

基于信息分享机制的粒子滤波算法及其在视觉跟踪中的应用

邱雪娜^{1,2,3}, 刘士荣², 吕 强²

(1. 华东理工大学 自动化研究所, 上海 200237;

2. 杭州电子科技大学 自动化研究所, 浙江 杭州 310018; 3. 宁波工程学院 电信学院, 浙江 宁波 315216)

摘要: 针对基本粒子滤波方法存在的权值退化和计算效率低问题, 提出了一种基于信息分享机制的粒子滤波算法. 该方法将粒子群优化算法和蚁群优化算法的优化思想共同作用到粒子更新中, 实现粒子之间信息共享, 从而增强粒子的多样性和最优估计能力. 同时分析了该算法的收敛性. 视觉跟踪实验表明, 该算法能用较少的粒子实现单目标和多目标跟踪, 综合跟踪性能优于基本粒子滤波和基于粒子群优化的粒子滤波方法, 验证了本算法的有效性.

关键词: 粒子滤波; 信息分享机制; 视觉跟踪; 多目标跟踪

中图分类号: TP391 **文献标识码:** A

Particle filter algorithm based on information-shared mechanism and its application to visual tracking

QIU Xue-na^{1,2,3}, LIU Shi-rong², LÜ Qiang²

(1. Institute of Automation of East China University of Science and Technology, Shanghai 200237, China;

2. Institute of Automation of Hangzhou Dianzi University, Hangzhou Zhejiang 310018, China;

3. College of Electronic and Information Engineering of Ningbo University of Technology, Ningbo Zhejiang 315016, China)

Abstract: To deal with the weight-degeneracy and computation efficiency in particle filter, we propose a novel particle filter algorithm based on the information-shared mechanism. This method combines particle swarm optimization and ant colony optimization to update particles to fully share the population information. The particles diversity is recovered and the estimation precision is improved. The convergence of this algorithm is analyzed. Visual tracking experiments show that the proposed algorithm realizes both single-object tracking and multi-object tracking with fewer particles and better comprehensive tracking-performance than classic particle filters and the particle filter based on particle-swarm optimization.

Key words: particle filter; information-shared mechanism; visual tracking; multi-object tracking

1 引言(Introduction)

粒子滤波(particle filter, PF)起源于蒙特卡罗方法(Monte Carlo methods), 它通过离散化的随机测度逼近概率分布, 在非线性、非高斯系统中表现出很大的优越性, 因此被广泛应用于飞行器导航、机器人定位、数据检测、视觉跟踪等领域^[1, 2].

粒子滤波方法采用具有权重的粒子集来近似逼近待求问题的后验分布, 因此, 理论上该方法可以表示任意形式的概率分布. 但是该算法也存在以下两个缺点: 1) 权值的退化现象. 即经过多次迭代之后, 大多数粒子只有很小的权值. 2) 计算效率问题. 基本粒子滤波方法需要大量的粒子才能保证状态预估的精度, 特别当系统初始状态未知时, 粒子滤波需要大

量粒子才能保证粒子集的收敛性, 否则粒子集很容易发散从而导致预估失败.

针对粒子滤波存在的问题, 近年来已经提出了多种改进方法, 如: 辅助采样-重采样方法^[3, 4]、正则化采样方法^[5, 6]、自适应粒子滤波算法^[7]、无迹粒子滤波算法^[8, 9]、高斯粒子滤波算法^[10, 11]、基于遗传算法的粒子滤波^[12]、基于粒子群优化的粒子滤波^[13]、人工免疫粒子滤波^[14]等. 总的来说, 目前存在的这些改进粒子滤波方法, 主要可以分为两类: 一类是粒子样本分布的改进, 加速粒子集的收敛, 提高粒子滤波的预估性能; 另外一类是对重要性概率密度函数的改进. 在这两类方法中, 没有充分利用全体粒子的信息, 即仅仅利用了最优粒子的信息, 其他粒子

都没有被利用, 这样限制了上述两类改进方法所得到的粒子滤波算法最优估计能力的进一步提高。

本文提出了一种基于信息分享机制的粒子滤波算法(particle filter algorithm based on information shared mechanism, ISM-PF), 将粒子群优化算法中的个体历史最优粒子、全局最优粒子的概念和蚁群优化算法的信息分享机制相结合引导粒子位置的更新. 蚁群算法主要是通过一种信息分享机制, 实现蚁群个体之间的相互交流, 从而使整个蚁群涌现出较好的智能性^[15, 16]. 文献[17]将蚁群优化算法的信息素机制引入到粒子群算法中, 构建了一种粒子间信息共享的方式, 用来增大粒子间的信息交流程度, 从而提高算法的优化能力. 本文把基于信息分享机制引入到粒子位置的更新中, 粒子位置的更新不仅要考虑全局最优粒子和每个粒子本身的历史最优值所留下的信息, 还考虑其他非最优粒子留下的信息, 充分利用各个粒子的信息, 扩大粒子之间的信息分享, 提高粒子的最优估计能力, 并且增强粒子群的多样性. 这样既解决了粒子滤波的退化问题, 也改善了粒子分布, 提高了粒子滤波性能. 本文方法应用于视觉跟踪中, 能用较少的粒子达到较高的跟踪精度, 综合跟踪性能要明显优于基本粒子滤波方法(PF)和基于粒子群优化的粒子滤波方法(PSO-PF).

2 基本粒子滤波方法(Basic particle filter)

粒子滤波是一种为处理后验概率密度和观测过程概率密度为非高斯的问题而发展起来的方法, 它是通过非参数的Monte-Carlo模拟方法来实现递推Bayes滤波^[18].

非线性动态状态空间通常可表示成如下模型:

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \mathbf{v}_{k-1}), \quad (1)$$

$$\mathbf{z}_k = h_k(\mathbf{x}_k, \mathbf{w}_k). \quad (2)$$

其中: $f(*, *)$ 和 $h(*, *)$ 分别表示已知的状态转移函数和测量函数, \mathbf{x}_k 表示 k 时刻的系统状态向量, \mathbf{z}_k 表示 k 时刻的量测向量. \mathbf{v}_{k-1} , \mathbf{w}_k 为独立同分布的系统噪声和观测噪声. 粒子滤波算法描述如下:

1) 初始化. 在 $k = 0$ 时刻, 根据先验 $x_0^i \rightarrow p(x_0)$ 采样 N 个样本, 0 时刻第 i 个粒子的重要性权值 $\omega_0^i = 1/N$. 其中: $p(\mathbf{x}_0)$ 为样本先验分布; $k = 1, 2, \dots$ 为时间索引.

2) 序贯重要性采样. 假设 \mathbf{x}_k 服从一阶Markov过程, 给定 \mathbf{x}_k , 量测序列 \mathbf{z}_k 相互独立, 设 $\mathbf{X}_k = \{\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_k\}$, $\mathbf{Z}_k = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$, 根据Bayes滤波的基本原理有:

$$p_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{k-1}) = \int p_{k|k-1}(\mathbf{x}_k | \mathbf{x}_{k-1}) p_{k-1|k-1}(\mathbf{x}_{k-1} | \mathbf{Z}_{k-1}) d\mathbf{x}_{k-1}, \quad (3)$$

$$p_{k|k}(\mathbf{x}_k | \mathbf{Z}_k) = \frac{p_{k|k}(\mathbf{z}_k | \mathbf{x}_k) p_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{k-1})}{\int p_{k|k}(\mathbf{z}_k | \mathbf{x}_k) p_{k|k-1}(\mathbf{x}_k | \mathbf{Z}_{k-1}) d\mathbf{x}_k}. \quad (4)$$

迭代关系式(3)和(4)构成了最优Bayes解, 但在有限的模型条件下其解析解才存在. 由于直接从后验概率采样的困难, 在 $k - 1$ 时刻, 粒子滤波算法从一个容易采样的重要性分布函数 $q_{k|k}(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{Z}_k)$ 中采样, 独立抽取 N 个样本, 通过式(5)和(6)对粒子进行位置和权值更新, 得到 k 时刻状态的后验概率密度:

$$p_{k|k}(\mathbf{x}_k | \mathbf{Z}_k) \approx \sum_{i=1}^N \omega_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i). \quad (5)$$

其中权值 ω_k^i 计算公式为

$$\omega_k^i = \omega_{k-1}^i \frac{p_{k|k}(\mathbf{z}_k | \mathbf{x}_k^i) p_{k|k-1}(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q_{k|k}(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{Z}_k)}, \quad (6)$$

$$\tilde{\omega}_k^i = \omega_k^i / \sum_{i=1}^N \omega_k^i. \quad (7)$$

3) 退化检测和重采样. 通过公式(8)计算 N_{eff} :

$$N_{\text{eff}} = 1 / \sum_{i=1}^N (\tilde{\omega}_k^i)^2. \quad (8)$$

如果 $N_{\text{eff}} \ll N$, 则代表粒子严重退化, 需要重采样. 重采样过程中, 权值低的样本被淘汰, 而权值高的粒子被复制, 保持粒子数目不变. 重采样后的粒子和权值用 $\{\hat{\mathbf{x}}_k^i, \hat{\omega}_k^i\}_{i=1}^N$ 表示.

4) 估计状态信息.

$$\hat{\mathbf{x}}_k \approx \sum_{i=1}^N \hat{\omega}_k^i \hat{\mathbf{x}}_k^i. \quad (9)$$

若达到估计步数, 则停止; 否则, 转2).

3 基于信息分享机制的粒子滤波方法(Particle filter method based on information-shared mechanism)

为改善粒子分布, 加速粒子集的收敛, 文献[19]在序贯重要性采样后引入粒子群算法, 调节先验粒子向高似然区域移动, 使得粒子主要分布于高似然区域, 以利于提高系统状态的推理精度. 但是粒子算法存在早熟现象, 使得粒子分布过于集中, 粒子多样性下降. 为此, 本文提出了一种基于信息分享机制的粒子滤波方法, 既吸收了粒子群算法的优点, 使粒子向高似然区域运动, 又通过信息分享机制充分利用粒子之间的信息, 弥补粒子群算法的早熟现象, 保持粒子的多样性, 提高粒子滤波的状态估计性能.

3.1 信息分享矩阵的构造(Construction of information-shared matrix)

信息分享矩阵由环境信息分享矩阵和位置信息

分享矩阵组成,其构造方式如图1所示.

图1(a)是环境信息分享矩阵,矩阵各元素表示粒子的似然度.该矩阵的规模为 $2 \times N$,其中 N 为粒子的个数.矩阵第1行 $u_1^1, u_1^2, \dots, u_1^N$ 存储的是粒子和当前全局最优粒子之间产生的似然度信息,第2行 $u_2^1, u_2^2, \dots, u_2^N$ 存储的是粒子和个体历史最优粒子之间产生的似然度信息.

图1(b)是位置信息分享矩阵,矩阵元素保存的是全局最优粒子和历史最优粒子的位置信息.该矩阵的规模也是 $2 \times N$,其中第1行 $v_1^1, v_1^2, \dots, v_1^N$ 存储的是当前全局最优粒子的位置信息,第2行 $v_2^1, v_2^2, \dots, v_2^N$ 存储的是粒子个体历史最优值的位置信息.

因此,可以看到,粒子具有两种类型的信息,一种是环境信息,一种是位置信息,信息分享矩阵的作用就是提供了这两种信息交流的平台.

	1	2	3	...	$N-1$	N
1	u_1^1	u_1^2	u_1^3	...	u_1^{N-1}	u_1^N
2	u_2^1	u_2^2	u_2^3	...	u_2^{N-1}	u_2^N

(a) 环境信息分享矩阵 u

	1	2	3	...	$N-1$	N
1	v_1^1	v_1^2	v_1^3	...	v_1^{N-1}	v_1^N
2	v_2^1	v_2^2	v_2^3	...	v_2^{N-1}	v_2^N

(b) 位置信息分享矩阵 v

图1 信息分享矩阵的构造方式

Fig. 1 The construction of information-shared matrix

3.2 信息分享矩阵的更新(Updating of information-shared matrix)

信息分享机制的引入,主要起到粒子之间信息交流的媒介作用,也就是粒子应该在信息分享矩阵中留存信息,然后根据信息分享矩阵中的信息引导粒子位置的更新.根据这一特点,本节的信息分享矩阵的更新,主要是指粒子在信息分享矩阵中留存信息的方式.

环境信息更新如式(10)(11)所示:

$$u_{1,k}^j = u_{1,k}^j + \text{randn}(1) \times (F(x_k^j) - F(p_k^g)), \quad (10)$$

$$u_{2,k}^j = u_{2,k}^j + \text{randn}(1) \times (F(x_k^j) - F(p_k^j)). \quad (11)$$

其中: $j = 1, 2, \dots, N$; $u_{1,k}^j$ 表示 k 时刻环境信息分享矩阵的第1行第 j 个粒子; $u_{2,k}^j$ 表示 k 时刻环境信息分享矩阵的第2行第 j 个粒子; $F(x_k^j)$ 表示 k 时刻第 j 个粒子的似然度; $F(p_k^g)$ 表示 k 时刻全局最优粒子的似然度; $F(p_k^j)$ 表示 k 时刻第 j 个粒子的个体历史最优

粒子的似然度; $\text{randn}(1)$ 表示产生满足标准正态分布的一个随机数.

位置信息更新如式(12)和(13)所示:

$$v_{1,k}^j = v_{1,k}^j + \tau_1 \times \text{randn}(1) \times (p_k^g - x_k^j), \quad (12)$$

$$v_{2,k}^j = v_{2,k}^j + \tau_1 \times \text{randn}(1) \times (p_k^j - x_k^j). \quad (13)$$

其中: $v_{1,k}^j$ 表示 k 时刻位置信息分享矩阵的第1行第 j 个粒子; $v_{2,k}^j$ 表示 k 时刻位置信息分享矩阵的第2行第 j 个粒子; x_k^j 表示 k 时刻第 j 个粒子位置; p_k^g 为 k 时刻全局最优粒子; p_k^j 为第 j 个粒子的历史最优粒子; τ_1 为权重参数.

在计算粒子的个体历史最优值时,计算量会随着历史时刻的增多而增加.本文为了减少计算量,历史时刻选取当前时刻的前30个时刻,这里的30是经验值.

3.3 基于信息分享机制的粒子位置更新 (Updating of particle location with information-shared matrix)

当信息分享矩阵更新完毕后,本文将利用信息分享矩阵引导粒子位置的更新.由于信息的类型不同,一种是环境信息,另一种是位置信息,需要将这两种类型的信息融合.按照式(14)~(16)对信息分享矩阵中的位置信息和环境信息进行融合.

$$t_{1,k}^j = \text{randn}(1)/u_{1,k}^j + v_{1,k}^j, \quad (14)$$

$$t_{2,k}^j = \text{randn}(1)/u_{2,k}^j + v_{2,k}^j, \quad (15)$$

$$x_k^j = c_1 \times t_{1,k}^j + c_2 \times t_{2,k}^j. \quad (16)$$

其中: x_k^j 表示 k 时刻第 j 个粒子位置; c_1, c_2 为权重参数,满足 $c_1 + c_2 = 1$.

3.4 算法流程(Flowchart of algorithm)

如上所述,利用了粒子群全局最优、个体历史最优的思想和蚁群算法的信息分享机制,提出了一种基于信息分享机制的粒子滤波算法,它的基本步骤如下所示:

Step 0 初始化(当 $k = 0$ 时).

1) 初始化粒子滤波器. 根据先验 $x_0^i \rightarrow p(x_0)$ 采样 N 个样本, 0时刻第 i 个粒子的重要性权值 $\omega_0^i = 1/N$;

2) 在 $[0, 1]$ 范围内随机初始化环境信息分享矩阵,将位置信息分享矩阵初始化为零矩阵;

3) 局部最优粒子为每个粒子的初始化粒子,全局最优粒子为局部最优粒子中权值最大的一个.

Step 1 预测(当 $k \geq 1$ 时).

根据状态方程预测粒子位置 $\{x_k^i\}_{i=1}^N$.

Step 2 基于信息分享机制的粒子更新.

- 1) 计算粒子的似然度 $F(*)$;
- 2) 存储粒子的全局最优粒子 p_g^k 和似然度 $F(p_g^k)$;
- 3) 存储每个粒子的历史最优粒子 p_k^j 和似然度 $F(p_k^j)$;
- 4) 利用式(10)~(13)更新环境信息分享矩阵和位置信息分享矩阵;
- 5) 根据式(14)~(16)对粒子位置进行更新, 得到新的粒子集 $\{\tilde{x}_k^i\}_{i=1}^N$;
- 6) 对新的粒子集进行权值更新和归一化处理, 得到 $\tilde{p}_{k|k}(\mathbf{x}_k|\mathbf{Z}_k) \approx \sum_{i=1}^N \tilde{\omega}_k^i \delta(\mathbf{x}_k - \tilde{\mathbf{x}}_k^i)$.

Step 3 重采样.

为了解决粒子滤波的退化问题, 需要选择和复制权值较大的粒子, 对粒子集进行重采样, 得到新的粒子集 $\{x_k^i\}_{i=1}^N$:

$$p_{k|k}(\mathbf{x}_k|\mathbf{Z}_k) \approx \sum_{i=1}^N \omega_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i).$$

Step 4 $k = k + 1$, 返回到Step1.

4 收敛性分析(Convergence analysis)

收敛性是粒子滤波算法至关重要的一个问题, 下面从状态估计均方误差和经验测度两方面来考查基于信息分享机制的粒子滤波算法的收敛性.

假设 $B(\mathbb{R}^d)$ 表示 \mathbb{R}^d 上的有界函数空间(其中 d 为系统状态向量维数), $C_b(\mathbb{R}^d)$ 为 \mathbb{R}^d 上的连续有界函数空间, 并定义

$$\|\varphi\| = \sup_{x \in \mathbb{R}^d} |\varphi(x)|. \quad (17)$$

如果内积 $\langle \cdot, \cdot \rangle$ 中的密度函数是离散时, 定义求和内积, 即

$$\langle p_k^N, \varphi \rangle = \sum_{i=1}^N \omega_k^{(i)} \varphi(x_k^{(i)}). \quad (18)$$

4.1 状态估计均方误差的收敛性(Convergence of the mean square error of state estimation)

引理 1 假设对于任意有界函数 φ , 存在 $c_{0|0}$ 使式(19)成立(Step 0).

$$E[(\langle p_0^N, \varphi \rangle - \langle p_0, \varphi \rangle)^2] \leq c_{0|0} \frac{\|\varphi\|^2}{N}. \quad (19)$$

引理 2 假设对于任意有界函数 φ , 有

$$E[(\langle p_{k-1|k-1}^N, \varphi \rangle - \langle p_{k-1|k-1}, \varphi \rangle)^2] \leq c_{k-1|k-1} \frac{\|\varphi\|^2}{N}, \quad (20)$$

则经过 Step 1(预测)后, 存在任意一个常数 $c_{k|k-1}$, 有

$$E[(\langle p_{k|k-1}^N, \varphi \rangle - \langle p_{k|k-1}, \varphi \rangle)^2] \leq c_{k|k-1} \frac{\|\varphi\|^2}{N}. \quad (21)$$

引理 3 假设对于任意有界函数 φ , 有

$$E[(\langle p_{k|k-1}^N, \varphi \rangle - \langle p_{k|k-1}, \varphi \rangle)^2] \leq c_{k|k-1} \frac{\|\varphi\|^2}{N}, \quad (22)$$

则经过 Step 2(更新)后, 存在任意一个常数 $\tilde{c}_{k|k}$ 有

$$E[(\langle \tilde{p}_{k|k}^N, \varphi \rangle - \langle p_{k|k}, \varphi \rangle)^2] \leq \tilde{c}_{k|k} \frac{\|\varphi\|^2}{N}. \quad (23)$$

引理 4 假设对于任意有界函数 φ , 有

$$E[(\langle \tilde{p}_{k|k}^N, \varphi \rangle - \langle p_{k|k}, \varphi \rangle)^2] \leq \tilde{c}_{k|k} \frac{\|\varphi\|^2}{N}, \quad (24)$$

则经过 Step 3(重采样)后, 存在任意一个常数 $c_{k|k}$, 有

$$E[(\langle p_{k|k}^N, \varphi \rangle - \langle p_{k|k}, \varphi \rangle)^2] \leq c_{k|k} \frac{\|\varphi\|^2}{N}. \quad (25)$$

引理2~4的证明见文献[20].

定理 1 如果 p_k 是时刻 k 的后验分布, 对于任何有界函数 φ , 存在一个常数 $c_{k|k}$, 使得

$$E[(\langle p_{k|k}^N, \varphi \rangle - \langle p_{k|k}, \varphi \rangle)^2] \leq c_{k|k} \frac{\|\varphi\|^2}{N}. \quad (26)$$

证 根据引理2~4, 采用了和文献[20]相似的步骤可以得到定理1, 故定理1得以证明. 定理1表明基于信息分享机制的粒子滤波算法的收敛率为 $1/N$, 且独立于状态空间的维数.

4.2 经验测度的收敛性(Convergence of empirical measures)

为了证明经验分布收敛于真正的分布, 需要考查其经验测度的收敛性. 令 u^N 和 u 是 \mathbb{R}^d 上的概率测度, φ 为任意有界函数. 假如 u^N 是测量序列, u^N 弱收敛到 u 的条件是

$$\lim_{N \rightarrow \infty} \langle \mu^N, \varphi \rangle = \langle \mu, \varphi \rangle. \quad (27)$$

引理 5 假设 $p_{k-1|k-1}^N$ 几乎必然收敛于其真值 $p_{k-1|k-1}$, 即 $\lim_{N \rightarrow \infty} p_{k-1|k-1}^N = p_{k-1|k-1}$, 则经过Step1(预测)后, 有 $\lim_{N \rightarrow \infty} p_{k|k-1}^N = p_{k|k-1}$.

引理 6 假设 $p_{k|k-1}^N$ 几乎必然收敛于其真值 $p_{k|k-1}$, 即 $\lim_{N \rightarrow \infty} p_{k|k-1}^N = p_{k|k-1}$, 则经过Step2(更新)后, 有 $\lim_{N \rightarrow \infty} \tilde{p}_{k|k}^N = \tilde{p}_{k|k}$.

引理 7 假设 $\tilde{p}_{k|k}^N$ 几乎必然收敛于其真值 $\tilde{p}_{k|k}$, 即 $\lim_{N \rightarrow \infty} \tilde{p}_{k|k}^N = \tilde{p}_{k|k}$, 则经过Step 3(重采样)后, 有 $\lim_{N \rightarrow \infty} p_{k|k}^N = p_{k|k}$.

引理5~7的证明见文献[20].

定理 2 对所有 $k \geq 0$, $p_{k|k}^N$ 几乎必然收敛于其真值 $p_{k|k}$, 即 $\lim_{N \rightarrow \infty} p_{k|k}^N = p_{k|k}$.

证 根据引理5~7, 采用和文献[20]相似的步骤

可以得到定理2, 故定理2得以证明. 定理2说明粒子数趋于无穷时, 滤波后验密度估计是弱收敛的.

5 ISM-PF算法在视觉跟踪中的应用(ISM-PF application to visual tracking)

目标跟踪是计算机视觉的核心问题之一, 在智能监控、人机交互、医学诊断、机器人导航以及精确制导武器等众多领域有重要的实用价值和广阔的发展前景^[21]. 本文把基于信息分享机制的粒子滤波方法应用到目标跟踪, 并与基本粒子滤波、基于粒子群优化的粒子滤波方法^[19]进行比较, 以验证本文所提算法的有效性.

5.1 视觉跟踪算法实现(Implementation of visual tracking method)

本文通过矩形框来定位目标, 因此状态参数应包括矩形的中心点位置 x, y 和矩形的宽度 c_x 和高度 c_y , 状态向量 $\mathbf{x} = (x, y, c_x, c_y)$. 采用布朗运动模型, 即

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \mathbf{v}_{k-1}. \quad (28)$$

其中 \mathbf{v}_{k-1} 表示 $k-1$ 时刻的系统噪声矩阵.

每个粒子通过状态方程进行传递后, 必须根据粒子的似然性来确定权重, 粒子的权重可通过下式计算:

$$\omega = F(O). \quad (29)$$

其中候选区域 O 指以当前粒子位置 (x, y) 为中心, 以 c_x 和 c_y 为长和宽的矩形区域, $F(O)$ 由式(30)获得:

$$F(O) = \frac{1}{\sqrt{2\pi}\sigma_c} \exp\left(-\frac{d_c^2}{2\sigma_c^2}\right). \quad (30)$$

其中 d_c 为巴特查里亚(Bhattacharyya)距离.

$$d_c = \sqrt{1 - \rho[p, q]}. \quad (31)$$

$$\rho[p, q] = \sum_{u=1}^m \sqrt{p^{(u)}q^{(u)}}. \quad (32)$$

其中: $p = \{p^{(u)}\}_{u=1,2,\dots,m}$ 为粒子区域 O 的颜色直方图; $q = \{q^{(u)}\}_{u=1,2,\dots,m}$ 为目标颜色直方图; ρ 称为Bhattacharyya系数, ρ 越大, 说明粒子区域和目标区域的相似度越高. 式(10)和(11)中的似然函数通过式(30)计算.

5.2 单目标跟踪实验(Single object tracking experiment)

本实验为典型办公室环境下的视频序列, 图像大小为 128×96 , 只有一个被跟踪目标. 对这一序列目标跟踪的困难在于目标经历了光照变化、由于头部旋转而导致的视角变化等情况. 实验中的粒子数目为10. 其他参数如下 $c_1 = 0.8$, $c_2 = 0.2$, $\tau_1 = 0.1$, $\sigma_c = 0.03$.

图2显示了用3种滤波方法得到的目标跟踪结果, 从上到下依次为第5, 24, 45, 101, 142帧的跟踪结果. 其中第1列为PF的跟踪结果, 第2列为PSO-PF的跟踪结果, 第3列是ISM-PF的跟踪结果.



图2 单目标跟踪结果

Fig. 2 Tracking results of single object

从第1列可以看出, 在用较少的粒子跟踪目标时, PF方法跟踪窗口大多是偏离的, 跟踪正确率低, 原因在于基本粒子滤波方法粒子位置更新时没有机制引导, 一般需要大量的粒子才能得到较好的估计.

第2列是PSO-PF的跟踪结果, 从中可知, 该方法也能用较少的粒子得到较好的估计, 但是该方法容易陷入局部最优, 因为粒子更新受粒子全局最优值和每个粒子局部最优值的引导, 所以粒子比较集中的分布在目标中心, 如果目标移动较快, 该方法就不能迅速地跟踪上目标, 如图中的第45, 101, 142帧窗口偏离程度较大.

第3列是ISM-PF的跟踪结果, 粒子更新时, 考虑到粒子全局最优值和局部最优值的影响, 还考虑到其他粒子留下的环境信息和位置信息, 可以弥补基于粒子群优化的粒子滤波方法的陷入局部最优缺陷, 第3列中所示的各帧中跟踪窗口基本正确, 验证了本文方法的有效性.

表1显示了单目标跟踪实验中3种方法的运行时间, 其中PF方法单帧平均运行时间最短, ISM-PF其次, PSO-PF方法时间最长. 原因在于PSO-PF方法, 在计算粒子个体历史最优值时, 会随着历史时刻的增多计算量增大. 而本文方法在计算粒子个体最优值

时, 只计算最近30个历史时刻, 计算量不会随着历史时刻的增多而膨胀, 所以单帧运行时间要比PSO-PF少. 而PF方法, 虽然单帧运行时间较短, 但在较少的粒子下, 跟踪效果较差. 统观表1和图2, 本文方法的综合跟踪性能要优于其它两种方法.

表 1 单目标跟踪中3种方法运行时间比较

Table 1 Comparison of running time of three methods for single object tracking

跟踪方法	总帧数	单帧时间/ms
PF	150	4.5
PSO-PF	150	93
ISM-PF	150	29

5.3 多目标跟踪实验(Multi-object tracking experiment)

对于多目标跟踪, 由于目标之间会造成干扰, 因此比单目标跟踪要复杂. 把本文所提算法用到多目标跟踪, 原因在于本文所提算法能用较少的粒子得到较好的估计性能, 用于多目标跟踪中能减少计算量, 提高跟踪效率. 此序列图像大小 480×410 , 目的要跟踪两个网球运动员, 跟踪难度在于网球运动员运动较快. 实验中的粒子数目为10. 其他参数如下:

$$c_1 = 0.8, c_2 = 0.2, \tau_1 = 0.1, \sigma_c = 0.03.$$

图3显示了用3种滤波方法得到的目标跟踪结果, 从上到下依次为第24, 67, 128, 154, 203, 245帧的跟踪结果. 同样第1列为PF的跟踪结果, 第2列为PSO-PF的跟踪结果, 第3列是本ISM-PF的跟踪结果. 从图中可以看出, PF方法从第67帧开始跟丢目标, 跟踪正确率低. PSO-PF方法从第128帧开始, 其中一个运动员打球速度突然提高, 目标跟踪失败, 直到运动员出现在粒子窗口附近, 才恢复正确跟踪目标. 而本文方法, 都能正确的跟踪目标.

表2给出了多目标跟踪实验中3种方法的运行时间比较. 表2和图3, 同样显示了本文算法的综合跟踪性能最优.

表 2 多目标跟踪中3种方法运行时间比较

Table 2 Comparison of running time of three methods for multi-object tracking

跟踪方法	总帧数	单帧时间/ms
PF	265	54
PSO-PF	265	324
ISM-PF	265	87

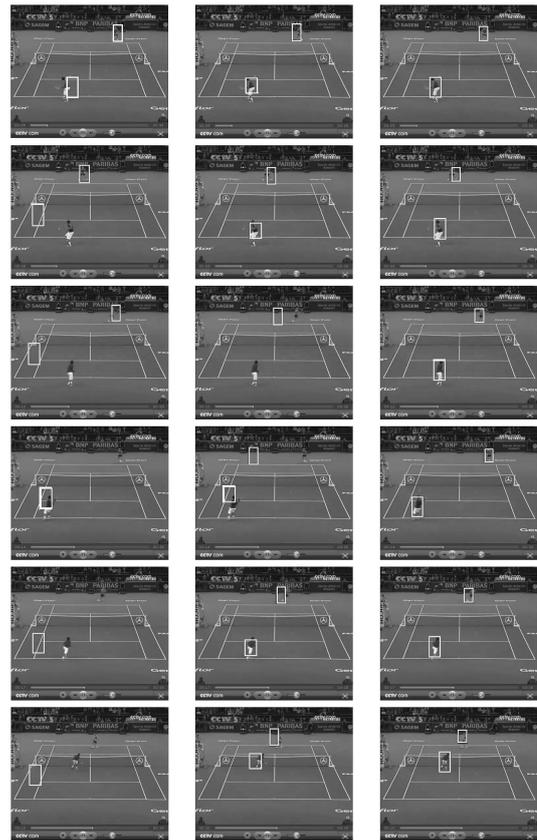


图 3 多目标跟踪结果

Fig. 3 Tracking results of multi-object

5.4 统计实验结果比较(Comparison of statistical experiment results)

为了进一步验证本文算法的稳定性和有效性, 本实验在相同条件下, 把5.2节和5.3节中的实验重复100次, 粒子数同样为10个, 然后统计跟踪正确率.

表3为单目标跟踪统计结果, 基于肤色特征的目标跟踪, 当人脸完全背过去的时候, 目标的颜色完全发生变化, 会导致跟踪失败, 本文所提方法的跟踪正确率为92.3%, 远远高于PF和PSO-PF方法.

表 3 单目标跟踪正确率比较

Table 3 Comparison of accurate rate for single object tracking

跟踪方法	实验次数	总帧数	正确跟踪率/%
PF	100	150	39.3
PSO-PF	100	150	77.3
ISM-PF	100	150	92.3

表4为多目标跟踪的统计结果, PF方法若仅用10个粒子进行跟踪, 效果很差, 跟踪正确率仅为14.7%, PSO-PF方法利用了粒子的局部和全局最优信息, 正确跟踪率达到86.4%, 而本文方法在PSO基础上, 再

结合粒子之间的信息分享,进一步提高了跟踪性能,正确跟踪率为96.3%。

表4 多目标跟踪正确率比较

Table 4 Comparison of accurate rate for multi-object tracking

跟踪方法	实验次数	总帧数	正确跟踪率/%
PF	100	265	14.7
PSO-PF	100	265	86.4
ISM-PF	100	265	96.3

总之,从表3和表4统计结果可知,在较少粒子情况下,本文所提方法的正确跟踪率明显优于PF和PSO-PF方法。

6 结论(Conclusions)

本文通过分析基本粒子滤波方法存在的退化和计算效率问题,将粒子群优化算法和蚁群优化算法的思想引入到粒子滤波中,提出了一种基于信息共享机制的粒子滤波算法。该方法将粒子群优化算法的全局最优粒子、个体粒子历史最优的概念和蚁群优化算法的信息分享机制相结合。由于信息共享机制的引入,使得粒子之间的信息交流更加充分,提高了粒子滤波最优估计能力。最后通过视觉跟踪实验,分别用于单目标、多目标跟踪中,均能用较少的粒子达到了较好的跟踪性能,验证了本文方法较好的估计性能,也验证了信息的充分分享对于粒子滤波的预估能力起到了良好的作用。

参考文献(References):

- [1] LIU J S, CHEN R. Sequential Monte Carlo methods for dynamic systems[J]. *Journal of the American Statistical Association*, 1998, 93(443): 1032 – 1044.
- [2] 杨小军, 潘泉, 王睿. 粒子滤波进展与展望[J]. *控制理论与应用*, 2006, 23(2): 261 – 267.
(YANG Xiaojun, PAN Quan, WANG Rui. Development and prospect of particle filtering[J]. *Control Theory & Applications*, 2006, 23(2): 261 – 267.)
- [3] MICHAEL K P, NEIL S. Filtering via simulation: auxiliary particle filters[J]. *Journal of the American Statistical Association*, 1999, 94(2): 590 – 599.
- [4] JOHNSTON C M, MOULD N, HAVLICEK J P, et al. Dual domain auxiliary particle filter with integrated target signature update[C] // *Proceedings of IEEE Conference on Computer Vision and Pattern*. Miami, Florida, USA: IEEE Computer Society, 2009: 54 – 59.
- [5] CHEN Z, HAYKIN S. On different facets of regularization theory[J]. *Neural Computation*, 2002, 14(12): 2791 – 2846.
- [6] ANTONACCI F, MATTEUCCI M, MIGLIORE D. Tracking multiple acoustic sources in reverberant environments using regularized particle filter[C] // *Proceedings of International Conference on Digital Signal Processing*. Wales, United Kingdom: IEEE Computer Society, 2007: 99 – 102.
- [7] FOX D. Adapting the sample size in particle filters through KLD-sampling[J]. *The International Journal of Robotics Research*, 2003, 22(12): 985 – 1003.

- [8] LIANG Z, MA X, DAI X. Robust tracking of moving sound source using scaled unscented particle filter[J]. *Applied Acoustics*, 2008, 69(8): 673 – 680.
- [9] SONG C, ZHAN H, JING W. A New Particle Swarm Optimization Based Unscented Particle Filtering [C] // *Proceedings of the 3rd International Conference on Bioinformatics and Biomedical Engineering*. Beijing, China: IEEE Computer Society, 2009: 1 – 4.
- [10] KOTTECHA J H, DJURIC P M. Gaussian particle filtering[J]. *IEEE Transactions on Signal Processing*, 2003, 51(10): 2592 – 2601.
- [11] KOTTECHA J H, DJURIC P M. Blind sequential detection for Rayleigh fading channels using hybrid Monte Carlo-recursive identification algorithms[J]. *Signal Processing*, 2004, 84(5): 825 – 832.
- [12] BHASKAR H, MIHAYLOVA L, MASKELL S. Population based particle filtering[C] // *IET Seminar on Target Tracking and Data Fusion: Algorithms and Applications*. Birmingham, UK: IET, 2008: 29 – 38.
- [13] 方正, 佟国峰, 徐心和. 粒子群优化粒子滤波方法[J]. *控制与决策*, 2007, 22(3): 273 – 277.
(FANG Zheng, TONG Guofeng, XU Xinhe. Particle swarm optimized particle filter[J]. *Control and Decision*, 2007, 22(3): 273 – 277.)
- [14] 张琪, 王鑫, 胡昌华. 人工免疫粒子滤波算法的研究[J]. *控制与决策*, 2008, 23(3): 293 – 301.
(ZHANG Qi, WANG Xin, HU Changhua. Research on artificial immune particle filter[J]. *Control and Decision*, 2008, 23(3): 293 – 301.)
- [15] DORIGO M, MANIEZZO V, COLORNI A. Ant system: optimization by a colony of cooperating agents[J]. *IEEE Transaction on System, Man, and Cybernetics-Part B*, 1996, 26(1): 29 – 41.
- [16] DORIGO M, BLUM C. Ant colony optimization theory: a survey[J]. *Theoretical Computer Science*, 2005, 344(2/3): 243 – 278.
- [17] 吕强, 刘士荣, 邱雪娜. 基于信息素机制的粒子群优化算法的设计与实现[J]. *自动化学报*, 2009, 35(11): 1410 – 1419.
(LÜ Qiang, LIU Shirong, QIU Xuena. Design and realization of particle swarm optimization based on pheromone mechanism[J]. *Acta Automatica Sinica*, 2009, 35(11): 1410 – 1419.)
- [18] CZYZ J, RISTIC B, MACQ B. A particle filter for joint detection and tracking of color objects[J]. *Image and Vision Computing*, 2007, 25(8): 1271 – 1281.
- [19] 方正, 佟国峰, 徐心和. 基于粒子群优化的粒子滤波定位方法[J]. *控制理论与应用*, 2008, 25(3): 533 – 537.
(FANG Zheng, TONG Guofeng, XU Xinhe. A localization method for particle-filter based on the optimization of particle swarm[J]. *Control Theory & Applications*, 2008, 25(3): 533 – 537.)
- [20] DAN C, ARNAUD D. A survey of convergence results on particle filtering methods for practitioners[J]. *IEEE Transactions on Signal Processing*, 2002, 50(3): 736 – 746.
- [21] 侯志强, 韩崇昭. 视觉跟踪技术综述[J]. *自动化学报*, 2006, 32(4): 603 – 617.
(HOU Zhiqiang, HAN Chongzhao. A survey of visual tracking[J]. *Acta Automatica Sinica*, 2006, 32(4): 603 – 617.)

作者简介:

邱雪娜 (1978—), 女, 博士研究生, 目前研究方向为机器视觉、智能机器人, E-mail: qiuxn26@hotmail.com;

刘士荣 (1952—), 男, 教授, 博士生导师, 目前研究方向为复杂系统建模与控制、智能机器人与智能系统, E-mail: liushirong@hdu.edu.cn;

吕强 (1977—), 男, 博士, 讲师, 目前研究方向为智能移动机器人的导航与控制, E-mail: lvqiang@hdu.edu.cn.