

基于粒子滤波和自适应模型的目标跟踪算法

梁楠, 郭雷, 王瀛

(西北工业大学 自动化学院, 710072 西安)

摘要: 为了提高粒子滤波的性能,使用集合卡尔曼滤波对建议分布进行改进,同时提出了用于视频跟踪的自适应融合模型.使用集合卡尔曼滤波结合当前的观测信息构造建议分布,结合当前观测信息对每一个粒子进行集合分析,得到新的建议分布,依据新的建议分布对粒子进行采样,同时在跟踪过程中将颜色特征模型和形状特征模型进行融合,并进行自适应更新.实验结果证明:相对于传统粒子滤波和扩展卡尔曼粒子滤波,使用新的建议分布可以更加有效地降低均方根误差,同时自适应融合模型的稳定性要高于使用单一颜色模型.使用新的建议分布和融合模型,可以有效提高粒子滤波的准确性和稳定性.

关键词: 目标跟踪;粒子滤波;集合卡尔曼滤波;建议分布;自适应融合模型

中图分类号: TP391

文献标志码: A

文章编号: 0367-6234(2012)10-0139-05

An object tracking algorithm based on particle filter and adaptive model

LIANG Nan, GUO Lei, WANG Ying

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

Abstract: To improve the performance of particle filter, ensemble Kalman filter is proposed to construct proposal distribution. And an adaptive fusion model is applied for object tracking. Using ensemble Kalman analysis to build the posterior probability distribution by integrating latest observation information. New particles are resampled from the new proposal distribution. In the tracking process, color model and shape model are fused and updated adaptively. Experimental results show the new proposal distribution can reduce the root mean square error more effectively than traditional particle filter and extended Kalman particle filter. The adaptive fusion model is more stable than single color model. The new proposal and adaptive fusion model can enhance the estimation accuracy and improve the stability of the object tracking.

Key words: object tracking; particle filter; ensemble Kalman filter; proposal distribution; adaptive fusion model

目标自动跟踪一直是目标探测与成像制导技术中的研究热点,通过滤波器对目标的量测值进行处理来估计目标的位置和运行轨迹.粒子滤波^[1-2]是一种基于序贯重要性采样的蒙特卡洛方法,通过递推的贝叶斯滤波来近似逼近最优化的估计,可以较好解决非高斯非线性观测下的目标跟踪^[3].其基本思想是采用带有权重的粒子集来表示对系统状态的估计,并通过序贯重要性采样

法来更新粒子集合,实现对系统状态的动态估计,其关键的问题是建议分布的选取,建议分布越接近后验概率分布,粒子滤波的性能越好.传统粒子滤波使用先验概率密度函数作为建议分布,建议概率密度与当前的测量值无关,粒子的使用效率较低.Freitas等使用扩展卡尔曼滤波为粒子滤波估计建议分布^[4],设计了扩展卡尔曼粒子滤波(EKF-PF),提高了粒子滤波的准确性,后人在此基础上作出了许多改进,但由于扩展卡尔曼滤波截断误差的存在,对于非线性运动较强的目标跟踪效果较差.

本文提出了一种基于粒子滤波的目标追踪方法,在粒子滤波视频跟踪的框架下,使用集合卡尔

收稿日期: 2011-11-10.

基金项目: 国家自然科学基金资助项目(60802084).

作者简介: 梁楠(1981—),博士研究生;

郭雷(1956—),男,教授,博士生导师.

通信作者: 梁楠, scorpio.lnboy@gmail.com.

曼滤波方法对建议分布进行了改进. 同时针对模型的实时更新设计了一种融合不同特征的观测相似性模型更新方法. 实验结果显示本文方法提高了粒子滤波跟踪过程的精确性和稳定性.

1 粒子滤波

非线性离散系统可以表示为

状态方程: $\mathbf{x}_t = f(\mathbf{x}_{t-1}) + \mathbf{v}_{t-1}$,

测量方程: $\mathbf{y}_t = h(\mathbf{x}_t) + \mathbf{w}_t$,

其中: $\mathbf{R}^n$ 空间中的 n 维向量 $\mathbf{x}_t$ 和 $\mathbf{y}_t$ 分别为系统在 t 时刻的状态值和观测值. $\mathbf{v}_t$ 和 $\mathbf{w}_t$ 分别为过程噪声和观测噪声.

通过粒子滤波得到后验分布 $p(\mathbf{x}_t | \mathbf{y}_{1:t})$ 的估计值. 依据贝叶斯理论有

$$p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) = \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) d\mathbf{x}_{t-1}, \quad (1)$$

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \frac{p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{\int p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) d\mathbf{x}_t}. \quad (2)$$

应用序列重采样原理, 后验分布可以由一组加权后的粒子表示为

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}) \approx \sum_{i=1}^{N_s} \tilde{\omega}_t^{(i)} \delta(\mathbf{x}_t - \mathbf{x}_t^{(i)}). \quad (3)$$

式中: N_s 为粒子数, $\tilde{\omega}_t^{(i)}$ 为归一化的粒子权重, 由

$$\tilde{\omega}_t^{(i)} = \omega_t^{(i)} / \sum_{j=1}^{N_s} \omega_t^{(j)} \text{ 得到.}$$

$$\omega_t^{(i)} = \omega_{t-1}^{(i)} \frac{p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)})}{q(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_t)}. \quad (4)$$

粒子 $\mathbf{x}_t^{(i)}$ 由建议分布 (也叫重要性密度函数) $q(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{0:t})$ 采样得到. 可见建议分布的准确性在粒子滤波中起着重要作用. 传统粒子滤波的建议分布的选取方法是令 $q(\mathbf{x}_k | \mathbf{x}_{k-1}^{(i)}, \mathbf{y}_{1:k}) = p(\mathbf{x}_k | \mathbf{y}_{k-1}^{(i)})$. 由于没有使用 k 时刻的观测信息 $\mathbf{y}_k$, 在目标非线性运动或者存在噪声的情况下, 使用传统建议分布会带来较高的估计误差.

2 建议分布设计

2.1 集合卡尔曼滤波

集合卡尔曼滤波^[5-6] (Ensemble Kalman filter; EnKF) 是基于随机动力预测理论发展而来的, 其原理为利用短期集合预报去估计随流型演变的背景误差协方差, 进行最优化分析, 而后实现对误差协方差的更新. 其目的是使模式向量的预测值尽可能地接近观测资料, 即通过已知的观测

资料估计和预测状态向量的概率密度函数.

集合卡尔曼滤波用方程表述为

$$\begin{cases} \mathbf{x}^a = \mathbf{x}^f + \mathbf{K}(\mathbf{y} - \mathbf{H}\mathbf{x}^f), \\ \mathbf{P}^a = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{P}^f, \\ \mathbf{K} = \mathbf{P}^f \mathbf{H}^T (\mathbf{H} \mathbf{P}^f \mathbf{H}^T + \mathbf{R}_e)^{-1}. \end{cases} \quad (5)$$

其中: $\mathbf{x}^f$ 为前一时刻所预测的控制变量向量集合, 称为背景场; $\mathbf{x}^a$ 为分析的控制变量向量的集合, 称为分析场; $\mathbf{K}$ 为增益矩阵; $\mathbf{R}_e$ 为观测误差协方差矩阵; $\mathbf{P}^a$ 与 $\mathbf{P}^f$ 分别为分析场误差协方差和预报场误差协方差矩阵.

集合卡尔曼滤波分析方法是结合预测的控制向量信息集合和观测信息集合对控制向量集合进行估计. 式(5)经集合分析后可得

$$\begin{cases} \bar{\mathbf{x}}^f = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{x}_n^f, \\ \mathbf{P}^f \mathbf{H}^T = (N_c - 1)^{-1} \sum_{n=1}^{N_c} (\mathbf{x}_n^f - \bar{\mathbf{x}}^f) (\mathbf{H} \mathbf{x}_n^f - \mathbf{H} \bar{\mathbf{x}}^f)^T, \\ \mathbf{H} \mathbf{P}^f \mathbf{H}^T = (N_c - 1)^{-1} \sum_{n=1}^{N_c} (\mathbf{H} \mathbf{x}_n^f - \mathbf{H} \bar{\mathbf{x}}^f) (\mathbf{H} \mathbf{x}_n^f - \mathbf{H} \bar{\mathbf{x}}^f)^T. \end{cases} \quad (6)$$

其中: N_c 为状态向量集合的成员个数, $\mathbf{P}^f \mathbf{H}^T$ 为模式控制向量与观测向量之间的观测误差协方差. 结合式(5)、(6)可得到如下滤波方程.

$$\begin{cases} \mathbf{x}_n^a = \mathbf{x}_n^f + \mathbf{K}(\mathbf{y}_n - \mathbf{H} \mathbf{x}_n^f), \\ \bar{\mathbf{x}}^a = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{x}_n^a, \\ \mathbf{P}^a = \mathbf{P}^f - \mathbf{P}^f \mathbf{H}^T (\mathbf{H} \mathbf{P}^f \mathbf{H}^T + \mathbf{R}_e)^{-1} \mathbf{H} \mathbf{P}^f. \end{cases} \quad (7)$$

2.2 建议分布的构造

集合卡尔曼滤波方法使用集合化方法对多轨迹数据进行最优化分析, 相对传统的卡尔曼滤波器, 其可以对非线性系统更准确地估计. 粒子滤波适用于非线性问题的跟踪, 但是仍需要选取合适的建议分布. 本文使用集合卡尔曼滤波方法进行建议分布的构造.

使用集合卡尔曼滤波方法对粒子运行轨迹进行预测, 首先需要对每一个粒子进行多轨迹的模拟以建立预测集合. 文献[7-8]中设计了使用平行扩展卡尔曼滤波器对目标进行多轨迹模拟的方法. 本文使用一组平行扩展卡尔曼滤波器对每一个粒子产生多轨迹的运动估计值 $\mathbf{x}_{(n,t|t-1)}^i$, $n \in 1:N_c$, N_c 为平行扩展卡尔曼滤波器个数. 在粒子滤波框架下, 对于粒子 $\mathbf{x}^i$, 令 $\mathbf{x}_{(n,t|t)}^i$ 为 t 时刻的分析场, 前一时刻产生的估计值集合 $\mathbf{x}_{(n,t|t-1)}^i$, $n \in 1:N_c$ 构成了背景场, $\mathbf{y}_{(n,t|t-1)}^i$ 为该粒子的第 n 个估计值对应的当前观测信息. $\mathbf{P}_{(n,t-1)}^i$ 与 $\mathbf{P}_{(n,t)}^i$ 分别为

前一时刻的预测控制向量和当前时刻的控制向量对应的协方差矩阵. 使用预测集合和当前观测信息对 $\mathbf{x}_{(n,t|t)}^i$ 进行集合分析; 可得

$$\begin{cases} \bar{\mathbf{x}}_{(t|t-1)}^i = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{x}_{(n,t-1)}^i, \\ \mathbf{P}^i(t|t-1)\mathbf{H}^T = (N_c - 1)^{-1} \sum_{i=1}^{N_c} (\mathbf{x}_{(n,t-1)}^i - \bar{\mathbf{x}}_{(n,t-1)}^i)(\mathbf{x}_{(n,t-1)}^i - \bar{\mathbf{x}}_{(n,t-1)}^i)^T, \\ \mathbf{HP}^i(t|t-1)\mathbf{H}^T = (N_c - 1)^{-1} \sum_{i=1}^{N_c} (\mathbf{H}\mathbf{x}_{(n,t-1)}^i - \mathbf{H}\bar{\mathbf{x}}_{(n,t-1)}^i)(\mathbf{H}\mathbf{x}_{(n,t-1)}^i - \mathbf{H}\bar{\mathbf{x}}_{(n,t-1)}^i)^T. \end{cases}$$

从而可得

$$\begin{cases} \mathbf{x}_{(n,t|t)}^i = \mathbf{x}_{(n,t|t-1)}^i + \mathbf{K}(\mathbf{y}_{(n,t|t)}^i - \mathbf{H}\mathbf{x}_{(n,t|t-1)}^i), \\ \bar{\mathbf{x}}_{(t|t)}^i = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{x}_{(n,t|t)}^i, \\ \mathbf{P}_{(t|t)}^i = \mathbf{P}_{(t|t-1)}^i - \mathbf{P}_{(t|t-1)}^i \mathbf{H}(\mathbf{HP}_{(t|t-1)}^i \mathbf{H} + \mathbf{R}_e)^{-1} \mathbf{HP}_{(t|t-1)}^i. \end{cases} \quad (8)$$

当前观测时刻粒子 $\mathbf{x}_{(n,t|t)}^i$ 的分布可以由均值 $\bar{\mathbf{x}}_{(t|t)}^i$ 和协方差 $\mathbf{P}_{(t|t)}^i$ 所描述的高斯分布 $N(\bar{\mathbf{x}}_{(t|t)}^i, \mathbf{P}_{(t|t)}^i)$ 描述. 可见该分布包含了当前观测值的信息, 比系统转移概率 $p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)})$ 更接近真实的后验分布, 能够准确描述当前粒子的分布信息. 从而使用此分布进行粒子的重采样与更新可以获得更优的结果. 即令

$$\mathbf{q}^i(\mathbf{x}_t | \mathbf{x}_{0:t-1}, \mathbf{y}_{1:t}) = N(\bar{\mathbf{x}}_{(t|t)}^i, \mathbf{P}_{(t|t)}^i).$$

在每一步跟踪完成之后, 使用式(8) 计算并获取建议分布 $\mathbf{q}(\mathbf{x}_t | \mathbf{x}_{0:t-1}, \mathbf{y}_{1:t})$, 并根据此分布进行新一轮的粒子采样.

3 颜色和形状特征的融合模型

文献[9]证明了采用多个特征比使用单一的特征有更好的跟踪效果. 颜色特征应用较广泛, 但其受目标的外部特性的影响比较大. 而边缘特性可以弥补颜色特征的不足, 本文将颜色特征和形状特征结合起来用于目标跟踪.

3.1 颜色相似性测量

颜色模型用来捕捉目标的颜色信息, 目标的颜色模型可以表示为直方图的形式^[10]. 本文使用 HSV 空间来表示颜色空间^[11]. 直方图包括关于色调 H 和饱和度 S 的 $n_h n_s$ 个条柱, 因为亮度信息受图像变化的影响不大, 因此可以假定目标颜色直方图由 $m_c = n_h n_s$ 个级别组成.

$\{\mathbf{x}_i^* | i=1, \dots, n\}$ 表示用来创建颜色模型的像素, 定义关于 $\mathbf{x}_i^*$ 的函数 $b: \mathbf{R}^2 \rightarrow \{1, \dots, m_c\}, b(\mathbf{x}_i^*)$ 表示 $\mathbf{x}_i^*$ 像素对应直方图的级数. 目标区域内中直

方图各级别的颜色密度分布按下式计算.

$$\hat{q}_u^{(c)} = \mathbf{K} \sum_{i=1}^n k(\mathbf{x}_i^*) \sigma[b(\mathbf{x}_i^*) - u], \quad c \in \{1, \dots, m_c\}. \quad (9)$$

其中: u 为直方图级别; $\hat{q}_u^{(c)}$ 为此级别下的归一化密度; σ 为狄拉克函数; $\mathbf{K}$ 为归一化因子, 使得

$$\sum_{u=1}^{m_c} \hat{q}_u^{(c)} = 1. \quad \mathbf{K} = \frac{1}{\sum_{i=1}^n k(\mathbf{x}_i^*)}. \quad (10)$$

权重函数 k 与 $\mathbf{x}_i^*$ 对目标中心的距离成反比, 对距离目标区域中心较远的像素赋予较小权值, 对较近的像素赋予较大的权重. 目标的颜色模型 $\hat{\mathbf{q}}_c = \{\hat{q}_u^{(c)} | u=1, \dots, m_c\}$ 与候选目标的颜色模型 $\hat{\mathbf{p}}_c = \{\hat{p}_u^{(c)} | u=1, \dots, m_c\}$ 间的近似关系可以表示为

$$\rho_c(\hat{\mathbf{q}}_c, \hat{\mathbf{p}}_c) = \sum_{u=1}^{m_c} \sqrt{\hat{q}_u^{(c)} \hat{p}_u^{(c)}}. \quad (11)$$

3.2 形状相似性测量

文献[12-13]中提出了利用边界点来描述物体的形状. 采用边界点的空间分布、相应边界点的数目和边界点上梯度强度这 3 种信息的组合来描述物体的形状. 用沿着轮廓的空间直方图来表示目标形状的空间分布. 在目标中心按逆时针方向将轮廓均匀分成 m_s 个区域. 建立函数 $s: \mathbf{R}^2 \rightarrow \{1, \dots, m_s\}, s(\mathbf{x}_i^*)$ 为 $\mathbf{x}_i^*$ 所在区域的索引号. 对于目标 q , 落入第 u 个区域的目标边界点数目表示为

$$n_u^q = \sum_{i=1}^N \delta[s(\mathbf{x}_i^*) - u]. \quad (12)$$

其中: N 为目标轮廓的边界点数, 则边界点落入第 u 个区域的概率为

$$\hat{q}_u^{(e)} = n_u^q / \sum_{u=1}^{m_s} n_u^q. \quad (13)$$

第 u 个条柱的边界点的平均梯度强度为

$$g_u^q = (\sum_{i=1}^N g(\mathbf{x}_i^*) \delta[s(\mathbf{x}_i^*) - u]) / n_u^q. \quad (14)$$

对于目标 q 和候选目标 p , 它们之间关于第 u 个条柱的边界点数目近似度可以定义为

$$\rho_u^n = \min(n_u^q, n_u^p) / \max(n_u^q, n_u^p). \quad (15)$$

目标 q 和候选目标 p 之间关于第 u 个区域的梯度强度近似度可以表示为

$$\rho_u^g = \min(g_u^q, g_u^p) / \max(g_u^q, g_u^p). \quad (16)$$

则目标 q 和候选目标 p 的形状模型的近似关系表示为

$$\rho_s(q, p) = \sum_{u=1}^{m_s} \sqrt{\min(\hat{q}_u^{(e)}, \hat{p}_u^{(e)}) \rho_u^n \rho_u^g}. \quad (17)$$

3.3 模型更新

本文结合颜色和形状特征,采用 Bhattacharyya 距离 $d_c = \sqrt{1 - \rho_c}$, $d_s = \sqrt{1 - \rho_s}$ 来描述目标相似度. 因此基于形状和颜色的目标模型似然概率表示为

$$p(y_t | x_t) = \frac{1}{2\pi\sigma_c\sigma_s} \exp\left[-\left(\lambda_1 \frac{d_c^2}{2\sigma_c^2} + \lambda_2 \frac{d_s^2}{2\sigma_s^2}\right)\right].$$

(18)

其中: λ_1 、 λ_2 为控制参数,分别表示各个特征模型的权重,根据环境的不同可以选择不同的权重.

在跟踪过程中需要对目标模型进行实时更新,本文在进行模型更新的时候,使用文献[14]中的更新模式同时对颜色模型和形状模型进行联合更新.

颜色模型更新为 $\hat{q}_c = (1 - \alpha_c)\hat{q}_c + \alpha_c\hat{p}_c$, 其中 α_c 受 d_s 控制.

$$\alpha_c = \begin{cases} 0, & d_s^2 > 0.7; \\ 0.2\exp(-d_s^2/0.3), & d_s^2 \leq 0.7. \end{cases}$$

(19)

形状模型更新为

$$\begin{aligned} n_q &= \{n_u^q\}_{u=1,\dots,m_s}, g_q = \{g_u^q\}_{u=1,\dots,m_s}; \\ n_q &= (1 - \alpha_s)n_q + \alpha_s n_p, g_q = (1 - \alpha_s)g_q + \alpha_s g_p. \end{aligned}$$

$$\alpha_s \text{ 的取值由控制参数 } d_c \text{ 决定,即}$$

$$\alpha_s = \begin{cases} 0, & d_c^2 > 0.7; \\ 0.2\exp(-d_c^2/0.3), & d_c^2 \leq 0.7. \end{cases}$$

(20)

在跟踪过程中,在每帧的目标位置同时计算颜色模型和形状模型,并采用上面的方法进行更新.

4 仿真实验

首先对于一维非线性系统来验证使用集合卡尔曼滤波构造建议分布的粒子滤波的有效性. 假设一维非线性系统的状态方程和量测方程分别为

$$x(t+1) = 1.5\exp(-2x^2(t)) + w(t),$$

$$y(t+1) = x^2(t+1) + v(t+1).$$

其中: 噪声 $w(t)$ 和 $v(t)$ 都服从 $N(0,1)$ 的正态分布. 同时使用本文提出的粒子滤波算法与扩展卡尔曼粒子滤波和传统粒子滤波算法对该系统模型进行滤波估计. 本文算法为单个粒子构造预测集合的成员数为 20, 两种滤波算法的粒子数都取 100, 分别在 Matlab 上进行 200 次的 Monte Carlo 仿真实验. 滤波结果的精确度采用均方根误差 RMSE 来描述. 一次仿真过程的比较结果如图 1 所示.




图 1 使用本文方法和其他粒子滤波器的 RMSE 对比

图 1 为仿真实验得到的三种不同粒子滤波算法的均方根误差 RMSE, 它定性地分析了三种滤波算法对状态估计的准确度. 如仿真结果所示, 这种新的建议分布由于得到了来自真实后验分布更多的支持, 因此 RMSE 更小.

使用本文方法对包含人脸的视频序列图像进行了跟踪验证. 用于实验的图像序列来自 Clemson 大学的头部跟踪数据库, 初始跟踪区域使用手动选取. 粒子数取值为 100, 预测集合数目为 15, λ_1 和 λ_2 均取值为 1.

图 2 为对包含人脸的视频序列进行跟踪验证的结果. 第一行为使用本文滤波算法和自适应融合模型跟踪的结果, 第二行为使用扩展卡尔曼粒子滤波和自适应模型跟踪的结果, 第三行为使用扩展卡尔曼粒子滤波和颜色模型的跟踪结果. 序列中的人脸包括了高速运动、缩放和角度的变化, 并且存在背景干扰. 从跟踪结果可以看出, 在头部快速运动和背景变化较大的情况下, 本文所提出的结合自适应融合模型的集合卡尔曼粒子滤波算法跟踪的结果要优于其他两者. 同时可以看出使用融合模型的跟踪结果要优于使用单个颜色模型.



图 2 粒子滤波跟踪结果

从试验结果可以看到, 本算法使用集合卡尔曼滤波器组对单个粒子进行建议分布的构造以及采用了融合的特征模型, 能更好地克服目标自身的变化和外界干扰对目标跟踪产生的影响, 提高了粒子滤波跟踪的准确性.

5 结 论

1) 在传统粒子滤波的框架下, 使用集合卡尔曼滤波结合当前观测信息构造建议分布.

2) 在跟踪过程中, 将颜色和形状这两种特征自适应地融合, 构造一个新的观测模型, 并在跟踪过程中自适应地进行更新. 实验结果证明了该方法的有效性和稳定性.

参考文献:

- [1] BANERJEE A, BURLINA P. Efficient particle filtering via sparse kernel density estimation[J]. IEEE Transactions on Image Processing, 2010, 19(9): 2480–2490.
- [2] YAN Zhai. Improved nonlinear filtering for target tracking [D]. Norman Oklahoma: University of Oklahoma Graduate College, 2007: 5–14.
- [3] GUNNARSSON F, BERGMAN N. Particle filter for positioning, navigation, and tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 425–437.
- [4] DE FREITAS F G. Bayesian methods for London neural networks[D]. Cambridge: Cambridge University, 1999.
- [5] LEEUWEN P J, EVENSEN G. Analysis scheme in the ensemble Kalman filter [J]. Mon Wea Rev, 1998, 126(6): 1719–1724.
- [6] EVENSEN G. The ensemble Kalman filter: theoretical formulation and practical implementation [J]. Ocean Dynamics, 2003, 53: 343–367.
- [7] LAINIOTIS D, PAPAPARASKEVA P. A new class of efficient adaptive nonlinear filters (ANLF) [J]. IEEE Transactions on Signal Processing, 1998, 46(6): 1730–1737.
- [8] LAINIOTIS D, PAPAPARASKEVA P. Efficient algorithms of clustering adaptive nonlinear filters [J]. IEEE Transactions on Automatic Control, 1999, 44(7): 1454–1459.
- [9] PEREZ P, VERMAAK J, BLAKE A. Data fusion for visual tracking with particles [J]. Proceedings of the IEEE, 2004, 92(3): 495–513.
- [10] COMANICIU D, RAMESH V, MEER P. Real-time tracking of non-rigid objects using mean shift [C]//IEEE Conference on Computer Vision and Pattern Recognition. South Carolina: IEEE Computer Society Technical Committee on Pattern Analysis and Machine Intelligence, 2000, 2: 142–149.
- [11] WU Y, HUANG T S. Robust visual tracking by integrating multiple cues based on co-inference learning [J]. International Journal of Computer Vision, 2004, 58(1): 55–71.
- [12] SHEN C, HENGEL A, DICK A. Probabilistic multiple cue integration for particle filter based tracking [C]//Proceedings of the 7th Digital Image Computing: Techniques and Applications. Sydney: The IEEE NSW Section, 2003: 399–408.
- [13] COLLINS R, LIU Y X. Online selection of discriminative tracking features [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2005, 27(10): 1631–1643.
- [14] ZUO J, ZHAO C H, CHENG Y M, *et al.* Particle filter based visual tracking using new observation model [C]//2007 IEEE International Conference on Automation and Logistics. Jinan: IEEE Robotics and Automation Society, 2007: 436–440.

(编辑 魏希柱)