

基于双层贝叶斯网增强学习机制的网络认知算法^{*}

褚灵伟, 李捷[†], 董晨, 陆肖元
(上海宽带技术及应用工程研究中心, 上海 200336)

摘要: 为提高网络认知的准确度, 采用双层贝叶斯网络模型对网络参数进行层次化描述; 采用强化学习推理算法对模型的条件概率表进行分级和学习, 删除冗余信息, 更准确地反映网络参数间的依赖关系, 保证网络认知算法的准确度。经仿真分析, 证明算法能够更好地描述网络参数的依赖信息, 具有较高的推理准确度。

关键词: 认知网络; 贝叶斯网络; 分层模型; 增强学习

中图分类号: TP393 **文献标志码:** A **文章编号:** 1001-3695(2014)05-1320-04

doi: 10.3969/j.issn.1001-3695.2014.05.008

Network cognitive algorithm based on double-layer Bayesian network enhanced learning

CHU Ling-wei, LI Jie[†], DONG Chen, LU Xiao-yuan

(Shanghai National Engineering Research Center for Broadband Networks & Applications, Shanghai 200336, China)

Abstract: In order to effectively improve the accuracy of cognitive network, this paper used a double-layer Bayesian networks model to describe the relations among different variables through a certain hierarchy. Thus, inference would become more accurate. It used reinforcement learning algorithm to learn and classify conditional probability table in the process of inference of these variables. This way could improve the inference accuracy and deleted redundant information, and it could more accurately reflect the dependent relationships among network parameters, guaranteed more conducive to precise inference. The simulation analysis proves the effectiveness of the algorithm.

Key words: cognitive network; Bayesian network; double-layer; reinforcement learning

传统网络是一个信息传输、接收、共享的平台, 用户可以通过它将各种丰富的信息联系在一起, 从而实现不同地域之间的信息共享。认知网络是近年新提出的前沿通信技术, 综合采用了感知、学习、重配置等技术, 使其具有重要的应用价值。认知网络是一个具有认知过程的网络, 它能通过感知当前的网络环境, 经过自身的理解与学习, 并依据这些理解和学习到的知识来调整其内部的相应配置以适应外部网络的变化, 具有一定的自适应能力, 即它能在动态自适应的过程中不断地学习和积累相关知识, 并以此为依据来对网络进行相关的调整、判决和再配置^[1]。认知网络具有上下文感知、自学习、重配置、跨层设计等基本特征^[2]。

目前, 认知网络已经成为国内外研究的热点, 其研究主要集中在以下几个方面: a) 认知网络体系结构; b) 认知网络环境感知技术, 主要研究了基于本体的知识建模方式, 使得认知网元获取的数据能够得到网络管理目标的理解^[3]; c) 认知网络 QoS 智能决策, 主要成果是认知网络 QoS 管理产生动态策略与规则的各种方法^[4]; d) 认知网络自适应配置, 其中的一项研究成果是提出了 QoS 调节系统, 对组件的运行行为进行基于规则的调节, 同时引入了预测控制, 可以预测 QoS 组件在当前环境中的操作, 推导出 QoS 组件应当作出哪些必要的改变^[5]。

可以看出, 国内外研究认知网络的现有研究成果缺乏对认知网络态势的全局性评估^[6], 对网络分层研究不足, 导致对网

络各层次节点之间的依赖关系利用不足; 缺乏对网络层次中各个网络节点的识别和它们之间相互关系的了解和认识, 进而导致网络认知能力下降, 推理缺乏可信度, 从而其推理结果不能完全满足某些高质量的网络应用需求。本文将贝叶斯网络理论和强化学习算法应用到网络中, 基于强化学习算法为现有的网络结构提出了一种准确反映网络各层次节点间关联关系的双层贝叶斯网络推理算法 (double-layer Bayesian network inference algorithm based on reinforcement learning, DBNIA)。

1 贝叶斯网络模型

贝叶斯网络是一种有向非循环网络^[7], 主要是由节点、有向弧线和条件概率分布表组成的, 包含一个反映节点依赖与独立关系的贝叶斯网络结构图和对应的条件概率表 (CPT)。图中的每个节点代表对应的变量; 条件概率标志节点与节点间的依赖强度, 也就是一系列的概率值^[8]。

在贝叶斯网络中, CPT 是其较重要的一个部分, 在贝叶斯网络进行推理的过程中, 主要是要计算由贝叶斯网络各节点组成的随机向量对应的联合概率分布, 它可以分解为随机变量边缘分布的乘积, 即

$$P(x_1, x_2, \dots, x_n | B) = \prod_{i=1}^n P(x_i, \pi_i) = \frac{\sum_{A - \{x_i\} \cup \pi_i} P(x_1, x_2, \dots, x_n)}{\sum_{A - \{x_i\}} P(x_1, x_2, \dots, x_n)} \quad (1)$$

式中: B 表示一个贝叶斯网络; $x_1, x_2, \dots, x_n$ 表示网络中的节

收稿日期: 2013-07-10; 修回日期: 2013-08-30 基金项目: 国家“863”计划资助项目 (2011AA01A109)

作者简介: 褚灵伟 (1982-), 男, 上海人, 工程师, 博士, 主要研究方向为未来网络、SDN; 李捷 (1979-), 男 (通信作者), 上海人, 工程师, 博士, 主要研究方向为未来网络、数据挖掘 (jieli@bnc.org.cn); 董晨 (1978-), 男, 上海人, 工程师, 学士, 主要研究方向为 SDN; 陆肖元 (1975-), 男, 江苏常州人, 高级工程师, 博士, 主要研究方向为未来网络、SDN、优化算法。

点,即问题随机变量; $A = \{x_1, x_2, \dots, x_n\}$ 表示问题的随机变量集合; $\pi_i (i = 1, 2, \dots, \infty)$ 表示贝叶斯网络的某个随机变量 i 对应的父节点集。

在应用贝叶斯网络模型进行推理时,即利用随机变量之间的依赖关系和 CPT 进行概率采样,在可能的问题空间中进行启发式的搜索。其中一个合理的评分函数是搜索成功的关键,它主要是用来评价当前所建立的贝叶斯网络对已有的训练数据的匹配程度。有两种主要的评分函数,即贝叶斯评分函数和最小描述长度原理 (minimal description length, MDL) 评分函数^[9],它们在数据样本数目增加时,在所构建的候选网络中,得分最高的网络将任意逼近数据样本的概率分布。本文采用贝叶斯信息准则 (BIC) 作为评分函数^[10]。

2 增强学习算法

强化学习 (reinforcement learning, RL) 是指自治单元 agent 通过与环境直接交互,学习到能达到其最终目标的最优动作,并使自治单元 agent 的动作能从环境中获得最优的累积奖赏值^[11]。这种算法的思想主要来源于生物在适应环境的学习过程中所产生的动作,它们一直都不是静止被动地等待,而是动态主动地与环境进行交互,并通过环境的反馈信号进行所做动作的修正。一般情况下,环境的反馈分奖励的或惩罚的。通过这种方式,生物在该交互过程中不断地获取和积累知识,并进一步改进自身的动作,以达到期望的目标。

强化学习算法过程通常可以用一个马尔可夫决策过程 (Markov decision process) 来表示,该马尔可夫决策过程由一个四元组来定义 $\langle s, a, r, t \rangle$ 。其中, s 是状态集合; a 是动作集合; $r: s \times a \rightarrow r$ 是奖励和惩罚函数,表示动作 a 在状态 s 下所得到的当前时刻奖赏值; $t: s \times a \rightarrow p(s)$ 是状态转移函数,表示动作 a 在状态 s 下到达下一个状态 s' 的概率。在强化学习算法的使用过程中,长期的奖赏和惩罚的积累是需要考虑的,一般需要定义一个目标函数 W 来从长期所学习到的累计知识中确定最优的动作,表示形式如下:

$$W^*(s_{t+1}) = \max \{ r_t + \gamma \sum_{s(t) \in s} p(s_{t+1} | s_t, a_t) W^*(s_t) \} \quad (2)$$

其中: s^* 表示所找到的最优解, $\gamma (0 \leq \gamma \leq 1)$ 是折扣因子。

3 问题描述

本文所关注的问题是一个 NP-hard 的推理准确性问题。该问题的最终目标是发现网络中的每个网络参数所对应的最大推理概率值。用数学公式描述该问题如下:

$$P = \arg \max_{\substack{p_i \in p(k), \\ k=1,2,\dots,m}} (U) \quad i \in \{1, 2, \dots, n\} \text{ and } m \in \{1, 2, \dots, M\} \quad (3)$$

式中的各项满足:

$$U = \arg \max_{\substack{p_i \in p(k), \\ k=1,2,\dots,m}} (P) \quad (4)$$

$$p = \frac{H_i(m)}{nS} \quad n \in \{n, (N-n)\}, H \in \{H, H'\} \quad (5)$$

$$H = \sum_{j=1}^S h(m) \quad m \in \{1, 2, \dots, M\} \quad (6)$$

其中: N 是一个网络中需要建模和推理分析的网络参数; S 是已感知的每个参数采样数据,每个参数的取值范围是 $[1, M]$ 。这里存在一个感知采样数据集,该数据集共有 $N \times S$ 项数据, N 表示该认知网络的网络节点数, S 表示总的采样数; i 为数据集的第 i 项参数,取值范围是 $[1, M]$ 。 $H_i(m)$ 表示当前第 i 参数第 m 个值在数据集中出现的总次数,即 $H_i(m) = \sum i(1 \rightarrow$

$S)(m)$ 。第 i 参数的第 m 个值的概率为 $p_i(m) = H_i(m) / (n \times S)$, 是每个参数值的先验概率。 $\arg \max(i) = \max(p_i)$ 表示每一个参数所对应的最大推理概率值 (最优值); $\arg \max(U) = \max(p_i) (i \text{ 为 } 1 \sim N)$ 是所有参数对应的最大推理概率值集合, U 就是推理数据集中的最优值。

4 基于双层贝叶斯网增强学习机制的网络认知算法

基于上述的分析和描述,传统的复杂网络优化问题可以通过分层的方式得到简化和解决,将复杂网络中不同节点之间通过一定的层次关系进行描述和建模,使得原本通过一个复杂网络模型的高维度问题作降维处理,从而使得问题得到了相应的简化,并为提出高效率和高可靠性的算法提供了可能性^[12,13]。本文首先描述一个双层贝叶斯网络推理模型,将传统的复杂网络优化问题进行了简化,并建立了一个双层的贝叶斯网络推理模型。在该模型中,为表示具有一定逻辑关系的层次结构,使用贝叶斯网络来描述网络节点之间的对应关系,其结构如图 1 所示。图 1 为两层的贝叶斯分层结构,其中顶层为分层模型中的整体贝叶斯网络结构;底层为顶层网络节点所对应的替换贝叶斯网络。




图1 双层贝叶斯网络结构

由图 1 可以看出,在该双层贝叶斯网络结构中,第一层是整体贝叶斯网络结构,它表示一个较粗粒度的节点或某个问题层次化后的子问题以及它们之间的关联关系。在该图中,由 A, B, C, D, E 来表示相关的节点变量,其中节点 C, B, D 是条件依赖于节点 A, E 条件依赖于 B ,而节点 A 和 E 之间是相互独立的。而第二层所表示的贝叶斯网络是第一层贝叶斯网络节点所对应的可替换贝叶斯网络。它表示一个较细粒度的节点或某个问题层次化后的另一个子问题及它们之间的关联关系。在该图中是由 $1, 2, 3, 4$ 来表示第二层贝叶斯网络的相关节点变量,其中节点 $2, 3, 4$ 条件依赖于节点 1 。在此处,整个第二层贝叶斯网络可以将第一层中的节点 E 进行替换,由此来表示这两层之间的关系是通过节点 E 来进行关联的。对应到某个现实的应用问题,即一个要解决的问题是可以进行层次化表示的,并可将其简单地拆分成双层结构,每层代表问题的一个子问题,并用节点表示子问题的变量,然后通过在不同层次之间构建相应的贝叶斯网络来表示这些节点的关联和依赖程度。但是这些子问题之间并不是相互独立的,它们之间是通过某个节点或某些节点进行关联的。在本文中,这些节点被称之为关键节点,如节点 E 。通过将这些节点进行替换,可以得到一个表示全局变量节点之间依赖和独立关系的双层贝叶斯网络模型。

该双层贝叶斯网络结构可以用一个三元组表示, $DBNT = \{G, T, R\}$ 。其中: G 为整体贝叶斯网络结构,即顶层网络; T 为 G 中节点所对应的可替换贝叶斯网络集合,即第二层的网络结构,若 G 中的节点没有可对应的贝叶斯网络,则 T 为空; R 为顶层贝叶斯网络节点与 T 中贝叶斯网络间的对应关系,代表了 V 中第 i 个节点和集合 T 中第 j 个元素的对应关系,且要求节点 i 的状态值与第 j 个贝叶斯网络根节点相同。

可以看出,该分层贝叶斯网络模型 DBNT 与一般贝叶斯网络模型的区别在于其某些节点对应了另一个贝叶斯网络,在应

用该模型时,可以将第二层贝叶斯网络 T 用第一层 G 中的某些节点代替。因此,采用分层的贝叶斯网络模型进行状态分析时,可以通过底层网络集合 T 中的贝叶斯网络完成信息的收集和分析,并按照条件依赖关系 R 将不同网络实体与顶层结构进行连接,从而动态构建贝叶斯网络。

在该贝叶斯网络推理中,其节点证据可分为两大类:a)具体证据,即能够确定节点为某一取值状态;b)不确定证据,以不定性表示节点的具体取值。若贝叶斯网络节点 V 的某一证据 e 为不确定证据,该不确定证据可表示为条件概率向量。由此可知,底层的贝叶斯网络和顶层的网络节点进行连接时,实际上是把底层贝叶斯网络实体所获得的证据和信息赋给顶层网络。由于该网络根节点状态值与顶层节点相同,可以将底层贝叶斯网络节点的推理结果作为不确定证据输入到相应顶层节点。其具体步骤如下:采用双层贝叶斯网络可完成对不确定信息的分级表示,并以此动态构建双层贝叶斯网络结构来作为证据输入贝叶斯网络中进行推理,最后得到概率信度值。但是,在实际操作该双层贝叶斯网络模型 DBNT 时,动态地置换贝叶斯网络节点会使顶层网络结构变得越来越复杂,并且每个节点对应的条件依赖表也将呈指数级地增长,会造成维护的成本很高,将降低推理的效率和准确度。此外,若对同一节点分别置换不同的贝叶斯网络又很容易造成网络结构的混乱,这些都为推理带来了一定的困难。

为有效地解决上述问题,采用强化学习的算法来解决动态构建贝叶斯网络的推理问题。因为在这个过程中,在将不确定信息输入到 DBNT 进行推理时,得到相关的概率信度值是一个关键的步骤,它的存在将决定不确定信息的可信度。其中,对于高可信的信息应保留在该贝叶斯网中,进行更精确的推理;而对于低可信的信息应该将其抛弃,它们的存在将严重地影响该贝叶斯网的精确推理。强化学习算法可以在此推理过程中对这些证据进行学习和判断,对不确定信息进行分级,并得到其概率信度值。具体过程如图2所示。




图2 双层贝叶斯网络的强化学习过程

从图2中可以看出其具体的流程如下:首先,在第一层贝叶斯网络中的某些节点被第二层中的贝叶斯网络所替代,如第一层的节点 D 被第二层的贝叶斯网络所替代,相当于第二层贝叶斯网络中的节点1条件依赖于节点 A ,故节点1的取值是受到节点 A 影响的,即 $p(1|A)$,第二层贝叶斯网络中的节点2、3、4是受到节点1取值影响的,它们条件依赖于节点1,即 $p(2,3,4|1)$;同样,第二层贝叶斯网络中的节点5是受到节点2、3、4取值影响的,即它们条件依赖于节点2、3、4,即 $p(5|2,3,4)$ 。由此可以得到节点5的依赖关系表,然后通过对该表进行强化学习,使得该模型中的某些变量或某些变量的信息可以被剔除。

假设 D 是属于第一层贝叶斯网络的节点变量,它的变量向量是 $\{d_1, d_2, d_3, \dots, d_n\}$,其中 n 是 D 中节点变量的个数, D'

是属于第二层贝叶斯网络的节点变量,它的变量向量是 $\{d'_1, d'_2, d'_3, \dots, d'_m\}$,其中 m 是 D 中节点变量的个数,利用式(7)描述如下:

$$P(d'_1, d'_2, \dots, d'_m | G) = \prod_{i=1}^m P(D'_i | G) = \frac{\sum_{D \cup D'} P}{\sum_{D \cup D'} P} \quad (7)$$

强化算法实施过程如下:通过前一步的贝叶斯网络节点的替换,可以得到一个相关变量的条件依赖表,可以在横轴和纵轴两个方向建立条件相关的强化学习概率,分别对应的是节点冗余的信息和节点本身,故可通过学习的策略来对多余的节点冗余信息和节点本身进行剔除。在横轴方向,节点5是条件依赖于节点2、3、4,故其强化学习概率向量有 $2^3 = 8$ 个组合条目,表示为 $\{p_1, p_2, \dots, p_8\}$,它们的初始概率都是相同的,由于没有任何的先验知识,它们的取值是相同的,都为 $\frac{1}{8}$;然后通过对其组合进行随机的取值,并将得到的组合进行环境的评估;环境将会给出奖励或惩罚的信息,利用这些环境的反馈信息和组合本身的知识进行概率的更新。如果某个组合的环境反馈为奖励,则将增加这个组合的概率;反之,如果某个组合的环境反馈为惩罚,则将减少这个组合的概率。最终通过相关的学习过程之后,得到最后的各个组合的选择概率向量 $\{0.145, 0.145, \dots, 0.005, 0.005\}$,如果某些组合的选择概率越过某个阈值,如0.008,那么这个组合认为它的信息就是冗余的,应该从这个条件依赖表中删除,如图2中的黑框所示。

在纵轴方向,节点5是条件依赖于节点2、3、4,故其强化学习概率向量有3个条目,表示为 $\{P_1, P_2, P_3\}$,它们的初始概率也都是相同的。同样由于没有任何的先验知识,它们的取值是相同的,都为 $\frac{1}{2}$;然后通过对其节点的全部取值组合进行统计,并将得到该节点所有取值的环境的评估统计值;环境将会根据节点的表现给出奖励或惩罚的信息,利用这些环境的反馈信息进行统计和概率的更新。最终通过相关的学习过程之后,得到最后的各个节点的选择概率统计向量 $\{0.45, 0.45, 0.1\}$,如果某些节点的统计概率越过某个阈值,如0.008,那么这个节点就认为它的信息是冗余的,它的存在并不能对该贝叶斯网的推理产生更好的影响,故其应该从这个条件依赖表中删除,如图2中的黑框所示。

最后,通过上述的强化学习过程,可以将多余的节点冗余信息和节点本身进行剔除,得到最终的简化图,其中的第二层节点4是可以从该网络中剔除的。进而深度地简化该双层贝叶斯网络结构,使得推理更加准确和可靠,也提升了推理的运算效率。

综上,本文提出了基于双层贝叶斯网增强学习机制的网络认知算法,其流程如下:

- 在时刻 $t \geq 1$,算法从所有可行解中根据均匀分布随机生成初始的问题解种群 $P(0)$ 。
- 算法基于当前的种群 $P(t)$ 选择出较优种群 $M(t)$,构建双层贝叶斯网络和符合这些相对较优解群 $M(t)$ 的概率依赖模型 $B(t)$ 。
- 当算法的结束条件未满足且推理未结束时,算法利用强化学习算法对当前的双层贝叶斯网模型进行推理,采样较优的解,强化学习算法根据环境的反馈进行概率更新。其结束条件定义为收敛到最优值或满足收敛次数或运行时间的要求,即 $\text{iten} = N$ 、 $\text{time} = N$,其中 N 为固定的迭代次数或运行时间。
- 将新产生的候选解利用相关的替换策略(替换最差点)

体或全部替换)替换掉当前种群中的某些个体,即将推理得到的较优($NP/2$)个解并入原始解群中,构成新的 NP 个解, NP 为种群中解的个数。

e)如果算法收敛到最优值,表明算法已收敛,此时算法结束;否则,程序转向步骤 b)。

5 仿真实验和分析

仿真实验分别使用 NS3^[14,15] 模拟网络场景并采样网络参数值,使用 MATLAB 工具箱 BNT 构建^[16] 贝叶斯网络模型和评估算法。本文模拟了一个无线网络,其中包括 1 个 AP 节点和 40 个用户节点(用户节点通过无线 AP 接入网络并两两通信)不同层次共 10 种网络参数的实际运行值。为了更加真实地反映算法的效果,分别采用 100 ms 和 1000 ms 间隔进行了两次采样,采样数均为 50 000,构成了两个不同的网络仿真数据场景。从中选择总采集数据量的 20%,用于贝叶斯网络学习评估推理模型的建立和概率表的统计;剩余 80% 数据用来对建立的学习评估推理模型和算法进行验证和评估。本文将其与传统的爬山算法和粒子群算法进行比较,所有算法的迭代数相同,为 1 000 次。各算法使用参数如表 1 所示。

表1 算法及其相关参数

参数	基于增强学习算法的双层贝叶斯网络推理算法 (DBNIRL)	爬山算法 (HS)	粒子群算法 (PSO)
基本参数	种群数:50 间隔数:50 采样数:25 学习参数:100	种群数:20 控制参数:0.3	种群数:50 惯性系数:0.9 C_1 :2.05 C_2 :2.05

最终实验结果如表 2 所示。其中, M_{avg} 、 M_{std} 和 M_{min} 分别表示对应算法所获得的平均值、所得结果的均方差以及所找到的最优解。每个算法都单独运行 15 次。

表2 算法性能比较结果

问题实例	DBNIRL			HS			PSO		
	M_{avg}	M_{std}	M_{min}	M_{avg}	M_{std}	M_{min}	M_{avg}	M_{std}	M_{min}
场景 1	0.2749	0.0007	0.2740	0.3625	0.0200	0.3232	0.2900	0.0124	0.2740
场景 2	0.4677	0.0013	0.4670	0.6064	0.0329	0.5590	0.5425	0.0347	0.4997
均值	0.3713	0.0010	0.3705	0.4845	0.0265	0.4411	0.4163	0.0236	0.3869

从表 2 中可知,所有算法都运行固定的迭代次数,运行时间相差不大。从性能上来看,本文算法优于其他被比较的算法,更适合于求解推理模型的准确度问题。在两种问题场景中, DBNIRL 的平均值是 0.2749 和 0.4677,方差为 0.0007 和 0.0013;而 HS 的平均值是 0.3625 和 0.6064,方差为 0.02 和 0.0329;PSO 的平均值是 0.2900 和 0.5425,方差为 0.0124 和 0.0347。在场景 1 中,DBNIRL 均值提高了 24.16% 和 5.20%;在场景 2 中,DBNIRL 均值提高了 22.88% 和 13.79%。DBNIRL 算法结果的方差也明显优于其他算法的结果方差,说明 DBNIRL 算法比其他算法具有更好的鲁棒性。

DBNIRL 算法与其他算法的平均值比较如图 3 所示。




图3 DBNIRL 算法的平均值与其他算法的比较结果

6 结束语

本文首先提出了一个双层贝叶斯网络模型。为了克服动

态地置换该双层贝叶斯网络节点导致的顶层网络结构变得越来越复杂、条件依赖表也将呈指数级增长、从而降低推理效率和准确度的问题,采用了强化学习的算法在推理过程中对所获取的网络节点的不确定信息进行学习和判断,简化网络结构,提高推理精度。在此基础上,本文提出了一种基于双层贝叶斯网增强学习机制的网络认知算法,设计了一种增强算法的不确定信息分级模型,从而将多余的冗余信息进行剔除,只保留里面面对推理最有用的信息,使其更利于精准推理。经仿真分析,提高了算法的全局和局部寻优能力,加快了搜索速度,提高了算法的稳定性。后续工作将深入研究如何扩展该双层贝叶斯网络模型,从而使其能够解决多层网络之间数据传输和分配的问题。

参考文献:

- [1] PEREZ-ROMERO J, DOYLE L, VURAN M C. Applications of cognitive radio networks [J]. *IEEE Vehicular Technology Magazine*, 2012, 6(4): 13-18.
- [2] LIU Juan, CHEN Wei, CAO Zhi-gang, et al. Cooperative beamforming for cognitive radio networks: a cross-layer design [J]. *IEEE Trans on Communications*, 2012, 60(5): 1420-1431.
- [3] 邵飞, 汪李峰, 伍春. 基于认知层的认知网络结构及其认知方法 [J]. *北京工业大学学报*, 2009, 35(9): 1181-1187.
- [4] CLARK D, BRADEN R, WROCLAWSKI J, et al. New ARCH: future generation Internet architecture, 2004- 235 [M]. Cambridge: MIT Computer Science & AI Lab, 2004.
- [5] GUY P, HARRY P. Specialissue: QoS, control and security in next generation networks [J]. *Telecommunication Systems*, 2008, 4(1): 3-16.
- [6] LUO Hong, TAO Hui-xiang. Data fusion with desired reliability in wireless sensor networks [J]. *IEEE Trans on Parallel and Distributed Systems*, 2011, 22(3): 501-512.
- [7] JAVADI F, JAMALIPOUR A. A multi-path cognitive resource management mechanism for QoS provisioning in wireless mesh networks [J]. *Wireless Network*, 2011, 17(1): 277-290.
- [8] SONG Heng-jie, MIAO Chun-yan. Implementation of fuzzy cognitive maps based on fuzzy neural network and application in prediction of time series [J]. *IEEE Trans on Fuzzy Systems*, 2010, 18(2): 1204-1235.
- [9] AZMAN A W, BIGDELI A, MOHD-MUSTAFAH Y, et al. A Bayesian network-based framework with constraint satisfaction problem (CSP) formulations for FPGA system design [C]//Proc of the 21st International Conference on Application-specific Systems Architectures and Processors. 2010: 81-88.
- [10] YANG Shu-lin, CHANG Kuo-chu. Comparison of score metrics for Bayesian network learning [J]. *IEEE Trans on SMC: Part A*, 2002, 32(3): 419-428.
- [11] BENGOTXEA E, LARRANAGA P, BLOCH I, et al. Reinforcement learning: a survey [J]. *Journal of Artificial Intelligence Research*, 1996, 4(1): 237-285.
- [12] PAUL T K, IBA H. Linear and combinatorial optimizations by estimation of distribution algorithms [C]//Proc of the 9th MPS Symposium on Evolutionary Computation. 2002.
- [13] NEIL M, TAILOR M, MARQUEZ D, et al. Modelling dependable systems using hybrid Bayesian networks [J]. *Reliability Engineering and System Safety*, 2008, 93(7): 933-939.
- [14] LIU Jun-yan. Bayesian network inference on risks of construction schedule-cost [C]//Proc of International Conference of Information Science and Management Engineering. 2010: 15-18.
- [15] HAO X, CHEN X, LIN H W, et al. Cooperative Bayesian optimization algorithm: a novel approach to simultaneous multiple resources scheduling problem [C]//Proc of the 2nd International Conference on Innovations in Bio-inspired Computing and Applications. 2011: 212-217.
- [16] MENDHE T K, KAMBLE P A, BADHIYE S S. PGBR protocol for cloud routing implementation in NS-3 [J]. *Journal of Electronics and Computer Science Engineering*, 2013, 2(1): 141-147.