

基于局部粒子密度的粒子滤波跟踪方法

张 继^{1,2}, 王洪元^{1,2}

(1 常州大学 信息科学与工程学院, 江苏 常州 213164;

2 常州市过程感知与互联技术重点实验室, 江苏 常州 213164)

摘 要: 定义了欧氏空间内的局部粒子密度的概念, 针对四种不同的情况作出分析, 对优选粒子的优劣作出评价并指导后续的粒子重采样和模板更新过程, 并在此基础上给出了一种新的基于局部粒子密度的目标跟踪方法. 比较实验显示, 相对于原始粒子滤波方法和其他粒子重要性重采样方法, 该方法在保证跟踪有效性的同时, 提高了跟踪效率.

关键词: 粒子滤波; 局部粒子密度; 视频目标跟踪; 重采样; 模板更新

中图分类号: TP391

文献标识码: A

文章编号: 1000—7180(2012)03—0093—05

A Novel Particle Filtering Tracking Method Based on the Local Density of Particles

ZHANG Ji^{1,2}, WANG Hong-yuan^{1,2}

(1 School of Information Science and Engineering, Changzhou University, Changzhou 213164, China;

2 Changzhou Key Laboratory for Process Perception and Interconnected Technology, Changzhou 213164, China)

Abstract: In this paper, we definite the conception, local density of particles in Euclidean Space, firstly. Then, take the scores of particles with the conception, and give four different cases to analysis the following procedure of particles re-sampling and model updating, and a novel particle filtering tracking method is proposed. Finally, experimental results show the efficiency and robustness of the proposed method.

Key words: particle filtering; local density of particles; video tracking; re-sampling; model updating

1 引言

近年来, 粒子滤波 PF 算法^[1]已成为目标跟踪领域的一种常用算法. 作为一种基于贯序蒙特卡洛方法的概率模型框架, 其思想是通过随机采样获取大量粒子, 然后将这些粒子在贝叶斯框架下近似状态变量的后验分布. 粒子滤波算法对于高度非线性系统能够取得较好的滤波效果, 但容易出现粒子多样性匮乏问题. 基于粒子重要性的重采样算法是缓解粒子多样性匮乏问题的一种有效方法^[1], 其思想是: 通过对粒子及其对应的权值进行重新采样, 以增加权值较大的粒子数. 最常用的重要性重采样方法

是随机采样, 其特点是: (1) 重采样的粒子总数与初始化粒子总数相同, 因此计算效率较低; (2) 权值较大的粒子被多次复制. 近几年, 有学者使用进化的方法(如粒子群优化 PSO 方法)来辅助粒子重采样^[2], 取得了较好的跟踪效果, 但由于是在大量粒子上实施进化, 计算复杂度很高, 且绝大多数粒子滤波算法没有提供确定性的信息指导目标模板的更新.

本文通过引入粒子密度的概念, 根据优选粒子的密度信息来确定如何实施样本重采样与目标模板的更新. 在解决粒子多样性匮乏问题的同时回避了需要大量粒子参与重要性重采样所带来的计算效率低的问题, 又确定性地给出了何时需要更新模板而

收稿日期: 2011—07—11; 修回日期: 2011—08—10

基金项目: 国家自然科学基金项目(61070121, 60973094); 江苏省自然科学基金项目(BK2009538); 江苏省产学研前瞻性联合研究项目(BY2009117)

何时不必更新,从而在保证跟踪可靠性的前提下进一步减少了算法的时间消耗。

2 基于粒子滤波的目标跟踪

2.1 基于粒子滤波的目标跟踪

假设视频目标的跟踪满足一阶马尔可夫模型,即某一时刻目标的状态仅与上一时刻该目标的状态有关。由于视频目标跟踪问题是一个高度非线性问题,因此该动态系统的状态方程(1a)式和观测方程(1b)式分别为:

$$x_t = f(x_{t-1}, w_t) = f(x_{t-1}) + w_t \quad (1a)$$

$$y_t = h(x_t, v_t) = h(x_t) + v_t \quad (1b)$$

其中, x_t 代表由 t 时刻目标的状态, y_t 是目标的观测, w_t 和 v_t 分别是系统噪声和观测噪声,且一般认为都是加性的高斯白噪声。粒子滤波算法可以分为预测和更新两个步骤:

$$p(x_t | y_{1:t-1}) = \int p(x_t | x_{t-1}) p(x_{t-1} | y_{1:t-1}) dx_{t-1} \quad (2)$$

$$p(x_t | y_{1:t}) = p(y_t | x_t) p(x_t | y_{1:t-1}) / K \quad (3)$$

其中, $K = \int p(y_t | x_t) p(x_t | y_{1:t-1}) dx_t$ 是归一化常数。基于粒子滤波的跟踪就是在此基础上提出的^[1]。

2.2 基于区域协方差描述子的粒子滤波跟踪框架

在区域协方差矩阵特征描述子^[2]的基础上,文献^[3]提出了基于区域协方差描述子的粒子滤波跟踪方法。将视频序列中目标的各种形变假设为服从仿射变换的形变,即将表示目标的状态和位置的粒子记作一个仿射变换矩阵 $S = (x, y, s_x, s_y, t_x, t_y)$, 其中 (x, y) 代表目标的位移, (s_x, s_y) 表示目标水平和垂直方向的尺度变化, (t_x, t_y) 表示目标水平和垂直方向的错切变化。基于该 6 维仿射变换参数与初始化目标区域大小,可以获取某帧图像中的一块候选区域,再对这个区域提取特征,即可将仿射变换应用于粒子滤波目标跟踪框架中(具体实现时有一些变化,详见文献^[4])。

2.3 区域协方差特征描述子

在 2.2 节所述的基于区域协方差特征描述子的粒子滤波跟踪方法中,图像中某个区域特征的提取是其关键。这种基于区域协方差矩阵 RCM 的特征描述子是由 Tuzel 提出的^[3]。基于积分图像的概念,该算法能够在极短时间内(几毫秒)计算图像中大量区域的、由多种信息(如坐标、颜色、梯度等)融合而

成的 RCM,具体方法见文献^[4]。该特征描述子的高效提取确保了基于其衍生的跟踪方法的高效性。对于每一帧图像,本文基于特征 $f_k = [x, y, I, |g_{L_x}|, |g_{L_y}|, |g_{L_{xx}}|, |g_{L_{yy}}|]$ 提取灰度图像的 7 维 RCM 特征,其中 (x, y) 表示二维坐标,后 5 维分别表示图像在 (x, y) 处的灰度值、沿 x 方向梯度幅值、沿 y 方向梯度幅值、沿 x 方向二阶梯度幅值、沿 y 方向二阶梯度幅值。彩色图像的特征亦可与之类似提取。

2.4 对称正定流形上的距离度量

根据定义易知^[3],按照 2.3 节的方法提取的区域协方差矩阵 RCM 都是对称正定阵,都落在对称正定(symmetric positive definite, SPD)空间内。在定义了合理的乘法和数乘之后,该空间构成了 SPD 流形。记 Sym_n 是 n 阶实对称阵空间, Sym_n^+ 是 n 阶实对称正定阵空间, GL_n 是 n 阶实可逆矩阵的群, M_n 是 $n \times n$ 的实矩阵空间。基于常用的矩阵加法和数乘的定义易证, Sym_n 构成向量空间,但 Sym_n^+ 不构成向量空间。两者通过矩阵指数映射和对数映射一一对应,即 $\forall A \in Sym_n^+, B \in Sym_n$, 有:

$$\log m(A) \in Sym_n, \exp m(B) \in Sym_n^+ \quad (4)$$

其中, $\log m$ 和 $\exp m$ 分别代表矩阵对数和矩阵指数。矩阵对数 $\log m(S) := U \cdot \text{diag}(\log(d)) \cdot U^T$, U 和 λ 是 S 的本征向量及其对应的本征值, $\text{diag}(\log(\lambda))$ 是以 $\log(\lambda)$ 为对角线元素的对角阵, $\log$ 是自然对数;类似地可以定义矩阵指数 $\exp m(S) := U \cdot \text{diag}(\exp(\lambda)) \cdot U^T$ 。在 SPD 流形上赋予不同的黎曼度量可以定义不同的 SPD 黎曼流形,常用的 SPD 流形上的黎曼度量有仿射不变度量和对数-欧氏度量^[3]。这里只介绍后文中将使用的对数-欧氏度量。

对于 $\forall S_1, S_2 \in Sym_n^+$, Arsigny ^[5] 定义了满足乘法交换律的对数乘法算子 $\odot$:

$$S_1 \odot S_2 := \exp m(\log m(S_1) + \log m(S_2)) \quad (5)$$

Arsigny 还证明了 $(Sym_n^+, \odot)$ 是李群,且映射 $\exp m: (Sym_n, +) \rightarrow (Sym_n^+, \odot)$ 是李群同构,其逆映射 $\log m: (Sym_n^+, \odot) \rightarrow (Sym_n, +)$ 也是李群同构。其上的距离度量定义如下:

$$d^2(S_1, S_2) = \|\log m(S_1) - \log m(S_2)\|_F^2 = \text{tr}((\log m(S_1) - \log m(S_2))^2) \quad (6)$$

该度量称为对数-欧氏(Log-Euclidean)度量^[6],其主要思想是:通过矩阵对数算子可以将 SPD 流形上的两个元素映射到向量空间上,再在向量空间上计算两者的欧氏距离。至此,就可以在对称正定流形内(而不是欧氏空间内)计算特征之间的距离。

3 基于局部粒子密度的粒子滤波目标跟踪方法

为缓解粒子滤波的多样性贫瘠问题,本节使用局部粒子密度的概念进行改进,并在此基础上给出了一种新的目标跟踪方法.

3.1 流形上的对数-欧氏度量向欧氏度量的转换

一般情况下,两个 RCM 特征(d 阶对称正定阵)间的距离可以按照式(6)的方法计算.这里需要将各个 RCM 特征描述为一个列向量的形式.

文献[5]中的处理方法是,对于某个 d 阶对称正定阵 C_i ,先通过矩阵对数映射 $\log m$ 将其映射为对称阵 $\log m(C_i)$,再按列优先拉伸($m=d^2$)维欧氏空间内的列向量 l_i .这种方法破坏了 RCM 特征样本间的几何结构,即若假设 l_1, l_2 分别为 $\log m(C_1)$ 和 $\log m(C_2)$ 拉伸成的 $d^2 \times 1$ 维列向量

$$\|l_1 - l_2\|_2 \neq \|\log m(C_1) - \log m(C_2)\|_F \quad (7)$$

本文借助文献[8]的度量方法,将对称正定流形上的对数-欧氏度量转换为向量空间上的欧氏度量.使得:

$$\begin{aligned} d^2(C_1, C_2) &= \|\log m(C_1) - \log m(C_2)\|_F \\ &= \|c_1 - c_2\|_2 \end{aligned} \quad (8)$$

其中, c_i 是 $L_i = \log m(C_i)$ 的上三角部分

$$L_i^{upper} = \left[\underbrace{L_i^{1,1}, \dots, L_i^{d,d}}_d, \underbrace{L_i^{1,2}, \dots, L_i^{d-1,d}}_m \right]^T \quad (9)$$

与矩阵

$$UT = \left[\underbrace{1, \dots, 1}_d, \underbrace{\sqrt{2}, \dots, \sqrt{2}}_m \right]^T \quad (10)$$

的乘积,即 $c_i = L_i^{upper} \cdot UT$,其中, c_i 的维数为 $d(d+1)/2, i=1, 2$. L_i^{upper} 的前 d 维和后 $m = d(d-1)/2$ 维分别是 L_i 的上三角阵中的对角线元素和非对角线元素.

与将 d 维对称正定阵直接拉成 d^2 维列向量的方法相比,通过该变换可以很好地保持各个特征相互之间的几何结构,同时又降低了特征的维数(前者为 d^2 维,后者为 $d(d+1)/2$ 维).

3.2 基于局部粒子密度的粒子选择与重采样

正如前面提到的,粒子多样性匮乏问题是粒子滤波算法中的一个关键问题.为解决该问题,本节基于局部粒子密度的概念进行粒子重采样.

对于 n 个粒子对应的特征,按照 3.1 节的方法可以将它们描述为 $d(d+1)/2$ 维的列向量.这样,在新帧到达时,就有 $6 \times n$ 大小的状态矩阵 X 及与

之对应的 $d(d+1)/2 \times n$ 大小的观测矩阵 Y .粒子滤波算法就是要在已知当前帧内的状态矩阵及其对应的观测矩阵的前提下,计算目标状态的后验概率.

对于 n 个粒子对应的观测矩阵 Y ,本节使用类似半监督判别分析[8]中定义相似度矩阵的方法,来定义粒子间的局部密度,并以局部密度的概念来指导粒子的选择、重采样与模板更新.

3.2.1 局部粒子密度的定义

定义局部粒子密度,需要借助目标模板的信息,首先定义 $n+1$ 列增广观测矩阵 Y^* 为:

$$Y^* = [Y_{d(d+1)/2 \times n}, M_{d(d+1)/2 \times 1}] \quad (11)$$

按照 3.1 节的方法可以定义 Y^* 中第 i 个粒子和第 j 个粒子间的距离为 $d_{i,j}^2 = d_{j,i}^2 = d^2(Y_i^*, Y_j^*)$,其中,特征 Y_i^* 和特征 Y_j^* 分别是 Y^* 的第 i 列和第 j 列($i, j=1, \dots, n+1$).相似度矩阵定义为:

$$S_{ij} = \begin{cases} \exp\left(-\frac{d_{ij}^2}{2\lambda}\right), & \text{if } Y_j^* \in N_p(Y_i^*) \\ 0, & \text{else} \end{cases} \quad (12)$$

其中, $N_p(Y_i^*)$ 代表粒子 i 的 p 邻域,本文中取 $p=5$.相似度矩阵 S 描述了各粒子间的相似程度.注意到:(1)只有粒子 j 落在粒子 i 的 p 邻域内才计算两者间的相似度,否则为 0(与文献[9]中的定义稍有不同);(2)粒子 j 落在粒子 i 的 p 邻域内与粒子 i 落在粒子 j 的 p 邻域内并不等价,即 S_{ij} 与 S_{ji} 不一定相等,但 d_{ij} 与 d_{ji} 总是相等;(3) $S_{ij} \in [0, 1]$,其值越接近 1 代表粒子 i 和粒子 j 越相似.

由此可见,相似度矩阵 S 的行和 $D_i^r = \sum_j S_{ij}$ 代表了粒子 i 的 p 个邻域粒子与粒子 i 的相似度之和.根据(12)式易知,对相似度矩阵 S 的第 i 行而言,由于只有 $S_{ii}=1$ 和粒子 i 的 p 邻域内的粒子与粒子 i 之间的相似度非零,因此, $D_i^r \in [1, p+1]$,将该值称为粒子 i 的行密度.其值的大小反映了粒子 i 与其附近粒子的局部关系;相似度矩阵 S 的列和 $D_j^c = \sum_i \text{sign}(S_{ij})$ 代表了在粒子集合中以粒子 j 为 p 邻域的粒子数量.根据式(3)知,对第 j 列而言,除了 $S_{jj}=1$ 之外,其余任一个 $\text{sign}(S_{ij})$ ($i=1, \dots, n+1$, 且 $i \neq j$)都有可能取 1,因此 $D_j^c \in \{1, \dots, n+1\}$,将该值称为粒子 j 的列密度.综上所述,将粒子 i 的行密度和列密度统称为粒子 i 的密度;又由于这里计算的是 p 邻域局部结构,因此也称为局部密度.为了符合“密度”的概念,对行密度和列密度分别归一化为 $D_i^r/(p+1)$ 和 $D_j^c/(n+1)$.

3.2.2 基于局部密度的粒子重采样

根据上节定义可知,相似度矩阵 S 的行和 D^r

的最后一行,即模板 M 的行密度 D_{n+1}^r ,给出了在粒子集合中与模板 M 最接近的 p 个粒子及各个粒子与模板间的相似度,其值大小反映了模板 M 周围的粒子密集程度,越接近 $p+1$ 代表模板 M 附近的粒子排列越紧密、距离模板 M 越近;同样的,矩阵 S 的列和 D^c 的最后一列,即模板 M 的列密度 D_{n+1}^c ,统计了 p 邻域中包含模板 M 的粒子数量,其值大小反映了整个粒子集合与模板 M 的接近程度。

这里有四种状态需要讨论:(1)若 $D_{n+1}^r > T_1$, $D_{n+1}^c > T_2$,认为有大量粒子落在模板 M 附近,且这些落在模板 M 附近的粒子都能够较好地描述目标的状态,则无需重采样且无需更新模板,将模板 M 的 p 邻域内粒子作为优选粒子;(2)若 $D_{n+1}^r > T_1$, $D_{n+1}^c \leq T_2$,认为以模板 M 为近邻的粒子较少($D_{n+1}^c \leq T_2$),但这些以模板 M 为近邻的少量粒子至少有几个能够较好地描述目标的状态($D_{n+1}^r > T_1$),此时无需更新模板,但需要对粒子重采样.重采样的方法包括进化算法(如粒子群优化、mean-shift 等)或者在模板 M 的 p 个邻域粒子附近直接重采样(本文使用粒子群优化方法),来改善粒子性能,并将优化结果作为优选粒子;(3)若 $D_{n+1}^r \leq T_1$, $D_{n+1}^c > T_2$,认为有一定数量的粒子以模板 M 为近邻,但是这些粒子与模板 M 仍有一定距离.若 T_2 不是太小,如设置 $T_2=1$ 或 2,出现这种情况的可能性不高,这是由于初始化的粒子是从多维单模高斯分布的方法产生的,粒子集合本身具有一定的聚集性.实验中也验证了这一推断:在所作的所有实验中,均未出现这种情况;(4)若 $D_{n+1}^r \leq T_1$, $D_{n+1}^c \leq T_2$,此时认为模板 M 附近的粒子密度很低且几乎没有粒子能够反映或用于估计目标的真实状态,考虑到一般在跟踪中都假设在相邻帧间目标不会出现太大的位移,也就是说粒子滤波初始化产生的粒子总有至少少量几个落在目标附近.因此,这时认为可能是由于目标出现了较大形变造成模板 M 附近粒子密度很低的结果,此时应更新模板但不重新采样,并将模板 M 的 p 邻域内粒子作为优选粒子。

3.3 模板更新策略

根据 3.2.2 节的描述,只有当 $D_{N+1}^r \leq T_1$, $D_{N+1}^c \leq T_2$ 时才更新模板.这里,使用简单的模板更新策略:

$$M_{\text{new}} = \gamma M_{\text{old}} + (1 - \gamma) M_{\text{est}} \quad (13)$$

其中, M_{old} 是上一帧的跟踪模板, M_{est} 是当前帧估计得到的目标状态所对应的观测, M_{new} 是更新后的模板, γ 是可调参数,本文设置为 $\gamma=0.7$ 。

3.4 基于粒子密度的目标跟踪框架

基于上述关于粒子密度的讨论,本节给出基于粒子密度的目标跟踪框架,见表 1。

表 1 基于粒子密度的视频目标跟踪框架

输入:视频序列 $\{I_t\}$, $t=0, \dots, T$, 粒子数量 n

输出:每帧跟踪得到的目标位置 X_t , $t=1, \dots, T$

令 $t=0$ 在初始帧手工选取目标 X_0 , 并计算其特征作为模板特征 M ;

For $t=1; T$

1. 初始化. 以 X_{t-1} 为均值 Σ 为方差的高斯先验分布生成 n 个粒子 $\{X_{t-1}^i; i=1, 2, \dots, n\}$, 并设置权值为 $w_{t-1}^i=1/n$;

2. 计算粒子密度. 具体步骤如下:

① 按照式(11)构造增广观测矩阵 Y^* ;

② 按照式(12)计算增广观测矩阵的相似度矩阵 S , 并计算 S 的最后一行和 D_{n+1}^r 与最后一列和 D_{n+1}^c , 分别作为模板 M 的行密度和列密度;

3. 分四种情况讨论 D_{n+1}^r , D_{n+1}^c 与阈值 T_1 , T_2 的关系, 并确定是否需要重采样粒子和是否需要更新模板;

4. 对于需要重采样的粒子,使用粒子群优化方法重采样,得到新的优选粒子;对于无需重采样的粒子,则选取模板 M 的 p 邻域内的 p 个粒子和以模板 M 为邻域的若干个粒子作为优选粒子;

5. 设最终得到优选粒子为 $\{X_j^*, j=1, \dots, n\}$, 计算它们与模板 M 间的相似度分别为 $w_j = \exp(-(d_{j,n+1})^2/2\lambda)$;

6. 获取当前帧目标位置 $X_t = \sum_j w_j X_j^*$, $j=1, \dots, n$;

7. 若第 3 步判断需要更新模板,则按照式(13)更新目标模板 M .

4 结束语

本文通过引入局部粒子密度的概念,目标模板周围的粒子密度信息来确定如何实施样本重采样与目标模板的更新.该方法在解决粒子多样性匮乏问题的同时,回避了需要大量粒子参与粒子重要性重采样所带来的计算效率低下的问题,又确定性地给出了何时需要更新模板而何时不必更新,从而在保证跟踪可靠性的前提下进一步减少了算法的时间消耗.通过比较实验结果与分析,验证了本文方法在目标出现多种复杂变化的情况下跟踪的鲁棒性和实时性。

参考文献:

- [1] Guofeng T, Zheng F, Xinhe X. A particle swarm optimized particle filter for nonlinear system state estimation[C]// Evolutionary Computation, CEC 2006. San

- Francisco, IEEE Congress on. 2006.
- [2] 胡士强,敬忠良. 粒子滤波算法综述[J]. 控制与决策, 2005, 20(4): 361-365.
- [3] Tuzel O, Porikli F, Meer P. Region covariance: a fast descriptor for detection and classification[C]// Computer Vision, 2006 IEEE 9th European Conference on. Switzerland, 2006.
- [4] Daqing C, Jiuqiang H, Zhijian Y. Visual tracking using region covariance and geometric particle filtering [C]// Image and Signal Processing (CISP), 2010 3rd International Congress on. China: Yantai, 2010.
- [5] Moakher M. A differential geometric approach to the geometric mean of symmetric positive-definite matrices [J]. Siam Journal On Matrix Analysis And Applications, 2005, 26(3): 735-747.
- [6] Arsigny V, Fillard P, Pennec X, et al. Log-Euclidean metrics for fast and simple calculus on diffusion tensors [J]. Magnetic Resonance In Medicine, 2006, 56(2): 411-421.
- [7] Wen J, Gao X, Li X, et al. Incremental pairwise discriminant analysis based visual tracking[J]. Neurocomputing, 2010, 74(1-3): 428-438.
- [8] Sivalingam R, Morellas V, Boley D, et al. Metric learning for semi-supervised clustering of region covariance descriptors [C]// Distributed Smart Cameras, 2009. ICDSC 2009. Third ACM/IEEE International Conference on. Italy: Como, 2009.
- [9] Deng C, Xiaofei H, Jiawei H. Semi-supervised discriminant analysis[C]//Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on. Brazil, 2007.

作者简介:



张继 男, (1981—), 硕士, 讲师. 研究方向为图像处理与分析.



王洪元 男, (1960—), 博士. 研究方向为模式识别与智能系统、图像处理等.

(上接第92页)

- [4] 张雄希. 无线传感器网络在城市智能公交系统中的应用[J]. 重庆交通大学学报: 自然科学版, 2009, 28(6): 1064-1066.
- [5] 李硕, 李文锋, 陈维克. 无线传感器网络在智能交通系统中的应用研究[J]. 机械与电子, 2010, 12(4): 14-16.
- [6] 康忠林. 智能交通系统中先进交通管理系统的设计与实现[D]. 福建: 华侨大学硕士学位论文, 2007.

作者简介:

吴磊 男, (1981—), 硕士. 研究方向为交通信息工程及控制.

侯忠伟 男, (1986—), 硕士研究生. 研究方向为交通物联网.

许登元 男, (1971—), 博士, 副教授. 研究方向为宽带无线接入及智能交通系统.