

增量学习 Rao-Blackwellized 粒子滤波的跟踪算法

陶杰, 查宇飞, 毕笃彦

TAO Jie, ZHA Yu-fei, BI Du-yan

空军工程大学 工程学院 信号与信息处理实验室, 西安 710038

Signal and Information Processing Lab, Engineering College, Air Force Engineering University, Xi'an 710038, China

E-mail: wl_tj2005@163.com

TAO Jie, ZHA Yu-fei, BI Du-yan. Tracking algorithm using incremental learning Rao-Blackwellized particle filter. *Computer Engineering and Applications*, 2009, 45(8): 172-174.

Abstract: The eigen subspace based tracking method is adaptive to the change of object state and is robust to lighting variation. Usually it supposes the eigenbasis vectors are static and trained offline, so tracking precision will degrade under large pose variation. This paper proposes an incremental learning based tracking algorithm using Rao-Blackwellized particle filter. The eigenbasis vectors in subspace are trained online and the object's projection parameter in subspace is updated online. Experiments show that the proposed method is more precise and robust under conditions such as large appearance variation, pose variation and lighting variation.

Key words: tracking algorithm; eigen subspace; incremental learning; Rao-Blackwellized particle filter

摘要: 基于特征子空间的目标跟踪方法能适应目标状态的变化, 并对光照等外部环境不敏感, 但通常假定特征子空间的基向量固定, 这样不仅需要离线训练, 而且在目标姿态发生较大改变时, 跟踪精度会降低。提出一种基于增量学习的 Rao-Blackwellized 粒子滤波算法, 通过在线学习获得特征子空间的基向量, 并用解析的方法对目标在子空间的投影参数进行在线更新。实验表明, 新算法在目标有较大形变、姿态变化和光照等条件变化时, 能保持较高跟踪精度, 具有较强的鲁棒性。

关键词: 跟踪算法; 特征子空间; 增量学习; Rao-Blackwellized 粒子滤波

DOI: 10.3778/j.issn.1002-8331.2009.08.052 文章编号: 1002-8331(2009)08-0172-03 文献标识码: A 中图分类号: TP391

1 引言

运动目标跟踪是计算机视觉领域的基本和关键组成部分, 近年来已成为研究的热点。运动目标跟踪的任务是在图像序列中确定当前目标的状态, 包括位置、速度、大小等参数。目前的跟踪方法大部分可以看作是基于模型的方法, 即首先建立模型来描述目标, 然后在后续帧中通过一定的搜索算法来确定目标的状态。传统的光流法^[1]采用固定模板和 SSD 准则, 不仅计算量大, 而且对光照等外部环境敏感。颜色直方图^[2]对目标姿态和形状变化不敏感, 具有良好的跟踪性能, 但由于没考虑像素的空间位置等信息, 容易受到相似颜色背景的影响。文献[3]提出一种基于外观模型的跟踪方法, 通过在小波域构建由三个高斯成分组成的混合模型来描述目标, 能很好地适应目标外形的变化, 并对光照、视角变化具有一定的鲁棒性, 但该方法的前提是目标各像素间相互独立, 缺少目标的整体结构信息, 在许多情形下往往会导致跟踪失败。文献[4]利用特征子空间来建立目标外观模型, 并结合参数化光流法来进行运动参数估计, 获得了很好的跟踪效果。

Rao-Blackwellized 粒子滤波是 Rao-Blackwellized 方法和

粒子滤波的结合, 它将状态变量分成两部分, 一部分以解析方式更新, 而另一部分通过粒子滤波方法来更新。与普通粒子滤波相比, 由于状态变量维数降低了, 从而可以在保证精度的情况下采用相对较少的粒子数, 节省计算量。文献[5]将特征子空间法和 Rao-Blackwellized 粒子滤波相结合, 将目标在子空间的投影系数作为状态变量组成部分, 并在跟踪过程中通过概率 PCA 来解析更新, 获得了鲁棒的跟踪效果。在该算法中, 特征子空间的基向量通过离线学习获得, 而且没有在线更新。在实践中, 一般很难获得大量好的样本来学习; 此外, 基向量固定, 所以这种方法不能很好地捕获到目标的快速变化。针对目标的变化在时域上的连续性, 文献[6]中提出的特征子空间增量学习方法, 这种方法通过在线学习不断更新特征子空间的基向量来适应目标的变化, 但是这种方法在目标快速变化时, 跟踪结果也会出现较大偏差。针对这些不足, 本文提出一种基于增量学习的 Rao-Blackwellized 粒子滤波算法, 特征子空间的基向量通过在线学习获得, 不仅不需要离线学习, 而且能提高算法的自适应能力, 在目标出现较大形变和姿态变化时, 能更好地跟踪目标, 提高跟踪的精度和鲁棒性。

基金项目: 国家高技术研究发展计划(863)(the National High-Tech Research and Development Plan of China under Grant No.2007AA701206)。

作者简介: 陶杰(1979-), 男, 博士, 主要研究方向为图像处理、运动目标跟踪; 查宇飞(1980-), 男, 博士, 主要研究方向为运动目标检测与跟踪; 毕笃彦(1962-), 男, 教授, 博士生导师, 主要研究方向为信号与信息处理、计算机视觉。

收稿日期: 2008-09-08

修回日期: 2008-10-06

2 Rao-Blackwellized 粒子滤波

2.1 粒子滤波

粒子滤波是一种基于递归 Bayes 估计思想的统计模拟方法,它的核心思想是用一些离散随机采样点(粒子)来近似系统随机变量的概率密度函数,以样本均值代替积分运算,从而获得状态最小方差估计。

假设前 k 个时刻的观测 $\mathbf{Y}_k = \{y_1, y_2, \dots, y_k\}$, 那么由 Bayes 公式可得到当前时刻状态 x_k 的值:

$$p(x_k | \mathbf{Y}_k) = \frac{p(y_k | x_k) p(x_k | \mathbf{Y}_{k-1})}{\int p(y_k | x) p(x | \mathbf{Y}_{k-1}) dx} \quad (1)$$

$$\text{其中 } p(x_k | \mathbf{Y}_{k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | \mathbf{Y}_{k-1}) dx_{k-1} \quad (2)$$

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 $q(x_k | x_{k-1}, \mathbf{Y}_k)$ 中采样,独立抽取 N 个样本,通过公式(2)、(3)对粒子进行状态和权值更新,得到 k 时刻状态的后验概率密度:

$$p(x_k | \mathbf{Y}_k) \approx \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (3)$$

通常情况下,将粒子先验分布作为重要采样性函数,即 $q(x_k | x_{k-1}, \mathbf{Y}_k) = p(x_k | x_{k-1})$, 那么 k 时刻粒子权重就由每个粒子的似然值大小决定,即 $w_k^i \sim w_{k-1}^i p(y_k | x_k^i)$ 。

2.2 Rao-Blackwellized 粒子滤波(RBPF)

Rao-Blackwellized 粒子滤波的前提条件是待估计状态能划分成两部分,然后一部分通过卡尔曼滤波等解析方法更新,另一部分通过粒子滤波方法来更新。

假设状态 \mathbf{x} 由两部分组成,即 $\mathbf{x} = [x_1, x_2]$, x_2 可以通过解析方式更新,已知前 k 个时刻的观测 $\mathbf{Y}_k = \{y_1, y_2, \dots, y_k\}$, 那么根据 Bayes 公式有

$$p(x_k | \mathbf{Y}_k) \sim p(y_k | x_{1,k}, x_{2,k}) \times \int_{x_{1,k-1}} \int_{x_{2,k-1}} p(x_{1,k}, x_{2,k} | x_{1,k-1}, x_{2,k-1}) p(x_{1,k-1}, x_{2,k-1} | \mathbf{Y}_{k-1}) \quad (4)$$

其中

$$p(x_{1,k}, x_{2,k} | x_{1,k-1}, x_{2,k-1}) = p(x_{2,k} | x_{1,k}, x_{1,k-1}, x_{2,k-1}) p(x_{1,k} | x_{1,k-1}, x_{2,k-1}) \quad (5)$$

若已知 $k-1$ 时刻粒子分布为 $\{x_{1,k-1}^i, w_{k-1}^i, \alpha_{k-1}^i(x_{2,k-1}) = p(x_{2,k-1} | x_{1,k-1}^i, y_{k-1})\}$, 而且 x_1 的先验分布与 x_2 无关,即

$$p(x_{1,k} | x_{1,k-1}^i, x_{2,k-1}) = p(x_{1,k} | x_{1,k-1}^i)$$

那么后验概率可以表示为:

$$p(x_k | \mathbf{Y}_k) \approx \sum_i w_{k-1}^i p(x_{1,k} | x_{1,k-1}^i) p(y_k | x_{1,k}, x_{2,k}) \times \int_{x_{2,k-1}} p(x_{2,k} | x_{1,k}, x_{1,k-1}^i, x_{2,k-1}) p(x_{2,k-1} | x_{1,k-1}^i, y_{k-1}) \quad (6)$$

因为假定 x_2 可以通过解析方式更新,所以上式的积分项可以通过解析方式获得,然后再对 x_2 进行边缘积分,就可以得到 x_1 的估计值。

3 特征子空间增量学习方法

特征子空间表示法较早应用在人脸检测与识别领域^[7],它通过 PCA(Principal Components Analysis)变换,构造一组低维空

间的向量,并通过这些向量来描述原始数据。近年来,子空间表示法被引入到跟踪领域,并引起许多研究人员的关注。子空间表示法用于目标跟踪时,由于图像是按时间序列逐帧处理,一般情形下不可能对目标进行离线学习,只能是先得到一个初始化子空间,然后在线更新。为了在保证精度的同时减少计算量, Ross 等人^[8]提出了一种改进的增量学习算法,同时更新基向量和均值。

假设已知前 n 帧图像 $\mathbf{A} = [\mathbf{I}_1, \dots, \mathbf{I}_n]$, 其均值为 $\bar{\mathbf{I}}_A = \frac{1}{n} \sum_{i=1}^n \mathbf{I}_i$,

那么通过对中心化矩阵 $\bar{\mathbf{A}} = [\mathbf{I}_1 - \bar{\mathbf{I}}_A, \dots, \mathbf{I}_n - \bar{\mathbf{I}}_A]$ 进行奇异值分解(Singular Value Decomposition, SVD), 就可以得到酉矩阵 \mathbf{U}_A 和对角阵 Σ_A , 该矩阵的每一列即是子空间的基向量。令 $\mathbf{B} = [\mathbf{I}_{n+1}, \dots, \mathbf{I}_{n+m}]$ 为 m 帧新图像, 相应均值 $\bar{\mathbf{I}}_B = \frac{1}{m} \sum_{i=n+1}^{n+m} \mathbf{I}_i$, 令 $\mathbf{C} = [\mathbf{A} \ \mathbf{B}] = [\mathbf{I}_1, \dots, \mathbf{I}_n, \dots, \mathbf{I}_{n+m}]$, 那么所要求的就是矩阵 \mathbf{C} 的酉矩阵 \mathbf{U}_C 和对角阵 Σ_C , 具体算法如下^[9]:

(1) 计算新矩阵 \mathbf{C} 的均值: $\bar{\mathbf{I}}_C = \frac{f \bar{\mathbf{I}}_A + \frac{m}{f} \bar{\mathbf{I}}_B}{f + m}$, f 是遗忘因子, 为不大于 1 的非负数;

(2) 计算 \mathbf{B} 的增广中心化矩阵:

$$\mathbf{B}^+ = [(\mathbf{I}_{n+1} - \bar{\mathbf{I}}_B), \dots, (\mathbf{I}_{n+m} - \bar{\mathbf{I}}_B), \sqrt{\frac{nm}{n+m}} (\bar{\mathbf{I}}_B - \bar{\mathbf{I}}_A)]$$

(3) 计算 $(\mathbf{B}^+ - \mathbf{U} \mathbf{U}^T \mathbf{B}^+)$ 的正交化矩阵 $\tilde{\mathbf{B}}$ 和矩阵 $\mathbf{R} =$

$$\begin{bmatrix} f \Sigma & \mathbf{U}^T \mathbf{B}^+ \\ 0 & \tilde{\mathbf{B}} (\mathbf{B}^+ - \mathbf{U} \mathbf{U}^T \mathbf{B}^+) \end{bmatrix};$$

(4) 对 \mathbf{R} 进行奇异值分解, 得到 \mathbf{U}_R 和 Σ_R , 那么 $\mathbf{U}_C = [\mathbf{U}_A, \tilde{\mathbf{B}}] \mathbf{U}_R$, $\Sigma_C = \Sigma_R$ 。

4 基于增量学习的 Rao-Blackwellized 粒子滤波算法

4.1 状态空间和运动模型

子空间表示法是对目标的确定表示, 当其用于跟踪时, 通常采用概率主成分分析(Probabilistic Principal Component Analysis, PPCA)^[8]。在 PPCA 框架下, 一幅 d 维图像 \mathbf{T} 表示为^[5,8]:

$$\mathbf{T} = \mu + \mathbf{W} \mathbf{a} + \mathbf{n} \quad (7)$$

其中 μ 是图像集的均值, \mathbf{a} 是子空间下对图像的描述, \mathbf{n} 为高斯噪声服从分布 $N(0, \sigma^2 \mathbf{I}_d)$, \mathbf{W} 为 $d \times q$ 的变换矩阵 ($q \ll d$), 它的最大似然估计值为 $\mathbf{U}_q (\mathbf{A}_q - \sigma^2 \mathbf{I}_q)$, \mathbf{A}_q 为对角矩阵, 对角线上的元素由前 q 个特征值由大至小依此排列, $\sigma^2 = \frac{1}{d-q} \sum_{i=q+1}^d \lambda_i$, 表示损失成分的平均。

本文采用仿射变换来描述物体的运动, 用 PPCA 来描述目标, 那么状态空间 $\mathbf{X} = (x, y, s, \theta, a)$, 分别表示 x, y 坐标、缩放比例、旋转角度和目标描述参数, 其中 a 通过卡尔曼滤波来更新。运动方程采用布朗(Brownian)运动模型, 即 $p(\mathbf{X}_t | \mathbf{X}_{t-1}) = N(\mathbf{X}_t; \mathbf{X}_{t-1}, \Sigma)$, Σ 为对角阵, 非零元素依次为 $\sigma_x^2, \sigma_y^2, \sigma_s^2, \sigma_\theta^2, \sigma_a^2$ 。

4.2 观测模型

模板图像经过由参数 (x, y, s, θ) 决定的仿射变换后得到的在当前帧的区域作为观测值, 那么 t 时刻由第 i 个粒子得到的似然值可表示为:



图1 dudek 序列测试结果

$$\frac{1}{\sqrt{2\pi I_d \sigma^2}} \exp\left(-\frac{1}{2} \|T^i - \mu - W a_i\|_{I_d \sigma^2}^2\right) \quad (8)$$

其中 $\|t - \mu\|_{\Sigma}^2 = (t - \mu)^T \Sigma^{-1} (t - \mu)$ 。

4.3 a 的解析更新和权重计算^[5]

假设 a 在 $t-1$ 时刻的分布为 $N(a_{t-1}; \hat{a}_{t-1}, P_{t-1})$, 那么 t 时刻的解析表达式为:

$$P_t = (\sigma^{-2} W^T W + (\sigma_a + P_{t-1})^{-1})^{-1} \quad (9)$$

$$a_t = P_t \times (\sigma^{-2} W^T (T - \mu) + (\sigma_a + P_{t-1})^{-1} a_{t-1}) \quad (10)$$

此时对应粒子权重为:

$$w_t^i = \frac{\sqrt{|2\pi P_t|}}{\sqrt{|2\pi I_d \sigma^2|} \sqrt{|2\pi(\sigma_a + P_{t-1})|}} \times \exp\left(-\frac{1}{2} (\|T^i - \mu - W a_i\|_{I_d \sigma^2}^2 + \|a_t - a_{t-1}\|_{\sigma_a + P_{t-1}}^2)\right) \quad (11)$$

4.4 算法步骤

为便于表达, 将状态表示为 $X = (\Theta, a)$, Θ 表示仿射变换参数。假定 $t-1$ 时刻粒子集为 $\{\Theta_{t-1}^i, w_{t-1}^i, a_{t-1}^i, P_{t-1}^i\}_{i=1}^N$, 具体算法如下:

(1) 手动获取前 5 帧图像中的目标, 对其奇异值分解, 得到初始粒子空间参数 U_0, Σ_0, \bar{I}_0 , 并初始化 Θ_0, a_0, P_0 , 令 $w_0 = 1/N$;

(2) For frame=1:M

1. 从先验概率 $p(\Theta|\Theta_{t-1}^i)$ 采样, 得到当前时刻粒子 Θ_t^i ;
2. 根据公式(9)、(10)得到 a_t^i 和 P_t^i ;
3. 通过公式(11)得到粒子权重 w_t^i ;
4. 选择最大权重对应的粒子作为当前时刻的估计;
5. 根据增量学习方法更新粒子空间参数 U, Σ, \bar{I} ;
6. 重采样粒子。

End

5 实验结果与分析

为了验证算法效果, 选取有较大姿态和形变的人脸图像序列作为跟踪对象, 所有的数据来自 <http://www.cs.toronto.edu/~dross/ivt/>。为了便于子空间表示, 每幅图像中的目标区域均被变换成 32×32 大小的矩形图像。实验中, 遗忘因子设为 0.95, 子空间基的个数取 10, 采样粒子的个数为 600。

首先测试的是 dudek 序列, 该序列中含多种人脸表情变化以及姿态和光照的变化。与文献[6]类似, 每间隔两帧图像抽取一幅图像来得到新的测试序列, 每 5 幅图像更新一次子空间参数 U, Σ, \bar{I} 。为便于比较, 在 dudek 序列上同时运行三种算法, 分别是文献[5-6]中算法和本文算法, 文献[5]中离线训练数据通过在整 dudek 序列上截取部分人脸数据得到, 部分测试结果

图 1 所示, 其中红色和蓝色方框分别代表文献[5]和[6]中算法的跟踪结果, 绿色框表示本文算法结果, 左上角数字表示当前帧数(在原始序列中的帧数), 分别为第 40、88、154、187、204、286、307、352、376 和 457 帧。在目标状态变化较小时, 三种算法定位精度相差不大, 本文算法略优于另两种, 但当目标外观发生较大改变时, 如第 286 帧图像由于运动造成模糊, 以及第 307、352、376 和 457 帧目标外观随运动而有较大改变时, 因为本文算法实时更新了目标描述参数 a , 所以能很快适应目标状态的变化, 跟踪精度优于原算法。图 2 为三种算法跟踪结果的结果的 RMS(Root Mean Square)误差曲线, 其中真实目标位置通过手动方法获得, 具体计算方法见文献[6]。这里分别用 RBPF 和 IVT 表示文献[5]和[6]中算法, 图中红色和蓝色曲线分别代表 RBPF 和 IVT 算法的跟踪误差, 绿色曲线表示本文算法跟踪误差。图中存在两个误差超过 40 的尖峰, 第一个是由于遮挡造成, 此时三种算法误差均较大, 第二个是由运动模糊造成, 此时本文算法受影响很小, 其余较大误差部分均是由较大状态改变造成。从图中可以看出, 本文算法在整体上误差较小, 鲁棒性好于其余两种算法。

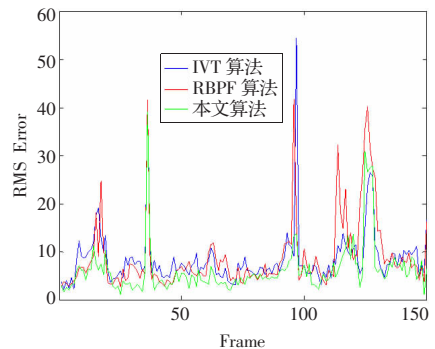


图2 dudek 序列测试误差曲线图

第二个测试序列为 fleet 序列, 该图像序列中存在人脸表情变化, 而且不仅有人脸左右一定角度的变化, 还存在明显的俯仰动作, 本文算法能适应这些变化, 始终较好地跟踪目标, 部分测试结果如图 3 所示。

6 结论与展

本文算法将增量子空间法和 RBPF 相结合, 通过在线学习获得特征子空间的基向量, 并用解析的方法对目标在子空间的投影参数进行在线更新, 算法适应目标状态变化的能力得到了加强, 在目标外观改变较大时仍能精确跟踪, 鲁棒性较好, 但在受到较大面积遮挡时会出现较大跟踪误差, 如何加强目标遮挡时的跟踪稳定性需作进一步的研究。

(下转 193 页)