

基于 RJMCMC 的视觉多目标跟踪算法

周 维 许海霞 郑金华

(湘潭大学信息工程学院 湘潭 411105)

摘 要 研究了基于 MCMC 的多目标跟踪算法。针对 MCMC 迭代过程中抽样置信度低以及不能进行有效迭代的问题,提出一种新的基于 RJMCMC 的视觉多目标跟踪算法。给定观测测量,将跟踪问题建模为状态量的最大后验估计(MAP)、关于 MAP 的先验与似然的估计。借助匹配阵给出了目标先验建议分布,设计了 4 种马氏链可逆运动方式;似然度量采用随空间加权的颜色直方图匹配衡量。MCMC 抽样过程中的状态由 MS 迭代产生,而不是随机走生成。基于似然度量导出了 MS 迭代式。实验结果及定量分析评估结果说明了本算法的有效性。

关键词 视觉多目标跟踪,可逆跳转马尔科夫链蒙特卡洛,贝叶斯推理,Mean-shift

中图分类号 TP391 **文献标识码** A

Multi-object Visual Tracking Based on Reversible Jump Markov Chain Monte Carlo

ZHOU Wei XU Hai-xia ZHENG Jin-hua

(School of Information Engineering, Xiangtan University, Xiangtan 411105, China)

Abstract MCMC-based multi-object visual tracking was investigated here. To improve the confidence of sampling and perform the iteration effectively, a new approach to multi-object visual tracking was proposed based on reversible jump Markov chain Monte Carlo (RJMCMC) sampling. Given image observation, the tracking problem was formulated as computing the MAP (maximum a posteriori) estimation. The prior proposal distribution of object was developed with the aid of association match matrix, and four types of reversible and jump moves were designed for Markov chains dynamics. The likelihood distribution measure was presented via position-weighted colour hist match between reference objects and candidate objects. The state updating was generated from mean-shift (MS) iteration, rather than from random walk in the MCMC sampling. Experimental results and quantitative evaluation demonstrate that the proposed approach is effective for challenge situations.

Keywords Visual multi-objects tracking, Reversible jump Markov chain Monte Carlo (RJMCMC) sampling, Bayes inference, Mean-shift

1 引言

学术界和军事应用领域中,多目标跟踪的研究一直是个难点问题,其任务是在噪声和杂波干扰等各种环境不确定因素下对目标的数目和状态进行估计。这一问题最初是对雷达目标数据进行处理,测量数据主要是运动信息,估计过程建模为运动状态预测、关联与估计,常用技术有最近邻法(NN)、集合论描述法、广义相关法、经典分配法、多假设法、概率数据关联(PDA)法、联合数据互联(JPDA)法、交互多模型(IMM)法等数据互联算法。这些方法一般是基于一对一的假设(一个目标对应于一个量测)。

随着视觉传感器的普遍应用,多目标的视觉跟踪成为研究的热点。但由于运动目标的交互行为、干扰严重及视觉检测过程的检测准确率低等因素,造成目标与观测量之间不再满足严格的一对一限制,会出现多对多,使跟踪难度更大。

Bayes 概率推理理论框架实现视觉多目标跟踪,大致上可分为 3 类:第一,借鉴雷达数据处理算法及采用关联估计的解决方法,如 1979 年 Reid^[1]提出的经典多假设跟踪(MHT)。目标交互可能会出现目标“新生、消失、组合、分裂,正常运动”等,故随目标个数增加,“假设”呈指数增长的趋势更加严重,其改进算法引入 MUTY^[2]、Viterbi^[3]修剪“假设”的个数;第二类,particle filter(PF)是常用的 Bayes 推理逼近方法,K. Okuma 提出基于 BPF 滤波的多目标跟踪^[4],由 ADaboost 检测器检测、PF 跟踪^[5],可以取得好的结果;第三类,MCMC 方法是一种贝叶斯推理随机抽样模拟仿真实验方法,其通过构造 Markov 链进行随机抽样,能够优化任意的高维能量函数,可克服解空间维数灾难问题。基于 MCMC 抽样的多目标跟踪^[6-14]、MRF-MCMC^[10],由 SVM 检测器检测目标,再借助 MRF 解决目标的交互。Zia Khan^[11]采用 CMC-PF 抽样维数可变的解空间,实现可变数目的目标跟踪。Kevin^[12], Tao

到稿日期:2011-08-19 返修日期:2011-11-22 本文受国家自然科学基金项目(61070088,60773047),湘潭大学自然科学基金项目(09XZ X24),湖南省教育厅一般项目(10C1269,11C1214)资助。

周 维(1978-),男,硕士生,讲师,主要研究领域为图像处理、计算机视觉、网络安全,E-mail:Bigdaddy2004@126.com;许海霞(1978-),女,博士生,讲师,主要研究领域为图像处理、计算机视觉;郑金华(1963-),男,博士,教授,博士生导师,主要研究领域为多目标进化算法。

Zhao^[13]采用 RJMCMC 抽样实现维数可变的 MC 过程。

采用检测器,使得检测率高,但增加了额外计算负担。而 MCMC 逼近过程最大的缺点是所需抽样次数多、迭代效率低。可以借助经典的关联方法,给出先验的建议分布,而不采用文献[12,13]的均值建议分布,这样可提高抽样置信度,减少抽样次数。其次,在有效的抽样基础上设计目标位置有效迭代计算方法。

本文提出一种改进的 RJMCMC 多目标跟踪算法。多目标视觉跟踪建模为 Bayes 准则下的最大后验估计 MAP,运用 RJMCMC 抽样求解 MAP。MAP 的两要素——先验与似然的设计:为了提高抽样置信度,设计了目标的先验建议分布和 4 种可逆运动方式构造马氏链;给出了采用随空间加权的颜色直方图匹配衡量的似然度量,并导出 MS 迭代来更新抽样状态,不采用常用的随机走方式更新。实现表明,本文算法在性能上优于 MHT^[1]和 BPF^[4]算法。

2 问题表述

给定一马尔可夫状态空间模型, t 时刻隐状态量 $X_t = \{X_{i,t}, i \in I_t\}$ 表示一个多目标状态, $X_{i,t}$ 是第 i 个目标, I_t 是目标索引标号集,目标总数 $m_t = |I_t|$ 。观测量(或检测量) $Y_t = \{Y_t^{fg}, Y_t^{bg}\}$,其中 Y_t^{fg}, Y_t^{bg} 分别是由检测过程分割出的前景与背景。多目标跟踪的目标:由获取的 t 时刻为止的所有观测量 $Y_{0,t} = \{Y_0, \dots, Y_t\}$ 来估计 t 时刻多目标的状态 X_t ,估计出目标数目且定位每个目标。从理论上讲,根据贝叶斯准则,状态 X_t 的后验概率密度分布函数(posterior probability distribution function, PDF) $p(X_t | Y_{0,t})$ 为

$$p(X_t | Y_{0,t}) \propto p(Y_t | X_t) p(X_t | Y_{0,t-1}) \quad (1)$$

且

$$p(X_t | Y_{0,t-1}) = \int p(X_t | X_{t-1}) p(X_{t-1} | Y_{0,t-1}) dX_{t-1}$$

式中, $p(X_{t-1} | Y_{0,t-1})$ 是已跟踪到的目标的先验信息; $p(X_t | X_{t-1})$ 是 MC 链的状态转移; $p(Y_t | X_t)$ 是观测量的似然度,用于度量目标的预测量与观测量的相似度。跟踪问题建模为隐状态的最大似然(MAP)估计为

$$X_t^* = \arg \max_{X_t \in \Theta} p(X_t | Y_{0,t}) \quad (2)$$

式中, Θ 是多目标状态量的解空间。实际上,主要设计多目标状态量的先验建议分布、目标观测与预测的时空似然度量。

2.1 目标模型

跟踪系统中,目标模型在位置-颜色空间表示为 $X = \{x^*, b\}$, x^* 是目标质心,反映目标的运动轨迹。由于 HSV 色彩空间对光线的影响不敏感,目标掩码区域内的颜色信息 $b = \{b_j, \dots\}$ 采用 HSV 色彩表示。为了便于计算,3 分量 H, S, V 分别量化为 N_h, N_s, N_v 阶,在任一像素位置 x_j 量化的 3 分量 H, S, V 合并为一维信息 $b_j = H_j N_h N_v + S_j N_v + V_j$ ^[15]、一维色彩信息阶数 $N = N_h N_s N_v, b_j \in \{0, \dots, N-1\}$ 。多目标跟踪系统中第 i 个参考目标模型 $X_{i,t} = \{x_{i,t}^*, b_{i,t}\}$ 。相应地,在跟踪的当前帧中候选目标模型具有同样的形式。

2.2 先验概率

先验概率分布 $p(X_t | Y_{0,t-1})$ 主要由状态转移分布 $p(X_t | X_{t-1})$ 逼近^[14],各目标的状态相互独立。目标数目可变的多目标状态转移分布定义为

$$p(X_t | X_{t-1}) = \prod_{i \in I_t} p(X_{i,t} | X_{i,t-1}) \quad (3)$$

式中,相邻两帧中每个目标的状态可能是{新出现、消失的、正常跟踪的}。若目标 $X_{i,t}$ 是正常跟踪的, $p(X_{i,t} | X_{i,t-1}) = p_{update}(X_{i,t} | X_{i,t-1})$,索引号 $i^{(t)} = i^{(t-1)}$,目标状态服从高斯分布,并由一阶回归模型预测 $X_{i,t} = X_{i,t-1} + \omega_{t-1}$, ω_{t-1} 是过程噪声。

当目标 $X_{i,t}$ 是新目标时, $p(X_{i,t} | X_{i,t-1}) = p_{new}(X_{i,t})$,索引号 $i^{(t-1)} = \phi$,它在 t 时刻以前不存在,目标状态服从检测过程定义的先验混合高斯分布。若一大大小为 M 个像素的前景检测区域为 $\{x_j, b_j\}_{j=1}^M$,则其为新目标的分布为 $p_{new}(X_{i,t}) \sim \sum_{j=1}^M N(x_j, \sigma_{xj}) N(b_j, \sigma_{bj})$ 。

当目标在当前帧消失时, $p(X_{i,t} | X_{i,t-1}) = p_{dead}(X_{i,t-1})$,索引号 $i^{(t)} = \phi$,目标状态的概率设定为非零常数。

注:为了减少变量与符号,文中以目标 $X_{i,t}$ 代替目标状态 $x_{i,t}$ 。

2.3 联合似然度量

给定多目标状态转移以及图像中每个像素的检测概率,似然度量 $p(Y_t | X_t)$ 反映检测值与预测值的相似度。

2.3.1 目标检测

目标检测、跟踪是组成自动跟踪系统的有机整体。目标检测就是判断每个像素是属于前景 foreground(fg) 还是背景 background(bg),它可由分类器如 Support Vector Machine(SVM)、Adaboost 等以及多高斯背景建模如 Gaussian Mixture Model(GMM), Kernel Density Estimation(KDE) 等来实现。为了计算方便,采用 GMM^[16]。设在 HSV 色彩空间下任一像素 x_j 的均值与方差分别为 \bar{b}_j, σ_j ,在 t 时刻输入系统的图像帧 I 的任一像素 x_j 属于背景的概率为

$$p_{bg}(I_j) = p_{bg}(b_j) \propto \max\{\exp(-\frac{(b_j - \bar{b}_j)^2}{\sigma_j}), \epsilon\} \quad (4)$$

式中, ϵ 是一个小的常数;增强模型的鲁棒性,参数 \bar{b}_j, σ_j 的更新如文献[16]所述。检测后,当前图像帧通过阈值分割为前景 Y_t^{fg} 、背景 Y_t^{bg} 。

2.3.2 似然度量

目标交互运动时,若存在严重遮挡,观测量 Y_t^{fg} 的区域块不能简单地表示为目标参考模型——对应关联关系。在给定状态量情况下,每个像素属于前景 Y_t^{fg} 或背景 Y_t^{bg} 可认为是条件独立的,则检测量的联合似然表示为

$$p(Y_t | X_t) = p(Y_t^{fg} | X_t) p(Y_t^{bg} | X_t) \quad (5)$$

式中,右边第一项是目标与前景的相似度量,即检测的多目标区域与参考模型多目标的相似匹配度量;第二项是检测区域属于背景的概率。首先分析第一项,采用常用的目标相似性的度量——Bhattacharya 距离进行衡量。

第 i 个参考目标 $X_{i,t} = \{x_{i,t}^*, b_{i,t}\}$ 的颜色信息 $b_{i,t}$ 表示为随空间变化的加权直方图:

$$H_{i,t} = C \sum_{j=1}^n k(\|x_i\|^2) \delta[b(x_i) - u] \quad (6)$$

式中, u 是量化等级,取值为 $0, \dots, N-1$; x_i 是此参考目标掩码区域的像素点位置; C 是归一化常数。

相应地,在源于检测量 Y_t^{fg} 的任意区域中,与 $X_{i,t}$ 相匹配的候选目标 $Y_{j,t} = \{y_{j,t}, b_{j,t}\}$ 的颜色信息 $b_{j,t}$ 表示为以 y 为中心、随空间变化的加权直方图

$$H_{j,t}(y) = C_o \sum_{j=1}^n k\left(\left|\frac{y - y_i}{\sigma}\right|^2\right) \delta[b(y_i) - u] \quad (7)$$

式中, y_j 是检测量 Y_t^{fg} 区域内的像素点位置, C_o 是归一化常

数。则其似然度量

$$p(Y_i^{fg} | X_{i,t}) = \sqrt{H_{i,t}^f H_{i,t}^g}(y) \quad (8)$$

给定一个多目标状态 X_t , 则多目标的联合似然为 $p(Y_i^{fg} | X_t) = \prod_{i \in I_t} p(Y_i^{fg} | X_{i,t})$ 。若检测量(或称观测量)没有对应的参考目标, 即出现新目标, 其似然度量设为一个非零常数。

背景 Y_i^{bg} 的似然度量采用同样的方法来计算。设源于背景 Y_i^{bg} 的像素位置 x_k 的颜色信息的直方图为 $H_{k,t}^g$, 则其似然度量为

$$p(Y_i^{bg} | X_t) = \prod_{j \in Y_i^{bg}} (p(I_j))^{k_{jg}} = \left(\prod_{u=0}^{N-1} H_{k,t}^g(u) \right)^{k_{jg}} \quad (9)$$

式中, k_{jg} 是平衡前景与背景的常数因子。计算先验与似然求得后验分布 $p(X_t | Y_{0,t})$ 来逼近目标分布 $p(X_t)$ 。

为了分析状态演变与更新时目标的似然度量, 第 i 个目标状态的产生由 Mean-Shift (MS) 迭代, 而不是 MCMC 概率抽样随机走, 它比随机走更有效。MS 是一种确定性的梯度下降逼近最优点的迭代算法。式(8)中观测量区域块的质心 y 不一定是目标真实质心位置, 它需要状态演变与更新过程中的 MAP 似然估计来确定。基于似然匹配度量建立 MS 迭代式, 其 MS 迭代式为

$$ms(y) = \frac{\sum_{j=1}^n y_j w_j k \left(\left| \frac{y - y_j}{\sigma} \right|^2 \right)}{\sum_{j=1}^n w_j k \left(\left| \frac{y - y_j}{\sigma} \right|^2 \right)} \quad (10)$$

权重 $w_j = \sum_{u=0}^{N-1} \delta[b(y_j) - u] \sqrt{\frac{H_{i,t}^f}{H_{j,t}^f(y)}}$, $k_\sigma(\cdot)$ 表示高斯函数。反复迭代搜索候选目标质心 y , 即搜索更新的目标状态 $x_{i,t}^*$ 。

3 数据驱动 RJMCMC 实现

在实际场景环境下, 目标间交互产生“进入的/退出的”、“新生的/消失的”、“分裂/合并”等情况, 使得每个时刻目标数目是变化的, 这也导致目标检测量(观测量)会出现“碎片/组合”现象, 从而造成检测量与预测量间的多对多映射。多目标状态量是一个维数可变的高维解空间, 针对数目可变化、目标交互影响, 我们采用可逆马尔科夫链蒙特卡洛(RJMCMC)抽样多目标状态量解空间, 通过计算最大后验概率(MAP)求得多目标状态量的最佳解。

3.1 RJMCMC

马尔可夫链蒙特卡洛(MCMC)是一种通过构造 Markov 链, 抽样来自目标分布的样本来进行参数、状态估计的贝叶斯随机模拟实验方法。可逆马尔科夫链蒙特卡洛(reversible jump Markov chain Monte Carlo, RJMCMC)是 1995 年 Peter J. Green^[17]提出的一种可构建跳转维数马尔可夫链的抽样方法。设计一系列的运动方式, 这些运动方式是可逆的, 在下一状态中可以跳转回原先的状态, 即跳转可逆。从一个初始状态开始, 通过抽样器随机抽样一种运动, 由建议概率分布 $q(z, z')$ 产生建议值或候选状态, 再计算准许率 $a(z, z')$, 决定的建议值或先前值将被添加到马尔可夫链中, 反复迭代构建一个可变维数的马氏链。

若一个平稳分布为 $p(X_t) = p(X_t | Y_{0,t})$ 的马氏链, 在第 g 次迭代中, 由建议分布 $q(\cdot)$ 产生建议候选状态 X_t^* , 从状态 $X_t^{(g-1)}$ 到状态 X_t^* 的接受概率为

$$a = \min\left(1, \frac{p(X_t^*)q(X_t^{(g-1)} | X_t^*)}{p(X_t^{(g-1)})q(X_t^* | X_t^{(g-1)})}\right) \quad (11)$$

虽然构建的马氏链是平稳分布的, 独立于建议分布 $q(\cdot)$ 和初始状态 $X_t^{(0)}$, 但是选择不同的建议分布会对 RJMCMC 的效率有很大的影响。数据驱动的 MCMC 提供了一个自下而上、从顶向底的原理框架, 其使得马氏链可有效地进行状态转移。下面分析如何通过有效的运动方式来进行马氏链状态转移。

3.2 马氏链动态过程设计

马氏链动态过程的设计就是设计 MC 过程隐状态可能发生的转移运动方式, 给出每种运动的建议分布 $q(\cdot)$, 根据每种运动的先验概率抽样服从建议分布 $q(\cdot)$ 的转移状态。

定义如下可能发生的转移运动方式构建马氏链状态转移, 进而求解多目标解空间的最佳状态解 X_t^* 。RJMCMC 的运动方式类型 $S = \{\text{产生(birth) / 消亡(death), 更新(update) / 交换(exchange), 合并(merge), 分离(split)}\}$ 。根据经验值设定选择每一种运动方式的先验概率为 p_v , 且 $\sum_{v \in S} p_v = 1$, 对目标 r 执行所选择的运动, 而其它目标状态保持不变。目标 r 被选择的概率为 $q_v(r)$, 运动对应基于当前观测的图像帧 I 驱动的建议分布。所有被选择的运动及所有被抽样的目标的多目标状态的建议分布定义为

$$q(X_t^*) = \sum_{v \in S} \sum_r p_v q_v(r) q_v(X_t^* | r) \quad (12)$$

运用 MCMC 方法抽样目标时, 大多数文献^[12,14]采用均匀建议分布, 所需迭代次数多, 在实际系统中很难发挥作用。事实上, 目标属于新生、消失、更新哪一类, 可以借助预测信息与检测信息来设计建议分布 $q_v(r)$, 使得抽样更有效, 减少迭代数。

预测值与检测值间的相似阵 $\Omega(i, j) = D(x_{i,t}, y_{j,t})$, $i = 1, \dots, n, j = 1, \dots, m$, 其中 $x_{i,t}$ 是预测目标 $X_{i,t-1}$ 的质心, $y_{j,t}$ 是检测区(观测量) Y_j^{fg} 的质心, $D(\cdot)$ 是马氏度量函数。则目标 i 被更新的概率为 $p_u(i) = \sum_{j=1}^m \Omega(i, j)$; 目标 i 是新生的、消失的概率分别为 $p_{new}(j) = 1 - \sum_{i=1}^n \Omega(i, j)$, $p_{dead}(i) = 1 - \sum_{j=1}^m \Omega(i, j)$ 。通过相似阵 Ω 给出将某一运动 v 执行于某一目标 r 的概率 $q_v(r)$ 以及特定运动 v 对应的建议分布如下。

新生运动: 候选状态量 X_t^* 中随机增加一个新目标, 其它目标保持不变, 则目标数目为 $I_t^* = I_t \cup \{r\}$ 。目标 r 被增加的概率为

$$q^{birth}(r) \propto \begin{cases} p_{new}(r), & r^{(t-1)} = \phi \\ p_u(r), & r^{(t)} = r^{(t-1)} \end{cases} \quad (13)$$

新目标 r 的来源有两种可能情况: 当索引 $r^{(t)} = r^{(t-1)}$ 时, 表示目标 $X_{r,t}$ 是抽样于跟踪的目标; 当 $r^{(t-1)} = \phi$ 表示是新目标, 是抽样于当前检测区域时, 则其先验分布由检测过程估计。显然, 新目标状态转移分布 $p(X_{r,t} | X_{r,t-1})$ 也存在两种情况。新生运动建议分布为

$$q^{birth}(X_t^* | r) = p(X_{r,t} | X_{r,t-1}) \prod_{i \in I_t} p(X_{i,t} | X_{i,t-1}) \quad (14)$$

消失运动: 消失运动是新生运动的逆运动。随机删除一个目标, 其它目标保持不变, 目标 r 被删除的概率为

$$q^{dead}(r) \propto \begin{cases} 1 - p_{new}(r), & r^{(t)} = \phi \\ p_{dead}(r), & r^{(t)} = r^{(t-1)} \end{cases} \quad (15)$$

则候选状态量 X_t^* 中目标数目为 $I_t^* = I_t \setminus \{r\}$ 。当索引 $r^{(t)} = \phi$ 时, 表示检测区域的一个虚警假目标被删除; 当 $r^{(t)} = r^{(t-1)}$ 时, 跟踪的目标 r 消失了。消失运动的建议分布为

$$q_{dead}(X_t^* | r) = \prod_{l \in I_t, l \neq r} p(X_{l,t} | X_{l,t-1}) \quad (16)$$

交换运动:随机交换两个相邻目标的索引 ID 号,它是更新运动的逆运动。两个目标 r_1, r_2 被交换的概率为

$$q_{exchange}(r_1, r_2) \propto \frac{1}{|x_{r_1} - x_{r_2}|} \quad (17)$$

其建议分布 $q_{exchange}(X_k^* | i, j)$,只是交换目标 r_1, r_2 的配置,多目标状态 X_k^* 的其它量保持不变。

更新运动:动态过程进行更新运动时,随机选择一个目标,目标 r 被更新的概率 $q_{update}(r) \propto p_u(r)$,保持所有其它目标状态不变,候选状态量 X_r^* 的维数不变,目标 r 的状态采用分层 HMS 迭代更新:

$$q_{update}(X_{r,t} | r) \propto N(X_{r,t}^* | X_{r,t}, \omega) \quad (18)$$

与前面表示方式相同,用目标 $X_{r,t}^*$ 代替目标更新的状态 $x_{r,t}^*$, ω 是随机噪声, $N(\cdot)$ 是高斯分布函数。

注意,为了变量表示的一致与简化,在不影响理解的情况下,所有建议分布表示中直接用目标 $X_{r,t}^*$ 代替状态 $x_{r,t}^*$,目标状态也是当前帧中的目标质心。

MS 是一种基于目标特征的匹配迭代跟踪算法,从预测的初始位置起匹配迭代搜索候选状态量。如目标出现“组合”,也就是检测过程将多个目标检测合为一个,即多对一,组合目标中的每一个目标均由上一帧预测其当前位置,自然多个目标可以找到一块重叠部分的当前检测区。若检测时出现空洞或多个碎片,表示目标分裂,仍从上一帧预测位置起迭代。当目标覆盖到多个碎片时,迭代匹配度最大,即一对多匹配。

因此,目标的“合并”与“分裂”情况都可合并并在“更新”中。

3.3 算法总结

基于 RJMCMC 的视觉多目标跟踪原理框图如图 1 所示。由 GMM 背景建模与目标检测自动完成跟踪系统的初始化,随后输入跟踪系统的每一帧,由检测与 RJMCMC 抽样来完成多目标跟踪任务。多目标跟踪建模贝叶斯推理,通过 RJMCMC 抽样求得状态量的最大似然(MAP)估计。对跟踪过程的任意时刻 t 进行 T 次抽样,在 RJMCMC 抽样迭代过程中计算组成后验概率的两部分:先验分布与似然度量。 t 时刻 RJMCMC 抽样迭代最佳状态 X_t^* 的具体过程如下:

(a)初始化 RJMCMC 抽样器。从马氏链 $t-1$ 时刻的状态选取一个样本初始化 RJMCMC 抽样器,根据目标的状态转移模型,使所有目标运动,把此时的目标状态作为种子当作新链的初始状态 $X_t^{(0)}$,并初始化后验概率 $P(X_t^{(0)})$;

(b)从前一个抽样的候选状态开始迭代 $X_t^{(s)} = X_t^{(s-1)}$;

(c)MH 规则抽样 T 次:

I)根据概率 p_v 的值,从 4 种运动中随机选择一种运动 v ,随机选择服从目标分布 $q_v(r)$ 的目标 r ;

II)把选择的运动方式 v 执行于目标 r ,由该运动的建议分布 $q_v(X_t^* | r)$ 产生建议候选状态 X_t^* ;

III)计算似然 $p(Y_t | X_t^*)$ 和后验分布 $p(X_t^* | Y_{0:t}) \propto p(Y_t | X_t^*)q(X_t^*)$;

IV)用后验分布 $p(X_t^* | Y_{0:t})$ 逼近目标 $p(X_t^*)$;

V)计算准许率 a ,产生服从均匀分布的随机数 k ,若 $a > k$,接收候选状态 X_t^* ,否则丢弃。

(d)计算状态量的最大似然估计 X_t^* 。

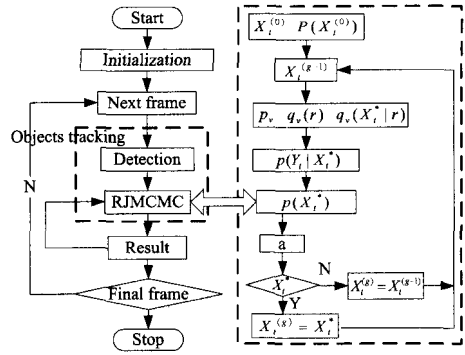


图 1 基于 RJMCMC 的视觉多目标跟踪原理框图

4 实验结果与分析

采用模拟数据与各类不同的真实数据来分析验证本文算法的性能。真实数据来源于 OTCBVS Benchmark Dataset、棒球运动员序列以及其它场景序列,都是由固定摄像机获取的。实验环境:主频为 1GHz Pentium IV 笔记本 PC,所有算法采用非优化的 MATLAB7 编程实现。参数设置:颜色量化阶 $N_b=8, N_s=3, N_v=3$,RJMCMC 抽样的参数 p_v 根据经验值来设置,如目标交互的频繁程度、存活周期等,本文 $p_{birth}=0.1, p_{dead}=0.1, p_{update}=0.7, p_{exchange}=0.1$,在似然度量中参数 $\lambda_g=0.005$ 。

本文提出的视觉多目标算法是基于 RJMCMC 抽样实现的,目的是通过提高目标状态抽样置信度和似然度量的有效性来取得较好的跟踪性能。下面给出跟踪帧的实验结果,每个目标的定位用方框表示,并附目标 ID 标号。

4.1 模拟数据实验

通过计算机生成一些出现特定事件的模拟数据来分析验证本文算法是否能够提高抽样置信度。假定在大小为 $L \times L$ 的平面区域内,存在未知数目的运动目标。每个目标具有不同的外观颜色,并用圆圈表示,以独立的速度在 2D 平面上运动。目标间交互、遮挡产生“合并与分裂、进入与退出、正常运动”等。在场景内还存在有一定数量的、服从均匀分布的虚假目标。

通过抽样来预测和定位目标的状态。RJMCMC 抽样迭代中执行各种运动方式的目标抽样于两种不同分布:均匀分布 $U(r)$ 和本文提出的先验建议分布 $q_v(r)$ 。目标的状态估计与定位结果如图 2 所示。从实验结果直观地分析,在相邻两帧中,有 6 个目标,目标的真实状态 ID2 是消失的, ID5 是新生的,其它是正常跟踪状态。每 100 抽样中,抽样于分布 $q_v(r)$ 时, ID2 以消失状态被抽的次数是 8, ID5 是新生状态出现 7 次;抽样于分布 $U(r)$ 时, ID2 以消失状态被抽的次数是 3, ID5 是新生状态出现 4 次。比较结果说明,采用本文设计的建议分布 $q_v(r)$ 具有更高抽样置信度。显然,在跟踪系统中,状态抽样越准确,状态迭代效率越高,似然度量越有效。




图 2 多目标跟踪模拟数据第 31,55 帧实验结果

4.2 真实数据实验(Real sequence data)

4.2.1 序列 1

源于 OTCBVS Benchmark Dataset^[18]的室外视频图像序列用来分析测试本文提出的跟踪算法,图像大小为 320×240 像素,帧频为 30Hz,场景是 Ohio 州立大学校园的交叉路口,场景背景固定。共测试视频中 1000 帧。每帧 RJMCMC 抽样 500 次,最大似然估计确定多目标状态。实验结果如图 3 所示。第 100,140,298,320 的帧跟踪结果如下:场景中从 0 到 238 帧有 4 个目标交互,出现“遮挡”、“合并”事件;240 到 420 帧间 ID3, ID4 号两个目标消失;从 554 帧起目标全部消失。从跟踪结果看,本算法能够较好地跟踪目标。




图 3 真实序列 1 的跟踪结果

4.2.2 序列 2

室内图像序列为高速滑行的棒球运动员比赛场景,图像大小为 320×240 像素,序列长度为 100 帧。第 18,37,60,81 帧的跟踪结果如图 4 所示。尽管运动员目标之间的“遮挡”、“合并”频繁出现,但采用本算法能够很好地检测与跟踪到大部分目标。




图 4 真实序列 2 的跟踪结果

通过检测率、跟踪率等统计方法对本算法进行定量的性能分析,并与 MHT^[1],BPF^[4]算法进行比较,如表 1 所列。BPH 算法采用 Adaboost 检测法,MHT 与本文采用 GMM 检测法。

表 1 定量跟踪性能评估

Dataset	Performance par(%)	Our method	BPF	MHT
Hockey player	r_d	97.11	77.78	97.11
	r_{fd}	0.22	0.12	0.22
	r_t	75.94	74.11	65.31
OTCBVS	r_d	98.69	78.72	98.69
	r_{fd}	0.16	0.21	0.16
	r_t	67.31	64.15	61.21

正确(True)检测率 r_d :时刻 t 的观测量/检测区前景区会

出现“碎片”与“组合”,故采用面积来定义态复萌 $r_d = \frac{\sum_{A_i \in Y_t^f} A_i \cap \sum_i A_i^G}{\sum_i A_i^G}$,其中 A_i^G 是第 i 个目标掩码区域的真实面积, A_i 是检测区前景 Y_t^f 中第 i 个区域的检测面积。

虚警(False-alarm)检测率 r_{fa} :在跟踪中虚警/假目标给新目标的识别带来干扰。若前景检测区 A_i 满足 $A_i \cap A_j^G = \emptyset$,则检测区 A_i 是虚警目标,假目标。 r_{fa} 定义为所有帧中每帧的虚假目标数与总的真实目标数比值的均值。

正确跟踪率 r_t :跟踪目标的面积 A_i^{obj} 与其真实面积 A_i^G 的重叠率表示为 $Overlap_i = \frac{A_i^{obj} \cap A_i^G}{A_i^G}$,如果 $Overlap_i > 0.6$,则

成功跟踪的目标计算器加 1;计算一帧中所有成功跟踪的目标与总目标数的比值,将所有帧频的比值取均值,即为正确跟踪率 r_t 。

结束语 本文提出一种基于 RJMCMC 的视觉多目标跟踪算法,其将跟踪问题建模为贝叶斯推理下的最大似然估计,并采用 RJMCMC 抽样实现。在室内、室外不同场景下的跟踪定性、定量结果说明了本算法具有较好的跟踪性能。本文的主要贡献是:

1)设计了 4 种可逆运动方式构造马氏链,并给出有效的先验建议分布。通过计算上一帧多目标状态的运动特征与当前检测的多目标状态的运动特征关联度,在关联度的基础上给出 MC 过程先验建议概率分布,提高了目标新生、消失、更新等状态的抽样置信度。

2)采用颜色加权直方图估计似然度量,导出了 MS 迭代算法。RJMCMC 抽样“更新”运动时,目标状态的更新运用 MS 算法迭代搜索其候选状态,而不采用通常 MCMC 的“随机走”法,MS 更新比随机走更有效。

下一步工作主要是开发颜色空间来改进目标模型,使得目标与相似目标的区分度更高。

参考文献

- [1] Reid D. An algorithm for tracking multiple targets[J]. IEEE Trans on Automat and Contr,1979,24(6):84-90
- [2] Zhen Ding, Vandervies D. A modified Murty algorithm for multiple hypothesis tracking[J]. Signal and Data Processing of Small Targets, 2006(6236):62360V. 1-62360V. 10
- [3] Kräußling A. Tracking Multiple Objects Using the Viterbi Algorithm[J]. Lecture Notes Electrical Engineering, 2008, 15: 233-247
- [4] Okuma K, Taleghani A, De Freitas N, et al. A boosted particle filter: Multitarget detection and tracking [C] // Proc. ECCV. 2004:28-39
- [5] Kreucher C, Morelande M, Kastella K, et al. Particle Filtering for Multitarget Detection and Tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41: 1396-1414
- [6] Oh S, Russell S, Sastry S. Markov chain Monte Carlo Data Association for General Multiple-target Tracking Problems [C] // Proceedings of the 43rd IEEE Conference on Decision and Control. 2004
- [7] Yu Qian, Medioni G. Integrated Detection and Tracking for Multiple Moving Objects Using Data-driven MCMC Data Asso-

- ciation[C]// IEEE Workshop on Motion and Video Computing, 2008;1-8
- [8] Yu Qian, Medioni G. Multiple-target Tracking by Spatiotemporal Monte Carlo Markov Chain Data Association[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2196-2210
- [9] Ma Yun-qian, Yu Qian, Cohen I. Multiple Hypothesis Target Tracking Using Merge and Split of Graph's Nodes[J]. ISVC, 2006(1): 783-792
- [10] Xue Jian-ru, Zheng Nan-ning. Sequential Sampling Belief Propagation Algorithm in Multi-target Tracking[J]. Science in China, Ser. E, 2005, 35(10): 1049-1063
- [11] Khan Z, Balch T R, Dellaert F. MCMC-based Particle Filtering for Tracking a Variable Number of Interacting Targets[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(11): 1805-1918
- [12] Smith K, Gatica-Perez D, Odobez J M. Using Particles to Track Varying Numbers of Interacting People[C]// Proc. IEEE Conf. Computer Vision and Pattern Recognition, 2005; 962-969
- [13] Zhao Tao, Nevatia R. Tracking multiple humans in complex situations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 7: 1208-1221
- [14] Zhao Tao, Nevatia R, Wu Bo. Segmentation and Tracking of Multiple Humans in Crowded Environments[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(7): 1198-1211
- [15] Forsyth D A, Ponce J. Computer Vision: A Modern Approach [M]. Prentice Hall, 2003; 58-102
- [16] Stauffer C, Grimson E. Learning Patterns of Activity Using Real time Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 747-757
- [17] Green P J. Reversible Jump Markov Chain Monte Carlo Computation and Bayesian Model Determination[J]. Biometrika, 1995, 82(4): 711-732
- [18] OTCBVS. Benchmark Dataset Web [EB/OL]. <http://www.cse.ohio-state.edu/otcbvs-bench/>

(上接第 252 页)

方法(如周炎涛提出的基于信息熵改进的 TFIDF 方法^[7]、柴玉梅提出的基于术语频率和逆文档频率改进的 TDF 方法^[15]、台德艺提出基于特征词分布集中度系数改进的 TF-IDF-DIC 方法^[15])比较,其宏 F1 值也略高于其他改进 TFIDF 方法。

从图 1 可以看出,在不同的特征维数上 TFIDF_Ci 方法无论结合 KNN 算法还是遗传算法所得的宏 F1 值都比传统 TFIDF 方法结合 KNN 或遗传算法的宏 F1 值要高。这说明 TFIDF_Ci 方法都比传统 TFIDF 方法有更好的适应性,分类精度也更高。

实验表明,改进的 TFIDF_Ci 方法在训练集规模不同情况下是非常有效的,并且具有高稳定性,性能优于传统分类方法和其他部分改进 TFIDF 分类方法,尤其在类分布不均匀语料集上性能提高显著。同时该方法仅考虑类本身的影响因素,不增加其他的计算和分析难度,适合大规模文本特征选择,有很强的实用性。

结束语 为了解决传统 TFIDF 方法在处理分布类别少、类间区分能力不强的问题,本文通过增加文本类区分加权频率来提升特征词条所在的文档的所属类与其他文档类的区分能力,提出了 TFIDF_Ci 方法。实验表明,TFIDF_Ci 方法性能优于传统的 TFIDF 方法和多个改进的 TFIDF 方法,文本特征选择提升了文本分类精度。

参 考 文 献

- [1] Jensen R, Shen Qiang. New Approaches to Fuzzy-Rough Feature Selection[J]. IEEE Transactions on Fuzzy Systems, 2009, 17(4): 824-838
- [2] Ma Yong-jun, Zhan Lin-qiang. Research on the Evaluation of Feature Selection Based on SVM[J]. Informatics in Control, Automation and Robotics, 2012, 133(1): 407-414
- [3] Fan Wen-tao, Bouguila N, Ziou D. Unsupervised Hybrid Feature Extraction Selection for High-Dimensional Non-Gaussian Data Clustering with Variational Inference[J]. IEEE Transactions on Knowledge and Data Engineering, 2012, PP(99): 1
- [4] Niu Shen, Hu Le-le, et al. Predicting protein oxidation sites with feature selection and analysis approach[J]. Journal of Biomolecular Structure and Dynamics, 2012, 29(6): 650-658
- [5] Mehdi H A, Nasser G A. Text feature selection using ant colony optimization[J]. Expert Systems with Applications, 2009, 36(3): 6843-6853
- [6] Chen Hui-ling, Yang Bo, et al. A support vector machine classifier with rough set-based feature selection for breast cancer diagnosis [J]. Expert Systems with Applications, 2011, 38(7): 9014-9022
- [7] 周炎涛,唐剑波,王家琴. 基于信息熵的改进 TFIDF 特征选择算法[J]. 计算机工程与应用, 2007, 43(35): 156-158
- [8] 孙德才,孙星明,张伟,等. 基于匹配区域特征的相似字符串匹配过滤算法[J]. 计算机研究与发展, 2010, 47(4): 663-670
- [9] 张玉芳,彭时名,吕佳. 基于文本分类 TFIDF 方法的改进与应用 [J]. 计算机工程, 2006, 32(19): 76-78
- [10] 黄华军,谭峻珊,等. 基于高阶统计的网页隐秘信息检测研究 [J]. 电子与信息学报, 2010, 32(5): 1136-1140
- [11] 施聪莺,徐朝军,杨晓江. TFIDF 算法研究综述[J]. 计算机应用, 2009, 6(29): 167-169
- [12] 陆玉昌,鲁明羽,李凡,等. 向量空间中单词权重函数的分析和构造[J]. 计算机研究与发展, 2002, 39(10): 1205-1210
- [13] 林永民,吕震宇,等. 文本特征加权方法 TF · IDF 的分析与改进 [J]. 计算机工程与设计, 2008, 29(11): 2923-2925
- [14] 柴玉梅,王宇. 基于 TFIDF 的文本特征选择方法[J]. 微计算机信息, 2006, 22(3): 24-26
- [15] 台德艺,王俊. 文本分类特征权重改进算法[J]. 计算机工程, 2010, 9(36): 197-199