

基于小数据集 BN 学习的无人机威胁评估方法

李叶¹, 吕志刚^{1,2}, 邸若海^{1*}, 李亮亮¹, 张炜尧¹, 王洪喜²

¹西安工业大学电子信息工程学院, 陕西 西安 710021;

²西安工业大学机电工程学院, 陕西 西安 710021

摘要 在错综复杂、瞬息万变的作战环境中,敌方干扰及传感器性能局限等因素易导致获取的战场信息不充分。为使无人机在信息不充分条件下具备威胁评估的能力,提出基于小数据集的贝叶斯网络(BN)威胁评估建模方法。从小数据集条件下 BN 结构学习和参数学习的两个问题入手,利用 Bootstrap 方法获取的约束矩阵作为评分函数上的约束项,提出一种基于小数据集的 BN 结构学习算法,并提出一种基于区间先验约束的 BN 参数学习算法。仿真结果表明,与传统 BN 学习算法相比,本文提出的小数据集条件下 BN 学习算法在 UAV 威胁评估建模中具有更高准确性和可用性。

关键词 遥感; 贝叶斯网络; 小数据集; 矩阵化约束; 无人机; 威胁评估

中图分类号 TP181

文献标志码 A

doi: 10.3788/LOP202158.1628001

Threat Assessment Method for UAV Based on a Bayesian Network with a Small Dataset

Li Ye¹, Lü Zhigang^{1,2}, Di Ruohai^{1*}, Li Liangliang¹, Zhang Weiyao¹, Wang Hongxi²

¹School of Electronic and Information Engineering, Xi'an Technological University, Xi'an, Shaaxi 710021, China;

²School of Mechatronic Engineering, Xi'an Technological University, Xi'an, Shaaxi 710021, China

Abstract In the complex and rapidly changing environment of a battlefield, information is lost by factors such as interference of the enemy and limited sensor performance. To ensure that an unmanned aerial vehicle (UAV) can make threat assessments when sufficient information is lacking, this paper proposes a new Bayesian network (BN) learning method with a small dataset. For structure learning and parameter learning with a small dataset, the scoring function is constrained by the constraint matrix obtained by the Bootstrap method. The learning algorithm is proposed based on a BN structure learning with a small dataset and an interval a priori-constrained BN parameter learning algorithm. Simulation results demonstrated the higher accuracy and availability of the proposed method than traditional methods for UAV threat assessment on a small dataset.

Key words remote sensing; Bayesian network; small dataset; matrix constraint; unmanned aerial vehicle; threat assessment

OCIS codes 280.5600; 100.4993; 140.5495

1 引言

目前,在解决无人机(UAV)威胁评估问题的众

多形形色色的方法^[1-6]中,贝叶斯网络(BN)凭借其能够形象地模拟人类思维的特点,成为了解决此类问题的有效工具。文献[7]利用专家知识建立的

收稿日期: 2020-09-23; 修回日期: 2020-11-04; 录用日期: 2020-12-08

基金项目: 电子信息系统复杂电磁环境效应国家重点实验室基金(CEMEE2020Z0202B)、陕西省自然科学基金基础研究计划(2020JQ-816)、陕西省教育厅专项科研项目(20JK0680)、西安市科技计划项目(2020KJRC0033)

通信作者: *xfwtdrh@163.com

BN 模型,完成了地面战场威胁等级决策。文献[8]将 BN 与线性高斯近似方法相结合完成了 UAV 战场威胁态势的评估。文献[9]利用加权动态云 BN 构建空战威胁评估模型,然后利用证据相关法进行概率推理。文献[10]在考虑外部环境信息的基础上采用 BN 建立目标威胁等级评估模型,进而利用消息传播算法进行概率推理。文献[11]利用动态 BN 对战场环境的威胁态势进行建模,并将其用于无人机路径规划。然而,上述文献中都是在完备的数据集条件下应用传统的 BN 结构学习与参数学习算法来解决 UAV 的威胁评估问题,但是在实际的战场环境下,一方面,由于传感器性能的局限以及敌方实施干扰、欺骗等,UAV 采集的信息量往往不充足,另一方面,有时为了达到“先敌决策,先敌打击”的战术目的,不得不尽早做出决策。此时传统的 BN 学习算法难以满足对学习精度的要求,这对网络的推理有很大的影响,故无法获取满足要求的威胁评估结果。

本文提出一种基于小数据集 BN 学习的无人机威胁评估方法。首先,利用基于 Bootstrap 方法获取 BN 结构的矩阵化约束,然后,提出基于矩阵化约束的 BN 结构学习算法和基于先验约束的 BN 结构参数学习算法,最后,利用所提算法解决小数据集条件下的 UAV 威胁评估问题。

2 小数据集的概念

构建 BN 模型到底需要多少数据呢?这是一个极为复杂的问题,一些学者就此问题进行了一些前期的研究,现将其中部分结论以定理形式给出。

定理 1^[12] 设 G 为要构建的 BN 网络结构, P^* 为符合某一结构 G^* 的参数分布,同时网络中所有的变量都满足 $P^*(x_i | \Sigma_i^{G^*}) > \lambda$,其中 x_i 为第 i 个变量, Σ_i 为变量 x_i 的父节点集,如果通过最大似然估计求出 G 上的参数分布为 P ,且存在

$$M \geq \frac{1}{2} \frac{1}{\lambda^{2(d+1)}} \frac{(1 + \epsilon^2)}{\epsilon^2} \log \frac{nK^{d+1}}{\delta}, \quad (1)$$

则有

$$P[\text{KL}(P^*, P) - \text{KL}(P^*, P_{\theta^{\text{opt}}}) < n\epsilon] > 1 - \delta, \quad (2)$$

式中: M 为样本数量; λ 为网络中参数的下限; d 为最大父节点数; K 为变量的最大状态数; δ 为置信度; n 为网络的节点数; ϵ 为每个节点对应参数的 Karhunen-Loève(KL)散度; $\text{KL}(P, Q) = \sum_x P(x) \log \frac{P(x)}{Q(x)}$,

表征 P 分布和 Q 分布的散度; $P_{\theta^{\text{opt}}}$ 表示在结构确定之后与真实分布 KL 距离最小的参数分布。

从定理 1 可知,构建网络所需的样本数据量与所要构建网络的复杂度、学习精度和置信度密切相关,且还需按照系统自身的节点数和最大状态数进行计算。在本文的无人机威胁评估系统中, $n = 4$, $\epsilon \in [1, 5]$, $K = 2$ 。为了探究参数学习的准确性,选择 $\lambda = 0.3$, $\delta = 0.05$, $d = 2$ 时,利用定理 1 计算所需的样本量,结果如图 1 所示。本文取 $\epsilon = 5$ 时(节点数为 4 时所需数据量为 2771)的数据量作为本文小数据集的上界,进而作为本文实验数据量选择的依据。




图 1 数据量与误差之间的关系

Fig. 1 Relationship between data volume and error

3 任务描述

UAV 威胁评估是自主侦察任务中的子模块。UAV 以全部战场态势信息为输入,根据实时获取的敌方位置信息、敌方对抗信息以及敌方类型信息,综合离线的领域专家知识,完成对当前战场态势的威胁评估。图 2 是 UAV 威胁评估的战场背景示意图,具体的评估实现过程如下。

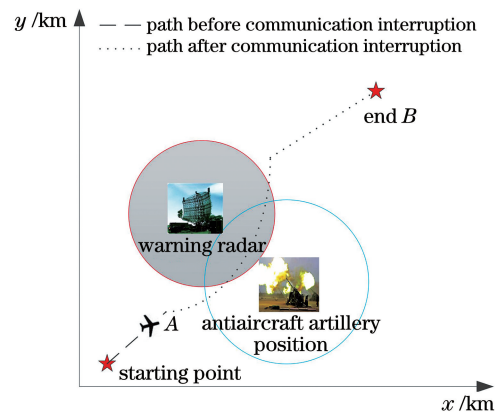


图 2 UAV 威胁评估的战场想定

Fig. 2 Battlefield scenario of UAV threat assessment

首先,通过卫星对某一区域进行预先侦察,获得该区域威胁空间的相关信息。本研究中威胁空间仅考虑警戒雷达和高炮阵地两种威胁,其中高炮阵地对 UAV 具有杀伤威胁。

1) UAV 在战场飞行途中,实时接收来自指挥控制台的相关目标威胁程度信息,同时 UAV 实时

应用机载传感器对周围环境进行不断探测,融合各传感器获得的战场数据信息,将观测数据进行离散化信息处理。如表 1 所示为目标节点信息的离散化结果,其中目标威胁程度节点为隐藏变量的外在表现节点,根据给定的目标威胁空间,划分为高和低两个等级。

表 1 目标节点信息的离散化

Table 1 Discretization of target node information

Target node name	Meaning	Value range and meaning
Type information I	Which of the two types does the target belong to	$\{1, 2\} = \{I1: \text{Warning radar}, I2: \text{Antiaircraft Artillery Position(AAP)}\}$
Confrontation information K	Combat capability of target weapon	$\{1, 2\} = \{K1: \text{yes}, K2: \text{no}\}$
Location information L	Whether UAV is in the detection range of target attack and search	$\{1, 2\} = \{L1: \text{no}, L2: \text{yes}\}$
Threat level information T	Threat level of the UAV relative to the target at the current moment	$\{1, 2\} = \{T1: \text{low}, T2: \text{high}\}$

2) UAV 抵达 A 点时,由于受到敌方干扰,与指挥控制台之间的通信中断,此时 UAV 进入威胁评估阶段,但由于进入战场环境的时间相对较短,传感器获得的信息较少,无法获得充足的观测数据。此时应用小数据集条件下的 BN 学习方法,可以完成 UAV 在小数据集条件下的威胁

评估。

3) 随着 UAV 不断进入威胁区域,传感器对周围环境不断探测,战场环境信息进一步累加,观测数据量增加,UAV 威胁评估的准确性提高,直到完成本次飞行任务,安全抵达终点 B。

UAV 威胁评估具体流程如图 3 所示。

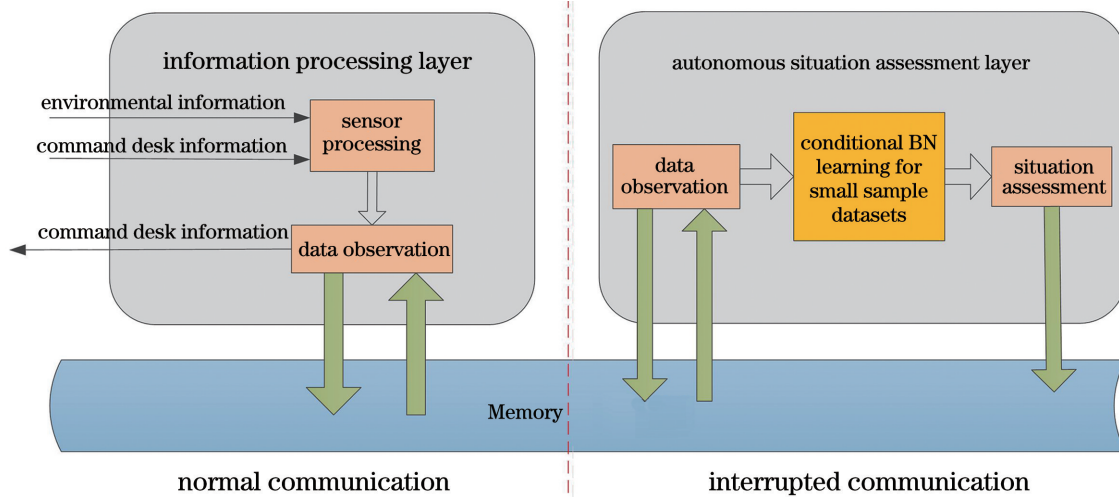


图 3 UAV 威胁评估框架图

Fig. 3 UAV threat assessment framework diagram

4 基于矩阵化约束的 BN 结构学习算法

4.1 Bootstrap 抽样

Bootstrap 抽样^[13-14]是由美国 Stanford 大学统计系 Efron 教授在总结前人研究成果的基础上提出的一种新的计算机模拟统计方法。在统计学中,该方法常用于处理小数据集问题。基于给定的观测数

据,该方法不需要其他假设,也不需要增加信息,即可对统计量的分布情况进行仿真处理和统计推断。

将 Bootstrap 抽样应用到 BN 结构的学习过程中,利用该方法对给定的小数据集 D 进行随机、有放回的重抽样,在不改变网络信息的条件下,得到 n 个节点的 m 个样本集 $D^* = \{D_1, D_2, \dots, D_m\}$,达到了扩展小数据集的目的,利于 BN 结构的进一步

学习。

4.2 BN 矩阵化表达

BN 结构表示节点和节点之间的定性关系。本研究以经典 Asia 网络^[15]为例描述 BN 的矩阵化数学表达形式,如图 4 所示;在 BN 结构中,当节点之间连线存在定性关系,即节点 i 指向节点 j 时,矩阵中第 i 行第 j 列的元素为 1;当节点之间连线不存在定性关系时,矩阵中第 i 行第 j 列的元素为 0。应用上述思想,能够利用矩阵形式形象地表达 BN 结构。




图 4 BN 结构矩阵化表达

Fig. 4 BN structure matrix expression

4.3 构建约束矩阵

构建约束矩阵的方法如图 5 所示。首先,假设静态 BN 模型具有 n 个节点,观测小数据集 $D = \{X(1), X(2), \dots, X(t)\}$, 利用 Bootstrap 抽样方法

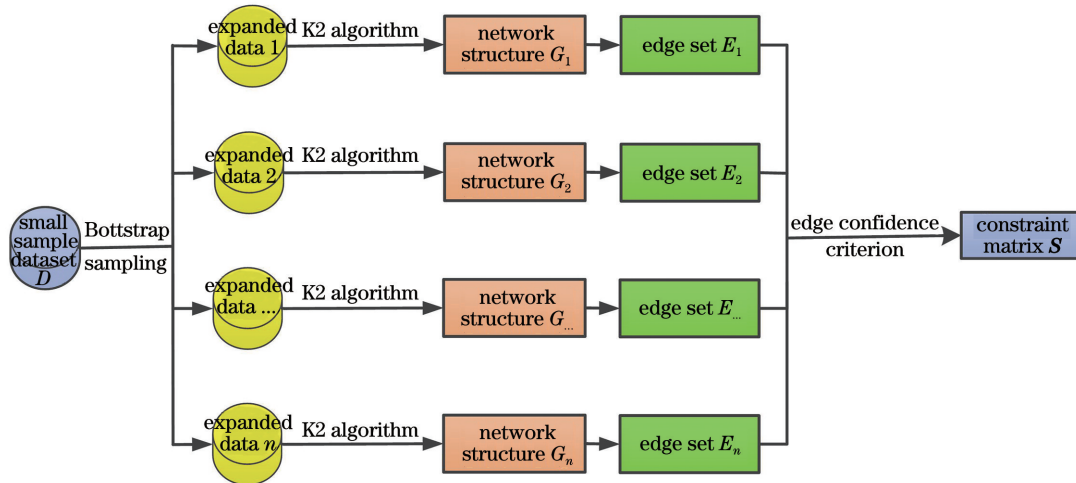


图 5 构建约束矩阵流程图

Fig. 5 Construction flow chart of the constraint matrix

4.4 基于矩阵化约束的贝叶斯模型评分方法

在 BN 结构学习过程中,评分函数是网络模型的一个选择标准,用于评判网络结构关系与样本数据的匹配程度。本研究利用 Bootstrap 抽样方法构建约束矩阵,利用矩阵化约束算法改变评分函数,使评分函数在原有的基础上增加约束项。该方法通过约束项的修正,最终有效地减少样本数据与网络模型的偏差;通过修正拟合度,评分效果得到大幅改

将小数据集扩展为 m 个含有 r 个样本的数据集 $D = \{D_1, D_2, \dots, D_m\}$, 其中 $D_p (1 \leq p \leq m)$ 表示第 p 个含有 r 个样本的数据集,将其加入到扩展样本数据集中,可得 m 个含有 m' 个样本的数据集 $D' = \{D_1 + D, D_2 + D, \dots, D_m + D\} = \{D'_1, D'_2, \dots, D'_m\}$ 。结合领域知识,在经典完备数据集下利用 K2 结构学习算法^[16-17]学习数据集 D' 中每个数据集的拟合网络模型,将学得的网络结构集合 $G = \{G_1, G_2, \dots, G_m\}$ 中的边的存在概率进行统计,即

$$\text{sum}(e_{ij}) = \sum_{k=1}^m p(e_{ij} \in G_k), i \in n, j \in n, \quad (3)$$

$$\theta_{ij} = \frac{\text{sum}(e_{ij})}{m}, \quad (4)$$

其中: $e_{ij} (i \in n, j \in n)$ 表示存在节点 i 指向 j 的有向边,如果边 e_{ij} 存在于所得 BN 结构 $G_k (k \in m)$ 中,则 $p(e_{ij} \in G_k) = 1$,当边 e_{ij} 不存在于边结构 G_k 中,则 $p(e_{ij} \in G_k) = 0$; m 为所得 BN 结构数。根据 (3) 式和 (4) 式求得约束矩阵 S , 即

$$S = \begin{bmatrix} \theta_{11} & \dots & \theta_{1n} \\ \vdots & & \vdots \\ \theta_{n1} & \dots & \theta_{nn} \end{bmatrix}. \quad (5)$$

善,所学结构准确性得以提升。该方法在小数据集条件下同样拥有好的结构学习效果。

基于矩阵化约束的贝叶斯模型评分函数可表示为

$$\log P(D | G) \approx \log P(D | G, \theta) - \frac{d}{2} \log t - \prod_{j=1}^n S(p, j) \cdot \frac{W}{t}, \quad (6)$$

其中 t 为原有的样本数据量, n 为网络中的节点个

数,参数矩阵 θ 由 $d = \prod_{i=1}^n q_i (r_i - 1)$ 个独立参数组成, q_i 为节点 i 的父节点状态数, r_i 为节点 i 的状态数, p 为网络节点 j 的父节点标识, W 为约束项调节因子(由样本量的大小决定其取值)。

在评分函数中,第一项是模型 G 的对数似然度,它度量的是结构 G 与数据 D 的拟合程度;第二项是模型复杂度的惩罚项,它能够有效地避免数据与复杂结构过度拟合;第三项是矩阵化约束惩罚项,能够优化样本数据与网络模型的拟合度,修正偏差。直观地来讲,该评分函数既要选择简单的结构模型,又要充分地 与样本数据进行拟合。

4.5 算法过程描述

小数据集条件下,基于 Bootstrap 方法的矩阵化约束 BN 结构学习算法^[18]的算法流程如图 6 所示,具体步骤如下。

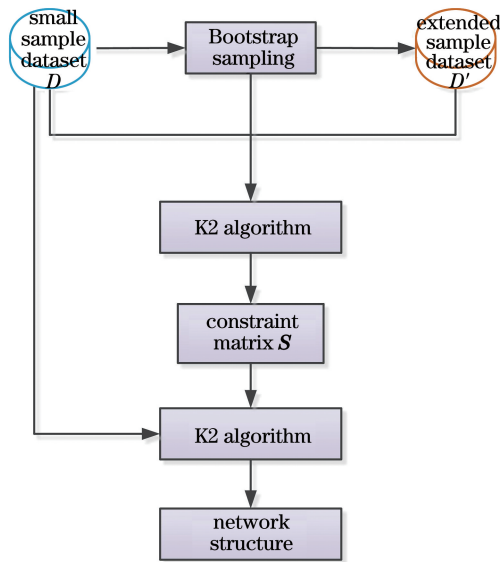


图 6 基于矩阵化约束 BN 结构学习算法流程图

Fig. 6 Flow chart of BN structure learning algorithm based on matrix constraints

- 1) 给定初始的小数据集 D ;
- 2) 利用重复 Bootstrap 抽样,得到扩展数据集 $D' = \{D_1 + D, D_2 + D, \dots, D_m + D\}$;
- 3) 利用 K2 算法学习数据集 D' 中每个子集,得到该数据集对应的网络结构集 $G = \{G_1, G_2, \dots, G_m\}$;
- 4) 将网络结构集 $G = \{G_1, G_2, \dots, G_m\}$ 转化为约束矩阵 S ;
- 5) 应用约束矩阵 S 约束评分函数,得到基于约束条件下的评分函数;
- 6) 在小数据集条件下,基于矩阵约束的评分函

数并结合 K2 算法构建 BN 结构模型。

5 基于先验约束的参数学习算法

5.1 先验参数分布模型

首先要选用一个概率分布 $P(\theta)$ 来表示 θ 的先验知识,然后把数据集 $D = \{Y_i, Y_{i-1}, \dots\}$ 的影响用似然函数 $L(\theta | D) = P(D | \theta)$ 来归纳,最后使用贝叶斯公式将先验分布和似然函数结合,得到 θ 的后验分布,即

$$P(\theta | D) \propto P(\theta)L(\theta | D). \quad (7)$$

在 i. i. d 条件下,即变量独立同分布时,(7) 式中 $L(\theta | D)$ 为多项式似然函数的共轭分布,如果假设先验分布 $P(\theta)$ 是 Dirichlet 分布,即

$$P(\theta) = \prod_{i=1}^n \prod_{j=1}^q \prod_{k=1}^r \theta_{ijk}^{\alpha_{ijk}-1}, \quad (8)$$

则后验分布 $P(\theta | D)$ 也是 Dirichlet 分布,这使得贝叶斯估计变得简单。其中, α 为位置参数,

$\sum_{i=1}^r \alpha_{ijk} = 1, \theta_{ijk}$ 为最大似然估计值,其表达式为

$$\theta_{ijk} = \frac{N_{ijk}}{\sum_k N_{ijk}}, \quad (9)$$

其中, N_{ijk} 为当节点 i 的状态为 k 时,且其父节点集为父节点集 Σ_i 中的第 j 个父节点集时的样本个数。

因此在观测样本下, θ 的后验分布 $P(\theta | D)$ 为

$$p(\theta | D) \propto \prod_{i=1}^n \prod_{j=1}^q \prod_{k=1}^r \theta_{ijk}^{N_{ijk} + \beta \alpha_{ijk} - 1}, \quad (10)$$

其中 β 为形参。因此当样本量 D 很小时,这个估计主要依赖于先验知识,当样本量 D 增大时,这个估计越来越依赖于样本数据,越来越接近最大似然估计值。

在(8)式的 Dirichlet 先验分布中参数物理意义不明显,在实际应用中很难由领域知识直接确定。考虑到 Dirichlet 分布的边缘分布是 Beta 分布,根据贝叶斯估计和领域知识建立的先验 Beta 分布模型,在 i. i. d 条件下有

$$P(\theta) = B[\alpha, \beta] \theta^{\alpha-1} (1 - \theta)^{\beta-1}, \quad (11)$$

其中 $B[\alpha, \beta] = \frac{\tau(\alpha + \beta)}{\tau(\alpha)\tau(\beta)}$, α 和 β 均大于 0,称为 Beta 分布的两个超参数。为更加准确地描述领域知识,将领域知识表示为先验分布超参数 α 和 β 描述的估计值以及估计值的可信度。该 Beta 分布的期望与方差分别为

$$\begin{cases} E(\theta'_1) = \frac{\alpha + \beta\theta_0}{\alpha + \beta} \\ \sigma(\theta'_1) = \frac{\alpha\beta(1 - \theta_0)^2}{(\alpha + \beta)^2(\alpha + \beta + 1)} \end{cases}, \quad (12)$$

其中, θ_0 初始参数估计值, θ'_1 为下一次迭代先验参数。

5.2 约束条件下先验参数的确定方法

参数的先验信息通常以连续区间的形式给出。例如, 根据领域知识或专家经验, 可给出先验参数估计区间 $\theta_{ijk} \in [\theta_1, \theta_2]$ 。首先以均匀分布描述先验信息, 然后以先验参数为变量, 将均值作为约束, 方差作为目标, 利用最优化方法求出与该均匀分布最为接近的 Beta 分布。作为参数的先验分布, 均匀分布的均值和方差可表示为

$$\begin{cases} E_u(\theta_{ijk}) = \frac{(\theta_1 + \theta_2)}{2} \\ \sigma_u(\theta_{ijk}) = \frac{(\theta_1 - \theta_2)^2}{12} \end{cases} \quad (13)$$

采用约束条件下的凸优化方法^[19]求解两个 Beta 分布的先验参数。凸优化模型的约束条件^[20]为

$$\min(\sigma_u - \sigma), \text{ s. t. } E = E_u, \alpha > 0, \beta > 0. \quad (14)$$

将 (12) 式和 (13) 式联立, 通过 (14) 式即可求解出能够准确描述领域知识的先验参数 α 和 β , 以及对应的 Beta 分布 $B[\alpha, \beta]$; 对该先验分布进行采样, 可得先验条件下的虚拟样本, 从而将领域知识利用约束条件下的先验参数转化为样本数据。该方式增加了网络数据信息量, 提高了小数据集条件下的 BN 参数学习精度。

5.3 算法过程描述

下面给出小数据集条件下基于先验约束的 BN 参数学习算法^[21-22]的具体步骤, 算法流程如图 7 所示。

- 1) 给定 BN 初始参数 θ_0 。
- 2) 在完备样本数据集下, 获得无约束条件下的条件概率统计模型。

3) 利用根据专家领域知识得出的参数估计区间 $\theta_{ijk} \in (\theta_1, \theta_2)$ 来约束先验 Beta 分布。Beta 分布 $B[\alpha, \beta]$ 进行 n 次采样后统计。设 N 为采样的总个数, 当采样结果满足 $\theta_1 < B(i) < \theta_2$ 时, Beta 分布的形参 β 的个数增加 1, 位置参数 τ 可表示为

$$\tau = \frac{\prod_{k=1}^i B(k)}{\beta}. \quad (15)$$

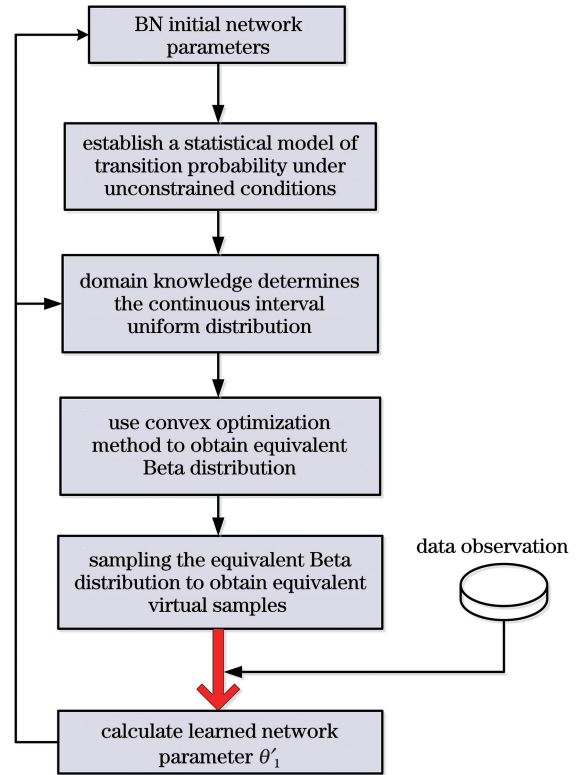


图 7 基于先验约束的参数学习算法流程图

Fig. 7 Flow chart of parameter learning algorithm based on prior constraints

4) 通过 (14) 式建立的凸优化方程, 完成先验参数的分布函数估计, 对该分布函数进行采样获得 Beta 分布下的虚拟等价样本。

5) 将获得的等价样本加入 BN 转移概率统计模型, 统计真实样本与虚拟等价样本量, 求得 BN 网络参数, 表达式为

$$\theta_{ijk} = \frac{s\tau + N_{ijk}}{s + N_{ij}}, \quad (16)$$

其中 $\sum_k \tau_{ijk} = 1$, τ 可由先验参数估计值确定。

6) 返回步骤 3), 对领域知识的连续区间的均匀分布及网络参数进行更新, 继续下一次网络递归的参数估计。

6 仿真及分析

6.1 算法仿真

本研究采用 Asia 网络进行算法验证, 样本量由 10 增加到 100。将本文提出的 K2 算法与原 K2 算法进行对比, 为了避免数据采样随机性的影响, 对每个算法都运行 10 次, 求取平均值作为最终结果, 算法对比结果如图 8~11 所示。

由图 8 和图 9 可以看出, 在数据量为较小时,

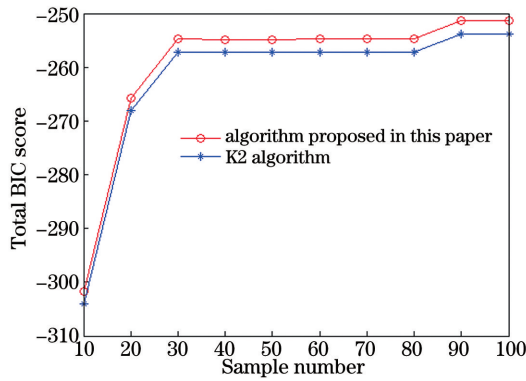


图 8 本文算法与 K2 算法的总 BIC

Fig. 8 Total BIC score of the algorithm proposed in this paper and the K2 algorithm




图 9 本文算法与 K2 算法的平均 BIC

Fig. 9 Average BIC score of the algorithm proposed in this paper and K2 algorithm

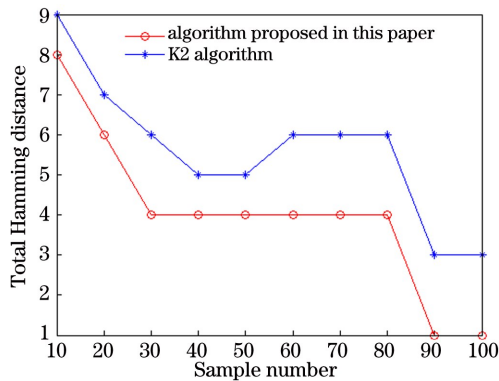


图 10 本文算法与 K2 算法的总汉明距离

Fig. 10 Total Hamming distance between the algorithm in this paper and the K2 algorithm




图 11 本文算法与 K2 算法的平均汉明距离

Fig. 11 Average Hamming distance between the algorithm in this paper and the K2 algorithm

本文所提算法得到的 BN 结构的 BIC 评分优于原始 K2 算法。且由图 10 和图 11 可以看出,当样本量大于 35 时,本文算法得到的 BN 结构的汉明距离更小。由此证明本文增加的约束项使 K2 算法在小数据集集中也可得到较好的学习效果。

6.2 基于 BN 的无人机威胁评估系统仿真

针对小数据集条件,利用 BN 结构学习与参数学习的算法,实现了 UAV 在通信中断后的威胁评估。通过分析相同数据集条件下传统 BN 学习算法的对比仿真实验,验证了本文提出的小数据集下 BN 学习算法的优越性和可行性。下面给出具体的仿真条件和仿真方法:

1) 本文仿真工作使用的 Matlab 版本为 R2010a,运行环境为操作系统 Window XP。

2) 在通信中断前,UAV 接收到的数据较少。由于 BN 的参数学习需要在 BN 结构稳定后进行,故仿真中首先在小数据集条件下学习威胁评估模型的 BN 结构,当所学威胁评估模型的 BN 结构稳定后,学习该 BN 结构对应的网络参数。

3) UAV 威胁评估过程中应用第 4 节提出的基于矩阵化约束 BN 结构学习算法完成威胁评估模型的结构学习,利用第 5 节提出的基于先验约束的 BN 参数学习算法完成威胁评估模型的学习。

4) 专家对模型有一定的认知,威胁评估网络节点序的信息为 {T,L,K,I}。表 2 给出了参数对应的

表 2 参数对应的区间约束

Table 2 Interval constraints corresponding to parameters

Target threat	Target type	Target confrontation	Target location
(T1: low,T2: high)	(I1: Warning radar,I2: AAP)	(K1: yes,K2: no)	(L1: far,L2: near)
T1(low)	[0.3,0.7]	([0.7,0.9], [0.1,0.3])	([0.3,0.7], [0.3,0.7])
T2(high)	[0.3,0.7]	([0.2,0.4], [0.6,0.8])	([0.5,0.7], [0.3,0.5])

区间约束。

5) 威胁评估模型初始参数如表 3 所示。

6) 根据以上相同的样本数据,在相同的条件下

利用传统的 K2 结构学习算法和最大似然估计参数学习算法完成对 UAV 威胁评估模型的学习。

7) 完成对仿真结果的分析。

表 3 威胁评估模型初始参数

Table 3 Initial parameters of threat assessment model

Target threat (T1: low, T2: high)	Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low) 0.5	(0.5, 0.5)	(0.8, 0.2)	(0.5, 0.5)
T2(high) 0.5	(0.9, 0.1)	(0.3, 0.7)	(0.6, 0.4)

图 12~15 分别为 20 组、30 组、40 组以及 50 组数据条件下应用小数据集条件下 BN 结构学习算法的网络学习结果,当网络结构稳定后开始进行参数学习。




图 12 20 组数据本文算法所得的威胁评估网络

Fig. 12 Threat assessment network based on 20 sets of data by our algorithm




图 13 30 组数据本文算法所得的威胁评估网络

Fig. 13 Threat assessment network based on 30 sets of data by our algorithm




图 14 40 组数据本文算法所得的威胁评估网络

Fig. 14 Threat assessment network based on 40 sets of data by our algorithm




图 15 50 组数据本文算法所得的威胁评估网络

Fig. 15 Threat assessment network based on 50 sets of data by our algorithm

通过以上在不同数据样本量条件下学习威胁评估网络的仿真结果发现,当样本量大于 40 组时,网络结构趋于稳定,不随样本数据量的增加而变化,此时可确定威胁评估网络模型如图 16 所示。

威胁评估网络模型结构已经稳定,此时利用基于先验约束的 BN 参数学习算法学习模型网络参数。下面分别给出 40 组、50 组、60 组数据样本量条件下的参数学习结果,如表 4~6 所示。

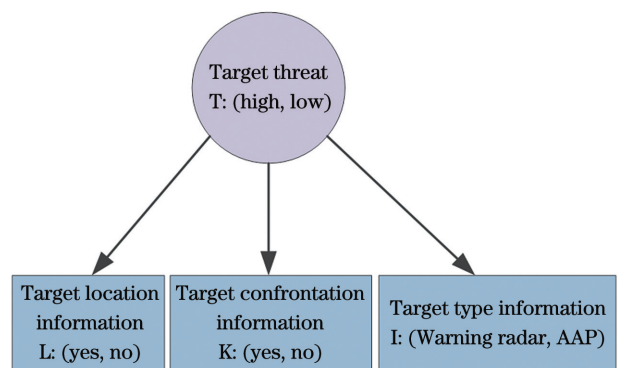


图 16 UAV 威胁评估网络模型结构

Fig. 16 UAV threat assessment network model structure

表 4 40 组数据本文算法所得模型参数

Table 4 40 sets of data model parameters obtained by our algorithm

Target threat (T1: low, T2: high)		Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low)	0.5173	(0.4841, 0.5159)	(0.7866, 0.2134)	(0.5086, 0.4914)
T2(high)	0.4827	(0.9008, 0.0992)	(0.2240, 0.7760)	(0.64050, 0.3595)

表 5 50 组数据本文算法所得模型参数

Table 5 50 sets of data model parameters obtained from our algorithm

Target threat (T1: low, T2: high)		Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low)	0.4867	(0.4391, 0.5609)	(0.8094, 0.1906)	(0.4454, 0.5546)
T2(high)	0.5133	(0.8851, 0.1149)	(0.2189, 0.7811)	(0.5343, 0.4657)

表 6 60 组数据本文算法所得模型参数

Table 6 60 sets of data model parameters obtained by our algorithm

Target threat (T1: low, T2: high)		Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low)	0.4657	(0.4583, 0.5417)	(0.8146, 0.1854)	(0.4484, 0.5516)
T2(high)	0.5343	(0.8866, 0.1134)	(0.2380, 0.7620)	(0.5069, 0.4931)

下面利用相同的数据样本在相同的条件下应用传统的 K2 结构学习算法与最大似然参数学习算法完成对 UAV 威胁评估模型的学习。由于网络模型稳定后才可以进行 BN 参数学习,故先利用 K2 结构学习算法学习威胁评估网络。下面分别列出在 40 组、50 组、60 组和 70 组数据样本量的条件下 K2 结构学习算法的学习结果,如图 17~20 所示。




图 17 40 组数据 K2 算法所得威胁评估网络

Fig. 17 Threat assessment network derived from 40 sets of data by K2 algorithm




图 18 50 组数据 K2 算法所得威胁评估网络

Fig. 18 Threat assessment network derived from 50 sets of data by K2 algorithm




图 19 60 组数据 K2 算法所得威胁评估网络

Fig. 19 Threat assessment network derived from 60 sets of data by K2 algorithm

由以上结构学习结果可以看出,当数据样本量达到 60 组时,威胁评估模型网络开始稳定,可以应用最大似然估计参数学习 (MLE) 算法^[23]学习网




图 20 70 组数据 K2 算法所得威胁评估网络

Fig. 20 Threat assessment network derived from 70 sets of data by K2 algorithm

络模型参数。下面列出 60 组、70 组、80 组数据样本量条件下 MLE 算法得到的威胁评估模型网络参数

表 7 60 组数据 MLE 算法所得模型参数

Table 7 Model parameters obtained from 60 sets of data by MLE algorithm

Target threat (T1: low, T2: high)	Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low) 0.4750	(0.4737, 0.5263)	(0.6184, 0.3452)	(0.4474, 0.5526)
T2(high) 0.5250	(0.6548, 0.3452)	(0.3929, 0.6071)	(0.4643, 0.5357)

表 8 70 组数据 MLE 算法所得模型参数

Table 8 Model parameters obtained from 70 sets of data by MLE algorithm

Target threat (T1: low, T2: high)	Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low) 0.5286	(0.3784, 0.6216)	(0.8649, 0.1351)	(0.4595, 0.5405)
T2(high) 0.4714	(0.7879, 0.2121)	(0.1212, 0.8788)	(0.6061, 0.3939)

表 9 80 组数据 MLE 算法所得模型参数

Table 9 Model parameters obtained from 80 sets of data by MLE algorithm

Target threat (T1: low, T2: high)	Target type (I1: Warning radar, I2: AAP)	Target confrontation (K1: yes, K2: no)	Target location (L1: far, L2: near)
T1(low) 0.5875	(0.4255, 0.5745)	(0.8298, 0.1702)	(0.3830, 0.6170)
T2(high) 0.4125	(0.9394, 0.0606)	(0.1515, 0.8485)	(0.6061, 0.3939)

表 10 本文算法的 KL 散度结果

Table 11 KL-divergence results of this algorithm

40 groups	50 groups	60 groups
0.0163	0.0161	0.0156

表 11 MLE 算法的 KL 散度结果

Table 11 KL-divergence results of MLE algorithm

60 groups	70 groups	80 groups
0.0188	0.0160	0.0132

从以上参数学习结果和 KL 散度结果可以看

学习结果,如表 7~9 所示。

根据以上两种方法对威胁评估模型网络参数进行学习,利用 KL 散度来衡量所学参数结果与真实网络模型参数之间的差距。由于基于矩阵化约束的 BN 结构学习算法在样本量为 40 组时已经学到了稳定的威胁评估模型网络,而 K2 算法则在 60 组数据样本量时威胁评估网络才稳定,因此基于先验约束的 BN 参数学习算法的参数学习结果分别是在 40 组、50 组和 60 组样本量的条件下得到的,最大似然估计参数学习算法(MLE)的参数学习结果则是在 60 组、70 组和 80 组样本量的条件下得到的。表 10 和表 11 分别为基于先验约束的 BN 参数学习算法和最大似然估计算法(MLE)的 KL 散度结果。

出,无论是小数据集条件下的 BN 学习算法还是传统的 BN 学习算法,随着样本量的不断增加,算法学得的网络参数精度不断提高,KL 散度不断减小并趋近于 0,与真实威胁评估网络模型参数不断逼近。但本文算法在 40 组样本条件下所学的参数 KL 散度评分结果与传统的 BN 学习算法在 70 组样本量时所学的参数 KL 散度评分结果相当,这充分地体现了本文算法相对于传统 BN 学习算法具有对样本数量依赖性小和学习精度高的优势,这些优势使得本文算法具备在小数据集条件下应对 UAV 威胁评估建模的能力。

下面利用相同数据样本,分别应用真实网络参数、本文算法所得的网络参数和传统 BN 学习算法得到的网络参数完成威胁评估模型网络推理,得到样本数据量与威胁评估结果的变化曲线,以此表征不同数据量条件下的威胁程度,如图 21 所示。

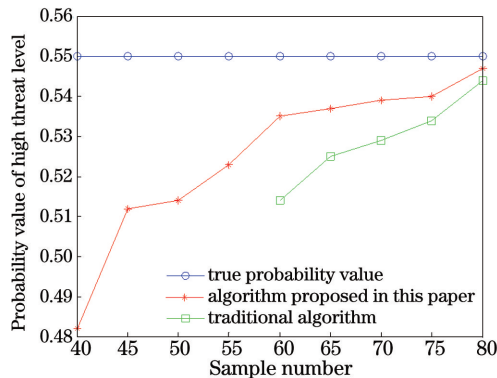


图 21 数据量与威胁概率的关系图

Fig. 21 Relationship between data volume and threat probability

上面仿真实验表明,随着样本数量的增加,小数据集条件下的 BN 学习算法与传统的 BN 学习算法得到的网络参数的精度不断增加,并且均不断地逼近真实参数所得到的推理结果。但当样本数量为 40 组时,小数据集条件下的 BN 学习结构学习算法已经学到了真实的威胁评估模型网络,而后开始进行参数学习,而且当样本数量达到 50 时,推理结果与传统 BN 学习算法 60 组的推理结果相当。由于数据样本量在 40 组到 60 组的过程中,传统 BN 结构学习 K2 算法无法学到稳定的威胁评估 BN 结构,进而不能进行 BN 参数学习,因此,在 40 组到 60 组数据样本量之间,没有威胁程度评估推理结果。当数据样本量从 60 组到 80 组增加的过程中,传统 BN 学习算法才逐渐发挥作用,渐渐地逼近小数据集条件下 BN 学习算法与真实参数的推理结果。

7 结 论

针对 UAV 在小数据集条件下的威胁评估问题,本文提出矩阵化约束的 BN 结构学习算法,进而结合基于先验约束的 BN 参数学习算法完成了 BN 的结构学习和参数学习。通过与传统 BN 学习算法的仿真实验作对比,结果表明,传统算法至少需要 60 组数据才能得到推理结果,而本文算法仅需 40 组数据就有能力解决 UAV 威胁评估的问题,验证了本文算法的优越性。本文算法的不足之处在于 BN 结构学习采用近似学习算法,学习到的结构为

局部最优解,会影响最后的推理准确度。下一步的工作是考虑引入另一种约束,对 BN 结构近似学习算法进行改进,或直接采用改进的精确学习算法(受限于节点数,最多处理 26 个节点)来提高推理结果的准确度。

参 考 文 献

- [1] Wang Y, Liu S Y, Zhang W, et al. Threat assessment method with uncertain attribute weight based on intuitionistic fuzzy multi-attribute decision [J]. *Acta Electronica Sinica*, 2014, 42(12): 2509-2514.
王毅, 刘三阳, 张文, 等. 属性权重不确定的直觉模糊多属性决策的威胁评估方法 [J]. *电子学报*, 2014, 42(12): 2509-2514.
- [2] Mata F, Martínez L, Herrera-Viedma E. An adaptive consensus support model for group decision-making problems in a multigranular fuzzy linguistic context [J]. *IEEE Transactions on Fuzzy Systems*, 2009, 17(2): 279-290.
- [3] Wang J Q, Li K J, Zhang H Y. Interval-valued intuitionistic fuzzy multi-criteria decision-making approach based on prospect score function [J]. *Knowledge-Based Systems*, 2012, 27: 119-125.
- [4] Lee H, Choi B J, Kim C O, et al. Threat evaluation of enemy air fighters via neural network-based Markov chain modeling [J]. *Knowledge-Based Systems*, 2017, 116: 49-57.
- [5] Zhang B Y, Yin J P, Wang S L, et al. Research on virus detection technique based on ensemble neural network and SVM [J]. *Neurocomputing*, 2014, 137: 24-33.
- [6] Benavoli A, Ristic B, Farina A, et al. An application of evidential networks to threat assessment [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 45(2): 620-639.
- [7] Yang J, Gao W Y, Liu J. Threat assessment method based on Bayesian network [J]. *Journal of PLA University of Science and Technology (Natural Science Edition)*, 2010, 11(1): 43-48.
杨健, 高文逸, 刘军. 一种基于贝叶斯网络的威胁估计方法 [J]. *解放军理工大学学报(自然科学版)*, 2010, 11(1): 43-48.
- [8] Okello N, Thorns G. Threat assessment using Bayesian networks [C]//Sixth International Conference of Information Fusion, 2003, July 8-11, 2003, Cairns, QLD, Australia. New York: IEEE Press, 2003: 1102-1109.
- [9] Yang A W, Li Z W, Xu A, et al. Threat level assessment of the air combat target based on

- weighted cloud dynamic Bayesian network[J]. *Flight Dynamics*, 2020, 38(4): 87-94.
- 杨爱武, 李战武, 徐安, 等. 基于加权动态云贝叶斯网络空战目标威胁评估[J]. *飞行力学*, 2020, 38(4): 87-94.
- [10] Cen M, Guo Y N, Lu K. Bayesian network based threat assessment method for vehicle[J]. *Journal of Computers*, 2012, 7(7): 1726-1732.
- [11] Gao X G, Li Q Y, Di R H. MPC three-dimensional dynamic path planning for UAV based on DBN threat assessment[J]. *Systems Engineering and Electronics*, 2014, 36(11): 2199-2205.
- 高晓光, 李青原, 邸若海. 基于 DBN 威胁评估的 MPC 无人机三维动态路径规划[J]. *系统工程与电子技术*, 2014, 36(11): 2199-2205.
- [12] Di R H, Gao X G, Guo Z G. Bayesian networks structure learning based on improved BIC scoring[J]. *Systems Engineering and Electronics*, 2017, 39(2): 437-444.
- 邸若海, 高晓光, 郭志高. 基于改进 BIC 评分的贝叶斯网络结构学习[J]. *系统工程与电子技术*, 2017, 39(2): 437-444.
- [13] Low L Y, Efron B. The Jackknife: the Bootstrap and other resampling plans[J]. *Journal of the American Statistical Association*, 1983, 78(384): 987.
- [14] Chwila A, Żądło T. On the choice of the number of Monte Carlo iterations and Bootstrap replicates in empirical best prediction[J]. *Statistics in Transition New Series*, 2020, 21(2): 35-60.
- [15] Lauritzen S L, Spiegelhalter D J. Local computations with probabilities on graphical structures and their application to expert systems [J]. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1988, 50(2): 157-194.
- [16] Cooper G F, Herskovits E. A Bayesian method for the induction of probabilistic networks from data[J]. *Machine Learning*, 1992, 9(4): 309-347.
- [17] Jiang J K, Wang J Y, Yu H, et al. Poison identification based on Bayesian network: a novel improvement on K2 algorithm via Markov blanket [M] // Tan Y, Shi Y H, Mo H W. *Advances in swarm intelligence. Lecture notes in computer science*. Heidelberg: Springer, 2013, 7929: 173-182.
- [18] Gal E. Bagged structure learning of Bayesian networks[J]. *Journal of Machine Learning Research*, 2011, 15: 251-259.
- [19] Zhou L, Liu X X, Fang Y J, et al. Systematic biases estimation based on convex optimization under Bayesian framework [J]. *Journal of Detection & Control*, 2019, 41(4): 92-97.
- 周林, 刘先省, 方拥军, 等. 贝叶斯框架下基于凸优化的系统偏差估计方法[J]. *探测与控制学报*, 2019, 41(4): 92-97.
- [20] Zhang Z. *Research on non-convex optimization algorithms for UAV path planning problems [D]*. Shanghai: Shanghai Jiao Tong University, 2019.
- 张哲. 无人机航迹规划问题的非凸优化算法研究 [D]. 上海: 上海交通大学, 2019.
- [21] Yang Y, Gao X G, Guo Z G. Learning BN parameters with small data sets based by data reutilization[J]. *Acta Automatica Sinica*, 2015, 41(12): 2058-2071.
- 杨宇, 高晓光, 郭志高. 小数据集条件下基于数据再利用的 BN 参数学习[J]. *自动化学报*, 2015, 41(12): 2058-2071.
- [22] Guo Z G, Gao X G, Di R H. Learning Bayesian network parameters from small data set: an adaptive method[J]. *Control Theory & Applications*, 2016, 33(7): 945-955.
- 郭志高, 高晓光, 邸若海. 小数据集条件下贝叶斯网络自适应参数学习方法[J]. *控制理论与应用*, 2016, 33(7): 945-955.
- [23] Lei J N. *Study and implementation of Bayesian network parameter learning algorithm [D]*. Xi'an: Xidian University, 2018.
- 雷江南. 贝叶斯网络参数学习算法研究与实现[D]. 西安: 西安电子科技大学, 2018.