

文章编号: 1001-0920(2008)12-1407-06

## 基于图形模型动态感知下的多无人机航迹协同

郭文强, 高晓光, 肖秦琨

(西北工业大学 电子信息学院, 西安 710072)

**摘要:** 为解决对当前形势估计不足以及对未来情况预测的问题, 采用图形模型中动态贝叶斯网络 (DBN) 建立突发威胁体感知的模型, 利用 DBN 的状态转移网络、观测转移网络及 DBN 的学习和推理算法, 实现了对突发威胁体的动态感知. 提出一种基于图形模型动态感知下的多架无人机航迹协同规划方法, 并据此实现多无人机飞行航迹协同规划. 仿真结果表明了这种基于图形模型动态感知下的多架无人机协同方法的正确性和可行性.

**关键词:** 动态贝叶斯网络; 无人机; 动态感知; 协同航迹规划

中图分类号: TP181

文献标识码: A

## Multiple UAVs cooperative trajectory planning via dynamic sensing based on graphical model

GUO Wen-qiang, GAO Xiao-guang, XIAO Qin-kun

(School of Electronic and Information, Northwestern Polytechnical University, Xi'an 710072, China.

Correspondent: GUO Wen-qiang, E-mail: gwq66@yahoo.com.cn)

**Abstract:** Focusing on solving the shortage problems of present situation estimation and future forecasting, dynamic sensing model for pop-up threats is established by dynamic Bayesian network (DBN), which is a kind of graphical models. Dynamic sensing for pop-up threats can be achieved by parameters' change in relative DBN's transition networks and DBN's learning and inference algorithm. An autonomous optimization for multiple UAVs cooperative path planning based on DBN is proposed, which supplies the realization foundation for UAVs cooperative trajectory planning. Simulation results show that this UAVs cooperative trajectory planning via dynamic sensing based on this graphical model is correct and practical.

**Key words:** Dynamic Bayesian network (DBN); Unmanned air vehicles (UAVs); Dynamic sensing; Cooperative trajectory planning

### 1 引言

空中战场在现代战争中的地位日益突出, 多架无人机航迹协同是多架无人作战飞机协同作战的关键技术<sup>[1]</sup>. 依据滞后的信息进行决策, 必然造成打击的低效能, 因此未来的无人机应具有高度的自主能力, 即在不同航行阶段能及时动态感知和评估变化的形势和环境, 并能够自动进行重规划, 从而实现多架无人机航迹协同下自主飞行<sup>[2]</sup>.

图形模型是概率论与图论密切结合的产物, 动态贝叶斯网络是其重要组成部分. 国内外对动态贝叶斯网络理论和应用的研究非常活跃<sup>[3,4]</sup>. 文献[5]采用离散模糊动态贝叶斯网络, 对若干可观测目标

特征参数综合推理出目标的类型, 提高了无人作战飞机的自动目标识别能力. 本文则提出利用动态贝叶斯网络建立空天作战环境中突发威胁体的感知系统框架, 并据此进行多无人机飞行航迹协同, 解决了对当前形势估计不足以及对未来情况预测的问题.

### 2 基于动态贝叶斯网络的威胁感知系统

#### 2.1 动态贝叶斯网络

动态贝叶斯网络 (DBN) 是对由大量随机过程组成的状态空间模型的一种新颖灵活的图形表达方式. DBN 可视为将静态贝叶斯网络沿时间轴变化进行拓展得到, 它具有多种表达形式<sup>[6]</sup>. 卡尔曼滤波模型 (KFM) 与隐马尔可夫模型 (HMM) 是两种最常见

收稿日期: 2007-10-08; 修回日期: 2008-01-29.

基金项目: 国家自然科学基金项目 (60774064); 国家自然科学基金重大项目 (90205019).

作者简介: 郭文强 (1971—), 男, 陕西咸阳人, 副教授, 博士生, 从事先进控制理论与应用的研究; 高晓光 (1957—), 女, 辽宁鞍山人, 教授, 博士生导师, 从事火力与指挥控制、作战效能分析等研究.

的 DBN 形式.

### 2.2 突发威胁体感知动态贝叶斯网络

对空天中的威胁体进行目标识别所需要的主要特征量有速度、高度、雷达回波分析等,这些特征可通过各种现有技术获得<sup>[5]</sup>. 基于静态贝叶斯网络的无人机潜在威胁等级评估,主要由无人机对抗威胁的能力、敌方的威胁区域和弹性威胁等因素决定,它们主要体现在威胁体的类型、位置及航向等特征量信息中<sup>[7]</sup>. 采用综合打分等方法可得到突发威胁体威胁等级  $X_{threat}(L)$ . 根据 Miller 理论,可用威胁等级得分值来反映人们关于目标的相对威胁重要性认识,一般取 1~9,其中:1,3,5,7 和 9 分别表示绝对弱、较弱、较强、很强、绝对强 5 个等级,两等级间的状态相应取 2,4,6,8.

在某一时刻  $t$  的数据融合推理基础上,可将形成的威胁体的位置和速度静态贝叶斯网络与单个时间片的目标识别静态贝叶斯网络相结合,组成新的贝叶斯网络,即威胁等级评估贝叶斯网络;然后沿时间轴拓展形成相应的动态贝叶斯网络. 利用该动态贝叶斯网络可以跟踪突发威胁体,预测其特征信息,并据设定的无人机与突发威胁体间距离阈值,实施协同路径局部重规划. 威胁体感知动态贝叶斯网络结构如图 1 所示. 其中:在单个时间片  $t$  的贝叶斯网络中观测量可以用  $Y_{t,m} (m = 1, 2, \dots, N, N$  为传感器数量) 表示,如  $Y_{t,1}$  表示可观测威胁体的位置、速度;  $X$  表示 KFM 的隐含状态,如目标真实的位置、速度;  $Q$  表示 HMM 中隐含状态;  $Q_{t,N}$  为目标类型识别结果,威胁体威胁等级对应的序列用  $Q_t$  表示.




图 1 突发威胁体感知动态贝叶斯网络

### 2.3 推理算法

对 DBN 进行推理首先应学习该系统所对应的参数. 利用经典的 Expectation maximization(EM) 或 Baum-Welch 算法<sup>[8]</sup> 可对 DBN 参数进行最大似然(Maximum likelihood) 估计,它是 DBN 学习的基础. 该威胁体感知 DBN 实际上是 KFM 模型(隐变量节点是连续的)与 HMM 模型(隐变量节点是离散的)组成的混合网络. 据文献[9] 结论,当连续隐结

点与离散隐节点相互独立时,可将其分解为连续 DBN 和离散 DBN 进行推理,即首先对 KFM 进行推理,然后对 HMM 进行推理.

#### 2.3.1 KFM 的参数学习及推理

KFM 假定  $X^t \in R^{N_x}, Y^t \in R^{N_y}$ , 状态转移函数及观测转移函数均服从线性高斯分布,有

$$\begin{cases} X^{t+1} = AX^t + W^t, W^t \sim N(0, Q); \\ Y^t = CX^t + V^t, V^t \sim N(0, R). \end{cases} \quad (1)$$

其中:  $W^t$  和  $V^t$  为  $N_x$  维与  $N_x$  维相互独立的高斯噪声信号;  $A$  是一个  $N_x \times N_x$  的状态转移矩阵; 观测矩阵  $C$  为  $N_y \times N_x$  的矩阵;  $Q$  为系统动态噪声信号方差;  $R$  为观测噪声信号方差<sup>[3]</sup>.

对 KFM 进行推理首先应学习该线性动态系统(LDS) 对应的参数,即通过观测数据学习状态转移矩阵  $A$ , 观测矩阵  $C$ , 系统过程噪声矩阵  $Q$  和系统观测噪声矩阵  $R$ . 方法是先通过先验知识建立初始参数,进而用 EM 算法结合观测数据进行迭代修正.

应用文献[3] 指出的前向-后向算法或 Rauch-Tung-Striebel (RTS) 算法便可对该 KFM 某一点进行推理. 较准确地估计出  $x_t$  后,再应用预测公式  $x_{t+H|t} = A(t, t+H)x_{t|t}$ , 预测出  $x_{t+H}$  的值,其中  $A(t, t+H)$  为  $t$  时刻到  $(t+H)$  时刻系统的状态转移矩阵.

#### 2.3.2 HMM 的参数学习及推理

当 DBN 隐节点取值空间为离散型时,其推理的一种方式是将复杂的动态网络化成简单的 HMM 图型模式,从而应用 HMM 的成熟算法解决 HMM 所面临的 3 个问题:应用期望最大值算法(EM) 进行在线学习,确定 HMM 的基本参数;应用 Viterbi 解码算法,获得最优的隐含状态估计序列;在得到最优估计序列基础上,可充分应用 DBN 的推理算法进行预测.

$X_t$  和  $Y_t$  表示 HMM 隐含序列和观测序列;  $x_t$  表示  $t$  时刻隐含变量的值,  $y_t$  表示  $t$  时刻观测变量的值;  $x_t$  存在  $n$  种状态,即  $x_t \in \{1, 2, \dots, n\}$ . 其模型参数主要有 3 个:1) 初始隐状态分布矩阵  $\pi = (\pi_i)_{1 \times n}$ , 其中  $\pi_i = P(x_1 = i)$ ; 2) 隐状态转移矩阵  $A = (a_{ij})_{n \times n}$ , 其中  $a_{ij} = P(x_t = i | x_{t-1} = j)$ ; 3) 观测矩阵  $B = (b_{ik})_{1 \times n}$ , 其中  $b_{ik} = P(y_t = k | x_t = i)$ . 在不与代表 KFM 参数混淆的情况下, HMM 的参数可简化为  $\lambda = (A, B, \pi)$ .

HMM 学习实质上是参数最优化问题,即找到最佳参数  $\lambda^*$ , 使

$$\lambda^* = \arg \max_{\lambda} P(Y, X | \lambda). \quad (2)$$

基于上述 EM 思想的 Baum-Welch 算法,无论在观测数据完备或部分观测数据的基础上,都可较

好地学习到 HMM 的参数. 通过对随时间变化的观测序列推理运算, 并结合 HMM 模型构造条件  $\lambda = (A, B, \dots)$ , 应用 Viterbi 算法便可推理出合理的隐含状态序列.

### 3 航迹协同规划分解策略

除位置和形状已知的静止威胁外, 无人机 (UAV) 在实战环境中所面临的威胁主要来自敌方地面或空中的探测雷达. 本文无人机飞行区域的威胁点均认为是敌方雷达. 文献 [10] 给出了多架 UAV 以路径长度为协同变量进行协同规划的分解算法. 这里选用将分解算法改进为以多架 UAV 飞行时间  $t_a$  为协同变量的分解算法.

路径初规划阶段, 每架 UAV 计算出自己的最优路径, 由于速度  $V_{\min} \leq V \leq V_{\max}$ , 每条路径  $i$  有 1 个对应的飞行代价  $J_i$  和到达目标的时间范围  $S_{t,i}$ . 这里采用能体现威胁点威胁等级差异的改进型 Voronoi 图进行求解<sup>[4]</sup>.

在初始的改进型 Voronoi 图中, 第  $i$  条边的飞行代价为

$$J_i = kJ_{\text{threat},i} + (1 - k)J_{\text{fuel},i}, \quad 0 \leq k \leq 1. \quad (3)$$

式中:  $J_{\text{threat},i}$  为 UAV 飞行的威胁代价, 指的是 UAV 暴露在敌方雷达下的程度, 其所受的威胁与 UAV 到雷达距离的 4 次方的倒数成正比;  $J_{\text{fuel},i}$  为 UAV 飞行中的燃油代价, 与路径长度有关;  $k$  为平衡系数.

第  $j$  个威胁点对第  $i$  条边的威胁代价为

$$J_{\text{threat},i,j} = \text{Length}_i \times \left( \frac{1}{d_{\frac{1}{6}}^{4,i,j}} + \frac{1}{d_{\frac{1}{2}}^{4,i,j}} + \frac{1}{d_{\frac{5}{6}}^{4,i,j}} \right) \times X_{\text{threat}}(\text{Level})_j. \quad (4)$$

具体分析及参数含义参见文献 [11].

将飞行代价  $\sum_{i=1}^n J_i$  作为路径优化的目标函数,

以多架 UAV 飞行代价最小为优化目标. 首先求出  $n$  架 UAV 的交集  $S = S_{t,1} \cap S_{t,2} \cap \dots \cap S_{t,n}$ , 估计抵达时间  $t_a$  在区间  $S$  取最小值; 然后将  $t_a$  传给每一架 UAV, UAV 根据  $t_a$  和各自规划的路径选择合适的速度飞行. 各架 UAV 之间交流的内容是时间  $t_a$  和  $J_i$ . 这种分解算法有利于将一个高维的优化问题分解成一个低维、计算量小的问题, 并可使得路径优化的目标函数最小, 即在最大限度地增加团队的生存能力的基础上, 保证团队完成任务的时间最少.

### 4 突发威胁下多 UAV 自主航迹协同优化

1) 由卫星、预警机或高空侦察机获得某一区域的地形和威胁分布数据, 经数据融合后, 按预先的经验知识对该区域的固定威胁目标进行威胁等级的量

化, 依据各个固定威胁点  $X_{\text{threat}}$  值按改进型 Voronoi 图法进行构图; 采用前述协同路径规划分解策略, 在确定各 UAV 飞行起点和终点后, 求解初始粗略最短路径; 进行路径细化后, 确定出各无人机实际可飞的协同航迹.

2) 各 UAV 将航空地图及预规划的路径装入其火控计算机, 按预先规划好的路径飞行. 在飞行途中, 应用其所带传感器, 如电子雷达, 光电雷达, 红外搜索跟踪装置 (IRST), 敌我识别器 (IFF), 电子对抗报警器等, 以及机载数据链的数据 (含预警机、地面指控系统、友机的数据) 进行探测, 不断感知环境变化. 将传感器信号进行数据融合, 一旦发现突发威胁体, 即进行定位及目标跟踪. 在此期间, UAV 仍沿预先规划好的路线飞行, 并不断探测其与突发威胁体间的距离  $d$ .

3) 在得到融合信号序列的基础上, 建立突发威胁体  $X_{\text{pop-up}}$  感知 DBN.

4) 应用前向 - 后向推理算法和 Viterbi 解码算法进行推理, 得到该时刻及未来时刻威胁体的位置、速度的最优滤波值  $\hat{x}$  及威胁等级的最优滤波值  $\hat{s}$ .

5) 当预测  $d$  小于某一设定阈值时, 开始航迹协同局部路径重规划. 在补充了威胁体信息后, 重新构造改进型 Voronoi 图, 求解下一轮粗略最短路径, 细化路径后得到更新的实际可飞路径.

6) UAV 未到达目标点时, 返回步骤 2), 根据  $X_{\text{pop-up}}$  位置及威胁等级等变化, 重新学习、修改  $X_{\text{pop-up}}$  感知 DBN 模型, 以便适时进行新一轮路径协同优化; 当 UAV 到达目标点时, 自主航迹协同优化过程结束.

### 5 仿真分析

为验证上述基于 DBN 的图形模型动态威胁感知下多架无人机自主航迹协同优化方法的正确性与可行性, 在 Matlab7.1 环境下进行仿真实验.

想定多架无人机自主协同编队飞行, 每架无人机分配一个目标. 由于战场环境的动态不确定性, 敌方威胁有 2 种类型: 已知的和突发的. 已知的威胁在无人机任务开始时已由卫星或预警机探知其位置等信息; 而突发威胁只在执行任务过程中才被发现. 当原路径规划区域内突然出现敌方新的威胁体时, 借助 DBN 图形模型可将复杂多变的背景因素 (此处特指突发威胁体) 经信息预处理后, 融入到 DBN 的转移网络中, 对突发威胁体予以感知, 预测未来情况, 进而自主进行航迹协同优化功能. 多机编队的组织体系中小编队通常由 2 ~ 4 架飞机组成. 限于篇幅, 此处仅给出 2 架和 3 架无人机自主航迹协同仿真结果.

5.1 2架无人机的自主航迹协同

5.1.1 初始集合点规划及执行规划

首先给出已知的威胁点、2架飞机的起始点和目标点坐标.取无人的速度区间为 $[0.8, 1.2]$ ,以威胁点作为母点构建改进型 Voronoi 图.计算各条边的代价矩阵(平衡系数  $k$  取 0.4),并采用 Dijkstra 算法寻找到 2架飞机各自的最优路径.

目标点是事先探知的,所以无人机在出发时已规划好初始路径(见图 2 中粗虚线).其中:1号和 2号无人机起始点  $S_1, S_2$  和目标点  $D_1, D_2$  坐标分别为  $(30, 5), (58, 10)$  和  $(60, 82), (80, 80)$ , 驶入角均为  $45^\circ$ .1号无人机的规划初始路径长度为 91.0464 km, 2号无人机的路径长度为 84.2971 km.因此,2架无人机可以同时到达目标,双机间协同变量  $t_a = 223.1529$  s.




图 2 双机协同初始航迹规划及突发威胁的运动情况

5.1.2 威胁体感知

在执行任务过程中,无人机编队获得的目标信息是不断变化的.设  $X_1$  为敌方突然出现的移动威胁体,其位置及状态变化如图 2 中灰色星型所示.假设  $t = 79.6253$  s 时无人机探测到了新的移动威胁体  $X_1$ ,连续观测后获得了 12 s 的观测数据.

1) 威胁体位置和速度的推理计算

已知部分观测数据如表 1 所示.首先学习获取 KFM 模型参数:根据先验知识或随机选取转移矩阵  $A_1$ ,观测矩阵  $C_1$ ,噪声矩阵  $R_1, Q_1$ ;进而通过 EM 学习算法结合观测数据得到修正后的参数矩阵  $A_2$ ,

表 1 突发威胁  $X_1$  部分观测融合数据

坐标	观测值 / 10 km				
$x$	7.9599	7.9566	7.9518	7.9479	7.9449
$y$	3.9961	3.9964	3.9956	3.9956	3.9955
$x$	7.9404	7.9359	7.9315	7.9282	7.9224
$y$	3.9966	3.9961	3.9972	3.9963	3.9966
$x$	7.9192	7.9134	7.9090	7.9030	7.8969
$y$	3.9957	3.9944	3.9957	3.9946	3.9956

$C_2, R_2$  和  $Q_2$ .

依据学习、修正得到的参数,由 Kalman 滤波算法获得滤波后  $X_1$  航迹.图 2 中灰色星型虚线表示 KFM 推理结果.  $X_1$  起点观测数据  $y = [80.002, 40.001]^T$ ,经滤波、推理得到 3 s 后,即当 2号无人机飞行至图 2 中  $S_{21}$  点时,  $X_1$  的数据

$$x = [74.44092, 39.29797, -0.57381, 0.05314]^T.$$

2) 威胁等级的推理计算

首先根据先验知识估计 HMM 模型参数  $A_0, B_0, \theta_0$ ;进而应用学习算法结合观测数据进行修正,得到  $A_1, B_1$  和  $\theta_1$ .

在调整好参数的基础上,针对后续数据进行推理,即应用 Viterbi 解码估计出隐含变量的最大可能值,求解结果如图 3 所示.条形码对应数字为  $X_1$ ,对应威胁等级  $G$ ,观测变量为 9 个状态,最终推理值在 150 代,推理威胁等级  $X_1(G) = 3$ .于是,推理得到 2号 UAV 飞行至图 2 中  $S_{21}$  点时,  $X_1$  的位置及状态估计为

$$x = [74.44092, 39.29797, -0.57381, 0.05314]^T;$$

威胁等级  $X_1(G) = 3$ .图 4 中灰星表示  $X_1$  相应预测位置.




图 3 威胁等级 HMM 系统 Viterbi 解码图




图 4 重新规划的协同航迹

### 5.1.3 重新规划

为了规避突发威胁  $X_1$ , 当 2 号 UAV 与  $X_1$  间距  $d$  接近设定阈值时, 即 2 号 UAV 飞至图 4 中  $S_{21}$  点时, 会以  $S_{21}$  点为新始发点进行局部路径规划, 并与 1 号 UAV 交流协同变量  $t_{a2}$ .

局部路径重规划后航迹如图 4 中粗虚线所示. 无人机编队在后半程飞行中, 1 号和 2 号无人机的路径长度将分别为 52.4393 km 与 44.8486 km, 此时  $t_{a2} = 128.5276$  s.

分别取  $i$  为 1 和 2, 则将图 2 中点  $S_i$  至  $S_{i1}$  以及图 4 中点  $S_{i1}$  至  $D_i$  间航迹连接起来, 即为  $i$  号无人机经多机自主协同优化后的航迹.

### 5.2 3 架无人机的自主航迹协同

3 架无人机针对 2 个突发威胁体的自主航迹协同过程, 类似于前述 2 架无人机自主航迹协同情况.

#### 5.2.1 3 机协同初始航迹规划及突发威胁感知

图 5 为 3 机协同初始航迹规划及突发威胁感知情况示意图.




图 5 3 机协同初始航迹规划及突发威胁感知情况

1 号 ~ 3 号无人机起始点和目标点分别为  $S_1$  至  $S_3$  和  $D_1$  至  $D_3$ . 多架无人机出发前已规划好初始路径, 如图 5 中粗虚线所示. 此时, 3 机间协同变量  $t_a = 233.0493$  s.

$X_1$  为敌方突然出现的第 1 个移动威胁体, 其位置及状态如图 5 中灰色星型所示.  $t = 79.8324$  s 时, 无人机对  $X_1$  连续观测, 获得了 12 s 的观测数据. 利用本文的突发威胁体感知动态贝叶斯网络学习得到模型参数, 经动态贝叶斯网络推理计算得到 3 s 后  $X_1$  的位置及状态估计为

$$x = [37.84459, 36.84886, -0.12612, 0.073102]^T;$$

威胁等级  $X_1(G) = 3$ . 3 s 后, 3 架无人机分别飞至点  $S_{11}$ ,  $S_{21}$  和  $S_{31}$ .

#### 5.2.2 3 机协同航迹重规划

为了规避突发威胁  $X_1$ , 1 号无人机飞至图 5 中  $S_{11}$  点后需重新规划路径, 即以  $S_{11}$  点为新始发点进

行局部路径重规划, 并与 2 号和 3 号无人机交流协同变量  $t_{a2}$ . 用前述方法重规划后的路径如图 6 中粗虚线所示. 此时, 3 机间重规划协同变量  $t_{a2} = 154.2481$  s.




图 6 针对突发威胁  $X_1$  的协同航迹重新规划

对比图 6 和图 5 可知, 由于突发威胁  $X_1$  的出现, 此时为保证多架 UAV 飞行代价  $J_i$  最小, 即在最大限度地增加团队生存能力的基础上, 保证团队完成任务的时间最少, 1 号和 2 号 UAV 均进行了局部路径重规划; 而 3 号 UAV 只需调整飞行速度, 仍沿原初始航迹行进即可满足任务要求.

#### 5.2.3 针对突发威胁 $X_2$ 的 3 机协同航迹重规划

又经 37.7327 s, 图 6 中星型所示  $X_2$  为敌方又突然出现一新的移动威胁体. 无人机获得了  $X_2$  的 10 s 连续观测数据. 利用突发威胁体感知动态贝叶斯网络学习得到的模型参数, 经推理计算得到 5 s 后  $X_2$  的位置及状态估计为

$$x = [60.89574, 51.65679, -0.57043, 0.029756]^T;$$

威胁等级  $X_2(G) = 5$ . 此时, 3 架无人机分别飞至点  $S_{12}$ ,  $S_{22}$  和  $S_{32}$ .

重规划后的路径如图 7 粗虚线所示. 此时, 3 机间重规划协同变量  $t_{a2} = 154.2481$  s.




图 7 针对突发威胁  $X_2$  的协同航迹重新规划

取  $i$  分别为 1, 2 和 3, 将图 5 中相应点  $S_i$  至  $S_{i1}$ ,

图 6 中  $S_{i1}$  至  $S_{i2}$  及图 7 中  $S_{i2}$  至  $D_i$  间航迹连接起来, 即为  $i$  号无人机经多机自主协同优化后的航迹。

## 6 结 论

本文在构建基于动态贝叶斯网络威胁体感知模型的基础上, 利用 DBN 中状态转移网络及观测转移网络参数变化, 实现了对空天环境中突发威胁体的动态感知, 进而提出了基于图形模型动态感知下的多无人机航迹自主协同规划方法。实验结果表明, 这种自主规划方法, 可实现多无人机航迹协同, 并充分利用 DBN 的学习和推理算法, 有效解决多无人机协同飞行过程中对当前形势估计不足以及对未来情况预测的问题, 具有较强的实效性。这种基于图形模型的动态感知框架, 还可应用于协同空战中的干扰协同、攻击协同和火力分配等方面, 为辅助决策提供了一种行之有效的办法。

## 参考文献(References)

- [1] McLain T W, Chandler P R, Pachter M. A decomposition strategy for optimal coordination of unmanned air vehicles [C]. 2000ACC. Chicago, 2000: 369-373.
- [2] Chandler P R, Rasmussen S, Pachter M A. UAV cooperative path planning [C]. 2001ACC. Denver, 2001: 50-55.
- [3] Murphy K. Dynamic Bayesian networks: Representation, inference and learning [D]. Berkeley: Computer Science Division, 2002.
- [4] 肖秦琨, 高晓光, 高嵩. 基于混合动态贝叶斯网络的无人机路径重规划[J]. 系统仿真学报, 2006, 18(5): 1301-1306.  
(Xiao Q K, Gao X G, Gao S. Local path replanning for UCAV based on mix-state dynamic Bayesian networks [J]. J of System Simulation, 2006, 18(5): 1301-1306.)
- [5] 史建国, 高晓光, 李相民. 离散模糊动态贝叶斯网络用于无人作战飞机目标识别[J]. 西北工业大学学报, 2006, 24(1): 45-49.  
(Shi J G, Gao X G, Li X M. Improving identification capability of UCAV [J]. J of Northwestern Polytechnical University, 2006, 24(1): 45-49.)
- [6] Russell S, Norvig P. Artificial intelligence: A modern approach [M]. 2nd ed. New Jersey: Prentice Hall, 2003.
- [7] 杨有龙, 高晓光. 无人战斗机的态势感知模型框架[J]. 飞行力学, 2003, 21(3): 6-9.  
(Yang Y L, Gao X G. A model framework of situation awareness for uninhabited combat air vehicle [J]. Flight Dynamics, 2003, 21(3): 6-9.)
- [8] Digalakis V, Rohlicek J R, Osterdorf M. ML estimation of a stochastic linear systems with the EM algorithm and its application to speech recognition [J]. IEEE Trans Speech and Audio Proc, 1993, 1(4): 431-442.
- [9] Pavlovic V. Dynamic Bayesian networks for information fusion with applications to human-computer interfaces [D]. Urbana Champaign: University of Illinois, 1999.
- [10] 孟波波, 高晓光, 丁琳. 基于突发任务多无人作战飞机攻击多目标研究[J]. 系统仿真学报, 2007, 19(1): 176-179.  
(Meng B B, Gao X G, Ding L. Research on method of multiple UCAVs multi-target attacking path planning based on pop-up mission [J]. J of System Simulation, 2007, 19(1): 176-179.)
- [11] 杨有龙. 基于图形模式的表达方式[D]. 西安: 西北工业大学, 2003.  
(Yang Y L. Intelligent optimization based on graphical models [D]. Xi 'an: Northwestern Polytechnical University, 2003.)

(上接第 1406 页)

[11] Whitley L D. Fundamental principles of deception in genetic search [J]. Foundations of Genetic Algorithms, 1991, 1(3): 221-241.

[12] Zhang Q. On stability of fixed point of limit models of univariate marginal distribution algorithm and factorized distribution algorithm [J]. IEEE Trans on Evolutionary Computation, 2004, 8(1): 80-93.

[13] Zinchenko L, Muhlenbein H, Kureichik V, et al.

Application of the univariate marginal distribution algorithm to analog circuit design [C]. Proc of NASA/DoD Conf on Evolvable Hardware. Washington: IEEE Computer Society Press, 2002: 93-101.

[14] Zhang Q, Muhlenbein H. On the convergence of a class of Estimation of distribution algorithms [J]. IEEE Trans on Evolutionary Computation, 2004, 8(2): 127-136.