# 基于修正积分卡尔曼粒子滤波的自适应目标跟踪算法

李昱辰<sup>1,2</sup>,李战明<sup>1,2</sup>

(1. 兰州理工大学 电气与信息工程学院, 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室, 兰州 730050)

摘 要:针对当前粒子滤波权值退化问题以及精度与时耗的矛盾,提出了一种新的高精度自适应粒子滤波算法。该算法综合考虑优选建议分布函数和重采样两种并行改进滤波性能的方法:首先,在积分卡尔曼滤波 (QKF)的基础上引入修正因子,通过修正的积分卡尔曼滤波(PQKF)产生优选的建议分布函数,较好地克服了粒 子退化现象,在提高滤波精度的同时降低了运算量;在重采样阶段,通过引入系统估计和预测提供的新息差值在 线自适应调整采样粒子数,较好地保证了粒子采样的高效性和算法的实时性。实验表明,新算法具有高精度、低 时耗的优点,是一种高精度自适应粒子滤波算法。

关键词: 粒子滤波; 重要性函数; 积分卡尔曼滤波; 统计线性回归

中图分类号: TP391 文献标志码: A 文章编号: 1001-3695(2012)07-2776-04 doi:10.3969/j.issn.1001-3695.2012.07.103

## Adaptive object tracking based on pruning quadrature Kalman particle filter

LI Yu-chen<sup>1,2</sup>, LI Zhan-ming<sup>1,2</sup>

(1. College of Electrical & Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 2. Key Laboratory of Advanced Control of Industrial Processes of Gansu Province, Lanzhou 730050, China)

**Abstract**: This paper proposed a new adaptive particle filter for the particle degeneration phenomenon and the contradiction between accuracy and consumption. Considering two parallel improving filtering methods, such as optimum proposed distribution function and re-sampling. First, used pruning quadrature Kalman filter produce optimization proposal distribution function, on the basis of quadrature Kalman filter, introduced pruning factors to improve filtering precision and reduce the running time. In resampling stage, introduced system estimation and prediction for the new spreads value online adaptive adjustments sampling particle counts, kept better sampling efficiency and real-time. Theoretical analysis and experiments show that the proposed new particle filter algorithm has higher accuracy and lower computation time than other improved particle filters, which is a new kind of particle filter algorithm for high precision.

**Key words**: particle filter(PF); important density function; quadrature Kalman filter(QKF); statistical linear regression (SLR)

## 0 引言

粒子滤波是一种针对非线性、非高斯噪声系统的统计滤波 方法,其主要思想是通过一组加权的采样粒子来表示状态的后 验概率密度<sup>[1]</sup>。理论上该方法可以表示任意形式的概率分 布,目前已在目标跟踪领域获得了成功的应用<sup>[2-9]</sup>。但是在实 际应用中,粒子滤波算法一直存在两大难题,即粒子退化和计 算量过大的问题。

针对粒子滤波算法的两大难题,研究人员提出了不少解决 办法。文献[10]提出采用扩展卡尔曼滤波(EKF)产生重要性 概率密度函数,该算法在估计性能上有所改善,但是由于 EKF 在模型线性化和高斯假设中引入了过多的近似误差,导致其改 进效果不是很明显;文献[11]提出采用不敏卡尔曼滤波 (UKF)产生重要性函数,由于 UKF 对高斯随机变量的均值和 方差可以精确到二阶以上的水平,因此具有较好的估计性能, 但是该算法要进行复杂的 UT 变换,计算量较大,算法实时性 较差,同时,UKF 之后的重采样算法本质上相当于加入了随机 扰动,所以重采样粒子的有效性存在着相对消弱的缺陷;文献 [3]在 UKF 的基础上融入了马尔可夫链—蒙特卡罗(MCMC) 抽样算法,在一定程度上提升了滤波性能,但是滤波时间却几 乎增加了一倍。为降低运行时间,增强算法的实时性,文献 [12]采用积分卡尔曼滤波(QKF)产生重要性概率密度函数, 由于积分卡尔曼滤波的多数计算均可采用离线计算的方法,且 不存在复杂的 UT 变换,因此该方法在提升滤波性能的同时也 有效降低了运行时间。但是该方法只是简单地采用积分卡尔 曼滤波来计算重要性概率密度函数,没有对两种算法的融合进 行优化,导致该方法在滤波精度和实时性方面的改进效果不是 很明显。

本文提出了一种新的粒子滤波算法,即修正的自适应积分 卡尔曼粒子滤波算法(pruning adaptive quadrature Kalman particle filter, PA-QKPF)。该算法首先在积分卡尔曼滤波的基础上 引入修正因子,实时在线调整积分点数,通过修正的积分卡尔 曼滤波(PQKF)产生更加接近真实后验概率分布的优选建议 分布函数,提高滤波精度的同时,增强了算法的实时性;接着深 入分析了过程噪声方差对采样效率的影响,在重采样阶段,引

#### 收稿日期: 2011-11-10; 修回日期: 2011-12-25

作者简介:李昱辰(1982-),男,博士研究生,主要研究方向为图像检索、智能信息处理(35146291@qq.com);李战明(1962-),男,教授,博导,主 要研究方向为复杂系统的建模与控制、神经模糊系统与软计算、计算机控制系统的理论与工程. 入系统估计和预测提供的新息差值,通过获得的观测新息差值,在线自适应调整所需采样粒子数,较好地保证了粒子采样的高效性和算法的实时性。

## 1 基本滤波介绍

#### 1.1 标准粒子滤波

粒子滤波(PF)是当前解决非线性问题的有效算法,该算 法通过一组带有权值的粒子 $\{x_k^{(i)}, \omega_k^{(i)}\}_{i=1}^N$ 来表示 k 时刻目标 状态的概率密度函数。其中:N代表采样粒子数目, $x_k^{(i)}$ 表示 目标的某种可能状态;权值  $\omega_k^{(i)}$ 表示该粒子所能代表目标真 实状态的概率赋值。通过对这组带权重的粒子进行加权平均, 就可以估计出目标在 k 时刻的状态。但是标准的粒子滤波是 通过有限的离散粒子来逼近连续的概率分布,粒子权值的方差 随着时间递增,经过若干次迭代以后,除了极少数粒子外,其余 的粒子归一化权值可以忽略不计,使得粒子集无法正确描述后 验概率分布,产生权值退化现象,影响了滤波的性能。为此,研 究人员在文献[13]中引入了重采样的步骤,以克服粒子权值 退化问题,通过引入有效粒子数  $N_{\text{eff}}$ 来判定是否需要进行重 采样。

$$N_{\rm eff}(k) = \frac{N}{1 + \operatorname{var}(\omega_k^{*i})} = \frac{N}{E(\omega_k^{*i})^2}$$
(1)

其中: $\omega_{k}^{*i} = \frac{p(x_{k}^{i}|y_{1:k})}{q(x_{k}^{i}|x_{k-1}^{i},y_{k})}$ 。有效粒子数越小,表明权值退化现 象越严重。当 $N_{\text{eff}}$ 小于某一经验给定的初始阈值 $N_{\text{th}}$ 时,需要对 粒子进行重新采样。

#### 1.2 积分卡尔曼滤波

积分卡尔曼滤波算法最先由 Arasaratnam 等人在文献[14] 中提出,通过一簇近似高斯分布的高斯厄米特积分点,采用统 计线性回归(SLR)的方法将非线性函数近似为线性函数,该算 法与 EKF、UKF 以及高斯厄米特滤波器相比,具有更高的滤波 精度。文献[14]中给出了详细的证明。其具体的算法描述 如下:

1)时间更新

假设在 k 时刻,系统的后验概率密度函数为  $p(x_{k-1} | z_{1:k-1}) = N(\hat{x}_{k-1|k-1}, P_{k-1|k-1}),$ 对其进行相应的因式分解,则有

$$P_{k-1|k-1} = S_{k-1|k-1} S_{k-1|k-1}^{\mathrm{T}}$$
(2)

计算积分点  $\{X_{j,k-1|k-1}\}_{j=1}^{m}$ :

$$X_{j,k-1|k-1} = S_{k-1|k-1}\xi_j + \hat{x}_{k-1|k-1}$$
(3)  
对积分点进行预测估计:

$$X_{j,k|k-1}^* = f(X_{j,k-1|k-1}) \quad j = 1, \cdots, m$$
(4)

其中:m为积分点个数。系统的状态预测值和相应的误差协方 差为

$$\hat{X}_{k|k-1} = \sum_{j=1}^{m} \omega_j X_{j,k|k-1}^*$$
(5)

$$P_{k|k-1} = Q_k + \sum_{j=1}^{\infty} \omega_j (X_{j,k|k-1}^* - X_{k|k-1}) (X_{j,k|k-1}^* - X_{k|k-1})^{\mathrm{T}}$$
(6)

其中:Q<sub>k</sub> 是过程噪声协方差。在时间更新阶段,可以获得系统的预测概率密度函数为

$$p(x_k | z_{1;k-1}) = N(\hat{X}_{k|k-1}, P_{k|k-1})$$
(7)

2) 量测更新

$$P_{k|k-1} = S_{k|k-1} S_{k|k-1}^{1} \tag{8}$$

估计积分点集 $\{X_{j,k|k-1}\}_{j=1}^{m}$ :

$$X_{j,k|k-1} = S_{k|k-1}\xi_j + \hat{x}_{k|k-1}$$
(9)

预测估计相应的量测点集 $\{Z_{j,k|k-1}\}_{j=1}^{m}$ :

$$\{Z_{j,k|k-1}\}_{j=1}^{m} = h(X_{j,k|k-1}) \quad j = 1, \cdots, m$$
 (10)  
量测的预测估计:

$$\hat{z}_{k|k-1} = \sum_{j=1}^{m} \omega_j Z_{j,k|k-1}$$
(11)

新息协方差矩阵:

$$P_{zz,k|k-1} = R_k + \sum_{j=1}^{m} \omega_j (Z_{j,k|k-1} - \hat{z}_{k|k-1}) (Z_{j,k|k-1} - \hat{z}_{k|k-1})^{\mathrm{T}} (12)$$
  
其中: R<sub>k</sub> 是量测噪声协方差。

下: 机 定重(例 未 广 ) 万.

互协方差矩阵:

$$P_{xz,k|k-1} = R_k + \sum_{j=1}^{m} \omega_j (X_{j,k|k-1} - \hat{x}_{k|k-1}) (Z_{j,k|k-1} - \hat{z}_{k|k-1})^{\mathrm{T}}$$
(13)

Kalman 增益:

$$K_k = \mathbf{P}_{xz,k|k-1} \mathbf{P}_{xz,k|k-1}^{-1}$$
(14)

状态更新估计和相应的协方差:  
$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - \hat{z}_{k|k-1})$$
 (15)

$$P_{k|k} = P_{k|k-1} - K_k P_{zz,k|k-1} K_k^{\mathrm{T}}$$
(16)

$$P_{k|k} = S_{k|k} S_{k|k}^{\mathrm{T}} \tag{17}$$

则系统过程的概率密度可以表示为

$$p(x_k | z_{1:k}) = N(\hat{x}_{k|k}, P_{k|k})$$
(18)

关于积分卡尔曼滤波中积分点  $\xi_j$  和相应的权值  $\omega_j$  的计算,文献[8]给出了一种很有效的方法,该方法利用了正交多项式和三角对角线矩阵之间的关系,这里给予简单介绍。考虑一个标量随机变量 x,假设其满足高斯概率分布,则函数 g(x)的期望值可以近似为

$$E(g(x)) = \int_{p} g(x) N(x,0,1) \, \mathrm{d}x \approx \sum_{i=1}^{m} \omega_{i} g(\xi_{i})$$
(19)

假定 J 是一个对称三对角线矩阵,其对角线元素为零,并 且满足以下关系:

$$J_{i,i+1} = \sqrt{i/2} \quad 1 \le i \le m - 1 \tag{20}$$

设  $\lambda_i$  是 *J* 的第 *i* 个特征值,  $\eta_i$  是  $\lambda_i$  对应的标准化特征向 量,则 积 分 点  $\xi_i$  的 取 值 为  $\xi_i = \sqrt{2} \lambda_i$ , 相 应 的 权 重  $\omega_i = ((\eta_i)_1)^2, (\eta_i)_1 \ge \eta_i$ 的第一个元素。对于 *x* 是向量高斯变量的情况, 文献[10]给出了积分点和相应权值的具体解法。

#### 2 改进的粒子滤波算法

#### 2.1 积分修正因子

从概率意义上讲,不同权重赋值的积分点对积分的贡献也 不同:权重较大的积分点对积分运算具有较大的贡献,权重较 小的积分点对积分的运算贡献较小,并且影响了算法的实时 性。基于此,本文考虑引入积分修正因子 θ<sub>m</sub>,对积分点进行在 线自适应修正,通过设置初始权重阈值,丢弃权重较低的积分 点,保留权重较高的积分点进行运算。

例如,假设有 m 个积分点,相应的阈值可以计算为

$$\theta_m = \frac{\omega_1 \omega_{\left[\frac{m+1}{2}\right]}}{m} \tag{21}$$

如果积分点权重  $\omega_i \ge \theta_m$ ,保留积分点 $\xi_i$ ;如果积分点权重  $\omega_i < \theta_m$ ,则丢弃积分点 $\xi_i$ ,然后对调整后的积分点重新进行归一化处理。由于这一步是采用离线计算的方法,因此,修正因子的引入非但没有增加算法的计算负担(因为权重较小粒子的抛弃),反而提升了算法的实时性。

粒子滤波在实际应用中需要预先确定系统的状态方程和 观测方程。通常情况下,系统的状态方程是无法精确获得的。 假设非线性非高斯随机状态空间模型为

$$\begin{cases} x_t = f(x_{t-1}) + v_{t-1} \\ y_t = h(x_t) + w_t \end{cases}$$
(22)

其中:v<sub>t-1</sub>为系统噪声,假设其服从零均值高斯分布,各分量间 相互独立,则噪声方差就决定了采样的精度。当前的粒子滤波 算法都是根据经验预先设定好系统噪声的方差<sup>[4]</sup>,由于系统 状态的随机性,固定方差很难正确描述系统特性:过大的噪声 方差会导致大量的无效采样粒子产生,而过小的噪声方差又可 能使采样不能包含真正的系统状态,从而导致滤波精度下降甚 至失效。因此,本文考虑引入新息残差估计,通过系统估计和 预测差值提供的新息知识,在重采样阶段利用量测新息在线自 适应调整采样粒子数,在保证粒子采样高效性的同时,也很好 地实现了算法的实时性。

假设 k 时刻系统的状态估计值和预测值分别为  $\hat{x}_k$  和  $x_k$ , 则相应的新息残差估计可以表示为

$$e^k = \hat{x}_k - x_k$$
  
则系统的噪声方关可以表示为

$$\delta^{k} = \begin{cases} \min\left(e^{k}, \delta_{\max}\right) & e^{k} > \delta^{k-1} \\ \max\left(\alpha\delta^{k-1}, e^{k}, \delta_{\min}\right) & e^{k} < \delta^{k-1} \end{cases}$$
(24)

为了避免系统噪声过小导致粒子贫乏现象的产生,设置系统的噪声方差下限为δ<sub>min</sub>,上限为δ<sub>max</sub>。同时,为了避免估计误差使系统噪声减小过快,算法中利用衰减因子α控制噪声方差的减小速度。采样中粒子的数量与系统的噪声相关,当系统噪声较小时,用少量的采样粒子就可以高精度地逼近系统分布;当噪声较大时,粒子的采样范围扩大,同时增加采样粒子数目,以保证采样的精度。本文采用 Sigmoid 函数表示上述粒子数量和系统噪声方差之间的关系:

$$N_{k} = N_{\min} + (N_{\max} - N_{\min}) \left( \frac{2}{1 + \exp(-\beta(\delta^{k} - \delta_{\min}))} - 1 \right)$$
(25)

其中: $N_{\min}$ 和 $N_{\max}$ 分别表示最小和最大粒子数; $\delta^{i}$ 为系统在k时刻的系统噪声方差,也可以理解为系统在k时刻的不确定性度量。

#### 2.3 PA-QKPF 算法

通过上面的分析,本文采用修正后的积分卡尔曼滤波产生 优选的建议分布函数,在重采样阶段,引入观测新息残差在线 自适应调整所需采样粒子数,产生一种新的高精度实时性粒子 滤波算法,即 PA-QKPF。算法的具体实现步骤如下:

1)初始化

在 
$$k = 0$$
 时刻,从先验分布  $p(x_0)$  中抽取粒子  $x_0^{(i)}$ ,并设置:

$$\hat{x}_{0}^{(i)} = E[x_{0}^{(i)}]$$
(26)

$$P_{0}^{(i)} = E\left[\left(x_{0}^{(i)} - \hat{x}_{0}^{(i)}\right)\left(x_{0}^{(i)} - \hat{x}_{0}^{(i)}\right)^{\mathrm{T}}\right]$$
(27)

$$P_{0}^{(i)} = S_{0}^{(i)} \left( S_{0}^{(i)} \right)^{\mathrm{T}}$$
(28)

初始化的权值设为

$$\omega_0^{(i)} = 1/N \tag{29}$$

2) 预测和更新

利用 P-QKF 计算积分点,并通过式(21) 自适应调整积分 粒子数,更新粒子

$$X_{(1,\dots,m),k-1}^{(i)} = S_{k-1}^{(i)} \xi_j + \hat{x}_{k-1}^{(i)} \quad j = 1,\dots,m$$
(30)

时间更新:

$$X_{(1,\cdots,m),k|k-1}^{*(i)} = f(X_{(1,\cdots,m),k-1}^{(i)})$$
(31)

$$\hat{x}_{k|k-1}^{(i)} = \sum_{j=1}^{m} \omega_j X_{j,k|k-1}^{*(i)}$$
(32)

$$P_{k|k-1}^{(i)} = Q_k + \sum_{j=1}^{m} \omega_j (X_{j,k|k-1}^{*(i)} - \hat{x}_{k|k-1}^{(i)}) (X_{j,k|k-1}^{*(i)} - \hat{x}_{k|k-1}^{(i)})^{\mathrm{T}}$$
(33)

(i)

量测更新:

$$P_{k|k-1}^{(i)} = S_{k|k-1}^{(i)} (S_{k|k-1}^{(i)})^{1}$$

$$X_{(1,\dots,m)}^{(i)} = S_{k|k-1}^{(i)} = S_{k|k-1}^{(i)} \xi_{i} + \hat{x}_{k|k-1}^{(i)}$$
(34)
(34)

$$Z_{(1,\dots,m),k|k-1}^{(i)} = h(X_{(1,\dots,m),k|k-1}^{(i)})$$
(36)

$$P_{zz,k|k-1}^{(i)} = R_k + \sum_{j=1}^{m} \omega_j (Z_{j,k|k-1}^{(i)} - \hat{z}_{k|k-1}^{(i)}) (Z_{j,k|k-1}^{(i)} - \hat{z}_{k|k-1}^{(i)})^{\mathrm{T}}$$
(37)

$$P_{xx,k|k-1}^{(i)} = \sum_{j=1}^{m} \omega_j \left( X_{j,k|k-1}^{(i)} - \hat{x}_{k|k-1}^{(i)} \right) \left( Z_{j,k|k-1}^{(i)} - \hat{z}_{k|k-1}^{(i)} \right)^{\mathrm{T}}$$
(38)  
$$V_{xx,k|k-1}^{(i)} = P_{xx,k|k-1}^{(i)} \left( P_{xx,k|k-1}^{(i)} - \hat{z}_{k|k-1}^{(i)} \right)^{\mathrm{T}}$$
(38)

$$\mathbf{x}_{k}^{(i)} = \mathbf{r}_{xz,k|k-1} (\mathbf{P}_{xz,k|k-1})$$
(39)  
$$\hat{\mathbf{x}}^{(i)} = \hat{\mathbf{x}}^{(i)} + \mathbf{K}^{(i)} (z, -\hat{\mathbf{x}}^{(i)})^{\mathrm{T}}$$
(40)

$$\mathbf{x}_{k}^{(i)} = \mathbf{x}_{k|k-1}^{(i)} + \mathbf{x}_{k}^{(i)} (\mathbf{x}_{k}^{(i)} \mathbf{x}_{k|k-1}^{(i)})^{\mathrm{T}}$$
(10)  
$$\mathbf{p}_{k}^{(i)} = \mathbf{p}_{k}^{(i)} \mathbf{v}_{k}^{(i)} (\mathbf{x}_{k}^{(i)})^{\mathrm{T}}$$
(41)

$$\mathbf{F}_{k}^{\mathsf{r}} = \mathbf{F}_{k|k-1} - \mathbf{K}_{k} - \mathbf{F}_{zz,k|k-1}(\mathbf{K}_{k})$$
(41)

$$\begin{aligned} x_{k}^{(i)} &\sim q(x_{k}^{(i)} \mid x_{0:k-1}^{(i)}, z_{1:k}) \approx N(x_{k}^{(i)}, \hat{x}_{k}^{(i)}, P_{k}^{(i)}) \end{aligned} \tag{42} \\ \nexists \psi_{k} P_{k}^{(i)} = S_{k}^{(i)} (S_{k}^{(i)})^{\mathsf{T}}_{\circ} \end{aligned}$$

相应的权重可以表示为

$$\boldsymbol{\omega}_{k}^{(i)} = \boldsymbol{\omega}_{k-1}^{(i)} \frac{p(z_{k} | x_{k}^{(i)}) p(x_{k}^{(i)} | x_{k-1}^{(i)})}{q(x_{k}^{(i)} | x_{0,k-1}^{(i)}, z_{1,k})}$$
(43)

归一化的权重为

(23)

$$\overline{\boldsymbol{\omega}}_{k}^{(i)} = \boldsymbol{\omega}_{k}^{(i)} / \sum_{i=1}^{N} \boldsymbol{\omega}_{k}^{(i)}$$
(44)

其中: $p(z_k | x_k^{(i)})$ 为量测值  $z_k$  的似然函数。

3) 重采样

给定重采样的初始阈值  $N_{th}$ ,如果有  $N_{eff} < N_{th}$ ,则令 $\overline{\omega}_{k}^{(i)} =$ 1/N,利用粒子集 { $x_{k}^{(i)}, \overline{\omega}_{k}^{(i)}, i = 1, \dots, N$ } 进行重采样。根据式 (24)计算 k + 1 时刻系统的噪声方差,再由式(25)计算出所需 的采样粒子数  $N_{m}$ 。

4)输出

经过上面算法的迭代,滤波分布的经验概率分布、系统状态估计以及误差协方差的输出值分别为

$$\hat{p}(x_k | z_{1;k}) = \frac{1}{N_m} \sum_{i=1}^N \delta(x_k - x_k^{(i)})$$
(45)

$$\hat{x}_{k} = \frac{1}{N_{m}} \sum_{i=1}^{N} x_{k}^{(i)}$$
(46)

$$P_{k} = \frac{1}{N_{m}} \sum_{i=1}^{N} (\hat{x}_{k} - x_{k}^{(i)}) (\hat{x}_{k} - x_{k}^{(i)})^{\mathrm{T}}$$
(47)

### 3 实验及分析

#### 3.1 非线性系统仿真

考虑到系统状态估计的非线性非高斯性,本文采用如下系统模型<sup>[15]</sup>对 PF、EKF、UKF、PQKF 和 PA-QKPF 五种滤波方法的滤波精度、平均滤波时间进行了综合比较:

$$\begin{cases} x_{t} = 1 + \sin\left(0.4\pi t\right) + 0.5x_{t-1} + v_{t-1} \\ y_{t} = \begin{cases} 0.2x_{t}^{2} + n_{t} & t \leq 30 \\ 0.5x_{t} - 2 + n_{t} & t > 30 \end{cases}$$
(48)

为增强过程噪声  $v_{t-1}$ 的随机性,实验中通过在噪声 Gamma (3,2)的基础上叠加高斯白噪声的方法,量测噪声  $n_t \sim N(0, 0.00001)$ ,实验中取  $\alpha = 0.9$ ,采用两个不同阶次观测模型对系 统状态进行观测,观测时间为 T = 60。实验中,系统状态的估 计采用均值估计器,即

$$\hat{x}_{t} = \frac{1}{N} \sum_{j=1}^{N} x_{t}^{j}$$
(49)

一次独立实验的均方误差定义为

$$MSE = \left(\frac{1}{T}\sum_{t=1}^{N} (\hat{x}_t - x_t)^2\right)^{1/2}$$
(50)

**仿真**1 首先进行一步时间迭代,对给定的系统模型进行 预测跟踪,得到的观测预测分布和系统后验概率分布的分布图 形如图1所示,系统的跟踪曲线如图2所示。从图中可以看 出,几种改进的粒子滤波算法在跟踪精度上明显优于标准的粒 子滤波算法,这主要是因为改进粒子滤波算法中融入了最新的 量测信息。



仿真2 为检验本文算法的滤波精度和时间消耗,实验中 采用50步时间迭代,对各种粒子滤波算法的均方误差根、均方 误差根均值和方差以及相应的平均时间消耗进行了比较,所得 均方误差根曲线如图2所示。表1给出了均方误差根均值和 方差以及相应的平均时间消耗。由图2和表1可以明显看出, 几种改进后的粒子滤波算法由于融入了最新的量测值,滤波精 度明显优于标准粒子滤波算法;同时,由于本文算法采用了积 分点和粒子数目的在线自适应调整,在保证采样粒子的高效性 和多样性的同时,也在一定程度上降低了算法的时间损耗,提 高了算法的实时性,在滤波精度和实时性方面均明显优于其他 几种改进的粒子滤波算法。

表1 各种算法的统计性能比较

算法		性能指标	
	均值	方差	运行时间/s
PF	0.377 36	0.041 31	1.271 6
EKF	0.313 13	0.010 89	3.799 2
UKF	0.096 47	0.005 60	7.218 9
PQKF	0.063 14	0.003 09	7.8078
PA-QKPF	0.041 28	0.002 11	4.8174

#### 3.2 人脸跟踪实验

为了进一步验证本文改进算法的有效性,将其应用到人脸 跟踪序列中,并将本文算法和标准粒子滤波算法跟踪效果进行 比较。实验中采用基于颜色直方图的跟踪方法进行跟踪,以直 方图所包含的真实人脸中心轮廓信息量大小作为区分跟踪效 果好坏和精度高低的标准。测试序列选自斯坦福大学的人脸 测试序列。 图 3 为较大偏转跟踪结果。由图 3 可看出,粒子滤波方法 对姿态的改变具有很好的鲁棒性,两种粒子滤波方法在姿态发 生改变的情况下都保持了很好的跟踪效果,但是本文算法的跟 踪精度明显高于标准粒子滤波算法。在图 4 第 244 帧,由于遮 挡的原因,标准粒子滤波算法跟踪失败;在图 5 第 301 帧,由于 相似背景人脸的影响,标准粒子滤波算法也跟踪失败。但是在 两种情况下,本文改进的粒子滤波算法均保持了较好的跟踪精 度,主要原因是采用了修正的卡尔曼滤波方法产生优选的建议 分布函数,融入了最新的量测信息,有效提升了滤波算法的鲁 棒性。



由人脸跟踪实验可以看出,两种算法在人脸旋转、遮挡和背 景变化较大的情况下,跟踪效果都受到了一定程度的影响,但是 仍然能够实现有效的跟踪,而本文所提到的算法,一直保持了较 高的跟踪精度和鲁棒性,始终都能够很好地锁定目标人脸。

#### 4 结束语

粒子滤波器在解决非线性非高斯滤波问题中已经取得了 非常好的效果,但是粒子权值退化和计算量较大仍然是尚待解 决的难题。针对这两个难题,本文提出了一种新的高精度实时 性粒子滤波算法,即 PA-QKPF。该算法的提出为非线性滤波 问题提供了一种新的解决方法,在下一步的工作中,笔者将考 虑用 PA-QKPF 算法解决说话人跟踪问题。 (下转第 2783 页) (上接第2779页)

#### 参考文献:

- [1] GORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation [J]. IEEE Proceedings on Radar and Signal Processing, 1993, 140(2):107-113.
- [2] 李远征, 卢朝阳, 高全学, 等. 基于多特征融合的均值迁移粒子滤 波跟踪算法[J]. 电子与信息学报, 2010, 32(2):411-415.
- [3] 张苗辉,刘先省.基于 MCMC 无味粒子滤波的目标跟踪算法[J]. 系统工程与电子技术,2009,31(8):1810-1813.
- [4] 王书朋, 姬红兵. 用于目标跟踪的自适应粒子滤波算法[J]. 系统 仿真学报, 2010, 22(3):630-633.
- [5] BRASNETT P, MIHAYLOVA L, BULL D, et al. Sequential Monte Carlo tracking by fusing multiple cues in video sequences [J]. Image and Vision Computing, 2007, 25(8):1217-1227.
- [6] 曹洁,李伟.基于多特征融合的目标跟踪算法[J].兰州理工大学 学报,2011,37(2):80-84.
- [7] MORRIS B T, TRIVEDI M M. Contextual activity visualization from long-term video observations [J]. IEEE Intelligent Systems, 2010,

**25**(3):50-62.

- [8] 刘晨光,程丹松,刘家锋,等.一种基于交互式滤波器的视频中多 目标跟踪算法[J].电子学报,2011,39(2):260-267.
- [9] 夏思宇,潘泓,金立左,等.基于特征组合的人脸跟踪方法[J].数 据采集与处理,2011,26(1):15-19.
- [10] DOUCET A, GODSILL S J, ANDRIEU C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. Statistics and Computing, 2000, 10(3):197-208.
- [11] JULIER S J, UHLMANN J K. Unscented filtering and nonlinear estimation[J]. IEEE Trans on Signal Processing, 2004, 92(3):401-422.
- [12] WU Chun-lin, HAN Chong-zhao. Quadrature Kalman particle filter[J]. Systems Engineering and Electronics, 2010, 21 (2):175-179.
- [13] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for on line non-linear/non-Gaussian Bayesian tracking [J]. IEEE Trans on Signal Processing, 2002,50(2):174-188.
- [14] ARASARATNAM I, HAYKIN S, ELLIOTT R J. Discrete-time nonlinear filtering algorithms using Gauss-Hermite quadrature [J]. Proceedings of the IEEE, 2007, 95(5):953-977.
- [15] Van der MERWE R. A doucet the unscented particle filter advance in neural information processing systems M]. [S. I.]; MIT Press, 2000.