

# 基于高阶时空模型的视觉传感网络数据关联方法

万九卿<sup>1</sup> 刘青云<sup>1</sup>

**摘要** 数据关联是视觉传感网络联合监控系统的基本问题之一. 本文针对存在漏检条件下视觉传感网络的数据关联问题, 提出高阶时空观测模型并在此基础上建立了数据关联问题的动态贝叶斯网络描述. 给出了数据关联精确推理算法并分析了其计算复杂性, 接着根据不同的独立性假设提出两种近似推理算法以降低算法运算量, 并将提出的推理算法嵌入到 EM 算法框架中, 使该算法能够应用于目标外观模型未知的情况. 仿真和实验结果表明了所提方法的有效性.

**关键词** 数据关联, 视觉传感网络, 高阶时空模型, 动态贝叶斯网络

**DOI** 10.3724/SP.J.1004.2012.00236

## Data Association in Visual Sensor Networks Based on High-order Spatio-temporal Model

WAN Jiu-Qing<sup>1</sup> LIU Qing-Yun<sup>1</sup>

**Abstract** One of the fundamental requirements for visual surveillance with visual sensor networks is the correct association of camera's observations with the tracks of objects under tracking. In this paper, we propose a high-order spatio-temporal model to deal with the problem of missing detection, and then formulate the data association problem with dynamic Bayesian networks. After presenting the exact inference algorithm for data association and showing its computational intractability, we derive two approximate inference algorithms based on different independency assumptions. To apply the algorithms when the object appearance model is unavailable, we incorporate the proposed inference algorithms into EM framework. Simulation and experimental results demonstrate the effectiveness of the proposed method.

**Key words** Data association, visual sensor networks, high-order spatio-temporal model, dynamic Bayesian networks

在许多城市公共场所中, 视觉传感网络监控系统得到了越来越广泛的应用. 视觉传感网络由多个摄像机组成, 每个摄像机可对其视场范围内的局部区域进行观测, 且不同摄像机的视场是非重叠的. 很多复杂的视觉监控任务, 如在一定范围内对多个目标 (如行人或车辆) 的联合跟踪、智能交通流量监测、行人行为的分析任务等, 其核心问题均为对不同摄像机的观测数据进行数据关联, 即确定摄像机的观测数据所对应的目标标号. 由于视频监控系统的成像质量往往较低, 且同一目标在不同观测条件下的外观会发生很大的变化, 使得单纯根据目标的外观特征进行数据关联无法满足使用要求<sup>[1-2]</sup>. 因此需要结合监控区域的拓扑结构和视觉传感节点的时空观测信息进行综合推理以提高关联准确率.

近年来, 有关视觉传感网络数据关联的问题引起了国内外学者的高度关注. 通过建立适当的模型, 数据关联问题可以转化为最优化问题求解. 文献 [3]

提出了一种多目标优化框架研究视觉传感网络数据关联问题, 将各个摄像机上的观测数据作为节点, 将外观模型和时空模型转换为节点之间的相似性测度, 此时数据关联问题转换为节点上的最优路径的搜寻问题, 用动态规划的方法对这一问题进行求解. 文献 [4] 提出了一种基于最小费用流模型的数据关联算法, 在求取最大效用时引入关联数限制, 建立最小费用流模型对问题求解.

与上述方法不同, 贝叶斯方法更适于描述数据关联问题内在的不确定性, 同时可以有效地实现多源信息的融合. 一种研究思路是将视觉传感网络数据关联过程看作是对全部观测数据集合的一个分划, 且使得分划后的每一个子集中观测都来自于同一个目标. 例如, 文献 [5] 考虑观测数据的分划集合, 其中每个分划集合代表一个目标的运动轨迹, 利用动态贝叶斯网络建立目标观测数据的生成模型, 并以此为基础计算各个分划集合的后验概率, 关联结果由具有最大后验概率的分划确定. 文献 [6] 则用隐马尔科夫模型描述单个目标在视觉传感网络中的运动, 用不同的状态变量表示目标被摄像机检出、目标位于观测盲区或目标被漏检等情况, 每个分划的后验概率可根据该模型来计算. 在这种研究思路中, 数据关联的复杂性体现在分划空间的组合膨胀上. 文献 [5] 仅保留具有较高后验概率的若干个分划假

收稿日期 2010-11-24 录用日期 2011-05-15  
Manuscript received November 24, 2010; accepted May 15, 2011  
北京市自然科学基金 (4113072) 资助  
Supported by Beijing Natural Science Foundation (4113072)  
本文责任编辑 乔红  
Recommended by Associate Editor QIAO Hong  
1. 北京航空航天大学自动化科学与电气工程学院 北京 100191  
1. School of Automation Science and Electrical Engineering,  
Beijing University of Aeronautics and Astronautics, Beijing  
100191

设. 然而, 这种对分划空间的近似方式有可能使正确的分划假设由于其后验概率较低而被丢弃. 文献 [6-7] 采用马尔科夫链蒙特卡罗采样 (Markov chain Monte Carlo, MCMC) 方法对分划空间进行逼近. 尽管 MCMC 方法已经被广泛应用于数据关联, 但其仍存在着计算量大以及对初始条件敏感的问题<sup>[8-9]</sup>.

视觉传感网络数据关联贝叶斯方法的另一种研究思路是引入表征目标标号的随机变量, 即所谓关联变量, 并建立关联变量和观测数据之间的概率模型, 然后将数据关联问题转化为对关联变量后验分布的推理问题<sup>[10-11]</sup>. 引入关联变量可以避免对分划空间的枚举过程, 然而, 由于时空观测信息的引入使得这类方法存在如下两方面的问题: 1) 基于时空观测信息的数据关联推理算法很容易受到目标漏检的影响, 事实上, 漏检往往使得目标真实轨迹具有很低的后验概率, 从而导致数据关联的偏差. 但在实际应用中, 由于观测条件的限制, 单个摄像机对目标的漏检是难以避免的; 2) 由于不同摄像机获得的时空观测信息之间相互依赖, 使得状态空间随着观测数的增加呈指数型膨胀, 从而导致数据关联精确推理在计算上的不可行性. 因此, 需要寻求有效的近似推理算法进行数据关联.

本文针对上述问题, 提出一种基于高阶时空观测模型的视觉传感网络快速数据关联方法. 本文主要贡献如下: 1) 通过引入表征目标运动路径的随机变量建立了高阶时空观测模型, 可以方便地描述由于漏检引起的目标运动路径的不确定性. 将高阶时空观测模型和状态转移模型、外观观测模型相结合, 建立了视觉传感网络数据关联问题的混合动态贝叶斯网络描述, 将数据关联问题转化为该模型上的推理问题. 仿真结果表明高阶时空观测模型可以极大地提高数据关联推理对于漏检的鲁棒性; 2) 推导了数据关联精确推理算法, 分析了该算法在计算上的不可行性. 为了降低计算量, 分别基于边缘分布独立性和条件分布独立性假设给出了两种近似推理算法, 并对各自的计算复杂度进行了分析. 仿真结果表明基于条件独立假设的近似推理算法可以实现推理精度与运算复杂度之间更好的折中; 3) 为了解决外观模型参数未知的问题, 将所提推理算法与传统 EM 相结合, 提出一种推广 EM 算法框架, 同时解决了数据关联和外观模型参数估计问题. 仿真结果表明, 由于有效地利用了时空观测信息, 相比传统 EM 算法, 推广 EM 算法更易于收敛到外观模型参数的真实值.

## 1 问题模型

假设  $K$  个目标在具有  $M$  个摄像头的监控区

域内运动, 该视觉传感网络拓扑结构如图 1 所示. 图中每个节点对应一个摄像头, 每条边对应观测节点之间的一条连通路. 记传感网络参数矩阵为  $A = \{\mathbf{a}_{uv}\}_{u,v=1}^M$ , 其中  $\mathbf{a}_{uv} = (\pi_{uv}, t_{uv}, s_{uv})$ ,  $\pi_{uv}$  为目标从摄像头节点  $u$  运动到  $v$  的转移概率,  $\pi_{uv} = 0$  表示  $u$  点和  $v$  点之间不存在直接连通的路径;  $t_{uv}$  为目标从  $u$  点运动到  $v$  点的时间均值,  $s_{uv}$  为时间方差. 每当摄像头捕捉到某个目标时, 产生一个观测  $\mathbf{y}_i = \{o_i, d_i, c_i\}$ , 其中  $o_i$  表示目标的外观观测, 如颜色或长度等;  $c_i$  和  $d_i$  为时空观测,  $c_i$  为摄像头标号,  $d_i$  表示摄像头  $c_i$  捕获目标的时间. 假定目标观测数据集  $\{\mathbf{y}_i\}_{i=1}^N$  中的元素已按照产生时间的先后顺序排列. 数据关联问题就是要确定每个观测数据所对应的目标标号.




图 1 视觉传感网络拓扑结构

Fig. 1 Topology of visual sensor networks

对每一个观测引入一个关联变量  $x_i \in \{1, \dots, K\}$ ,  $x_i = k$  表示观测  $y_i$  由第  $k$  个目标产生; 另外引入一组状态变量  $z_i = \{z_i^{(k)}\}_{k=1}^K$ , 其中  $z_i^{(k)} \in \{0, \dots, i-1\}$  表示在  $y_i$  之前由第  $k$  个目标产生的上一个观测的序号,  $z_i^{(k)} = 0$  表示第  $k$  个目标首次出现. 将  $(x_i, z_i)$  作为隐藏状态, 此时数据关联问题转化为计算关联变量的边缘后验概率  $p(x_i | \mathbf{y}_{0:i})$  的问题. 我们将首先给出理想观测条件下系统的状态转移模型和观测模型, 接着针对漏检问题提出高阶时空观测模型, 最终建立完整的数据关联动态贝叶斯网络推理模型.

### 1.1 状态转移模型

由系统状态定义可知系统状态转移过程为一阶马尔科夫过程, 状态转移模型为

$$p(x_i, z_i | x_{i-1}, z_{i-1}) = p(x_i) f(z_i | x_{i-1} = k, z_{i-1}^{(k)} = l) \quad (1)$$

其中,  $p(x_i)$  为关联变量先验概率, 在没有任何先验知识的条件下可假设为均匀分布; 在给定  $x_{i-1}$  和  $z_{i-1}$  的条件下, 辅助变量  $z_i$  的取值是确定的. 具体地, 如果第  $i-1$  个观测由第  $k$  个目标产生, 则  $z_i^{(k)}$

应该等于  $i-1$ , 而  $z_i$  中其他变量应保持不变, 即

$$z_i^{(k)} = z_{i-1}^{(k)}[x_{i-1} \neq k] + (i-1)[x_{i-1} = k] \quad (2)$$

其中,  $[g] \equiv 1(0)$  当且仅当  $g$  为真 (假).

## 1.2 观测模型

系统观测模型分为外观观测模型和时空观测模型两个部分, 当给定当前状态时, 假定二者相互独立. 假设每个目标的外观观测服从高斯分布, 则外观观测模型为

$$p(o_i | x_i = k) = N(o_i; \mu_k, \sigma_k^2) \quad (3)$$

其中,  $\mu_k$  和  $\sigma_k^2$  分别为第  $k$  个目标外观观测的均值和方差. 时空观测模型描述了同一目标的相邻时空观测之间的依赖关系, 假定目标在两相邻节点  $u$  和  $v$  之间的运动时间符合高斯分布, 则时空模型为

$$\begin{aligned} p(d_i, c_i | x_i = k, z_i^{(k)} = l, \mathbf{y}_{0:i-1}) = \\ p(d_i | x_i = k, z_i^{(k)} = l, d_l, c_l = u, c_i = v) = \\ \begin{cases} \text{常数}, & l = 0 \\ N(d_i - d_l; t_{uv}, s_{uv}), & l \neq 0 \end{cases} \end{aligned} \quad (4)$$

在上述时空观测模型中, 除了可以将目标捕获时间作为观测信息外, 其他时空观测, 如目标在摄像机视场内的运动方向等, 也可作为观测变量, 其相应的时空观测模型可按文献 [5] 中的方式建立. 这种建模过程的灵活性便于实现在数据关联过程中对多源观测信息的融合.

## 1.3 高阶时空观测模型

在摄像机对目标的检测过程中, 漏检是难以避免的. 由于时空观测间的相互依赖, 漏检造成的推理误差会随着推理过程迅速传播, 极大地降低数据关联准确率. 由于漏检引起的观测数据的缺失导致了目标运动路径的不确定性, 为此我们引入一组状态变量  $\omega_i = \{\omega_i^{u,v}\}_{u,v=1}^M$ , 其中  $\omega_i^{u,v} \in \{1, \dots, R_{uv}^L\}$  表示节点  $u$  到  $v$  的长度小于或等于  $L$  的路径的编号, 此处路径长度指沿该路径在  $u$  和  $v$  之间的节点个数,  $L=0$  表示节点  $u$  和  $v$  直接连通.

将  $(x_i, z_i, \omega_i)$  作为隐藏状态, 则系统状态转移模型变为

$$\begin{aligned} p(x_i, z_i, \omega_i | x_{i-1}, z_{i-1}, \omega_{i-1}) = \\ p(x_i)p(\omega_i)f(z_i | x_{i-1} = k, z_{i-1}^{(k)} = l) \end{aligned} \quad (5)$$

其中, 目标运动路径的先验概率  $p(\omega_i)$  可根据目标沿该路径运动的转移概率计算, 将从节点  $u$

到  $v$  的第  $r$  条长度小于或等于  $L$  的路径记为  $\omega_i^{(u,v)} = (u, w_0^{(r)}, \dots, w_{L-1}^{(r)}, v)$ , 则

$$\begin{aligned} p(\omega_i^{(u,v)} = r) = \\ \frac{\pi_{uw_0^{(r)}} \left( \prod_{l=1}^{L-1} \pi_{w_{l-1}^{(r)} w_l^{(r)}} \right) \pi_{w_{L-1}^{(r)} u}}{\sum_r \pi_{uw_0^{(r)}} \left( \prod_{l=1}^{L-1} \pi_{w_{l-1}^{(r)} w_l^{(r)}} \right) \pi_{w_{L-1}^{(r)} u}} \end{aligned} \quad (6)$$

时空观测模型变为

$$\begin{aligned} p(d_i, c_i | x_i = k, z_i, \omega_i, \mathbf{y}_{0:i-1}) = \\ p(d_i | x_i = k, z_i^{(k)} = l, \omega_i^{(u,v)} = \\ r, d_l, c_l = u, c_i = v) = \\ \begin{cases} \text{常数}, & l = 0 \\ N(d_i - d_l; \bar{t}_{uv}^{(r)}, \bar{s}_{uv}^{(r)}), & l \neq 0 \end{cases} \end{aligned} \quad (7)$$

上述高斯分布的均值和方差可根据视频传感网络系统参数矩阵  $A$  计算. 目标从  $u$  点沿路径  $r$  运动到  $v$  点的平均时间为

$$\bar{t}_{uv}^{(r)} = t_{uw_0^{(r)}} + \sum_{l=1}^{L-1} t_{w_{l-1}^{(r)} w_l^{(r)}} + t_{w_{L-1}^{(r)} v} \quad (8)$$

目标从  $u$  点沿路径  $r$  运动到  $v$  点的时间方差为

$$\bar{s}_{uv}^{(r)} = s_{uw_0^{(r)}} + \sum_{l=1}^{L-1} s_{w_{l-1}^{(r)} w_l^{(r)}} + s_{w_{L-1}^{(r)} v} \quad (9)$$

由式 (5)~(9) 定义的概率模型可以用于描述视觉传感网络中非相邻节点之间的时空观测的转换关系, 因此可以看作是高阶时空观测模型. 该模型的阶数为  $L$ , 当  $L=0$  时即退化为传统时空模型 (4).

## 1.4 混合动态贝叶斯网络描述

动态贝叶斯网络用有向图的形式描述复杂的随机过程, 其中图节点对应于随机变量, 有向边对应于条件概率分布<sup>[12]</sup>. 视觉传感网络数据关联问题的混合动态贝叶斯网络模型如图 2 所示. 图中用方框表示离散随机变量, 圆框表示连续随机变量; 用虚线边表示确定性依赖关系, 实线边表示概率依赖关系. 其中指向  $z_i$  的有向边由式 (2) 定义, 指向  $y_i$  的有向边由式 (3) 和式 (7) 定义. 为了建立动态贝叶斯网络模型, 初始条件取为  $z_1^{(k)} = 0, k = 1, \dots, K$ . 在建立了视觉传感网络数据关联的动态贝叶斯网络模型之后, 数据关联问题可归结为动态贝叶斯网络上的推理问题, 即计算关联变量的后验概率  $p(x_i | \mathbf{y}_{0:i})$ .

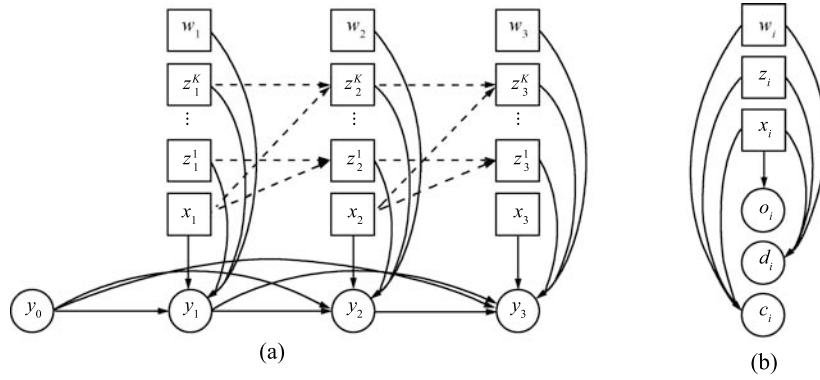


图 2 混合动态贝叶斯网络模型 ((a)) 和单时间片内变量依赖关系 ((b))

Fig. 2 Dynamic Bayesian networks model ((a)) and dependency in a single time slice ((b))

## 2 数据关联精确推理

注意到在图 2 所示的动态贝叶斯网络中  $\omega_i$  为时间片内部变量, 不参与状态的转移. 因此我们定义信念状态 (Belief state) 为  $p(x_i, z_i | \mathbf{y}_{0:i})$ , 关联变量  $x_i$  的后验分布可以通过计算信念状态的边缘分布得到. 该信念状态需要根据新的观测数据不断更新, 由贝叶斯公式可得

$$p(x_i, z_i | \mathbf{y}_{0:i}) = \sum_{\omega_i} p(x_i, z_i, \omega_i | \mathbf{y}_{0:i}) = \quad (10)$$

$$\frac{1}{L_i} \sum_{\omega_i} p(\mathbf{y}_i | x_i, z_i, \omega_i, \mathbf{y}_{0:i-1}) p(x_i, z_i, \omega_i | \mathbf{y}_{0:i-1}) =$$

$$\frac{1}{L_i} \lambda_i(x_i = k) \eta_i(z_i^{(k)} = l) \sum_{x_{i-1}} p(z_i, x_{i-1} | \mathbf{y}_{0:i-1})$$

其中,  $L_i = p(\mathbf{y}_i | \mathbf{y}_{0:i-1})$  为归一化常数.  $\lambda$  和  $\eta$  定义为

$$\begin{cases} \lambda_i(x_i = k) = p(x_i = k) p(o_i | x_i = k), \\ \quad k = 1, \dots, K \\ \eta_i(z_i^{(k)} = l) = \sum_{\omega_i^{(u,v)}} p(\omega_i^{(u,v)}) p(d_i | x_i = k), \\ \quad z_i^{(k)} = l, \omega_i^{(u,v)}, d_i, c_l = u, c_i = v, \\ \quad l = 0, \dots, i-1 \end{cases} \quad (11)$$

式 (10) 中状态变量  $(z_i, x_{i-1})$  的联合预测分布为

$$p(z_i, x_{i-1} = j | \mathbf{y}_{0:i-1}) =$$

$$\sum_{z_{i-1}} f(z_i | x_{i-1}, z_{i-1}) p(x_{i-1} = j, z_{i-1} | \mathbf{y}_{0:i-1}) =$$

$$\begin{cases} \sum_{z_{i-1}=0}^{i-2} p(x_{i-1} = j, z_{i-1} = m, z_i^{(-j)} = z_i^{(-j)} | \mathbf{y}_{0:i-1}), \\ \quad z_i^{(j)} = i-1, z_i^{(-j)} = 0, \dots, i-2 \\ 0, \quad \text{其他} \end{cases} \quad (12)$$

其中,  $(-j)$  表示非  $j$ . 根据式 (2), 在  $x_{i-1} = j$  的条件下只有当  $z_{i-1}^{(-j)} = z_i^{(-j)}$  时求和项非零, 这一条件极大地简化了上式中的求和运算. 式 (10)~(12) 定义了信念状态的完整更新过程.

由式 (10) 可知, 在第  $i$  次信念状态的更新过程中, 需要计算  $K^i K$  个状态的概率, 当目标和观测数目增大时, 计算量会急剧膨胀. 因此, 基于精确推理算法的视觉传感网络数据关联在计算上是不可行的, 必须要寻找相应的近似推理算法.

## 3 数据关联近似推理

为减小推理计算量, 可以将信念状态近似表示为某种因子分解形式. 具体地讲, 在第  $i$  次迭代计算中, 根据式 (10)~(12) 对近似信念状态进行更新, 再将更新后的信念状态近似为该因子分解形式, 接着进行下一步迭代. 文献 [13] 用 Kullback-Leibler (KL) 距离作为概率分布逼近误差测度, 并证明了在一定条件下离散状态变量联合分布的逼近误差不会随着迭代过程而累积. 本文将基于不同的独立性假设, 考虑两种不同的信念状态分解形式, 推导各自相应的近似推理算法, 并对不同算法运算复杂度进行分析和比较.

“活跃路径” (Active path)<sup>[14]</sup> 是分析贝叶斯网络中随机变量依赖关系的有力工具. 由图 2 可以看到, 相关随机变量通过如下三类活跃路径相互依赖:  $z_i^{(j)}$  和  $z_i^{(k)}$  通过路径  $z_i^{(j)} \rightarrow x_{i-1} \rightarrow z_i^{(k)}$  和  $z_i^{(j)} \rightarrow \mathbf{y}_i \rightarrow z_i^{(k)}$  相互依赖;  $x_i$  和  $z_i^{(k)}$  通过路径  $x_i \rightarrow \mathbf{y}_i \rightarrow z_i^{(k)}$  相互依赖. 由观测模型可知, 当给定  $x_i$  时, 第二类活跃路径自动消失. 在第一种近似推理方法中, 忽略所有活跃路径; 而在第二种近似推理中, 忽略第一类路径, 而保留其余两类.

### 3.1 近似推理算法 I

假定信念状态中的各变量相互独立, 可以将其

分解为  $x_i$  和  $z_i^{(k)}$  的边缘分布的乘积

$$p(x_i, z_i | \mathbf{y}_{0:i}) \approx \tilde{p}(x_i, z_i | \mathbf{y}_{0:i}) = p(x_i | \mathbf{y}_{0:i}) \prod_{k=1}^K p(z_i^{(k)} | \mathbf{y}_{0:i}) \quad (13)$$

关联变量  $x_i$  的边缘分布为

$$p(x_i = k | \mathbf{y}_{0:i}) = \frac{1}{L_i} \lambda_i(x_i = k) \sum_{z_i} \eta_i(z_i^{(k)} = l) p(z_i | \mathbf{y}_{0:i-1}) = \frac{1}{L_i} \lambda_i(x_i = k) \sum_{z_i^{(k)}} \eta_i(z_i^{(k)} = l) \times \sum_{x_{i-1}} p(z_i^{(k)} = l, x_{i-1} | \mathbf{y}_{0:i-1}) \quad (14)$$

辅助变量  $z_i^{(k)}$  的边缘分布为

$$p(z_i^{(k)} = l | \mathbf{y}_{0:i}) = \frac{1}{L_i} \sum_{x_i} \sum_{z_i^{(-k)}} \lambda_i(x_i = k) \eta_i(z_i^{(k)} = l) p(z_i | \mathbf{y}_{0:i-1}) = \frac{1}{L_i} \lambda_i(x_i = k) \eta_i(z_i^{(k)} = l) \sum_{x_{i-1}} p(z_i^{(k)} = l, x_{i-1} | \mathbf{y}_{0:i-1}) + \frac{1}{L_i} \sum_{x_i=1, x_i \neq k}^K \lambda_i(x_i = j) \sum_{z_i^{(j)}} \eta_i(z_i^{(j)} = m) \sum_{x_{i-1}} p(z_i^{(j)} = m, z_i^{(k)} = l, x_{i-1} | \mathbf{y}_{0:i-1}) \quad (15)$$

在式 (14) 和式 (15) 中存在两种预测分布, 其中  $(z_i^{(k)}, x_{i-1})$  的联合预测分布为

$$p(z_i^{(k)} = l, x_{i-1} = n | \mathbf{y}_{0:i-1}) = \sum_{z_{i-1}^{(k)}} f(z_i^{(k)} = l | x_{i-1} = n, z_{i-1}^{(k)}) \times p(x_{i-1} = n, z_{i-1}^{(k)} | \mathbf{y}_{0:i-1}) = \begin{cases} p(x_{i-1} = k | \mathbf{y}_{0:i-1}), & n = k, l = i - 1 \\ p(x_{i-1} = n | \mathbf{y}_{0:i-1}) p(z_{i-1}^{(k)} = l | \mathbf{y}_{0:i-1}), & n \neq k, l = 0, \dots, i - 2 \\ 0, & \text{其他} \end{cases} \quad (16)$$

$(z_i^{(k)}, z_i^{(j)}, x_{i-1})$  的联合预测分布为

$$p(z_i^{(j)} = m, z_i^{(k)} = l, x_{i-1} = n | \mathbf{y}_{0:i-1}) = \sum_{z_{i-1}^{(j)}} \sum_{z_{i-1}^{(k)}} f(z_i^{(j)} = m, z_i^{(k)} = l | x_{i-1} = n, z_{i-1}^{(j)}, z_{i-1}^{(k)}) \times p(x_{i-1} = n, z_{i-1}^{(j)}, z_{i-1}^{(k)} | \mathbf{y}_{0:i-1}) = \begin{cases} p(x_{i-1} = j | \mathbf{y}_{0:i-1}) p(z_{i-1}^{(k)} = l | \mathbf{y}_{0:i-1}), & n = j, m = i - 1, l = 0, \dots, i - 2 \\ p(x_{i-1} = k | \mathbf{y}_{0:i-1}) p(z_{i-1}^{(j)} = m | \mathbf{y}_{0:i-1}), & n = k, m = 0, \dots, i - 2, l = i - 1 \\ p(x_{i-1} = n | \mathbf{y}_{0:i-1}) p(z_{i-1}^{(j)} = m | \mathbf{y}_{0:i-1}) \times p(z_{i-1}^{(k)} = l | \mathbf{y}_{0:i-1}), & n \neq j, n \neq k, m = 0, \dots, i - 2, l = 0, \dots, i - 2 \\ 0, & \text{其他} \end{cases} \quad (17)$$

以上两式利用了式 (13) 中的独立性假设. 根据式 (14)~(17) 对信念状态进行第  $i$  次更新时, 只需计算  $K + Ki$  个状态的概率, 极大地简化了计算.

### 3.2 近似推理算法 II

由图 2 可知, 关联变量  $x_i$  和辅助变量  $z_i$  之间通过观测  $y_i$  相互依赖. 因此在对信念状态近似过程中, 我们保留  $x_i$  和  $z_i$  的相关性, 同时假定  $z_i^{(j)}$  和  $z_i^{(k)}$  在给定  $x_i$  时条件独立. 此时信念状态分解为

$$p(x_i, z_i | \mathbf{y}_{0:i}) \approx \tilde{p}'(x_i, z_i | \mathbf{y}_{0:i}) = p(x_i | \mathbf{y}_{0:i}) \prod_{k=1}^K p(z_i^{(k)} | x_i, \mathbf{y}_{0:i}) \quad (18)$$

关联变量  $x_i$  的边缘分布仍如式 (14) 所示.  $x_i$  和  $z_i^{(k)}$  的联合后验概率为

$$p(x_i = j, z_i^{(k)} = l | \mathbf{y}_{0:i}) = \frac{1}{L_i} \lambda_i(x_i = j) \sum_{z_i^{(-k)}} \eta_i(z_i^{(j)} = m) p(z_i | \mathbf{y}_{0:i-1}) = \begin{cases} \frac{1}{L_i} \lambda_i(x_i = k) \eta_i(z_i^{(k)} = l) \times \sum_{x_{i-1}} p(z_i^{(k)} = l, x_{i-1} | \mathbf{y}_{0:i-1}), & j = k \\ \frac{1}{L_i} \lambda_i(x_i = j) \sum_{z_i^{(j)}} \eta_i(z_i^{(j)} = m) \times \sum_{x_{i-1}} p(z_i^{(j)} = m, z_i^{(k)} = l, x_{i-1} | \mathbf{y}_{0:i-1}), & j \neq k \end{cases} \quad (19)$$

在式 (18) 给出的独立性假设下, 式 (16) 变为

$$p(z_i^{(k)} = l, x_{i-1} = n | \mathbf{y}_{0:i-1}) = \begin{cases} p(x_{i-1} = k | \mathbf{y}_{0:i-1}), & n = k, l = i - 1 \\ p(x_{i-1} = n, z_{i-1}^{(k)} = l | \mathbf{y}_{0:i-1}), & n \neq k, l = 0, \dots, i - 2 \\ 0, & \text{其他} \end{cases} \quad (20)$$

式 (17) 变为

$$p(z_i^{(j)} = m, z_i^k = l, x_{i-1} = n | \mathbf{y}_{0:i}) = \begin{cases} p(x_{i-1} = j, z_{i-1}^{(k)} = l | \mathbf{y}_{0:i-1}), & n = j, m = i - 1, l = 0, \dots, i - 2 \\ p(x_{i-1} = k, z_{i-1}^{(j)} = m | \mathbf{y}_{0:i-1}), & n = k, m = 0, \dots, i - 2, l = i - 1 \\ \frac{p(z_{i-1}^{(j)} = m, x_{i-1} = n | \mathbf{y}_{0:i-1}) p(z_{i-1}^{(k)} = l, x_{i-1} = n | \mathbf{y}_{0:i-1})}{p(x_{i-1} = n | \mathbf{y}_{0:i-1})}, & n \neq j, n \neq k, m = 0, \dots, i - 2, \\ & l = 0, \dots, i - 2 \\ 0, & \text{其他} \end{cases} \quad (21)$$

根据式 (19)~(21) 更新信念状态时, 需要计算  $K + K^2i$  个状态的概率, 尽管计算量有所增加, 但仿真结果表明推理精度可以得到大幅度的提高。

#### 4 未知外观模型情况

在上述讨论中, 我们假定目标的外观模型已知. 而在实际应用中, 这一假定往往是不成立的. 目标的外观模型参数  $\mu_k$  和  $\sigma_k$  需要根据观测数据进行估计. 如果每个观测对应的目标标号已知, 则外观模型估计问题很容易解决. 然而, 确定每个观测对应的目标标号正是数据关联要解决的问题. 本节中, 我们将目标标号作为缺失数据<sup>[15]</sup>, 将前面给出的推理算法与传统 EM 算法相结合, 提出一种扩展 EM 算法框架, 以同时解决数据关联和外观模型参数估计问题.

如图 3 所示, 模型参数记为  $\Theta := \{\alpha_k, \mu_k, \sigma_k\}_{k=1}^K$ , 其中  $\alpha_k = p(x_i = k)$  为第  $i$  个观测对应的目标标号为  $k$  的先验概率,  $\mu_k$  和  $\sigma_k$  分别为目标  $k$  的外观均值和方差. 在 E 步中, 我们采用前面所述的推理算法, 根据上一次 EM 迭代输出的模型参数  $\Theta^{\text{old}}$  计算每一个观测对应的关联变量的后验概率, 即  $p(x_i | \mathbf{y}_{0:i}, \Theta^{\text{old}})$ . 在 M 步中, 按下式对

模型参数进行估计:

$$\begin{cases} \alpha_k^{\text{new}} = \frac{1}{N} \sum_{i=1}^N p(x_i = k | \mathbf{y}_{0:N}, \Theta^{\text{old}}) \\ \mu_k^{\text{new}} = \frac{\sum_{i=1}^N o_i p(x_i = k | \mathbf{y}_{0:N}, \Theta^{\text{old}})}{\sum_{i=1}^N p(x_i = k | \mathbf{y}_{0:N}, \Theta^{\text{old}})} \\ \sigma_k^{\text{new}} = \frac{\sum_{i=1}^N p(x_i = k | \mathbf{y}_{0:N}, \Theta^{\text{old}}) (o_i - \mu_k^{\text{new}}) (o_i - \mu_k^{\text{new}})^T}{\sum_{i=1}^N p(x_i = k | \mathbf{y}_{0:N}, \Theta^{\text{old}})} \end{cases} \quad (22)$$




图 3 扩展 EM 算法框架

Fig. 3 The extended EM framework

上述 EM 算法可以看作是对高斯混合模型标准 EM 算法<sup>[16]</sup> 的推广. 在本文的 EM 算法中, 计算关联变量的后验概率时, 同时用到了外观观测和时空观测信息; 而在标准 EM 算法中, 只用到目标外观观测. 在仿真实验中将看到, 时空观测信息的加入使得 EM 算法更容易收敛到参数的真实值.

#### 5 仿真结果

为了生成仿真数据, 首先定义如图 1 所示的视频传感网络模型和相应的参数矩阵  $A$ , 以及每个目标的外观模型. 对于第  $k$  个目标, 随机选取起始节点, 根据  $\pi_{uv}$  生成该目标的运动路径. 在路径经过的每个节点上, 根据该目标的外观模型生成外观观测  $o$ , 再根据参数  $t_{uv}$  和  $s_{uv}$  生成时空观测  $d$ . 按此过程生成所有目标的观测数据后, 再按时间顺序对观测进行排序, 最终得到观测数据集  $\mathbf{y} = \{o_i, d_i, c_i\}_{i=1}^N$ . 为了验证算法在漏检条件下的有效性, 按照漏检率在上述观测集合中随机删除若干观测数据, 数据关联准确率指标  $q$  按下式计算:

$$q = \frac{1}{K} \sum_{k=1}^K q_k, \quad q_k = \frac{|\bar{Y}_k \cap Y_k|}{|Y_k|} \times 100\% \quad (23)$$

其中,  $K$  为目标数,  $\bar{Y}_k$  为来自于目标  $k$  的真实的观测集合;  $Y_k$  为由关联算法确定的来自于目标  $k$  的观

测集合.

### 5.1 高阶时空模型与传统时空模型比较

为了验证高阶时空模型处理漏检问题时的效果,在假定外观模型已知的条件下,采用精确推理算法,比较了基于不同阶数时空模型的数据关联结果,如表 1 所示.由表 1 可见,当漏检数逐渐增大时,基于传统时空观测模型的数据关联准确率迅速下降,而基于高阶时空观测模型的数据关联算法则对漏检表现出很强的鲁棒性.

表 1 漏检条件下基于不同阶数时空观测模型的数据关联平均准确率 (%)

Table 1 The average accuracy of exact inference in case of missing detection (%)

漏检数	1	2	4	8
0 阶模型	87.37	85.00	81.69	75.55
1 阶模型	92.49	90.51	85.18	82.15
2 阶模型	91.16	89.43	88.13	82.18

图 4 给出了其中一次仿真运行中关联变量边缘分布的推理结果.在图 4 中共有 4 个目标产生的 40 个观测,其中第 24 和 34 个观测发生漏检,用虚线框表示.图中每一列表示一个观测对应的关联变量的边缘分布,灰度对应概率值,纯黑代表概率为 1,纯白代表概率为 0.该观测对应目标的真实标号用星号表示.由图 4(a) 可见,当采用传统时空模型时,由于推理误差的传播,发生漏检后有大量的观测标号被误判,导致数据关联的准确率只有 73.61%.而采用一阶时空模型时,在发生漏检后推理算法仍能

准确判断观测对应的目标标号,使整个关联准确率达到 92.73%,如图 4(b) 所示.


### 5.2 精确推理与近似推理算法的比较

为了验证近似推理算法的性能,我们对高阶时空模型下不同推理算法的计算结果进行了分析比较.图 5 给出了在一阶时空模型下采用精确推理和两种近似推理算法得出的关联变量边缘分布,其中第 3, 10, 23 和 25 个观测发生漏检.仿真结果是在假设外观模型参数已知条件下得到的.由图 5 可以看到,近似推理算法 II 与精确推理给出的边缘分布几乎相同,而近似推理算法 I 与精确推理给出的结果却有显著的差别.在本次仿真中,精确推理和近似推理 II 的关联准确率均为 97.50%,而近似推理 I 仅为 86.11%.

为了定量比较两种近似推理算法的推理误差,我们计算了不同的近似推理算法与精确推理算法给出的关联变量边缘分布之间的 KL 距离. KL 距离计算式如下:


$$D[p(x_i) \parallel \hat{p}(x_i)] := \sum_{x_i} p(x_i) \ln \frac{p(x_i)}{\hat{p}(x_i)} \quad (24)$$

共对 25 组观测数据进行了计算,每组数据中包含 40 个观测,将每组观测计算得到的 KL 距离数据拼接起来,如图 6 所示.近似推理 I 与精确推理给出的边缘分布之间的 KL 距离如图 6(a) 所示,其均值为 1.1727;而近似推理 II 与精确推理给出的边缘分布之间的 KL 距离明显小于前者,其均值为 0.3933,且具有更少的毛刺,如图 6(b) 所示,说明推理算法 II 在推理精度上更接近于精确推理.



(a) 零阶时空模型

(a) 0-order spatio-temporal model



(b) 一阶时空模型

(b) 1-order spatio-temporal model

图 4 关联变量边缘分布的精确推理结果

Fig. 4 Marginal distributions of labeling variable in exact inference

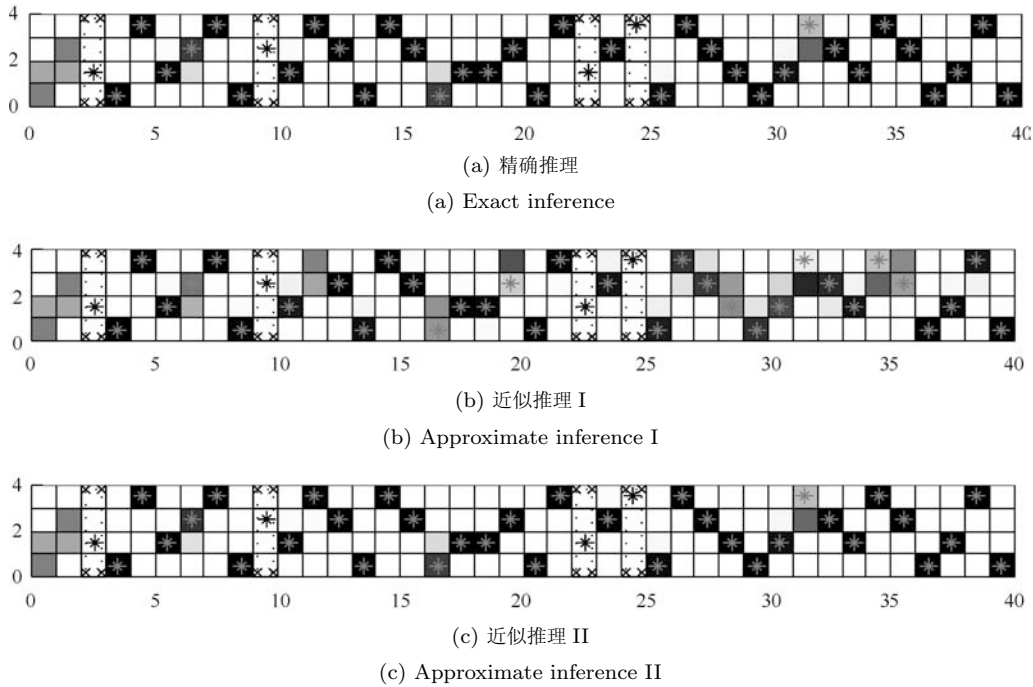


图 5 一阶时空模型下关联变量边缘分布推理结果

Fig. 5 Marginal distributions of labeling variable in inference with 1-order spatio-temporal model




图 6 近似推理与精确推理结果之间的 KL 距离

Fig. 6 KL divergence caused by approximate inference

### 5.3 外观模型未知情况下的结果

为了验证在外观模型未知条件下各种推理算法的效果, 我们将不同的推理算法嵌入 EM 算法框架计算关联变量后验概率, 对不同规模的观测数据集进行数据关联. 在标准 EM 算法<sup>[16]</sup>中, 关联变量后验概率按下式计算:

$$p(x_i = k | o_i, \Theta) = \frac{N(o_i; \mu_k, \sigma_k^2)}{\sum_j N(o_i; \mu_j, \sigma_j^2)} \quad (25)$$

表 2 和表 3 分别给出了各种数据关联推理算法

的平均准确率和一次 EM 迭代的平均计算时间. 表中数据为 100 次仿真实验结果的平均值, 在每次仿真中, 根据漏检率随机删除若干观测. 推理算法采用一阶时空模型, EM 算法中外观参数的初始值随机设定. 由表 2 可见, 相比于标准 EM 算法, 引入时空观测后使得数据关联准确率得到大幅提高, 其中精确推理算法具有最高的准确率. 然而, 由表 3 可见, 精确推理的运算时间随着观测数据的增加迅速增加, 当观测数据增加到  $4 \times 20$  (4 个目标, 每个目标 20 个观测) 时, 由于超出了内存限制使精确推理算法无法运行. 近似推理算法可以有效地降低运算复杂度,



由表 2 和表 3 可见, 近似算法 II 虽然比近似算法 I 慢一些, 但其推理精度几乎接近于精确算法, 表现出明显的优势.

表 2 在不同观测集合下数据关联的平均准确率 (%)

Table 2 The average accuracy of inference algorithms under different numbers of observations (%)

观测数目	标准 EM	精确推理	近似推理 I	近似推理 II
$3 \times 10$	63.28	84.37	72.21	82.79
$3 \times 20$	59.02	81.78	70.86	80.38
$4 \times 20$	53.82	<i>x</i>	70.07	82.66
$5 \times 20$	57.04	<i>x</i>	65.58	85.69

图 7 给出了由不同的推理算法计算关联变量后验概率时, EM 算法对外观模型参数的估计结果, 四个目标外观均值的真实值分别为 7, 10.5, 13.5, 17. 仿真结果表明, 采用精确推理和近似推理算法 II 计算关联变量后验概率时, EM 算法可以准确地估计

外观模型参数, 如图 7(b) 和 7(d); 而当采用式 (23) 和近似推理 I 计算关联变量后验概率时, EM 算法很容易陷入局部极大值, 如图 7(a) 和 7(c).

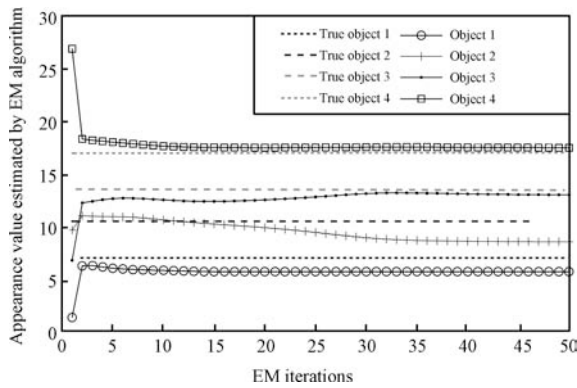
表 3 在不同观测集合下一次 EM 迭代平均计算时间 (s)

Table 3 Running time of inference algorithms under different numbers of observations (s)

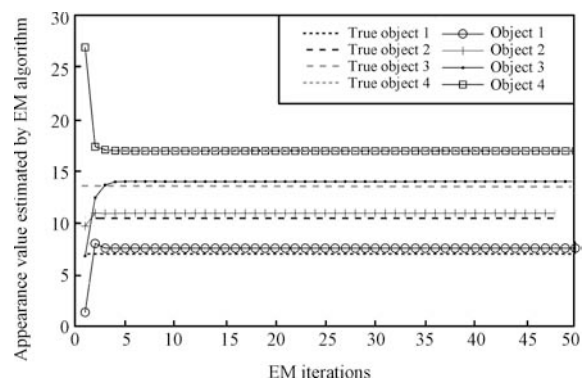
观测数目	标准 EM	精确推理	近似推理 I	近似推理 II
$3 \times 10$	0.0018	4.9809	0.1066	1.3130
$3 \times 20$	0.0036	73.4384	1.3776	8.2304
$4 \times 20$	0.0053	<i>x</i>	7.9897	41.750
$5 \times 20$	0.0076	<i>x</i>	29.992	149.49

### 6 实验结果

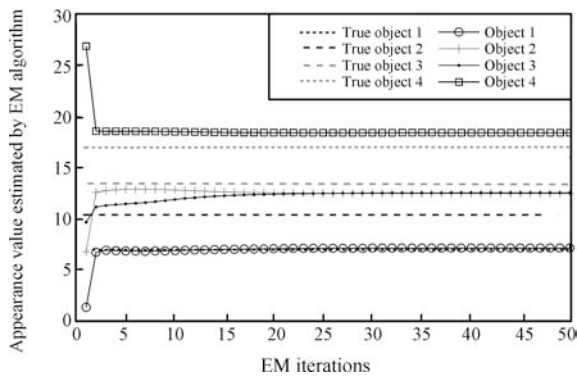
为了验证算法的实际效果, 我们在学校主楼内进行了视觉传感网络行人跟踪实验. 共设置了 6 个观测点以获取视频数据, 摄像机布局如图 8 所示.



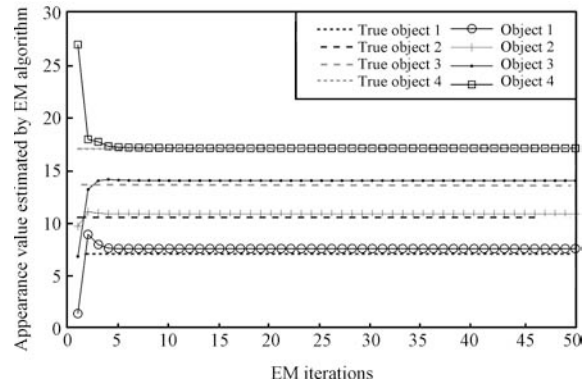
(a) 标准 EM  
(a) Standard EM



(b) 精确推理  
(b) Exact inference



(c) 近似推理 I  
(c) Approximate inference I



(d) 近似推理 II  
(d) Approximate inference II

图 7 不同推理算法结合 EM 的参数估计曲线

Fig. 7 Parameter learning curves of EM with different inference algorithms




图 8 行人跟踪实验摄像机布局

Fig.8 Experiment setup

对每段视频数据进行目标检测和特征提取后,共得到 5 个人的 75 个观测数据,每个观测数据由时空观测和外观观测组成.其中外观观测由提取到的目标的上、中、下三部分区域的 RGB 分量的均值构成,时空观测为摄像机编号、目标捕获时间以及目标在摄像机视场内的运动方向.在观测数据集中人为删除 10 个观测以检验漏检情况下算法性能.

在实验过程中发现,不同行人的运动速度具有较大的差别,同时行人在摄像头观测节点之间可能出现间歇性停顿,这些因素增大了节点间运动时间的方差,从而降低了时空观测对不同目标的分辨能力.因此,在实验中除了考虑目标捕获时间外,还将目标在摄像机视场内的运动方向也作为时空观测<sup>[5]</sup>.对应于运动方向观测的高阶时空模型可根据摄像机布局结构手工建立,在此不再赘述.改进后的时空模型可以方便地纳入本文提出的数据关联方法框架中.

在上述行人跟踪系统中,理想的轨迹重构算法应满足: 1) 划分为同一轨迹的观测应来自于同一个目标; 2) 来自于同一目标的观测应被划分到同一轨迹中.据此,我们采用如下三个指标来衡量轨迹重构效果<sup>[11]</sup>:

1) 准确率  $q$ , 可按式 (23) 计算;

2) 复杂度  $r$ :

$$r = \frac{1}{K} \sum_{k=1}^K r_k, \quad r_k = \frac{|\bar{Y}_k \cap Y_k|}{|\bar{Y}_k|} \cdot 100\% \quad (26)$$

3)  $F_1$  测度:

$$F_1 = \frac{2 \cdot q \cdot r}{q + r} \quad (27)$$

上式中各变量的含义与式 (23) 相同.表 4 给出不同的推理算法与 EM 相结合时的轨迹重构结果.图 9 给出了不同算法得到的重构轨迹,每一行对应一个行人的轨迹.由图 9 可见,由于光照等观测条件的变化,同一行人在不同摄像机节点处的外观有较大的差别.因此,单纯基于外观的推理,即标准 EM 算法的重构轨迹存在较大的误差.MCMC 算法目前被广泛用于多目标跟踪数据关联中<sup>[8-9]</sup>,该算法同时利用外观与时空观测信息进行数据关联推理,我们将 MCMC 推理与 EM 算法相结合,轨迹重构结果如图 9 (b) 所示,可以看出该算法并不能达到理想的轨迹重构效果.图 9 (c) 和 9 (d) 给出了采用本文提出的近似推理算法与 EM 相结合得到的重构轨迹,可以看到近似推理算法 II 能够有效地利用时空观测信息,使得每个行人的运动轨迹都能被可靠地重构.

表 4 不同数据关联算法的轨迹重构结果 (%)

Table 4 Recovered trajectories results of different association algorithms (%)

算法种类	准确率	复现度	$F_1$ 测度
标准 EM	63.07	55.23	58.89
MCMC	64.67	53.90	58.79
近似推理 I	71.60	57.56	63.82
近似推理 II	88.46	88.46	88.46

## 7 结论

本文主要研究视觉传感网络中的数据关联问题,针对漏检问题提出高阶时空观测模型,同时给出数据关联精确推理算法和两种近似推理算法,最后将推理算法与 EM 算法相结合以解决外观模型参数未知的问题,仿真和实验结果表明本文所提方法的有效性.本文的研究主要集中于前向推理算法,将其与在线 EM 算法<sup>[17]</sup>相结合可实现在线数据关联.我们对视觉传感网络数据关联后向推理方法也进行了深入研究,由于能够充分利用将来的观测数据,后向推理比前向推理具有更高的准确率,但运算复杂度也相应提高,且无法实现在线数据关联.有兴趣的读者可参阅文献 [18].

值得注意的是,在本文的研究中,进行数据关联需要将全部观测数据集中到统一的信息处理节点上进行处理,这种集中式结构不适宜于大规模视觉传感网络的应用.在进一步的工作中,将研究如何将本文的结果进行推广,实现分布式数据关联.

## 致谢

作者对参与视觉传感网络行人跟踪实验的全体研究生志愿者表示感谢.

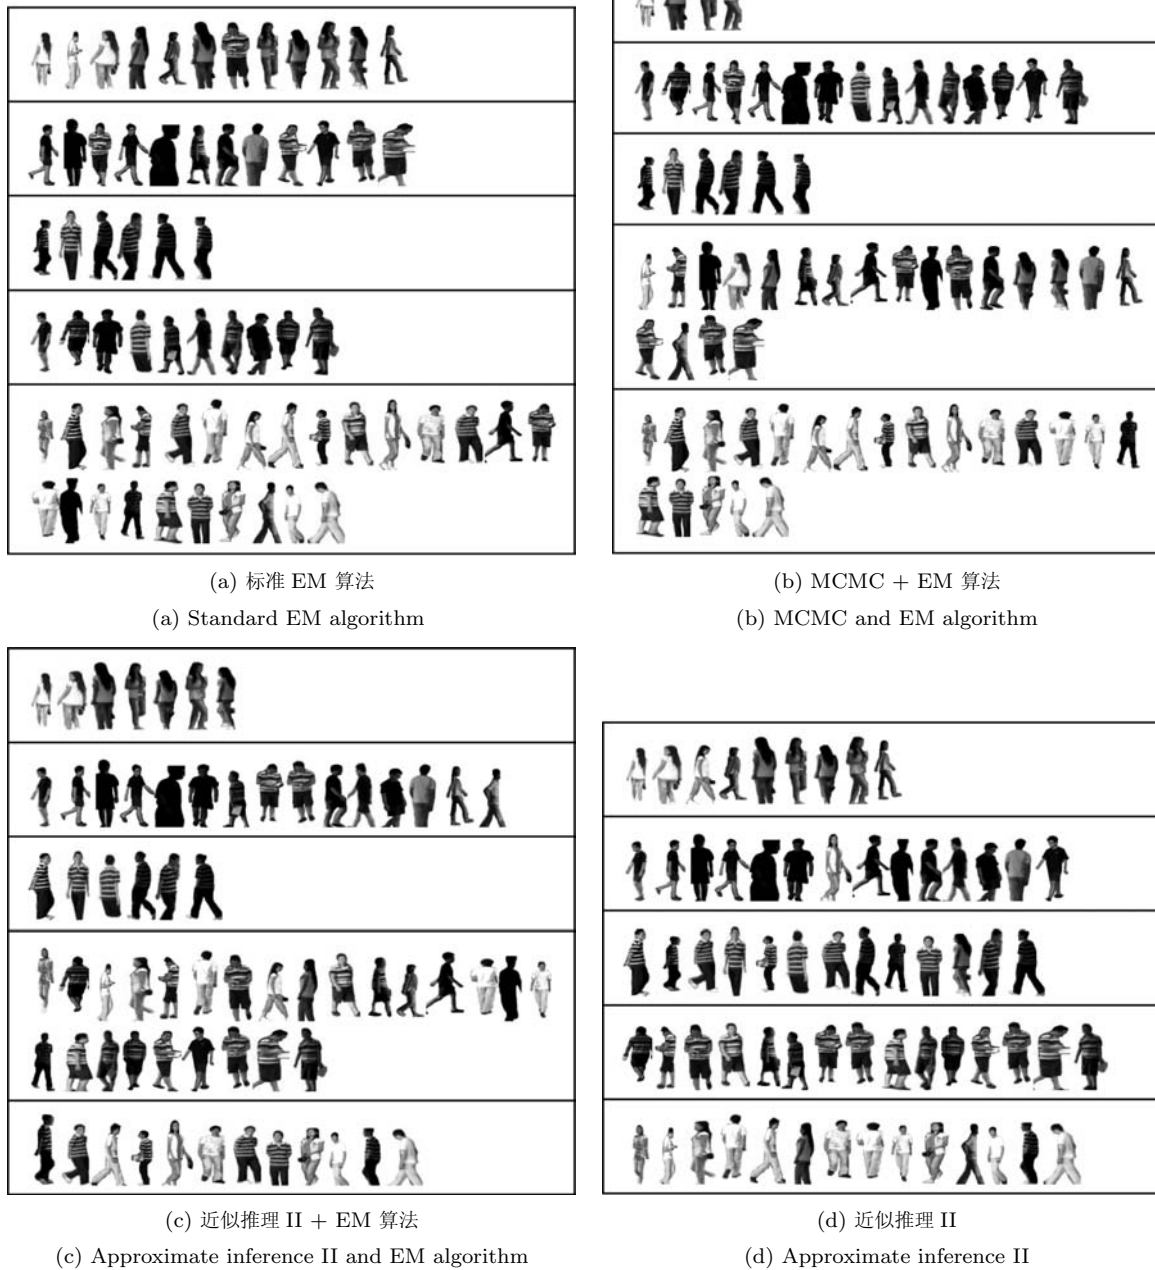


图 9 视觉传感网络行人跟踪实验结果

Fig. 9 Experimental results in visual sensor network

## References

- Gilbert A, Bowden R. Tracking objects across cameras by incrementally learning inter-camera color calibration and patterns of activity. In: Proceedings of the 9th European Conference on Computer Vision. Graz, Austria: Springer, 2006. 125–136
- Javed O, Shafique K, Rasheed Z, Shah M. Modeling inter-camera space-time and appearance relationships for tracking across non-overlapping views. *Computer Vision and Image Understanding*, 2008, **109**(2): 146–162
- Song B, Roy-Chowdhury A K. Robust tracking in a camera network: a multi-objective optimization framework. *IEEE Journal of Selected Topics in Signal Processing*, 2008, **2**(4): 582–596
- Liu Shao-Hua, Lai Shi-Ming, Zhang Mao-Jun. A min-cost flow based algorithm for objects association of multiple non-overlapping cameras. *Acta Automatica Sinica*, 2010, **36**(10): 1484–1489  
(刘少华, 赖世铭, 张茂军. 基于最小费用流模型的无重叠视域多摄像机目标关联算法. *自动化学报*, 2010, **36**(10): 1484–1489)
- Zajdel W, Klose B. A sequential Bayesian algorithm for


- surveillance with nonoverlapping cameras. *International Journal of Pattern Recognition and Artificial Intelligence*, 2005, **19**(8): 977–996
- 6 Camp F, Bernardin K, Stiefelhagen R. Person tracking in camera networks using graph-based Bayesian inference. In: Proceedings of the 3rd ACM/IEEE International Conference on Distributed Smart Cameras. Como, Italy: IEEE, 2009. 1–8
  - 7 Kim H, Romberg J, Wolf W. Multi-camera tracking on a graph using Markov chain Monte Carlo. In: Proceedings of the 3rd ACM/IEEE International Conference on Distributed Smart Cameras. Como, Italy: IEEE, 2009. 1–8
  - 8 Oh S, Russell S, Sastry S. Markov chain Monte Carlo data association for multi-target tracking. *IEEE Transactions on Automatic Control*, 2009, **54**(3): 481–497
  - 9 Goyat Y, Chateau T, Bardet F. Vehicle trajectory estimation using spatio-temporal MCMC. *EURASIP Journal on Advances in Signal Processing*, **2010**: Article ID 712854, 8 pages
  - 10 Zajdel W, Klose B. Gaussian mixture models for multi-sensor tracking. In: Proceedings of the 15th Dutch-Belgian Artificial Intelligence Conference. Nijmegen, Netherlands: BNAIC, 2003. 371–378
  - 11 Zajdel W. Bayesian Visual Surveillance: from Object Detection to Distributed Cameras [Ph. D. dissertation], University of Amsterdam, Netherlands, 2006
  - 12 Murphy K P. Dynamic Bayesian Networks: Representation, Inference and Learning [Ph. D. dissertation], University of California, Berkeley, USA, 2002
  - 13 Boyen X, Koller D. Tractable inference for complex stochastic processes. In: Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence. Madison, USA: Morgan Kaufmann, 1998. 33–42
  - 14 Shachter R D. Bayes-ball: the rational pastime (for determining irrelevance and requisite information in belief networks and influence diagrams). In: Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence. Madison, USA: Morgan Kaufmann, 1998. 480–487
  - 15 Dempster A P, Laird N M, Rubin D B. Maximum-likelihood from incomplete data via the EM algorithm. *Journal of Royal Statistics Society, Series B*, 1977, **39**(1): 1–38
  - 16 Bilmes J A. A Gentle Tutorial on the EM Algorithm and Its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models, Technical Report TR-97-021, University of California, Berkeley, USA, 1998
  - 17 Jepson A D, Fleet D J, El-maraghi T F. Robust online appearance models for visual tracking. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai, USA: IEEE, 2001. 415–422
  - 18 Wan J, Liu Q. Efficient data association in visual sensor networks with missing detection. *EURASIP Journal on Advances in Signal Processing*, 2011, **2011**: Article ID 176026, 25 pages



**万九卿** 北京航空航天大学自动化学院讲师。主要研究领域方向为信号/图像/视频处理, 统计推理与机器学习, 目标检测、跟踪与识别, 复杂系统故障诊断与健康管理。本文通信作者。

E-mail: wanjiuqing@gmail.com

**(WAN Jiu-Qing** Lecturer at the School of Automation, Beijing University of Aeronautics and Astronautics. His research interest covers signal/image/video processing, statistical inference and machine learning, target detection, tracking and recognition, and fault diagnosis and prognosis of complex system. Corresponding author of this paper.)



**刘青云** 北京航空航天大学自动化学院硕士研究生。主要研究方向为数字图像处理和目标跟踪。

E-mail: cnliuqingyun@gmail.com

**(LIU Qing-Yun** Master student at the School of Automation, Beijing University of Aeronautics and Astronautics. Her research interest covers digital signal processing and target tracking.)