

基于贝叶斯网络的认知引擎设计与重配置*

王娇[†] 周云辉 黄玉清 江虹

(西南科技大学信息工程学院, 绵阳 621010)

(2012年6月24日收到; 2012年8月19日收到修改稿)

以往的通信行为指导系统未来通信, 以满足用户需求并适应环境变化, 是认知无线电系统的核心所在, 为此提出了一种基于贝叶斯网络的认知引擎, 用于解决在复杂多变的电磁环境与用户需求条件下, 认知无线电系统参数自适应调整的问题. 通过对系统过去通信行为样本数据, 进行结构学习和参数学习建立认知引擎, 将系统当前环境状态和用户需求信息经预处理作为推理的证据, 应用引擎决策出系统此时最佳的工作参数, 完成系统参数重构. 本文利用 OPNET 工具建立一个移动无线网络完成仿真实验, 仿真结果表明该认知引擎能有效地使移动无线网络适应环境变化, 改善端到端通信性能, 进一步验证了建模方法的可行性.

关键词: 认知引擎, 贝叶斯网络, 重配置, 端到端性能

PACS: 84.40.Ua

DOI: 10.7498/aps.62.038402

1 引言

无线通信的迅速发展对频谱资源提出了更高的要求, 使得稀缺的频谱资源变得更加紧张. 然而, 传统无线网络之间缺乏有效的信息互通, 导致资源分配不合理及利用率低下. 同时, 由于外界因素以及网络自身的多样性和异构性, 使得无线网络呈现动态多变的特性. 为了适应环境的变化和满足人们对通信服务质量的需求, 提高资源利用率, 无线通信系统引入认知概念, 从而形成了一种学科交叉的通信技术——认知无线电 (cognitive radio, CR) 技术^[1].

认知无线电是一种智能无线通信技术^[2], 其智能性主要体现在认知学习、推理、决策与重配置能力上, 由认知引擎实现. 根据资源共享和通信服务质量等需求, 认知无线电技术充分利用认知学习能力从过去的通信行为中累积知识, 指导系统自身的参数推理决策, 并灵活进行重配置, 以适应环境的变化和满足用户需求, 实现网络资源的最优化利用, 提高网络端到端通信性能.

为实现认知无线电技术从而提高系统端到端

通信性能, 提出一种有效的认知引擎建模方法尤为重要. 目前认知无线电的研究主要集中在频谱检测与频谱共享方面, 对智能认知学习推理技术的研究还处于起步阶段, 主要形成了基于遗传算法、粒子群算法、案例推理、神经网络、最小二乘 SVM 等认知引擎建模方法. 在文献 [3] 中, 基于遗传算法的认知引擎通过设计多个优化目标, 从而调整无线电传输参数, 随着研究的深入, 量子遗传算法^[4]、免疫遗传算法^[5]相继被用于设计认知引擎, 改进基本遗传算法在收敛速度、收敛精度以及稳定性方面的不足. 然而这些方法还是局限在遗传算法范畴, 忽略了随着认知用户数的增加会导致算法收敛过慢, 难以满足系统实时通信的需求. 为提高算法收敛速度, 文献 [6] 提出了一种基于二进制粒子群算法的认知引擎设计方法, 然而与遗传算法一样, 粒子群算法也很难得到最优解. 文献 [7] 提出了一种基于集中时滞神经网络的学习方案, 针对不同无线电配置完成对数据速率的预测, 但网络中的通信参数不止数据率一种, 从而在实际应用中存在一定的局限性. 文献 [8] 又在遗传算法的基础上引入案例推理, 为遗传算法提供初始种群, 减小遗传算法选择初始种群的盲目性, 进一步提高算法的收敛速度,

* 国家自然科学基金 (批准号: 61072138) 和四川省科技厅应用基础研究项目 (批准号: 2010JY0173) 资助的课题.

[†] 通讯作者. E-mail: jiaozi_1985939@163.com

然而两种人工智能方法的结合势必会增加算法的复杂度. 继而, 一种 RBF 神经网络与最小二乘 SVM 的认知引擎模型分别在文献 [9] 与 [10] 中被提出, 用于学习信道特征, 仅仅用于物理层仿真, 缺乏进一步的应用验证. 文献 [11] 采用由 K-近邻、神经网络和决策树算法构成的多智能体, 优化视频会议通信性能, 同样多种方法的结合势必增加算法复杂度.

考虑到当前典型技术的局限性, 又由于认知无线电系统中频谱的动态性导致系统的不确定性和复杂性, 而贝叶斯网络 (Bayesian network, BN) 较其他机器学习算法具有处理不确定性和复杂性问题的明显优势, 具有可解释性和更易理解的知识表达能力以及处理不完整数据的能力. 贝叶斯网络还具有动态性和交互性, 一旦感知到新信息可通过学习更新网络, 同时人的主观意见也可以参与到网络建模中. 随着其不断发展, 贝叶斯网络的学习能力与推理决策能力也得到了很大提高. 贝叶斯网络以其坚实的理论、灵活的学习机制、强大的知识表达与推理能力和开放的决策体系成为人工智能和数据挖掘等智能领域强有力的工具, 在信息系统、经济、医学、工业、农牧业、交通管理、文化教育及国防系统等领域得到广泛应用. 因此本文采用贝叶斯网络构成认知引擎 (简称: BN 认知引擎), 用于自适应调整在复杂多变的电磁环境与用户需求条件下认知无线电系统参数, 改善端到端通信性能. BN 认知引擎从过去的通信行为中提取以贝叶斯网络结构与概率参数表示的知识, 根据当前无线环境的状态 (如: 干扰) 和用户需求 (如: 吞吐量、时延), 利用推理算法决策出系统此时最佳的工作参数 (如: 调制方式、功率), 进而实现对系统参数重构.

2 贝叶斯网络与 BN 认知引擎模型简介

2.1 贝叶斯网络

贝叶斯网络是一种以有向无环图表示变量间的相互关系, 以条件概率表示变量间的影响程度, 从而可以克服基于规则系统的许多概念上和计算上的困难. 贝叶斯网络主要由两部分组成 [12].

1) 模型结构: 具有 n 个节点的有向无环图 G

如图 1 所示, 图 G 中的节点对应于模型中的变量, 用 X 表示, 有向边代表变量的条件依赖关系. 用

$Pa(X_i)$ 表示节点 X_i 的父节点集.




图 1 简单贝叶斯网络

2) 相关参数: 与每个节点相关的条件概率表 θ

条件概率可以用 $p(X_i|Pa(X_i))$ 来描述, 它表达了节点 X_i 同其父节点的相关关系. 由于有向图蕴涵了条件独立性假设, 规定图 G 中的每个节点 X_i 条件独立于由 X_i 的父节点给定的非 X_i 后代节点构成的任何节点子集, 则对所有变量 $X = \{X_1, X_2, \dots, X_n\}$ 的联合概率分布如 (1) 式所示.

$$p(X) = \prod_{i=1}^n p(X_i|Pa(X_i)). \quad (1)$$

如果获得一定量的所有节点观测样本数据, 可通过对样本数据进行结构学习与参数学习确定模型结构和相关参数. 当给定某些可观测节点的值后, 可应用贝叶斯网络推理估计未知节点的值. 推理中, 将可观测节点的值称之为证据, 用 E 表示, 根据贝叶斯规则, 计算未知节点 X_i 取某值 x_i 的条件概率, 如下式所示:

$$p(X_i = x_i|E) = \frac{p(E, X_i = x_i)}{p(E)}. \quad (2)$$

2.2 BN 认知引擎模型

根据贝叶斯网络定义, 构建基于贝叶斯网络的认知引擎, 其一般结构如图 2 所示, 工作原理如下.

BN 认知引擎优化端到端性能的过程形成一个反馈控制认知环路, 由感知得到的环境信息和用户需求信息共同驱动整个认知环路的循环运行: 当感知信息发生了变化, 结合知识库中的 BN 认知引擎模型结构与相关参数 (其中, 引擎模型结构与相关参数由认知学习模块获得), 利用认知推理决策模块决策出当前通信网络的最佳工作参数, 经过参数重构评估系统性能是否得到改善或满足用户需求, 如果性能得到了改善且满足用户需求, 则将此次通信事件存入优良通信事件库 (优良通信事件库还存

储系统通信行为的样本数据), 并由 BN 认知学习模块挖掘知识更新知识库, 为以后认知推理决策模块的工作参数决策提供依据; 如果性能没有得到改善

或不满足用户需求, 网络利用感知到的新信息重新计算获得各参数节点的相关参数, 再次进行推理决策重构, 如此反复, 直到满足要求.

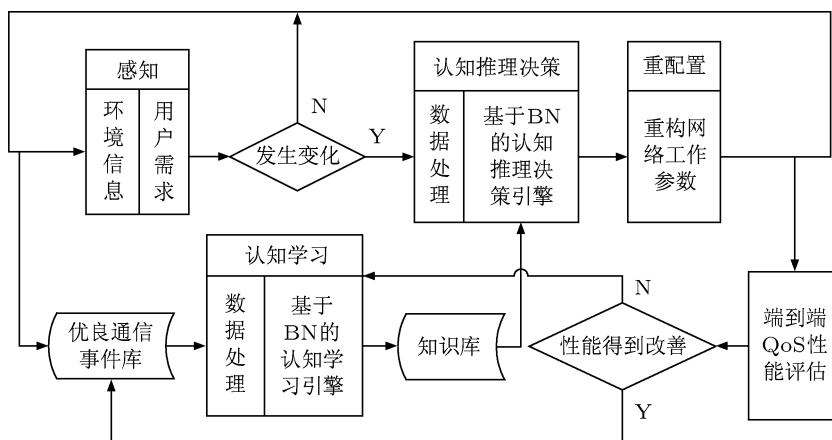


图2 BN 认知引擎框架

3 BN 认知引擎建模

面对动态变化的电磁环境与用户需求, 在通信系统中引入认知无线电技术, 建立认知引擎, 其目的在于利用认知引擎实现通信系统参数智能调整适应这种变化. 本文研究的通信系统为移动无线网络, 涉及的配置参数主要包括调制方式、编码效率、发送功率、带宽等, 用 $C = \{C_1, C_2, \dots, C_{nc}\}$ 表示; 环境参数主要包括移动节点的位置信息、频谱信息、干扰信息等, 用 $F = \{F_1, F_2, \dots, F_{nf}\}$ 表示; 用户需求参数主要包括业务类型、QoS 需求等, 用 $Q = \{Q_1, Q_2, \dots, Q_{nq}\}$ 表示; 性能参数主要为端到端吞吐量、时延与误码率等, 用 $J = \{J_1, J_2, \dots, J_{nj}\}$ 表示, 其中 nc, nf, nq, nj 分别表示配置参数、环境参数、用户需求参数、性能参数的个数. 则利用 BN 建立的认知引擎中通信参数为前面四种参数的集合, 文中用 $X = FUCUQUJ$ 表示, 参数变量个数 $n = nc + nf + nq + nj$.

认知学习作为基于 BN 认知引擎的核心, 主要由贝叶斯结构学习算法和参数学习算法实现, 用于获取指导认知推理决策配置参数的知识. 首先, 通过对样本数据进行结构学习, 获得认知引擎各通信参数节点间的 BN 模型结构 G , 然后再由参数学习算法确定通信参数节点间的相关参数 θ .

3.1 确定 BN 认知引擎模型结构

根据专家经验以及收集到的系统以往通信行

为事件, 建立样本数据, 利用贝叶斯结构学习算法—K2 算法 [12], 确定认知引擎模型结构 G . 为满足实时性的要求, 缩小算法的搜索空间, 使学习过程尽量缩短, K2 结构学习算法不再从一个空网络开始, 而是根据通信参数之间的相互关系与影响, 初步确定参数节点次序, 建立初始认知引擎模型结构, 如图 3 所示.




图3 初始认知引擎 BN 模型结构

基于初始的认知引擎模型结构, 定义一种评价模型结构优劣的评价函数, 根据事先确定的参数节点次序, 选择使后验概率 $p(X_i|X_j)$ 最大的参数节点 i 作为该节点 j 的父节点, 如 (3) 式所示. 其中, $p(X_i)$ 和 $p(X_j)$ 分别为参数节点 X_i 和 X_j 的先验概率, 可通过对样本数据分析计算得出.

$$p(X_i|X_j) = \frac{p(X_j|X_i) \cdot p(X_i)}{p(X_j)} \quad (3)$$

依次遍历完所有通信参数节点, 为网络添加节点或删除节点, 添加或删除有向边, 然后根据评价函数对网络结构进行评价, 得分最高的模型结构作为移动无线网络最终的贝叶斯网络结构.

评价函数如下:

$$\begin{aligned} & \max\{p(B_s, D)\} \\ & = p(B_s) \prod_{i=1}^n \max_{Pa(X_i)} \left[\prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \right], \quad (4) \end{aligned}$$

这里 $D = \{X_1, X_2, \dots, X_n\}$ 为给定的移动无线网络样本数据, 其包括 m 个样本, 每个样本包含 n 个离散通信参数节点 X , x_i 为认知引擎参数节点 X_i 的实例, 每个节点实例 x_i 有 r_i 种可能取值: $(x_{i1}, \dots, x_{ir_i})$; B_s 为移动无线网络模型结构, 在 B_s 中每个参数节点 X_i 的父节点集, 用 $Pa(X_i)$ 表示, 且 $Pa(X_i)$ 共有 q_i 种取值; N_{ijk} 为 D 中变量 X_i 的父节点集; $Pa(X_i)$ 为第 j 种取值的样本个数; $p(B_s)$ 为认知引擎模型结构的先验概率. 本文假设每种可能的认知引擎模型结构的先验概率相等.

3.2 确定 BN 认知引擎相关参数

在已确定认知引擎模型结构的基础上, 利用贝叶斯参数学习算法确定各参数节点处的条件转移概率. 针对完整通信行为的样本数据, 本文采用最大似然估计 (maximum likelihood estimation, MLE) 方法获得各通信参数节点间的条件转移概率; 针对具有样本缺失的通信行为数据, 采用期望最大化 (expectation maximization, EM) 算法获得条件转移概率 [12]. 假设 θ 为 BN 认知引擎模型结构中各通信变量的条件概率参数表, $\theta = (\theta_1, \theta_2, \dots, \theta_n)$, 各通信变量节点之间的转移概率密度函数为 $p(X_i|\theta)$, 利用样本数据 D 进行概率参数学习估计参数 θ .

1) 针对完整通信行为样本数据的 BN 认知引擎相关参数确定

根据贝叶斯网络所包含的条件独立性关系, 可对概率参数表 θ 的似然函数 $p(X_i|\theta)$ 进行如下变换:

$$\begin{aligned} L(D : \theta) &= \prod_{m=1}^m \prod_{i=1}^n p(X_i | Pa(X_i), \theta_i) \\ &= \prod_{i=1}^n \prod_{j=1}^{q_i} L(D : \theta_{ij}). \quad (5) \end{aligned}$$

由 (5) 式可以看出, CR 系统参数节点的似然函数 $L(D : \theta)$ 的求极值问题可分解为对各个因子 $L(D : \theta_{ij})$ 的求极值. 由于各通信参数节点不变且其父节点已知, 则各个通信事件实例相互独立, 概率参数 θ_{ij} 的似然函数为

$$L(D : \theta_{ij}) = p(D | \theta_{ij}), \quad (6)$$

当 $L(D : \theta)$ 的值最大时, θ 为 BN 认知引擎通信变量之间的条件概率参数表.

2) 针对不完整通信行为样本数据的 BN 认知引擎相关参数确定

当 CR 系统的通信行为样本数据存在缺失时, 本文利用 EM 算法获得各通信参数间的条件转移概率值, 具体步骤为: ① 初始化, 随机为 BN 认知引擎模型结构 G 的相关参数 θ 赋初值 (设置各参数节点的初始概率相等); ②: 求期望, 计算每个通信事件样本在 θ 条件下发生的期望统计因子, 并用其期望值补齐样本, 使缺失的通信事件样本成为完整样本; ③: 最大化, 根据补齐后的完整通信事件样本, 利用 MLE 方法寻找使模型结构的似然函数最大化的新条件概率参数 θ ; ④: 根据新的概率参数 θ 迭代步骤 ② 和步骤 ③, 直到算法收敛.

3.3 确定 BN 认知引擎推理决策模型

推理决策反映认知引擎的“逻辑思维”能力是使用知识的过程. 若环境信息或用户需求信息发生了变化, 则这两类信息经过预处理后作为推理决策的证据, 结合性能指标需求, 融合 BN 认知引擎的模型结构 G 和相关参数 θ , 由联合树算法实现系统最佳配置的推理决策.

利用 BN 认知引擎进行推理决策之前, 需将模型结构经以下步骤转换为联合树 [12].

步骤1 建立 BN 认知引擎模型结构的正图 (Moral 图): 将模型结构中同一通信参数节点 X_i 的父节点 $Pa(X_i)$ 两两相连, 同时去掉每一条连接边的从属关系.

步骤2 将模型结构正图三角化: 对包含 4 个及以上通信参数节点的环, 增加一条无向边将环中两个非相邻通信参数节点连接起来, 完成对认知引擎模型结构正图的三角化.

步骤3 确定 BN 认知引擎三角化图中恰当的团节点, 每个团节点都是无向图的子图.

步骤4 建立 BN 认知引擎模型结构的联合树: 其联合树必须包含所有团节点, 交集作为连接两个团节点的分隔节点.

再将当前环境信息 F 和用户需求信息 Q 经过预处理后作为推理证据 E , 在 BN 认知引擎联合树上进行概率扩散, 更新模型结构使整个联合树达到全局一致, 利用 (2) 式计算所求通信变量的边缘概率, 然后选择具有最大边缘概率的配置参数变量 C 作为推理决策的结果.

4 BN 认知引擎在移动无线网络中的应用

4.1 移动无线网络建模

为了评估 BN 认知引擎性能, 本文利用 OPNET 仿真软件建立如图 4 所示的移动无线网络通信模型, 用于获取认知引擎所需的通信事件样本数据, 完成重配置仿真验证实验. 在图 4 所示的移动无线网络中, tx 表示发送节点, rx 表示接收节点, jam 表示干扰节点, 发送节点与干扰节点沿图中所示的轨迹移动, 而接收节点位置固定. 为体现网络环境的动态多变, 干扰节点由远到近向接收节点移动再远离接收节点, 且发送干扰信号干扰发送节点与接收节点间的数据传输. 详细的参数设置如表 1 所示.

表 1 移动无线网络参数设置

参数类型	参数取值
信道衰落	自由空间模型
业务类型	Voice, Video, Ftp, Email
功率	0.001, 0.005, 0.01, 0.05/W
调制方式	BPSK, GMSK, 16QAM
带宽	10, 100/kHz
发送数据速率	1024, 10240/bps




图 4 基于 OPNET 建立的移动无线网络

4.2 样本数据预处理

根据用户的不同需求 (文中体现为业务类型与发送数据速率), 模拟移动无线网络在不同发送功率、调制方式、带宽条件下的通信, 收集如

表 2 所示通信参数的值作为样本数据, 此时 $F = \{\text{dist}\}$, $Q = \{\text{service, rate}\}$, $C = \{\text{power, modu, bw}\}$, $J = \{\text{ber, thr, delay}\}$, 且 $X = F \cup C \cup Q \cup J$, $n = 9$. 由于样本数据中的干扰节点与接收节点间的距离、误码率、吞吐量与端到端时延为连续值, 因此在建立 BN 认知引擎之前需对数据进行离散化处理 and 属性转换. 为减小算法复杂度, 本文采用无监督等宽区间离散化算法对上述数据进行预处理, 等宽的每个区间表示通信参数变量的一种属性. 干扰节点与接收节点间的距离离散化为 3 种属性: 远距离、中距离、近距离, 分别用属性 1, 2, 3 代替; 误比特率将数量级范围 $[10^{-1}, 10^{-10}]$ 等宽离散化为 5 种属性, 分别用属性 1, 2, 3, 4, 5 代替; 吞吐量将区间 $[0, 1152]$ (bps) 等宽离散化为 10 种属性, 分别用属性 1, 2, 3, 4, 5, 6, 7, 8, 9, 10 代替; 端到端时延将区间 $[0.1, 10]$ (s) 离散化为 3 种属性, 分别用属性 1, 2, 3 代替.

表 2 移动无线网络 BN 认知引擎参数变量

通信参数变量类型	参数
环境参数	干扰节点与接收节点间的距离
用户需求参数	业务类型、发送数据速率
配置参数	功率、调制方式、带宽
性能参数	误码率、吞吐量、端到端时延

4.3 移动无线网络 BN 认知引擎构建

本文分别收集容量为 800, 2000 和 5000 的样本数据, 并取每组样本数据中的 2/3 作为训练数据, 1/3 作为测试数据. 假设各种通信参数的每种属性先验概率相等, 如: 干扰节点与接收节点间的距离属性的先验概率 $p(1) = p(2) = p(3)$, 且 $p(1) + p(2) + p(3) = 1$. 通过对训练数据进行结构学习和参数学习获取移动无线网络的模型结构以及相关参数, 模型结构 G 如图 5 所示. 从图 5 中可以看出配置参数的选择依赖环境参数与用户需求参数, 同时影响整个网络的通信性能, 除此之外, 各层内参数相互影响. 这里, 由于篇幅的限制, 移动无线网络通信事件参数及其属性较多, 因此在这里不再列出 BN 认知引擎相关参数, 即各通信参数之间的条件转移概率表 θ .

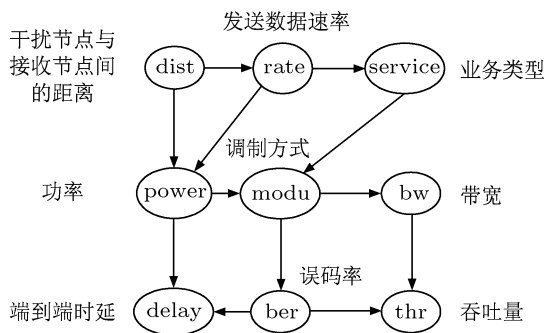


图5 移动无线网络 BN 认知引擎模型结构 G

4.4 引擎推理精度仿真分析

将容量为 5000 的样本数据中 1/3 作为测试数据, 并将测试数据中的环境信息与用户需求信息(干扰节点与接收节点之间的距离、发送数据速率和业务类型) 以及配置参数(功率、调制方式和带宽) 经过离散化处理成相应属性后, 作为 BN 认知引擎的推理证据 E, 并在模型结构上进行概率传递, 选择每种性能参数具有最大后验概率的性能值作为当前推理决策结果. 如获得端到端时延值的公式为

$$x_0^i = \arg \max p(x = \text{delay} | E), \quad (7)$$

然后, 将推理的结果与测试数据中的目标值进行比较, 评估 BN 认知引擎推理决策的精度. 鉴于文献 [7] 给出了多变的数据速率预测, 并进行了有效配置, 因此, 为验证文中引擎的有效性, 用文献 [7] 中基于集中时滞神经网络 (focused time-delay neural network, FTDNN) 构建的引擎来配置参数, 并进行仿真对比分析, 其比较结果如图 6—8 所示. 为精确显示, 文中仅给出 100 个随机样本的比较结果. 参考文献 [7] 中 FTDNN 的参数设置, 根据本文样本数据的特点, 设置 1 个隐含层, 隐含层神经元个数为 10 个, 时延为 5, 最大迭代次数为 1000, 学习速率为 0.01.

从图 6—8 仿真结果可知, BN 认知引擎推理决策精度大约在 92% 左右, FTDNN 的预测精度大约在 86%, 可见在本文中采用 BN 建立的认知引擎性能明显优于基于 FTDNN 的性能. 然而, 在实际通信事件样本数据采集过程中, 有可能存在样本数据缺失的情况. 针对这种情况, 本文利用由 EM 算法建立缺失样本数据的引擎模型相关参数. 为进一步验证本文建模方法的有效性, 分别利用容量为 800, 2000 和 5000 的样本数据建立引擎并测试引擎性

能, 在完整样本与不同样本缺失程度下的引擎推理决策精度如表 3 所示.




图6 针对误码率的推理性能比较

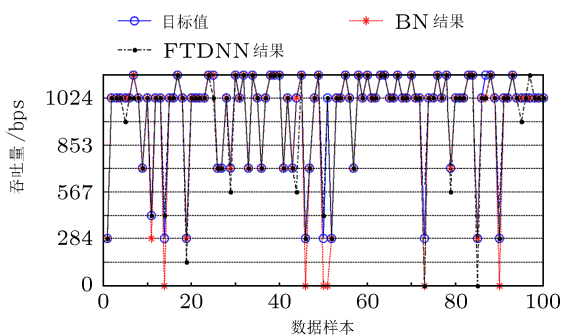


图7 针对吞吐量的推理性能比较

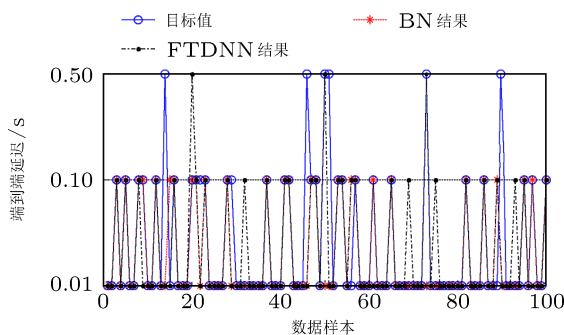


图8 针对端到端时延的推理性能比较

在表 3 中, 引擎推理决策精度分为两部分: 一部分为在完整样本下引擎推理决策的精度; 另一部分为在不同程度缺失样本下引擎的推理决策精度. 从表 3 中可以看出, 随着学习的样本容量的增加, 推理决策精度也随之提高, 且完整样本的推理决策精度明显高于缺失样本的精度, 如: 样本容量同为 5000 的完整样本推理决策的平均精度为

91.9%, 而样本缺失 20%时推理决策的平均精度为 84.1%, 然而样本缺失 60%的平均精度仅为 55.3%. 所以在实际应用中, 为了满足认知引擎实时性的要求, 通信事件样本数据的应尽量丰富与完整.

4.5 重配置实验仿真分析

为了进一步验证 BN 认知引擎模型性能, 本文将其应用于上述移动无线网络, 根据干扰节点与接收节点间位置变化关系, 以及对网络业务类型和数据发送速率的要求, 利用 BN 认知引擎推理决策配置参数对移动无线网络进行重配置, 重配置前后网络通信性能的变化如图 9(a)—(c) 所示.

在图 9 中, 横坐标为环境变化域, [1, 2, 3] 表示干扰节点与接收节点之间的距离由远、中到近的变化过程, 纵坐标为网络性能指标. 从图中可以看出, 随着距离的减小, 移动无线网络的通信性能逐

渐提高, 且重配置后的网络通信性能明显优于重配置前的网络性能, 其中端到端时延平均提高了约 66%, 吞吐量和丢包率平均提高了约 80%. 可见, 通过 BN 认知引擎对移动无线网络进行重配置, 网络的抗干扰的能力得到明显增强, 能更好地适应环境的变化.

表 3 模型推理决策精度

样本数据 (数据缺失度)	学习算法	推理算法	样本容量	精度
完整样本 (0%)	MLE	联合树	800	84.7%
			5000	91.9%
缺失样本 (20%)	EM	联合树	800	76.3%
			5000	84.1%
缺失样本 (60%)	EM	联合树	800	49%
			5000	55.3%

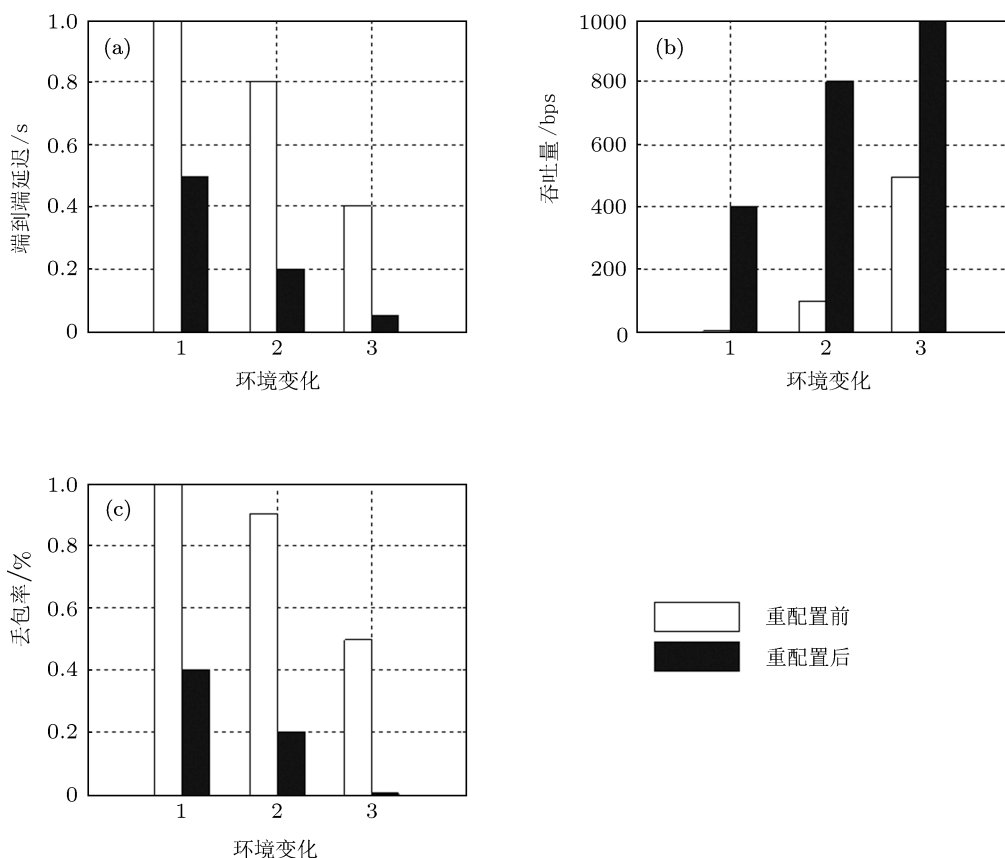


图 9 重配置前后移动无线网络的通信性能比较图 (a) 网络端到端时延; (b) 网络丢包率; (c) 网络吞吐量

5 结论

本文提出了一种基于贝叶斯网络的认知引擎, 给出了引擎设计原理与过程, 不仅实现了对引擎算

法的仿真, 还利用 OPNET 建立移动无线网络模拟通信系统, 实现了 BN 认知引擎重构系统配置参数的仿真实验. 仿真结果表明, 本文中基于 BN 所设计的认知引擎的性能明显优于集中时滞神经网络,

且通过对系统进行重配置能有效改善系统端到端通信性能. 在未来的研究中, 将进一步提高 BN 认知

引擎的推理决策精度, 考虑加强对 BN 认知引擎应用的深入研究.

-
- [1] Joseph M III 2000 *Ph. D. Dissertation* (Royal Institute of Technology)
 - [2] Haykin S 2005 *IEEE Journal on Selected Areas in Communications* **23** 201
 - [3] Thomas W R *Ph. D. Dissertation* (Virginia Polytechnic Institute and State University)
 - [4] Zhao Z J, Zheng S L, Shang J N, Kong X Z 2007 *Acta Phys. Sin.* **56** 6760 (in Chinese) [赵知劲, 郑仕链, 尚俊娜, 孔宪正 2007 物理学报 **56** 6760]
 - [5] Jiao C H, Wang K R 2010 *Systems Engineering and Electronics* **32** 1083 (in Chinese) [焦传海, 王可人 2010 系统工程与电子技术 **32** 1083]
 - [6] Zhao Z J, Xu S Y, Zheng S L, Yang X N 2009 *Acta Phys. Sin.* **58** 5118 (in Chinese) [赵知劲, 徐世宇, 郑仕链, 杨小牛 2009 物理学报 **58** 5118]
 - [7] Katidiotis A, Tsagkaris K, Demestichas P 2010 *Computers & Electrical Engineering* **36** 518
 - [8] Feng W J, Liu Z, Qin C L 2011 *Pattern Recognition and Artificial Intelligence* **24** 401 (in Chinese) [冯文江, 刘震, 秦春玲 2011 模式识别与人工智能 **24** 401]
 - [9] Jiang H, Ma J H, Huang Y H, Wu C 2011 *Journal of Xi Dian University* **38** 139 (in Chinese) [江虹, 马景辉, 黄玉清, 伍春 2011 西安电子科技大学学报 **38** 139]
 - [10] Jiang H, Wu C, Ma J H 2011 *Journal of University of Electronic Science and Technology of China* **40** 41 (in Chinese) [江虹, 伍春, 马景辉 2011 电子科技大学学报 **40** 41]
 - [11] Asma A, Badr B, Francine K, Fethi T B 2012 *International Journal of Distributed and Parallel Systems* **3** 91
 - [12] Jensen F V, Nielsen T D 2007 *Bayesian Networks and Decision Graphs* (New York: Springer Verlag)

Design and reconfiguration of cognitive engine based on Bayesian network*

Wang Jiao[†] Zhou Yun-Hui Huang Yu-Qing Jiang Hong

(School of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, China)

(Received 24 June 2012; revised manuscript received 19 August 2012)

Abstract

The past communication behaviors that guide the system communication in the future to satisfy the requirements of users and adapt to the changes of environment are the core part of cognitive radio system. In this paper, a cognitive engine based on Bayesian network is proposed to solve the parameters self-adaptive-adjusting problem of cognitive radio system under the complicated and highly varying radio environment and user requirement. Through structure learning and parameter learning of the sample data from the past communication behaviors, cognitive engine is established. The states of radio environment and requirements of users are made as inference evidences by data preprocessing, and the cognitive engine is used to make decision of the configuration parameters of communication system, and then the reconfiguration system is completed. A mobile wireless network is modeled to finish reconfiguration simulation using OPNET tool in this paper. Simulation results show that the proposed cognitive engine can make the wireless mobile network adapt to environment and effectively improve end-to-end communication performance. The feasibility of the method to model cognitive engine with Bayesian network is validated in this paper.

Keywords: cognitive radio, bayesian network, reconfiguration, end-to-end performance

PACS: 84.40.Ua

DOI: 10.7498/aps.62.038402

* Project supported by the National Natural Science Foundation of China (Grant No. 61072138) and Application Fundamental Research Project of the Technonology Department of Sichuan Province, China (Grant No. 2010JY0173).

[†] Corresponding author. E-mail: jiaozi_1985939@163.com