

基于抽象隐马尔可夫模型的 CGF 路径规划识别*

岳师光, 查亚兵, 尹全军, 张 琪

(国防科技大学 信息系统与管理学院, 湖南 长沙 410073)

摘要: 路径规划识别是一种以位置信息为输入的在线识别。为了使 CGF 能在仿真中识别对手的路径和终点目标, 在分析路径规划层次的基础上引入了抽象隐马尔可夫模型的识别框架。针对标准模型在对手更改终点目标和自上而下规划时无法识别的问题, 提出了一种顶层策略可变的抽象隐马尔可夫模型。为模型的顶层策略增加初始分布和策略终止变量, 更改了策略终止变量间的依赖关系, 使下层策略能被强制终止。给出了改进后 DBN 结构, 并通过推导条件概率更新和 RB 变量抽样流程实现了模型的近似推理。仿真实验表明, 改进模型能准确识别给定环境下的各类型航迹, 不仅在终点目标不变时能较好地维持标准模型的识别准确率, 在提供足够的观测数据后还能很好地解决变目标识别问题。

关键词: 计算机生成兵力; 规划识别; 路径规划; 抽象隐马尔可夫模型

中图分类号: TP181 **文献标志码:** A **文章编号:** 1001-2486(2014)01-0148-06

Path plan recognition by CGF based on abstract hidden Markov model

YUE Shiguang, ZHA Yabing, YIN Quanjun, ZHANG Qi

(College of Information System and Management, National University of Defense Technology, Changsha 410073, China)

Abstract: Path plan recognition has been a kind of online recognition using positions as inputs. To allow CGF to recognize opponents' paths and destinations in simulation, a recognition framework of Abstract Hidden Markov Model is introduced following analyzing the hierarchy of path plan. Since it is difficult to recognize the path plans using standard model when destinations are changed and plans are executed from top to bottom, the Abstract Hidden Markov Model with Changeable Top-level Policy is proposed. The initial distribution and termination variables of top policy were given and the relations between policy termination variables were adjusted to allow the lower policy for a forced termination. The modified DBN structure was presented, and the approximate inference was realized by deducing processes of updating conditional probability and sampling RB variables as well. Simulation experiments show that different kinds of typical paths in specific environment can be recognized efficiently with this method. The modified model not only confirms good recognition accuracy compared with the standard model under the circumstance when destination is not changing, but also performs well in solving destination changing path plan recognition problems with sufficient observation data provided.

Key words: computer generated forces; plan recognition; path plan; abstract hidden markov model

计算机生成兵力(Computer Generated Forces, CGF)是指仿真环境中由计算机生成和控制的仿真实体。通过对人类行为的充分建模, 这些实体能自主地对仿真环境中的事件和状态做出反应^[1]。在 CGF 行为建模过程中, CGF 的决策不但要考虑自身状况, 还要依据情报对其他实体的规划进行判断和预测, 因此规划识别(Plan Recognition, PR)是 CGF 自主参与仿真的前提。规划识别(也称意图识别, 策略识别)指通过观察对象实体的行为和状态序列判断其当前所执行的规划^[2]。路径规划识别(Path Plan Recognition,

PPR)是规划识别的一类, 即依据对象实体的运动轨迹, 判断其规划的路径和终点目标。PPR 在即时战略游戏和仿真对抗中具有重要的应用价值, 具备 PPR 能力的 CGF 在识别敌方实体的路径规划后, 能进行更有针对性的规划和决策。

尽管规划识别已被广泛应用于即时战略游戏^[3-4]、安全监控^[5]、战术辅助决策^[6]等领域, 但单独讨论路径规划识别的研究较少。与任务规划识别(Task Plan Recognition, TPR)相比, PPR 具有一定特殊性。一方面, PPR 是典型的在线识别(Online Plan Recognition, OPR), 即每获得一次新

* 收稿日期: 2013-06-06

基金项目: 国家自然科学基金资助项目(91024030)

作者简介: 岳师光(1987—), 男, 吉林长春人, 博士研究生, E-mail: yshg052@gmail.com;

查亚兵(通信作者), 男, 教授, 博士, 博士生导师, E-mail: zhayabing@139.com

的对象位置信息,就要对识别结果进行一次更新。另一方面,PPR 的输入信息是对象实体的状态(位置)信息,而非原子动作。因此使用层次隐马尔可夫模型^[7]、隐半马尔可夫模型^[8]、规划树语法^[9]等经典在线识别算法解决该类问题时,须另外构造动作识别模型,将状态序列转化为原子动作序列。这既增加了计算量,也容易造成信息丢失。还有一些经典算法虽将实体的状态序列作为输入,但仍存在一定不足。Pynadath 等^[10]在概率上下文无关语法(Probabilistic Context Free Grammars, PCFG)的基础上提出了概率状态依赖语法(Probabilistic State-Dependent Grammars, PSDG),并运用自然语言处理中的解析树进行规划识别,这种方法将状态序列作为输入,具有很强的描述客观世界的的能力,但 Bui 证明了 PSDG 的精确推理算法是不充分的^[11]。Avrahami-Zilberbrand 等^[12]提出了一种基于混合符号的概率规划识别算法,该算法通过引入逻辑判断降低了计算复杂度,并在改进后能够解决观测丢失、执行中断等特殊状况下的规划识别问题^[13],但其概率结果的计算实际上是基于层次隐马尔可夫模型的,观测的状态信息仍然要依赖特征决策树(Feature Decision Tree, FDT)才能转化为原子行动。

Bui^[14]在马尔可夫决策的基础上定义了抽象马尔可夫决策,提出了抽象隐马尔可夫模型(Abstract Hidden Markov Model, AHMM),通过 Rao-Blackwellisation 序贯重要性采样(RB-SIS)实现了模型的近似推理,并将 AHMM 应用于视频监控领域^[15-16]。此后,Bui 又通过引入记忆变量,在 AHMM 框架下解决了二阶马尔可夫决策中的策略识别问题^[17]。Saria 等运用 AHMM 研究了多 Agent 决策中的概率规划识别^[18]。

AHMM 适合解决 PPR 问题:第一,AHMM 无需单独构造模型来识别原子动作,其输入只包含识别对象的状态,这容易通过虚拟传感器获得;第二,一般情况下,路径规划结果只由当前位置和最终目标决定,因此路径规划具有马尔可夫性质;第三,由于 AHMM 允许观测误差,这降低了对航路点计算精度的要求,在无法计算航路点的情况下,仍然可以通过对地图进行分格来完成识别任务;第四,仿真系统能提供大量训练样本,这便于通过有监督的学习来完成 AHMM 的参数估计^[19]。

虽然 AHMM 具备以上优点,但直接将其用于 CGF 的 PPR 建模仍存在缺陷。一方面,AHMM 假设识别对象的顶层策略不变,但智能体在路径规划中可能由于状态或情报变更而改变终点目标

(顶层策略);另一方面,标准模型认为只有下层策略终止后上层策略才能结束,但实际路径规划时往往是自上而下的,下层策略是否终止应由上层策略决定而不是相反。

为了解决这两点不足,本文提出了一种顶层策略可变的 AHMM(AHMM with Changeable Top-level Policy, AHMM-CTP)。

1 可变目标路径规划与 AHMM

规划识别与应用背景密切相关,本文研究的背景是终点目标可变的全局路径规划。与其他规划问题相似,路径规划也具有层次化结构,其终点目标、运动方案和单段路径选择对应着 AHMM 框架中的各层策略。

1.1 可变目标路径规划

路径规划研究如何在几何空间中生成从初始出发点为目标点的几何路径。本文的研究背景是单架无人机(UCAV)选取固定地面目标进行攻击,出发点和每个目标点附近都有防空火力,无人机出发或打击目标均需穿越相应的防空区域。

规划过程中,无人机首先选定打击目标,再依据目标制定飞行方案,即确定需要通过防空区的次序。在单片防空区内,无人机根据防空火力的位置,基于 Voronoi 图计算航路点。到达新的航路点后,采用 Dijkstra 算法搜索当前飞行方案下(到达下一区域或终点目标)的最优路径,路径权重的计算方法参见文献^[20]。确定最优路径后,无人机既可能飞向最优航路点,也可能选择其他路径佯动。每次到达新的航路点时,无人机都以一定概率接收到返航命令,即以基地为终点目标。如此循环,直到返航或完成任务为止。由于无人机的路径选择只与当前位置有关,因此路径规划过程满足马尔可夫性质。

1.2 策略定义与路径规划

AHMM 将不同层次的规划定义为局部策略(Local Policy)和抽象策略(Abstract Policy)两类。设 A 为原子行动集, A 上的局部策略 π 是一个四元组 $[S, D, \beta, \sigma]$ 。其中, S 是当前策略 π 下的可用状态集, D 是执行策略 π 的目标状态集。 $\beta: D \rightarrow (0, 1]$ 为到达目标状态后终止 π 的概率,且 $\beta(d) = 1, \forall d \in D \setminus S$,即当智能体到达目标状态 d 后以概率 $\beta(d)$ 终止 π ,若 $d \notin S$,则 π 一定结束。 $\sigma: S \times A \rightarrow [0, 1]$ 为原子行动选择函数,代表智能体执行 π 时,在给定状态下选择某个可行原子动作的概率。

设 Π 为一个策略集, AHMM-CTP 在 Π 上定义的可变更抽象策略 π^* 是一个五元组 $\langle S_{\pi^*}, D_{\pi^*}, \beta_{\pi^*}, \sigma_{\pi^*}, \rho_{\pi^*} \rangle$ 。其中, $S_{\pi^*} \subset \cup_{\pi \in \Pi} S_{\pi}$ 是 π^* 的可用状态集, $D_{\pi^*} \subset \cup_{\pi \in \Pi} D_{\pi}$ 是 π^* 的目标状态集, $\beta_{\pi^*}: D_{\pi^*} \rightarrow (0, 1]$ 为到达目标状态 d 后终止策略 π^* 的概率。同理有 $\beta_{\pi^*}(d) = 1, \forall d \in D_{\pi^*} \setminus S_{\pi^*}$ 。 $\sigma_{\pi^*}: S_{\pi^*} \times \Pi \rightarrow [0, 1]$ 为策略选择函数, 代表智能体执行 π^* 时, 在给定状态下选择某个可行策略的概率。若 $\pi^* \in \Pi^K$, 即 π^* 为顶层策略, $\rho_{\pi^*}: S \times \Pi^K \rightarrow [0, 1]$ 给出了 π^* 终止后的初始分布。

原子行动和各级策略组成层次结构 $H = (\Pi_0, \Pi_1, \dots, \Pi_K)$, 其中 $\Pi_0 = A$ 为原子行动集, Π_1 为定义在 Π_0 上的局部策略集。以此类推, Π_k 为定义在 Π_{k-1} 上的抽象策略集 ($2 \leq k \leq K$), Π_K 为顶层策略集。

用 AHMM-CTP 描述 1.1 节中的规划方法时, 其最高策略层次 $K = 2$, Π_2 是终点目标的集合, Π_1 为穿过防空区的飞行方案, Π_0 则代表了无人机当前可用的单段路径集, s 即为航路点。因此, 无人机飞行过程中更改终点目标即对应着顶层策略 π^2 的终止和重新选择。航路点为 s 的情况下, $\sigma_{\pi^2}(s, \pi^1)$ 是飞行目标为 π^2 时选择飞行方案 π^1 的概率; $\sigma_{\pi^1}(s, \pi^0)$ 是飞行方案为 π^1 时选择单段路径 π^0 的概率; $\rho_{\pi^2}(s, \pi^2)$ 是目标 π^2 终止后新终点目标的初始分布。

1.3 自上而下的策略终止和选择

基于 AHMM 的识别框架是广义的动态贝叶斯网 (Dynamic Bayesian Network, DBN), 除 π_i^k 和 s_i 外, AHMM 还定义了布尔型变量 $e_i^k, e_i^k = T$ 代表 π_i^k 终止, $e_i^k = F$ 则 $\pi_i^k = \pi_{i-1}^k$ 。由于 AHMM-CTP 中智能体自上而下制定策略, 因此影响 e_i^k 的变量包括 π_i^k, π_i^{k+1} 和 s_i 。当 $k = K$ 时, e_i^K 仅受 s_i 和 π_i^K 影响, $Pr(e_i^K = T) = \beta_{\pi^K}(s_i)$ 表明顶层策略终止的概率。当 $k < K$ 时, e_i^k 受 s_i, π_i^k 和 π_i^{k+1} 影响, 此时又分为两种情况, 若 $e_i^{k+1} = T$ 则 $e_i^k = T$, 说明上层策略终止后下层策略被强制终止, 此时 e_i^k 为常量; 若 $e_i^{k+1} = F$, 则 $Pr(e_i^k = T) = \beta_{\pi_i^k}(s_i)$ 表明上层策略不变时下层策略终止的概率。原子行动在状态改变后都会终止, 即有 $e_i^0 = T$, 因此只有 s_i 和 π_i^1 影响 π_i^0 。

智能体对 π_i^k 的选择由 $s_i, \pi_i^{k+1}, \pi_{i-1}^k$ 和 e_{i-1}^k 决定。当 $e_{i-1}^k = F$ 时, π_{i-1}^k 在 t 时刻仍在执行, 因此 $\pi_i^k = \pi_{i-1}^k$ 。当 $e_{i-1}^k = T$ 时, 智能体根据 $\sigma_{\pi_i^k}(s_i, \pi_i^k)$ 选择 π_i^k 。特别当 $k = K$ 且 $e_{i-1}^k = T$ 时, π_i^{k+1} 的初始分布由 ρ_{π^K} 决定。图 1 给出了连续两个时间片内

AHMM-CTP 的 DBN 结构。

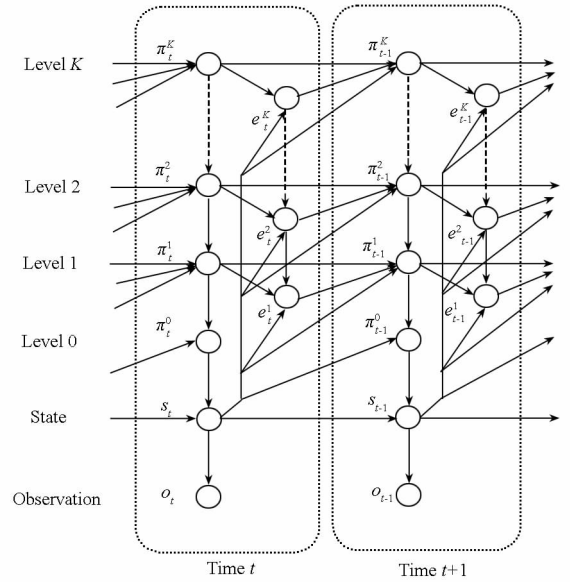


图 1 双时间片内的 DBN 结构

Fig. 1 DBN structure in double-time slices

Level 0 到 Level K 为不同层级的策略, State 为真实状态层, Observation 为观测状态层, 即 o_i 是 s_i 的观测值。Level K 到 Level 2 之间的依赖关系用虚线箭头省略表示。图 1 中单个时间片内策略终止变量间的影响关系与标准 AHMM 的 DBN 结构相反, 但仍允许定义变量 $l_i \in [0, K]$, 满足 $k \leq l_i$ 时 $e_i^k = T, k > l_i$ 时 $e_i^k = F$ 。这保证了新的 DBN 结构没有增加或减少 RB 变量, 因此原模型中的 RB-SIS 近似推理算法可以继承使用。

2 顶层策略可变 AHMM 的近似推理

AHMM 框架下的规划识别是一种在线识别, 它根据观测的历史状态数据计算下一时刻各个层次策略的分布, 即 $Pr(\pi_i^{0:K} | \tilde{o}_{i-1})$, 其中 $\tilde{o}_{i-1} = (o_1, o_2, \dots, o_{i-1})$ 。当仿真环境无观测噪声, $\tilde{l}_{i-1} = (l_1, l_2, \dots, l_{i-1})$ 已知时, 使用精确推理算法容易计算识别结果^[15]。但路径规划识别中往往难以获取精确的航路点, 也无法得知各个时刻执行的策略层次, 因此需要借助近似推理算法。

在改进网络参数更新步骤后, AHMM-CTP 仍可基于 RB-SIS 进行近似推理。记 $\tilde{s}_i = (s_1, s_2, \dots, s_i)$, RB 变量 $r_i = (s_i, l_i)$, 定义条件概率 $B_i = Pr(\pi_i^{all}, s_i, l_i, o_i | \tilde{s}_{i-1}, \tilde{l}_{i-1}), B_{i+} = Pr(\pi_i^{all} | \tilde{s}_i, \tilde{l}_i, o_i), C_i = Pr(\pi_i^{all}, s_i, o_i | \tilde{s}_{i-1}, \tilde{l}_{i-1})$ 。图 2 给出了 AHMM-CTP 单时间片内 C_i 和 B_i 的 DBN 结构。

由图 2 可知, C_i 是一种链式结构, 在链中存在一个节点 π_i^k 不被任何变量影响, 称 π_i^k 为 C_i 的 root, 也称 C_i 的根在 Level k 。又由于在同一时间片




图2 单时间片内的 DBN 结构

Fig. 2 DBN structure in single time slice

内 C_i 不被 e_i^k ($k = 1, 2, \dots, K$) 影响,因此可以将 B_i 进行因子化:

$$\begin{aligned} & Pr(\pi_i^{all}, s_i, l_i | \bar{s}_{i-1}, \bar{l}_{i-1}, o_i) \\ &= Pr(l_i | \pi_i^{all}, s_i) Pr(\pi_i^{all}, s_i | \bar{s}_{i-1}, \bar{l}_{i-1}, o_i) \\ &= Pr(l_i | \pi_i^{all}, s_i) C_i \end{aligned} \quad (1)$$

当 B_i 因子化后的所有条件概率已知时,计算 B_{i+1} 中的各个参数需要两个阶段:一是依据新获取的证据对 B_i 网络参数进行更新,即将 B_i 转为 B_{i+} ;二是将变量及依赖关系映射到下一个时间片,即将 B_{i+} 转为 C_{i+1} 。

本文计算 B_{i+1} 的第二阶段及 RB - SIS 流程与参考文献[15]相同,但图2的 DBN 结构与原模型不同,这使第一阶段中 RB 变量抽样和条件概率更新流程需要做出改进,下面给出详细步骤:

Step 1. 初始化 C_i , 从 $i = k$ 开始,将 root 逐层下移至 o_i ;

$$Pr(\pi_i^{i-1}) = \sum_{\pi_i^i} Pr(\pi_i^{i-1} | \pi_i^i) Pr(\pi_i^i) \quad (2)$$

$$Pr(\pi_i^i | \pi_i^{i-1}) \propto Pr(\pi_i^{i-1} | \pi_i^i) Pr(\pi_i^i) \quad (3)$$

$$Pr(s_i) = \sum_{\pi_i^0} Pr(s_i | \pi_i^0) Pr(\pi_i^0) \quad (4)$$

$$Pr(\pi_i^0 | s_i) \propto Pr(s_i | \pi_i^0) Pr(\pi_i^0) \quad (5)$$

$$Pr(o_i) = \sum_{s_i} Pr(o_i | s_i) Pr(s_i) \quad (6)$$

Step 2. 求 s_i 的后验概率

$$Pr(s_i | o_i) \propto Pr(o_i | s_i) Pr(s_i) \quad (7)$$

获取证据 o_i 后依据 $Pr(s_i | o_i)$ 对 s_i 进行抽样,从 $i = 0$ 开始逐层向上计算

$$Pr(\pi_i^{i+1} | s_i) = \sum_{\pi_i^i} Pr(\pi_i^{i+1} | \pi_i^i) Pr(\pi_i^i | s_i) \quad (8)$$

$$Pr(\pi_i^i | \pi_i^{i+1}, s_i) \propto Pr(\pi_i^{i+1} | \pi_i^i) Pr(\pi_i^i | s_i) \quad (9)$$

Step 3. 求 e_i^k 的后验概率

$$Pr(e_i^k | s_i) = \sum_{\pi_i^k} Pr(e_i^k | \pi_i^k) Pr(\pi_i^k | s_i) \quad (10)$$

对 e_i^k 进行抽样,计算

$$Pr(\pi_i^k | e_i^k, s_i) \propto Pr(e_i^k | \pi_i^k, s_i) Pr(\pi_i^k | s_i) \quad (11)$$

$$Pr(\pi_i^K | \pi_i^{K-1}, s_i, e_i^K) \propto Pr(\pi_i^{K-1} | \pi_i^K, s_i) Pr(\pi_i^K | s_i, e_i^K) \quad (12)$$

Step 4. 若 $e_i^k = T$, 将 B_{i+} 转化为 C_{i+1} , 返回 Step 1 开始下一周期。否则自上而下顺序对 e_i^i 抽样,并自 $i = K$ 开始向下计算

$$Pr(\pi_i^{i-1} | e_i^{K:i}, s_i) = \sum_{\pi_i^i} Pr(\pi_i^{i-1} | \pi_i^i, s_i) Pr(\pi_i^i | s_i, e_i^{K:i}) \quad (13)$$

$$Pr(e_i^{i-1} | s_i, e_i^{K:i}) = \sum_{\pi_i^{i-1}} Pr(e_i^{i-1} | \pi_i^{i-1}) Pr(\pi_i^{i-1} | s_i, e_i^{K:i}) \quad (14)$$

$$Pr(\pi_i^i | \pi_i^{i-1}, s_i, e_i^{K:i}) \propto Pr(\pi_i^{i-1} | \pi_i^i, s_i) Pr(\pi_i^i | s_i, e_i^{K:i}) \quad (15)$$

直到 $e_i^{i-1} = T$ 为止;

Step 5. 将 B_{i+} 转化为 C_{i+1} , 返回 Step 1 开始下一周期。

由于 Step 4 中 $i \geq l_i + 1$, 因此 $e_i^{K:i} = F$, 此时仍有 $Pr(e_i^{i-1} = T | \pi_i^{i-1}, e_i^{K:i} = F, s_i) = \beta_{\pi_i^{i-1}}(s_i)$ 。完成上述步骤后,就可以将变量及依赖关系映射到下一个时间片,并按照 RB - SIS 流程对 AHMM - CTP 进行近似推理,详细流程可参见文献[15], 关于模型参数学习的内容可参照文献[19]。

3 仿真试验

3.1 想定说明

仿真对抗中敌一架无人机从基地 S 起飞对我方 CGF 进行攻击,目标是雷达站 T_1 和 T_2 中的一个,从 S 起飞和攻击 T_1 、 T_2 分别需要穿过防空区 A 、 B 、 C ,抽象后的位置如图3所示。




图3 防空区位置

Fig. 3 Location of air defense zones

无人机通过 A 区后有 0.8 的概率直接飞向目标防空区,有 0.2 的概率到另一防空区佯动后再飞向打击目标。按照 1.1 节的路径规划方案,形成的航线和航路点如图4所示。

图4中菱形代表无人机的起飞基地,五角星代表雷达站,方块代表防空炮,虚线为可能选择的




图 4 无人机航线及航路点

Fig. 4 Paths and path points of the UCAV

单条路径。规划过程中,无人机到达一个航路点后以 $\beta_{\pi_i}(s_i)$ 的概率获得返航命令(目标点改为 S),且一旦返航后不再更改终点目标, $\beta_{\pi_i}(s_i)$ 和 $\beta_{\pi_l}(s_l)$ 可通过统计获得。另设获取的观测值以 0.8 的概率反映无人机的真实位置,以 0.2 的概率显示其邻接航路点,无人机选择最优单段路径的概率为 0.7。仿真时间 t 记录了无人机的飞行步长,即无人机每经过一个新航路点,有 $t = t + 1$ 。仿真起始时刻为 $t = 1$,此时飞行目标为 T_1 和 T_2 的先验概率各为 0.5, RB - SIS 的粒子数为 10000。

3.2 实验结果与分析

在真实目标为 T_2 的情况下,从实际规划的航迹库中选取三条典型航迹进行识别。表 1 给出了各条航迹的信息,路径规划的在线识别结果 ($t \leq 25$) 如图 5~7 所示。




图 5 航迹 I 的在线识别结果

Fig. 5 Online recognition results of trace I

表 1 三条典型航迹信息

Tab. 1 Profile of three typical paths

编号	飞行方案	防空区 变更时刻	到达目 标时刻	是否中 途返航
I	A→C	$t = 14$	$t = 21$	否
II	A→B→C	$t = 12, 26$	$t = 37$	否
III	A→C	$t = 12, 22$	$t = 31$	是




图 6 航迹 II 的在线识别结果

Fig. 6 Online recognition results of trace II




图 7 航迹 III 的在线识别结果

Fig. 7 Online recognition results of trace III

航迹 I 中,无人机选择直接飞向 C 区,尽管在 $t = 5$ 附近进行了佯动,但进攻 T_1 的概率没有超过 0.6,之后随着观测数据的增加,判断进攻 T_2 的概率稳步增高。

航迹 II 中,无人机先到 B 区再到 C 区,由于该方案的先验概率只有 0.2,因此在 $t = 13$ 前偏向认为目标为 T_1 ,但最大概率未超过 0.8。随着无人机转向 C 区,目标为 T_2 的概率逐渐增加,并最终接近于 1。

航迹 III 中,无人机同样选择直飞 C 区的飞行方案,除 $t = 8$ 之前识别结果略有振动外,进攻 T_2 的概率逐步上升。但从 $t = 16$ 开始,无人机返航的概率快速增加,而其接到返航命令的真实时刻也恰好是 $t = 16$,这反映出该识别算法能及时有效对顶层策略的改变做出判断。

为了比较 AHMM 和 AHMM-CTP 在不同飞行阶段的识别准确率,随机抽取 1000 条初始目标为 T_2 的飞行轨迹。其中单条轨迹的总仿真时长为 $T_i, i = 1, \dots, 1000$ 。使用上述两种算法分别计算轨迹 i 在 $t = qT_i (q = 0.1, 0.2, \dots, 0.9)$ 时刻的识别概率,将具有最大概率的目标作为轨迹 i 在 qT_i 时刻的识别结果,以识别正确的轨迹数占总轨迹数的比例作为取不同 q 值时算法的识别准确率。根据路径规划的特点, q 的大小反映了飞行轨迹

的不同阶段, q 越大则无人机离终点越近,且测试集中于无人机返航的航迹所占比例越大。AHMM 和 AHMM-CTP 的识别准确率对比如图 8 所示。

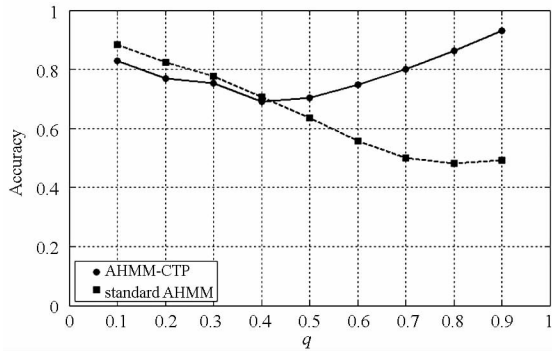


图8 识别准确率

Fig. 8 Recognition accuracy

图 8 中的圆点和方块分别为 AHMM-CTP 和标准 AHMM 的识别准确率。在前三分之一阶段,由于考虑了目标返航的可能性,AHMM-CTP 的准确率略低,但两者相差不大,这说明 AHMM-CTP 对于目标不变的路径规划同样有较好的识别效果。随着测试集中变更目标的轨迹增多,标准 AHMM 的识别准确度持续下降。而对 AHMM-CTP 而言,尽管前半段其准确率出现缓慢下降,但随着观测证据的增加反而出现了快速回升,在 $q = 0.9$ 时,其识别准确率已达到 0.932,这证明了改进算法对于变目标路径规划识别的有效性。

4 结语

本文研究了一种 AHMM 框架下的 CGF 路径识别方法。针对路径规划任务的特点,提出了顶层策略可变的 AHMM。该模型为顶层策略增加了初始分布并更改了策略终止变量间的影响关系,使 CGF 在对手更改终点目标并自上而下进行路径规划时仍能完成识别。实验表明,AHMM-CTP 能准确识别给定环境下的典型航迹,且无论终点目标是否变更都能保持较高的识别准确率。

在未来工作中,我们希望将本文的改进方案应用于其他 AHMM 后续模型,并进一步解决半马尔可夫决策和局部规划下的路径规划识别问题。

参考文献 (References)

[1] 郭齐胜,杨立功,杨瑞平,等. 计算机生成兵力导论[M]. 北京:国防工业出版社,2006:2-6.
GUO Qisheng, YANG Ligong, YANG Ruiping, et al. An introduction to computer generated forces [M]. Beijing: National Defense Industry Press, 2006:2-6. (in Chinese)

[2] 谷文祥,殷明浩,徐丽,等. 智能规划与规划识别[M]. 北京:科学出版社,2010:173-174.
GU Wenxiang, YIN Minghao, XU Li, et al. Intelligent plan and plan recognition[M]. Beijing: Science Press, 2010:173

-174. (in Chinese).

[3] Synnaeve G, Bessiere P. A Bayesian model for plan recognition in RTS games applied to StarCraft [C]//Proceedings of the AAAI Conference on AIIDE. Menlo Park, CA: AAAI Press, 2001:79-84.

[4] Kabanza F, Bellefeuille P, Bisson F, et al. Opponent behaviour recognition for real-time strategy games [C] // Proceedings of the AAAI Workshop on PAIR. Menlo Park, CA: AAAI Press, 2010:287-296.

[5] Zouaoui-Elloumi S, Roy V, Marmorat J P, et al. Securing harbors by modeling and classifying ship behavior [C]// Proceedings of Annual Conference on BRIMS, Red Hook, NY: Curran Associates, 2011:114-121.

[6] 邓海军,尹全军,胡记文,等. 基于MEBN的战术意图识别[J]. 系统工程与电子技术,2010,32(11):2374-2379.
DENG Haijun, YIN Quanjun, HU Jiwen, et al. Tactical intention recognition based on multi-entity Bayesian network [J]. Systems Engineering and Electronics, 2010, 32(11): 2374-2379. (in Chinese).

[7] Fine S, Singer Y, Tishby N. The hierarchical hidden markov model: analysis and applications [J]. Machine Learning, 1998,32:41-62.

[8] Duong T, Phung D, Bui H, et al. Efficient duration and hierarchical modeling for human activity recognition [J]. Artificial Intelligence, 2009(173): 830-856.

[9] Geib C W, Goldman R P. A probabilistic plan recognition algorithm based on plan tree grammars [J]. Artificial Intelligence, 2009(173):1101-1132.

[10] Pynadath D V, Wellman M P. Probabilistic state-dependent grammars for plan recognition [C] //Proceedings of the Sixteenth conference on UAI. Stanford, CA: Morgan Kaufmann Publishers Inc, 2000: 507-514.

[11] Bui H. Efficient approximate inference for online probabilistic plan recognition [C]// Proceedings of AAAI Fall Symposium on Intent Inference for Users, Teams and Adversaries. Menlo Park, CA: AAAI Press, 2002.

[12] Avrahami-Zilberbrand D, Kaminka G A. Hybrid symbolic-probabilistic plan recognizer: Initial steps [C]// Proceedings of AAAI Workshop on MOO. Menlo Park, CA: AAAI Press, 2006:1-7.

[13] Avrahami-Zilberbrand D, Kaminka G A, Zarosim H. Fast and complete symbolic plan recognition: Allowing for duration, interleaved execution and lossy observations [C]// Proceedings of the AAAI Workshop on MOO. Menlo Park, CA: AAAI Press, 2005:653-658.

[14] Bui H, Venkatesh S, West G. On the recognition of abstract markov policies [C]//Proceedings of the National Conference on Artificial Intelligence. Menlo Park, CA: AAAI Press, 2000: 524-530.

[15] Bui H, Venkatesh S, West G. Policy recognition in the abstract hidden markov models [J]. Journal of Artificial Intelligence Research, 2002,17:451-499.

[16] Bui H, Venkatesh S, West G. Tracking and surveillance in wide-area spatial environments using the Abstract Hidden Markov Model [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2001, 15(1): 177-196.

[17] Bui H. A general model for online probabilistic plan recognition [C]// Proceedings of IJCAI. San Francisco, CA: Morgan Kaufmann Publishers Inc, 2003: 1309-1318.

[18] Saria S, Mahadevan S. Probabilistic plan recognition in multiagent systems [C]// Proceedings of 24th ICAPS, Menlo Park, CA: AAAI Press, 2004:12-22.

[19] Johns J, Mahadevan S. A variational learning algorithm for the abstract hidden markov model [C]// Proceedings of the National Conference on Artificial Intelligence, Menlo Park, CA: AAAI Press, 2005:9-14.

[20] 肖秦琨,高嵩. 贝叶斯网络在智能信息处理中的应用 [M]. 北京:国防工业出版社,2012:222-257.
XIAO Qinkun, GAO Song. Application of bayesian network in intelligent information processing [M]. Beijing: National Defense Industry Press, 2012:222-257. (in Chinese)