0:t}^i | y_{1:t})} \quad (2)$$

其中重要密度 $q(x_{0:t}^i | y_{1:t}) = q(x_t | x_{0:t-1}, y_{1:t}) q(x_{0:t-1} | y_{0:t-1})$ ，当估计按照从 $p(x_{0:t-1} | y_{0:t-1})$ 到 $p(x_{0:t} | y_{0:t})$ 进行时，令 $q(x_t^i | x_{0:t-1}^i, y_{1:t}) = q(x_t^i | x_{t-1}^i, y_t)$ ，(2)式右边可因素分解为：

$$w_t^i \propto \frac{p(y_t|x_t^i)p(x_t^i|x_{t-1}^i)}{q(x_t^i|x_{t-1}^i, y_t)} \quad (3)$$

上式将(2)式的序列概率密度形式转变为较易计算的当前时刻概率密度，并且重要密度q(IDq)仅依赖于 $x_{t-1}$ 和 $y_t$ ，这是顺序蒙特卡罗方法的特点和便于实现的依据。

命题[5][9]：当且仅当试探性分布(或ID)  $q(x_{0:t-1}|y_{1:t-1})$  等于  $p(x_t|x_{t-1})$  时，基于条件  $x_{0:t-1}$  和  $y_{1:t}$  的重要性权  $w_t^i$  的方差最小。

在没有任何关于ID的先验知识的情况下，上述命题有助于我们正确地选择ID函数，尽管我们希望  $w_t^i$  的方差较小，然而单纯以命题为依据时会陷入经典PF算法的不利形式：遇到似然分布  $(p(y_t|x_t^i))$  很窄时很易导致“粒子退化”。

### 3 重要密度的选择与重要比率的计算

为解决“粒子退化”现象，本文对此进行下述改进。首先，目标跟踪可以描述为如下状态空间模型：

$$x_t^i = f(x_{t-1}^i, \sigma_m^2); y_t = h(x_t^i, \sigma_m^2) \quad (4)$$

上述  $x_t$  代表  $t$  时刻进行状态更新的粒子、 $y_t$  代表观测到的真实状态(或似然值)，可以由后文的估计得到。由  $x_t^i \sim N(F(x_{t-1}^i, 0), \sigma_x^2(t))$ ，很容易写出  $p(x_t^i|x_{t-1}^i) \cdot p(y_t|x_t^i)$  的概率分布形式。如果选择分界点  $\xi$  为先验分布曲线和似然分布曲线的交点，则令：

$$p(\xi|x_{t-1}^i) = p(y_t|\xi) \quad (5)$$

其中  $\min(x_{t-1}^i, y_t) < \xi < \max(x_{t-1}^i, y_t)$ ，由此可以解

$$\text{得：} \xi = \frac{x_{t-1}^i + \sigma_{x,y} \cdot y_t}{1 + \sigma_{x,y}}, \text{ 且 } \sigma_{x,y} = \frac{\sigma_x}{\sigma_y}; \text{ 当 } \sigma_{x,y} = 1 \text{ 时, } \xi = \frac{x_{t-1}^i + y_t}{2}。$$

为降低先验分布，并减少因似然分布过窄时粒子的退化效应，我们令：

$$q(x_t^i|x_{t-1}^i, y_t) = p(x_t^i|x_{t-1}^i) / p(x_t^i|\xi) \quad (6)$$

上式由  $\xi = (x_{t-1}^i + y_t) / 2$ ，引入了观测值  $y_t$  的作用。结合上述计算我们可以得到如下ID性质：

性质1：当  $y_t$  被看作高斯随机数时，重要密度  $q$  的无条件方差大于先验密度  $p(x_t^i|x_{t-1}^i)$  的方差。

性质2：由重要密度  $q$  得到的粒子归一化权  $w_t^i$  可以使使得粒子由先验概率高的区域向似然概率高的区域靠拢。结合上述计算和性质，我们可以写出如下重要比率公式：

$$\hat{w}_t^i \propto \frac{p(y_t|x_t^i)p(x_t^i|x_{t-1}^i)}{q(x_t^i|x_{t-1}^i, y_t)} = p(y_t|x_t^i) \cdot p(x_t^i|\xi) \quad (7)$$

不难发现  $(i, t)$ ：如果令  $\rho^{post} = \text{Var}(p(x_t^i|y_t))$ 、 $\rho^{lik} = \text{Var}(p(y_t|x_t^i) \cdot p(x_t^i|x_{t-1}^i))$  则有  $\rho^{lik} < \text{Var}(\hat{w}_t^i) < \rho^{post}$ ，结合上一章的命题及文献[8][10]中提供的衡量“粒子退化”程度的方法：令  $N_{eff} = N_s / [1 + \text{Var}(x_t^i)]$ ，如果  $N_{eff}$  越大，则“粒子退化”程度越小。因此，(6)式的ID选择方案避免了经典算法的缺陷(图1)。

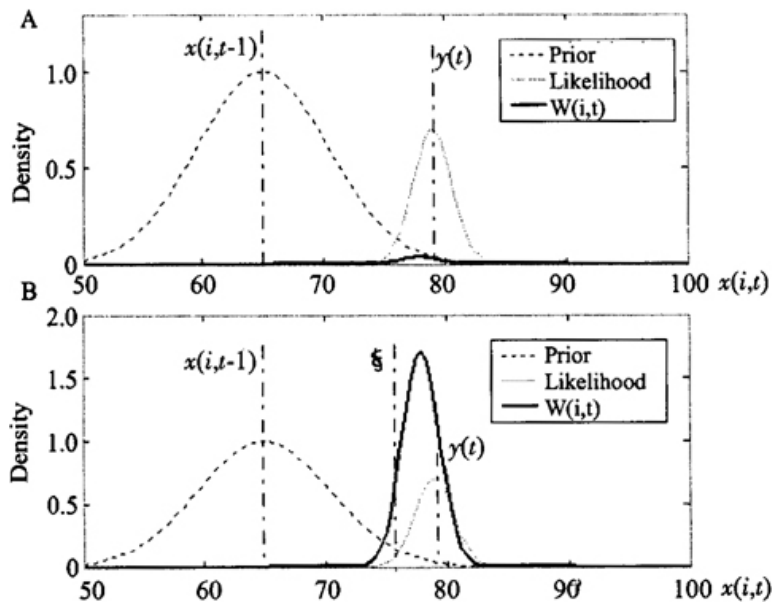


图1 两种算法下重要比率(权)的比较

Fig.1 Comparisons of two importance ratios based on different algorithms

A: The conventional distributions of prior, likelihood probabilities and weights; B: Improved distributions of prior, likelihood probabilities and weights

#### 4 观测点的似然估计

似然估计是本文的改进PF算法的重要组成部分。如前所述，一般状态估计问题需要的两个条件是状态转移方程和状态观测方程。在未知观测方程的情况下，我们有必要建立观测值 $y_t$ 估计模型，这里采用贝叶斯算法来构造似然估计模型

$p(y_t | X_t), X_t = \{x_i^i | i=1, \dots, N_t\}$ 。如果M代表轮廓线的长度(像素单位)，该模型将利用初始轮廓上的某一点 $\bar{x}_{t-1}(j), j=1, \dots, M$ 来预测当前轮廓中的真实点 $y_t(j)$ 。

##### 4.1 生成数据约束条件

为给帧间相关性约束提供数据条件，本文采用如下两种数据约束方法：其一，引用文献[11]的梯度向量流(GVF)扩散方程计算出图像的GVF场。GVF是一种优化的梯度场，它描述了图像中各像素相对于边缘的“势”分布，点x处的GVF表示为： $\vec{U}(x) = u(x) + v(x) \cdot i$ ，其中u, v为分量。其二，轮廓线相似性测度： $\rho = \phi(F(C_1), F(C_2))$ ，函数F(·)用来计算轮廓链码C的傅立叶形状描述子[12]；函数 $\phi(\cdot)$ 计算两组形状描述子的相关系数 $\rho(0 < \rho < 1)$ ， $\rho$ 越大相似度越高。

##### 4.2 基于粒子采样空间的似然估计模型

如果 $N_s$ 为粒子样本数量T、M为可变链码长度为时间长度，则 $\mathcal{R}^{Ns \times M \times T}$ 为粒子样本空间。建模之前，假设初始轮廓链码 $C_{t-1}$ ，(t=1)已经给定、 $\{\bar{x}_{t-1}(j) | j=1, \dots, M\}$ 为初始链码坐标，针对其中每一点 $\bar{x}_{t-1}(j)$ ，PF初始化时已产生粒子集： $x_{t-1}(j) = \{x_{t-1}^i(j) | x_{t-1} \in \mathcal{R}_{t-1}\}$ 。因此可通过 $\bar{x}_{t-1}$ 的 $N_s$ 个初始粒子 $x_{t-1}^i$ 估计似然值 $y_t$ 。

介入此算法的重要先验约束条件是轮廓线相似度 $\rho$ ，在估计当前帧的似然值 $y_t$ 时，引入了图像帧 $I_t$ 的L条灰度值介于 $I_{t-1}(\bar{x}_{t-1})$ 附近的闭合等值线 $\ell = \{\ell_i^{(n)} | n=1:L\}$ ，其意义在于：ROI的轮廓可看作是该区域的L条灰度近似且闭合的等值线链码按照优化方式选择合成，估计之前，每一条等值线依据其与 $C_{t-1}$ 的相似程度赋予相似度 $\rho^{(n)}$ ；估计过程中如果一点 $y_t$ 离 $\ell_i^{(n)}$ 最近，同样赋予点的相似度为 $\rho^{(n)}$ ，且点的相似度记为 $D(y_t, \ell^{(n)})$ 。如果令： $\vec{U}(y_t), \vec{U}(\bar{x}_{t-1})$ 分别为 $y_t, \bar{x}_{t-1}$ 处的梯度流矢量，那么数据的采样、生成事件与概率表示有如下对应关系： $D(y_t, \ell), \vec{U}(y_t) \vec{U}(\bar{x}_{t-1}) \rightarrow p(y_t; x_t^i | y_t, D(y_t, \ell)) \rightarrow p(x_t^i | y_t)$ 。进一步，可以得到如下后验概率公式：

$$p(y_t | X_t) p(y_t) * p(X_t | y_t) = p(D(y_t, \ell), U(y_t) U(\bar{x}_{t-1})) * \int P(x_t^i | y_t, D(y_t, \ell)) dx_t^i \quad (8)$$

其中  $y_t, x_t^i \sim N(f(\bar{x}_{t-1}, 0), \sigma_x^2(t))$ , 且  $x_t$  由状态转移得到。依据上式, 贝叶斯模型构造如下:

$$P(y_t | x_t) \propto \frac{1}{\sqrt{2\pi} K_{pri}} \exp \left\{ -\frac{|\vec{U}(y_t)| \vec{U}(x_{t-1})|^2}{D(y_t, \ell) \cdot K_{pri}} \right\} * \frac{1}{\prod_{i=1}^{N_t} \sqrt{2\pi} K_{pri}} \exp \left\{ -\frac{\sum_{i=1: N_t} (y_i - x_t^i)^2}{D(y_t, \ell) \cdot K_{pri}} \right\} \quad (9)$$

上式中, 用相似度  $D(y_t, \ell^{(n)})$  的倒数作为欧式距离系数, 从而保证当点的似然值相似度越大时后验概率越高,  $P(y_t | x_t)$  的计算结果为 PF 提供了重要的观测数据  $y_t$ , 其递归算法的概念模型见图 2。似然估计将前一帧轮廓线  $C_{t-1}$  上每一点  $x_{t-1}$  映射为当前帧的似然轮廓上。




图2 似然估计的递归计算模型  
Fig.2 Iteration model for the likelihood estimation

## 5 轮廓跟踪

利用 PF 进行轮廓估计时, 本文增强了经典 PF 算法的方面是: 首先, 似然估计结果纳入到 PF 算法的框架, 解决了没有观测方程条件下的状态预测问题; 其次, 先验密度函数引入了轮廓线相似度和梯度矢量流相似性, 从而约束了 PF 重采样结果, 使得粒子的分布沿着最优轮廓更新; 最后, 轮廓线细化。

### 5.1 状态转移与重要密度的计算

为提高初始化效果和粒子采样效益, 我们可以采用经典的光流计算方法解出图象的归一化光流场  $V(x, t)$ , 并且假定质点  $x_t$  的运动是沿归一化的光流矢量方向进行的, 如果  $\lambda$  为单位时间的平均运动幅度且  $|V(x, t)| \sim N(\lambda, \sigma_v^2)$ , 则粒子  $\{x_{t-1}(j) | j=1, \dots, \tilde{M}\}$  状态方程可以写为:

$$x_t(j) = f(x_{t-1}(j), n_{x,t}) \approx x_{t-1}(j) + V(x_{t-1}(j), t-1) + n_{x,t} \quad (10)$$

其中  $n_{x,t}$  为状态转移噪声, 且  $n_{x,t} \sim N(\lambda, \sigma_{x,t}^2)$ 。因此  $x_t$  为满足高斯分布条件的 Markov 空间坐标向量, 即  $x_t(j) \in \mathcal{R}_{t-1} \sim N(f(\bar{x}_{t-1}(j), 0), \sigma_{x,t}^2)$ 。为优化估计轮廓  $C_t$ , 在  $x_t(j)$  状态空间已确定的情况下, 可通过合理构造先验概率  $p(x_t | x_{t-1})$  和重要密度  $q(x_t | x_{t-1}, y_t)$ , 并产生重要比率  $\hat{W}_t^i$  来引导粒子的运动。决定粒子  $x_t^i$  能否作为当前轮廓上一点的关键因素是: (1) 与初始轮廓  $C_{t-1}$  上的点具有相近的梯度流矢量; (2) 其距离最近的等值线  $\ell^n$  与  $C_{t-1}$  具有最大相似度; (3) 具有状态变化的平滑性。由此, 状态转移事件和概率的对应关系可以表示为:  $x_t^i, D(x_t^i, \ell), \vec{U}(x_t^i) | x_{t-1}^i, \vec{U}(\bar{x}_{t-1}) \rightarrow p(x_t^i | x_{t-1}^i)$ 。进而, 其概率写为:

$$p(x_t^i | x_{t-1}^i) = \frac{\exp\left\{-\frac{[(x_t^i - x_{t-1}^i)^2 + |\vec{U}(x_t^i) + \vec{U}(x_{t-1}^i)|^2]}{D(x_t^i, \ell) \cdot K_c^2}\right\}}{1/\sqrt{2\pi} K_c} \quad (12)$$

接下来依据(6)式很容易计算出ID值。

## 5.2 PF算法与轮廓估计

首先获取第一帧图像的初始ROI轮廓(可采用各种方法),然后逐点完成图3的算法步骤。图中重采样的作用是依据粒子 $x_t^i$ 重要性权 $\hat{w}_t^i$ 的不同,复制样本 $\hat{x}_{0:t}$ 中权大的粒子并削减权小的粒子,以此获得的 $N_s$ 个粒子 $x_{0:t}^i$ 它在数值上接近后验分布 $p(x_{0:t}^i | y_{1:t})$ 。总之,轮廓估计的关键在于将轮廓线相似度和梯度流相似性引入重要比率函数的似然、先验、ID各项中,同时利用PF特有的重采样原理进行选择性的“复制”和“剔除”,从而保证了稳定的跟踪和估计效果,结合计算过程,轮廓线跟踪的主要过程见图4。

**1. Initializing and weights distributing: (t=1):**

$$X_0 = \{x_0^i(j) \mid i = 1, \dots, N_s; j = 1, \dots, M\}$$

$$w_0^1 = \dots = w_0^{N_s} = 1/N_s.$$

**2. For t=2, ..., T**

(a) Extracting the closed isolines and computing  $D(y_t, \ell^{(n)})$  for each point.

**For j=1, ..., M**

(b) Computing observation data using the Likelihood model:  $p(y_t \mid X_t)$ .

(c) Importance sampling, resampling and updating:

- Sampling according to proposal distribution:  $\hat{x}_t^i(j) \sim N(\xi_t^i, \sigma_\xi)$ , computing  $p(x_t^i \mid x_{t-1}^i)$  and  $p(y_t \mid x_t^i)$ .
- Computing the weights  $w_t^i$  and normalizing it.
- Resampling (selection and updating):  
 $[\{\hat{x}_t^i\}_{i=1}^{N_s}] = \text{resample} [\{\hat{x}_t^i, \tilde{w}_t^i\}_{i=1}^{N_s}]$

(d) Output:  
 $\bar{x}_{1:t} = \hat{x}_{1:t}^{\text{MAP}}(t) = \arg \max_{i=1, \dots, N_s} p(\hat{x}_{0:t}^i \mid y_{1:t})$

(e) Formation of contour  $C_{1:t}$ .

图3 基于增强PF的轮廓跟踪算法步骤  
 Fig.3 Algorithm for contour tracking using improved PF




图4 增强PF方法下轮廓线估计的基本过程

Fig.4 Basic process of contour tracking using improved PF (a) The initial contour of the t th frame; (b)

Initialization distribution of the particles; (c) Introduction of the degree of relativity measure about the contours and estimation of the likelihood value by the t th and t+1 th frame; (d) Particle distribution after one step of iteration computation of GPPF; (e) Generation of the contour of the t+1th frame.

## 6 分析与实验

由于真正的轮廓估计标准参照数据很难获得，所以一般二维医学图像的运动跟踪问题不便直接作出比较。本实验针对医学序列图像跟踪问题建立了如下评估方法：(1) 如果周期序列图像  $I(x, 1)=I(x, T)$ ，则点的始、末运动状态应具有平滑连续性；(2) 归一化轮廓线长度条件下，标准的手工勾勒轮廓与估计出的轮廓量化均方差应较小；(3) 并且参照文献[5][7]中提供的“粒子退化”依据：重要比率  $w_t^i$  的方差不随时间单调增加、保持平稳以降低“粒子退化”程度，并且重要比率具有较高计算效率。

实验中我们不妨将改进的ID算法(可称之为IID，即improved ID)、经典SIR-PF的ID算法及文献[13]中Matthew Orton的ID算法纳入本文的PF轮廓估计算法当中进行比较。IID优于其他ID的方面如下：图5为MR\_1和MR\_2两套图像在某一帧的估计结果与手工标准进行比较，IID作用下的跟踪结果更加接近实际轮廓，IID更加满足评估方法(2)的要求。图6说明了三种重要密度算法下单点的幅度的周期变化，IID算法下跟踪到的最终状态最接近初始状态。为方便归一化轮廓均方误差的计算，我们请有关心内科主治医生用手工勾出标准心脏左心室内边缘，以此作为标准的轮廓  $\bar{P}_m$ ，并将其与估计出的轮廓  $\hat{P}_m$  进行最小均方误差的量化计算，关于单点ID计算耗时  $T_s$  是指由t时刻轮廓线上一点

$\{x_t^i(m), w_t^i(m)|i=1, \dots, N_t\}$  估计出t+1时刻的对应点  $x_{t+1}^i(m)$  所需时间，如果序列图像有Fr帧，初始轮廓长M，则轮廓线的全周期跟踪时间为： $(T_s + \text{单点似然估计耗时}) \times M \times Fr$ 。综合各种比较结果，本文提出的IID算法以极少的耗时增量(0.39 s)换得极高的跟踪精度(接近经典ID算法得3倍)。由图7可见，周期计算过程中的三种重要比率w的方差分布，其中IID作用下的重要比率方差分布符合上述评估方法(2)的要求，粒子退化数最低。




图5 不同重要密度下的轮廓线跟踪效果比较

Fig.5 Comparisons of results of cotour tracking with different importance densities  
Upside: MR\_1 sequence; Downside: MR\_2 sequence




图6 三种重要密度算法下同一点的幅度跟踪结果

Fig.6 Comparison of motion magnitudes of each point on the contours using three different ID




图7 重要比率方差的周期分布 Fig.7 Distributions of the variance of the importance ratios in a periodic cardiac motion

参考文献:

[1] Björn S, Arasanathan T, Torr PH, et al. Filtering using a tree-based estimator[C]. Proc. 9th Int. Conf. on Computer Vision, France: Nice, 2003. 10.

[2] Arasanathan T, Björn S, Torr PH, et al. Learning a kinematic prior for tree-based filtering [C]. Proc British Machine Vision Conference, UK: Norwich, 2003. 9.

[3] Fablet R, Bouthemy P. Non parametric motion recognition using temporal multiscale Gibbs models[C]. IEEE Conf on Computer Vision and Pattern Recognition, Hawaii, CVPR'01, 2001. 12.

[4] Robin DM. Image sequence restoration using Gibbs distributions[D]. A thesis submitted to the University of Cambridge for the degree of Doctor of Philosophy, Department of Engineering, 1995.

[5] van-Merwe R, Doucet A. The unscented particle filter[R]. Technical Report CUED/F-INFENG/TR 380. Department of Engineering, Cambridge University, 2000.

[6] Hisashi T. Nonlinear and Non-Gaussian state-space modeling with Monte Carlo techniques: A survey and comparative study[C]. Faculty of Economics, Kobe University, Japan: Kobe, 2000. 1.

[7] Sanjeev A, Simon M, Neil G, et al. A tutorial on particle filters for on-line non-linear/non-Gaussian Bayesian tracking[J]. IEEE Trans Sign Proc, 2002, 50(2): 174-88.

[8] Liu JS, Chen R. Sequential Monte Carlo methods for dynamical systems[J]. J Am Stat Assoc, 1988, 93: 1032-44.

[9] Doucet A, Gordon NJ. Simulation-based optical filter for manoeuvring target tracking[C]. SPIE Signal and Data Processing of Small Targets, 1999. 3809.

[10] Bergman N. Recursive Bayesian estimation: Navigation and tracking application[D]. Linköping University, 1999.

[11] Xu CY, Jerry LP. Snakes, shapes, and gradient vector flow[J]. IEEE Trans Imag Proc, 1998, 7(3): 359-69.

[12] Zahn CT, Roskies RZ. Fourier descriptors for plane closed curves[J]. IEEE Trans Comp, 1972, 21: 269-81.

[13] Matthew O, Willian F. A Bayesian approach to tracking multiple targets using sensor arrays and particle filters[D]. Department of Engineering, Cambridge University, 2001.

参考文献:

[1] Björn S, Arasanathan T, Torr PH, et al. Filtering using a tree-based estimator[C]. Proc. 9th Int. Conf. on Computer Vision, France: Nice, 2003. 10.

[2] Arasanathan T, Björn S, Torr PH, et al. Learning a kinematic prior for tree-based filtering [C]. Proc British Machine Vision Conference, UK: Norwich, 2003. 9.

[3] Fablet R, Bouthemy P. Non parametric motion recognition using temporal multiscale Gibbs models[C]. IEEE Conf on Computer Vision and Pattern Recognition, Hawaii, CVPR'01, 2001. 12.

[4] Robin DM. Image sequence restoration using Gibbs distributions[D]. A thesis submitted to the University of Cambridge for the degree of Doctor of Philosophy, Department of Engineering, 1995.

[5] van-Merwe R, Doucet A. The unscented particle filter[R]. Technical Report CUED/F-INFENG/TR 380. Department of Engineering, Cambridge University, 2000.

[6] Hisashi T. Nonlinear and Non-Gaussian state-space modeling with Monte Carlo techniques: A survey and comparative study[C]. Faculty of Economics, Kobe University, Japan: Kobe, 2000. 1.

[7] Sanjeev A, Simon M, Neil G, et al. A tutorial on particle filters for on-line non-linear/non-Gaussian Bayesian tracking[J]. IEEE Trans Sign Proc, 2002, 50(2): 174-88.

[8] Liu JS, Chen R. Sequential Monte Carlo methods for dynamical systems[J]. J Am Stat Assoc, 1988, 93: 1032-44.

- [9] Doucet A, Gordon NJ. Simulation-based optical filter for manoeuvring target tracking[C]. SPIE Signal and Data Processing of Small Targets, 1999. 3809.
- [10] Bergman N. Recursive Bayesian estimation: Navigation and tracking application[D]. Linkoping University, 1999.
- [11] Xu CY, Jerry LP. Snakes, shapes, and gradient vector flow[J]. IEEE Trans Imag Proc, 1998, 7(3): 359-69.
- [12] Zahn CT, Roskies RZ. Fourier descriptors for plane closed curves[J]. IEEE Trans Comp, 1972, 21: 269-81.
- [13] Matthew O, Willian F. A Bayesian approach to tracking multiple targets using sensor arrays and particle filters[D]. Department of Engineering, Cambridge University, 2001.
- 

[回结果列表](#)