

# 基于粗糙集的认知无线网络跨层学习

江 虹<sup>1,2</sup>, 伍 春<sup>1,2</sup>, 包玉军<sup>1</sup>, 黄玉清<sup>1</sup>

(1. 西南科技大学信息工程学院, 四川绵阳 621010;

2. 西安电子科技大学综合业务网理论与关键技术国家重点实验室, 陕西西安 710071)

**摘 要:** 认知学习是认知无线网络(CRN)跨层设计中非常重要的一环,它要求通信网络能利用已知跨层环境参数进行知识提取学习,并根据需要重配置网络.本文提出了一种基于粗糙集的 CRN 跨层学习技术,构建了案例事件库、知识库与规则匹配器,该模型结合数据离散、属性约简、值约简与规则生成算法来解决 CRN 的跨层学习问题.通过典型测试数据集的仿真比较,选出一组适合于所提出模型的粗糙集算法集合.仿真结果表明,该算法集能有效解决 CRN 跨层学习中知识提取与规则生成的准确性及有效性等问题,提出的跨层学习模型能有效用于 CRN 中的知识学习.

**关键词:** 认知网络; 规则生成; 学习引擎; 跨层设计

**中图分类号:** TN911      **文献标识码:** A      **文章编号:** 0372-2112 (2012) 01-0155-07

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2012.01.025

## Cross-Layer Learning in Cognitive Radio Networks Based on Rough Set

JIANG Hong<sup>1,2</sup>, WU Chun<sup>1,2</sup>, BAO Yu-jun<sup>1</sup>, HUANG Yu-qing<sup>1</sup>

(1. Information College of Southwest University of Science and Technology, Mianyang, Sichuan 621010, China;

2. State Key Laboratory of Integrated Service Networks Xidian University, Xi'an, Shaanxi 710071, China)

**Abstract:** Cognitive learning is a very important part for cross-layer design in cognitive radio networks (CRNs). CRNs are required to take advantage of the known cross-layer parameters for learning environment and reconfiguring the network. This paper proposes a cross-layer learning scheme for CRN based on rough set, builds database of case events, knowledge base and rule matcher. This model solves the cross-layer learning in CRNs through combining data discretization, attribute reduction, value reduction and rule generation. By comparing the simulation results of typical testing data sets, a group of rough set algorithms are selected for the proposed model. The simulation results show that the set of algorithms can effectively solve accuracy and validity of knowledge extraction, rule generation for CRN cross-layer learning. The proposed model can be validly used in knowledge learning for CRNs.

**Key words:** cognitive radio networks; rule generation; learning engine; cross-layer design

## 1 引言

CRN 要求网络能自适应多变环境<sup>[1,2]</sup>,其设计区别于传统网络.传统网络协议栈采用分层设计原则,使其具有独立性、模块性.但分层设计不利于跨层参数共享,导致 CRN 的认知学习受到很大限制.

无线网络多层协议栈中,层间参数有复杂关系<sup>[3]</sup>.如 MAC 层退避与 RTS/CTS 有内在联系:公平性好的退避算法能保证有效接入,这时网络可不用 RTS/CTS 以减少额外开销.又如多次重传 RTS 都未收到 CTS 的节点,会使 DSR 协议查找新路由,但原路由可能仍有效,只是因信道被临时占用而无法使用,若用表路由则可避

免路由查找.可见跨层信息在 CRN 中有重要作用,为认知学习提供了条件.

无线跨层研究在学术界受到了很高的重视,相关的研究成果也较多<sup>[1~10]</sup>.但迄今为止,对无线网络的跨层研究多集中在性能优化方面<sup>[3~10]</sup>,如:文献[3]旨在实现拥塞控制和路由调度的性能优化.文献[4]通过引入信道预留机制,以最大化次用户吞吐量.文献[5]在有限带宽条件下,研究网络层与 MAC 层的跨层资源优化分配以满足 QOS 要求.文献[6]重点研究物理层与 MAC 层的联合优化策略,以实现资源有效分配.文献[7]用遗传算法(GA)基于 ACK 信号求解网络配置最优参数.文献[8]用分枝定界法对物理层、链路层和网络层联合优化.

文献[9]用模糊逻辑优化 MAC 层与传输层.这类基于性能优化的机制存在的主要问题是缺乏学习能力,没有知识存储与更新.在学习策略方面,文献[10,11]主要用增强学习算法对 CRN 中某层协议栈资源分配进行了研究.总体看,当前对 CRN 跨层学习机制的研究十分有限<sup>[12]</sup>,急需寻求新的学习机制以解决 CRN 中知识学习与知识形成等问题.

粗糙集(Rough Set-RS)具有提取潜在知识的能力,是一种具有很好应用潜力的学习技术<sup>[13]</sup>,本文将作为 CRN 跨层学习基础.据作者所知,将 RS 用在 CRN 技术的文献极少<sup>[14]</sup>,而将其用作跨层认知学习的研究还未见报道.本文旨在研究基于 RS 学习引擎的 CRN 跨层学习,建立相应模型框架,以完成 CRN 学习与知识提取,实现网络性能提升.

## 2 认知网络跨层模型设计

CRN 借助 CR 设备设计网络认知环路<sup>[15]</sup>,认知环路要求网络能感知理解当前环境,并具备学习能力,以决策和实时调整网络配置.

目前对 CRN 认知环路的设计,大多只停留在环路模型各组成部件的功能设计与分析<sup>[16]</sup>.本文建立的基于跨层模型的认知网络结构如图 1,以观察、学习、决策和行动为认知环路.送入环路的信息包括局部和全局信息.局部信息来自节点内部协议栈,包括物理层、链路层、传输层和应用层等参数信息.全局信息来自网络信息域,如:网络运行时间、吞吐量等.各层配备观察与行动两个模块.观察模块确定并采集协议栈状态参数,行动模块完成各层参数重配置.各层信息通过跨层信息总线收集传递,以事件向量形式封装存入事件案例库.

图 1 中,案例库中案例数据是 RS 学习引擎(RSLE)的数据源.为确保知识时效性,该引擎休眠时间段  $T_{slot}$  后启动, $T_{slot}$  为案例库新增案例数到达某阈值  $N_{thresh}$  时的时间.该案例库随环境变化载入新案例.事件案例对象




图1 基于粗糙集的跨层认知网络结构

( $\vec{ET} = \{\vec{en}, \vec{cofg}, \vec{cap}\}$ )是案例库的存储单位,环境参数  $\vec{en}$  对观察模块观察的环境信息进行分类描述,如节点数量、链路状态等;可配置参数  $\vec{cofg}$  包括:退避机制、路由协议等;性能参数  $\vec{cap}$  包括:吞吐量、丢包率等.

RSLE 引擎以案例库中案例矢量为处理对象,经预处理、离散以及约简等形成知识.知识被存入规则知识库,并通过接口完成访问与匹配.

规则匹配器匹配知识库中的规则,以下两种情况启动匹配,第一是组建新网络时,需配置合适参数达到相对满意性能.第二是在已建好网络中,网络环境发生变化,原有配置不能满足用户需求.匹配准则用规则相似度衡量,选择完全匹配或相识度最高的规则作为最优规则.

决策器根据匹配器中匹配的最优规则,选择可调参数,并以改变最少可调参数作为决策条件.特别是对满负荷运行网络,过多改变配置参数,可能会导致网络性能下降.

## 3 粗糙集学习引擎(RSLE)

粗糙集是一种重要的学习技术,与其它学习技术相比,RS 无需提供除问题所涉数据集外的先验信息,它用数据集等价关系来发现潜在规律并形成知识<sup>[13,17,18]</sup>.本文将 RS 引入 CRN 跨层学习,构建模型和提炼规则知识.如图 2,RSLE 由数据预处理、决策表形成、数据离散处理、属性重要度计算、属性约简和值约简模块组成.



图2 粗糙集学习引擎结构

### 3.1 粗糙集基础

粗糙集中,决策表定义为:  $S = \langle U, A, V, f \rangle$ ,  $U$  为对象集合即论域;  $A$  是由条件属性集  $C$  和决策属性集  $D$  组成的属性集合,即  $C, D \subseteq A$ , 且  $C \cup D = A, C \cap D = \emptyset$ .  $V = \bigcup_{a \in A} V_a$  是属性值集合,  $V_a$  是属性  $a \in A$  的值域;  $f: U \times A \rightarrow V$ , 即  $f(x, a) \in V$ , 它指定  $U$  中对象  $x$  的属性值. RS 中不可区分关系是基本原则,对  $R \subseteq A$ , 不可分辨关系  $IND(R)$  定义为:  $IND(R) = \{(x, y) \in U \times U \mid r \in R, r(x) = r(y)\}$ .  $IND(R)$  是一等价关系,由这种等价关系导出对  $U$  的划分记为  $U/IND(R)$ . RS 定义了下近似域( $B_-(X)$ )、上近似域( $B^-(X)$ )和边界域( $BNG(X)$ )三个域,记为  $B_-(X) = \bigcup \{Y_i \in U/IND(B) \mid Y_i \subseteq X\}$ ,  $B^-(X) = \bigcup \{Y_i \in U/IND(B) \mid Y_i \cap X \neq \emptyset\}$ ,  $BNG(X) = B^-(X) - B_-(X)$ .

约简是 RS 的重要概念,若  $P$  和  $Q$  是  $U$  的两等价关系簇,有  $Q \subseteq P$ , 若  $Q$  独立,且  $IND(Q) = IND(P)$ , 则称

$Q$  是  $P$  的一个约简, 记为  $Red(P)$ . 由下近似可得出约简, 在论域  $U$  中,  $Q$  的  $P$  正域记为  $POS_P(Q)$ , 定义为  $POS_P(Q) = \bigcup_{X \in U/Q} P_-(X)$ ; 若  $P$  的独立子集  $S \subset P$  有  $POS_S(Q) = POS_P(Q)$ , 则称  $S$  为  $P$  的  $Q$  约简.

### 3.2 粗糙集算法构建

在 RSLE 中, 数据离散、属性约简和值约简等模块有多种算法供选择, 不同算法组合会导致引擎性能不同<sup>[19]</sup>. 下文先分析离散、属性约简以及值约简算法, 通过仿真比较典型算法, 并以常用机器学习数据集作为仿真对象. 经仿真确定一组复杂度、效率和准确性适合于 RSLE 的算法. 数据集信息如表 1, 表中列出了 6 种常用数据集, 在样本数与决策类上都不同. 属性类型项表明了数据集中的属性类型, 包括实数型 (Real)、分类型 (Categorical)、整数型 (Integer).

表 1 机器学习数据集

数据集	样本数	条件属性数	属性类型	决策类
Iris	150.0	4	Real	3
Glass	214.0	9	Real	
Hayes-Roth	132.0	5	Categorical	3
Liver-disorders	345.0	6	Categorical, Integer, Real	2
Pima-Indians	768.0	8	Integer, Real	2
Wine	178.0	3	Integer, Real	121

表 2 列出了粗糙集常用算法, 其中数据离散算法 4 种, 属性约简 4 种, 规则生成 2 种.

表 2 仿真比较算法集

数据离散算法	属性约简算法	规则生成算法
Boolean reasoning	Genetic algorithm	ROSET 值约简
Entropy/MDL	Johnson's algorithm	一般值约简
Equal frequency binning	属性重要度	
基于属性重要度	信息熵	

#### 3.2.1 数据离散

CRN 跨层信息主要有枚举型和实数型. 如 MAC 层协议类型是枚举型, 而传输功率是实数型. 数据离散的对象是连续实数型数据, 其前提是不改变数据分类能力. 离散过程可描述为:  $L^a$  是某属性  $a$  的值域 ( $a \in A$ ), 断点集  $\{l_1^a, l_2^a, l_3^a, \dots, l_n^a\}$  将  $L^a$  分成  $n+1$  区域段, 落在某段的属性值用相同标识符表示.

为从典型离散算法中确定一种适用于 RSLE, 论文分析了表 3 所示的四种算法及其处理效果. 表 3 中  $A$  为数据集属性断点总数,  $B$  为用 GA 约简离散后的剩余属性数. 表中 Boolean reasoning 离散断点数最少, 但却未得出最少约简; 在离散 Pima-Indians 时, 其第二属性是连续的, 但却未生成离散该属性的断点集合. Entropy/MDL 能将属性划分得较多, 也能得出较少剩余属性, 但处理 Wine 时, 离散失效. Equal frequency binning 也同样存在离散不彻底的问题. 基于属性重要度的算法, 有较合理的断点集合, 属性约简能将数据最大限度的约简, 本文将其作为引擎中的离散算法.

表 3 数据离散仿真结果

数据离散算法	Iris		glass		Hayes-Roth		Liver-disorders		Pima-Indians		Wine	
	A	B	A	B	A	B	A	B	A	B	A	B
Boolean reasoning	8	4	15	8	15	5	21	6	22	8	15	6
Entropy/MDL	31	3	256	6	81	3	66	6	49	8	失效	3
Equal frequency binning	8	4	18	8	10	5	12	6	16	8	26	11
基于属性重要度	9	3	29	6	85	1	31	5	44	5	35	4

注: A - 断点数; B - 剩余条件属性数.

#### 3.2.2 属性约简

RSLE 中, 属性约简模块约简冗余信息. 本文选择具有最少属性数的约简作为约简结果. 约简算法有多种, 本文仿真分析四种典型的约简算法. 对表 1 前五组数据集用 Bool 算法离散, 对 Wine 用 Equal frequency binning 离散, 此离散为属性约简提供可约简决策表. 然后将离散结果交与不同约简算法, 得表 4 结果. 可知各算法均得

表 4 属性约简仿真

数据集	属性数	约简后的属性个数			
		Genetic	Johnson's	属性重要度	信息熵
Iris	4	4	4	4	4
glass	9	8	8	8	8
Hayes-Roth	5	5	5	5	5
Liver-disorders	6	6	6	6	6
Pima-Indians	8	8	8	8	8
Wine	13	11	11	11	11

出相同约简结果, 且 glass 与 wine 在约简后分别减少了一个与两个属性, 说明此两数据集有多余属性可约简.

文献[20]对算法复杂度进行了分析. GA 求最小约简时间复杂度为  $T = O(GEN * pop_{size} * |A| * |U| * \log |U|)$ ,  $|A|$  为属性集个数,  $|U|$  为  $U$  个数,  $GEN$  为种群迭代数,  $pop_{size}$  为种群数. 可知当算法执行次数和种群大小确定时, 算法运行时间会随论域对象个数增加近似线性上升. 属性重要度约简、信息熵约简以及 Johnson 约简算法的时间复杂度分别为  $T = O(|A| * |U|^2)$ 、 $T = O(|A|^2)$  和  $T = O(|A|^2 * |U|^2)$ . 本文将时间复杂度相对较低的信息熵约简算法作为候选算法.

#### 3.2.3 值约简与知识表示

值约简模块对 RSLE 中所有跨层信息进一步约简. 决策表中的一条案例可看成一条原始规则, 值约简将去掉该规则中的冗余成分, 这与属性约简处理的对象

不同.属性约简去掉决策表的多余属性,而值约简去掉原始规则中的多余属性值.值约简能生成更一般的规则.

为选择合适的值约简,本文分析两种典型值约简算法,仿真结果如表 5,从表 5 可知,采用基于属性重要度的值约简生成的规则,要比用 Rosetta 值约简的规则平均长度短.规则平均长度( $RL_{avr}$ )定义为:

$$RL_{avr} = \left( \sum_{i=1}^n RL_i \right) / n$$

$n$  为规则数,  $RL_i$  为规则长度(用规则属性数度量).本文选择规则平均长度最短的算法作为候选算法.表 5 属性重要度方法的平均长度比 Rosetta 值约简少一个单位长度,本文采用前者作为候选算法.

表 5 值约简仿真

数据集	对象数	约简后平均规则长度	
		Rosetta 值约简	重要度值约简
Iris	150.0	4	3.5
glass	214.0	8	6
Hayes-Roth	132.0	5	4
Liver-disorders	345.0	6	5.5
Pima-Indians	768.0	8	6
Wine	178.0	11	8

本文用 IF...Then...规则表示学到的知识,如:设有 ARQ、FEC 两种因子影响端到端吞吐量( $TH$ ),其相应知识规则可表示为:

- (1) IF ( $ARQ = on$ ) then ( $TH \uparrow$ );
- (2) IF ( $FEC = on$  or  $FEC = off$ ) then ( $TH$  is *Unaffected*).

第一条规则表示:若 ARQ 开启则吞吐量  $TH$  会上升;第二条规则表示:无论 FEC 开启或关闭,吞吐量不受影响.

## 4 仿真分析

### 4.1 MAC 层协议退避分析

分布式网络的 MAC 层协议主要采用 802.11 标准,各节点间数据发送与接收时可能出现多个节点同时向某节点发送报文而产生碰撞.降低碰撞需合理调度各节点对信道的访问,MAC 中用退避机制来达到此目的.退避算法既要减小节点间的碰撞概率,又要避免因退避时间过长而降低信道利用率,同时还要保证节点公平访问信道.

各种算法都有各自的最佳适用网络场景.如 MILD 算法用于较多节点数网络时,其竞争窗口值变化较平滑,网络吞吐量会略优于 BEB 算法;当网络节点数中等时,该算法会因  $CW$  线性递减而使窗口值变化较慢,易使节点  $CW$  值大于最优值,吞吐量会比 BEB 差;当节点数较少时,因 MILD 中  $CW_{min}$  初值较少,其吞吐量会优于

BEB.又如 SD 算法用在节点数较多的网络时,其吞吐量和公平性高于 BEB;当网络节点数较少时,节点在偶然碰撞时  $CW$  会加倍,算法需经多次成功发送后才使  $CW$  调为合理值,其公平性不如 BEB 算法.

综上,每种退避算法都有优缺点,有必要学习其潜在规律并形成规则知识,并将形成的知识用以指导配置网络运行.

### 4.2 多跳链式网络性能分析

为分析 CRN 多跳对网络性能的影响,本文建立 30 个网络仿真场景,跳数从 1 到 30,节点间距离为 200m 的链式静态结构(节点发射距离 250m).1 节点(源)以 CBR 向目的发 UDP 包(512 字节),链路层数据带宽 2M,数据包速 600Kbps.图 3 是仿真时间为 10s,各场景收到的数据包(星号),横坐标是网络跳数,纵坐标是收到数据包数.各网络均发送 1465 个数据包,在 1 至 6 跳,接收数据包随跳数增加剧烈下降;在 7 至 30 跳,收包基本在 300 左右.多跳网络中节点间的竞争会随跳数变化而变化,这时配置适合网络场景的退避算法,是很重要的.方框连线为拟合曲线,近似服从下式高斯函数:

$$f(x) = a_1 * \exp(-((x - b_1)/c_1)^2) + a_2 * \exp(-((x - b_2)/c_2)^2)$$

式中参数范围  $a_1 \in (1017, 1261)$ ,  $a_2 \in (112.7, 598)$ ,  $b_1 \in (0.2883, 1.234)$ ,  $b_2 \in (-175.3, 153.5)$ ,  $c_1 \in (2.197, 3.172)$ ,  $c_2 \in (-149.6, 313.1)$ .参数取对应范围的中间值,如(1017, 1261)中间值 1139,即拟合曲线置信度 95%,模型拟合决定系数 0.9926.以上场景分析知网络性能与配置参数和环境相关,而拟合结果体现了跳数与吞吐量间的高斯曲线关系.该曲线是通过图表分析得出的知识,虽然该知识只在特定参数下有效,但说明网络中存在潜在知识可学习.




图3 曲线拟合结果对照

### 4.3 模型仿真

为验证提出模型的有效性,本文结合 MAC 层、传输层、应用层等跨层信息,对其进行离线学习.收集不同场景的跨层信息,经学习形成规则知识.通过对随机生成的无线网络匹配最佳规则和重配置协议参数,来进行模型验证.

### 4.3.1 数据采集与规则生成

粗糙集认知跨层学习模型离线采集样本数据,形成案例数据库.本文建立表 6 所示仿真场景,节点间距离随机生成,表 6 中信道容量、数据速率等多个取值,它们的不同组合就是特定的一个网络场景.在不同场景中,分别通过跨层信息总线收集各跨层信息.感知的网络性能为:吞吐量、数据包端到端时延以及丢包率.表中每次仿真时间设为固定值 80s,目的是便于比较网络性能.

表 6 网络参数

仿真时间	80s	网络拓扑	链式网络
传输范围	250m	干扰范围	550m
MAC 协议	802.11 标准	包大小	512Bit
信道容量	2/6/11M	数据速率	200/600/102KB
退避机制	BEB/MILD	传输层协议	UDP(CBR)
节点数	$N=2,3,4,\dots,30$	路由协议	AODV

仿真涉及 522 个场景,采集的跨层信息(局部信息)包含物理层信道容量;MAC 层退避算法类型;传输层 CBR 数据率;应用层跳数、节点密度;全局信息有网络运行时间及吞吐量(收发包数).提取参数经处理存入事件案例库.节点密度定义为网络中活跃节点传输范围内的节点数均值.活跃节点指在某个会话中,参与数据包转发的通信节点.表 7 列举了离散采集的部分案例样本,每一行就是一个特定案例.表 7 第一行表示:数据速率 1024Kbps,节点密度 1.333,信道容量 6M,跳数为 2,退避算法为 BEB,仿真时间内,链路发送 19750 个数据包,接收 17309 个数据包.因仿真时间恒定,数据分析中,时间属性可被约简,此时发包与收包数的比例决定了网络性能.案例库中案例经比较形成以退避算法为决策属性的决策表.

表 7 采集的部分案例数据样本

数据速率	节点密度	信道容量	跳数	退避算法	仿真时间	发包数	收包数
1024	1.333	6	2	1	80	19750	17309
200	1.8333	2	11	1	80	3858	3850
600	1.8	2	9	1	80	11573	2725
600	1.333	2	2	1	80	11573	10358
1024	1.75	6	7	2	80	19750	6554
200	1.667	11	5	1	80	3858	3857
600	1.667	2	5	2	80	11573	4531
1024	1.9	6	19	1	80	19750	4493
200	1.7143	6	6	2	80	19750	3636
600	1.92	2	24	2	80	11573	3055

RSLE 的离散用基于属性重要度方法,属性约简用信息熵约简,值约简用属性重要度约简.表 7 条件属性的离散结果如表 8,可知前三个属性被分成三区域,第四属性被分成十五区域.该划分数据具有归类性,与模糊逻辑中用模糊变量<sup>[21]</sup>将属性分为不同等级类似,不

同的是前者用基于重要度方法,后者用隶属度函数.

表 8 离散断点集合

attribute1	{400,812}
Attribute2	{1.5500,1.6335}
attribute3	{4.0,8.5}
attribute4	{3.5, 4.5, 5.5, 6.5, 7.5, 11.5, 12.5, 13.5, 14.5, 17.5, 18.5, 19.5, 20.5, 21.5}

划分区域后属性约简输出为: { attribute1, attribute3, attribute4 }.属性 2(活跃节点密度)被约去,原因是网络为链式结构,活跃节点为链路中的节点,即跳数信息可转化为节点密度信息.原 522 条数据经处理生成 72 条规则,规则平均长度为 3.部分规则如图 4,其中 attribute1、2、3 和 4 分别为数据率、信道容量、跳数和退避算法.图 4 中第 1 条规则解释为,跳数属性在区间 [1, 3.5] 取值时,退避算法须采用标号为 1 的配置.该规则中并未像第 3 条规则一样指明第 1 与第 2 属性的取值范围,是因在规则 1 中包含的属性 3 在 [1, 3.5] 的取值已决定了属性 4,而与属性 1 和 2 无关.

```

Rules1: if attribute3 = [1, 3.5] then attribute4 = 1
Rules2: if attribute2 = [8.5, 11] and attribute3 = 4 then attribute4 = 1
Rules3: if attribute1 = [812, 1024] and attribute2 = [8.5, 11] and
attribute3 = 5 then attribute4 = 1
Rules4: if attribute2 = [8.5, 11] and attribute3 = 6 then attribute4 = 1
Rules5: if attribute1 = [812, 1024] and attribute3 = 7 then attribute4 = 2
Rules6: if attribute1 = [812, 1024] and attribute3 = 11 then attribute4 = 2
Rules7: if attribute1 = [812, 1024] and attribute3 = 12 then attribute4 = 2
Rules8: if attribute1 = [812, 1024] and attribute3 = 13 then attribute4 = 2
Rules9: if attribute1 = [812, 1024] and attribute3 = 14 then attribute4 = 2
Rules10: if attribute1 = [812, 1024] and attribute2 = [8.5, 11] and
attribute3 = 18 then attribute4 = 1
Rules11: if attribute1 = (0, 400] and attribute2 = (0, 4] and
attribute3 = 5 then attribute4 = 1
Rules12: if attribute3 = [21.5, 29] then attribute4 = 2

```

图 4 部分规则样本示例

### 4.3.2 重配置网络仿真

CRN 能实现协议与接口参数重配置.为验证提取的规则,本文以吞吐量、端到端时延和丢包率为性能比较参考.在 1000 × 1000 区域中产生 20 个节点,随机选择源目节点组建链式网络,源点以固定速率向目的点发送 CBR 流.数据率 400Kbps,信道容量 2M,路由协议 AODV,跳数 5,节点传输范围 250m.MAC 层在 BEB 与 MILD 间选择.仿真中匹配模型选第 11 条规则: if attribute1 = (0, 400] and attribute2 = (0, 4] and attribute3 = 5 then attribute4 = 1. attribute4 为 1 表明退避机制应采用 BEB.

图 5 为根据 RSLE 得出 BEB 配置(十字号)的吞吐量与默认采用 MILD(圆圈)的结果图.CBR 在第 60s 开启,在 60s 到 135s 中 MILD 平均吞吐量为 200.18KB,而

RSLE 用 BEB 平均吞吐量为 220.56KB(提高 9.73%)。但在 131.6s 时吞吐量为 89.85KB, 在 132.5s 时为 113.49KB, 在这 0.9s 内有一次抖动, 该抖动并不影响网络整体性能。在 135s 到 150s 内, MILD 平均吞吐量为 180.46KB, 采用 RSLE 选择的平均吞吐量为 221.53KB(提高 22.76%)。

图 6 虚线为采用 MILD 数据包端到端延时, 实线为 RSLE 的延时。数据包 ID 从 6309 至 14539 时用 MILD, 平均延时 1095.3ms; 而用 RSLE 时为 995.6 ms(少 9.11%)。在 14540 至 15676 用 MILD, 平均延时 1224.1ms, RSLE 时 994.4 ms(减少 18.75%)。

对丢包率, 仿真期间共发送了 8145 个 UDP 数据包, MILD 机制收到 4174 个(丢包率 48.75%), RSLE 选择的退避机制收到 4532 个(丢包率为 44.358%, 降低了约 4.4%)。通过以上三种网络性能参数分析, 知 RSLE 能有效提高吞吐量, 减少数据包延时, 降低丢包率。

为进一步验证 RSLE 在 CRN 中学习的优越性。随机产生 10 个场景, 每个场景的基本工作参数与图 5 和图 6 的网络参数相同。RSLE 在 BEB 与 MILD 中选择一种退避机制, 与之对比的是默认采用另一种。即每个场景被不同退避机制配置了两次, 并独立运行进行性能比较。其中, 第 3、第 6 和第 7 场景的跳数较少, 其他场景的跳数相对较多。仿真中, RSLE 在第 3、第 7、第 9 和第 10 个




图5 吞吐量比较




图6 延时比较

场景中选择了 MILD, 而在剩下的场景中选择了 BEB。采用默认方式与 RSLE 推理方式的平均吞吐量、平均延时和丢包率的对比结果如表 9。

表 9 平均吞吐量、平均延时和丢包率的对比结果

场景号	1	2	3	4	5	6	7	8	9	10
平均吞吐量 A	198434.6	458835.0	700000.8	439074.6	687491.4	499988.7	200012.1	293666.5	297327.6	313344
平均吞吐量 B	192318.2	347689.5	700000.8	249219.4	609086.2	494951.7	200012.1	134033.2	280313.4	291446.1
平均延时 A	0.0206	0.00892	0.00585	0.00932	0.00595	0.00819	0.0204	0.0139	0.0137	0.0130
平均延时 B	0.0212	0.0117	0.00585	0.0164	0.00672	0.00827	0.0204	0.0305	0.0146	0.0140
丢包率 A	0.5039	0.08236	0	0.4511	0.1406	0.00005534	0	0.7132	0.7096	0.6940
丢包率 B	0.5192	0.3046	0	0.6884	0.2386	0.01012	0	0.8691	0.7262	0.7153

注释: A-粗糙集引擎 B-默认选择

如表 9 所示, 第 3(第 7)场景采用不同退避机制时, 粗糙集方案(A)与默认方案(B)对应的平均吞吐量相同(如第 3 场景 A、B 对应的吞吐量均为 700000.8)。原因是这两种场景的跳数分别为 1 跳与 2 跳, 在跳数较少时 BEB 与 MILD 配置区别不大。在余下 8 个场景中基于 RSLE 的平均吞吐量都要高于默认退避机制。对平均延时, 第 3 与第 7 场景延时值相同, 而剩下的 8 个场景中默认方式的平均延时均大于 RSLE 的延时。对丢包率, 第 3 与第 7 场景的丢包率均为零, 剩余场景中 RSLE 方式的丢包率明显低于默认选择方式。

## 5 结论

本文研究了 CRN 跨层认知学习问题, 提出了一种基于 RS 的跨层认知模型, 该模型由学习引擎 RSLE、案


例事件库、知识库、规则匹配器相结合实现 CRN 的认知学习。RSLE 通过选择合适的离散、属性约简与值约简算法有效提高了知识提取的准确性。重配置网络的仿真证实了该引擎能有效学习跨层参数间的潜在知识, 得出的知识可通过知识库被共享并能很好运用于网络重构设计以提升其性能。

## 参考文献

- [1] Yanbing LIU, Qin ZHOU. State of the art in cross-layer design for cognitive radio wireless networks[A]. Proceedings of the 2009 International Symposium on Intelligent Ubiquitous Computing and Education[C]. Washington, DC, USA: IEEE Computer Society, 2009. 366 - 369.
- [2] Yu Yong, Wang Lifeng, Yu Quan. Cross-layer architecture in cognitive ad hoc networks[A]. WRI International Conference

- on Communications and Mobile Computing, CMC '09 [C]. Washington, DC, USA: IEEE Computer Society, 2009. 47 – 51.
- [3] Lijun Chen, Steven H Low, John C Doyle. Cross-layer design in multihop wireless networks [J]. Computer Networks, 2011, 55(2): 480 – 496.
- [4] 张敏. 认知无线网络跨层建模及性能分析 [D]. 广州: 华南理工大学, 2010.  
Zhang Min. Cross layer modeling and performance analysis for cognitive radio networks [D]. Guangzhou: South China University of Technology, 2010. (in Chinese)
- [5] 韩冰青. 移动 Ad Hoc 网络中资源分配及跨层技术研究 [D]. 江苏南京: 南京理工大学, 2010.  
Han bingqing. Research on resource allocation and cross layer technology in mobile ad hoc networks [D]. Nanjing: Nanjing University of Science & Technology, 2010. (in Chinese)
- [6] 管章玉. 认知与协作无线通信网络中基于博弈论的跨层优化理论研究 [D]. 山东济南: 山东大学, 2010.  
Guan zhangyu. Cross layer optimization in cognitive and cooperative wireless networks based on game theory [D]. Jinan, Shandong: Shandong University, 2010. (in Chinese)
- [7] Baynast A D, Mahonen P M. ARQ-based cross-layer optimization for wireless multicarrier transmission on cognitive radio networks [J]. Computer Networks, 2008, 52(4): 778 – 794.
- [8] Alexander M Wyglinski, Maziar Nekovee, Y Thomas Hou. Cognitive Radio Communications and Networks: Principles and Practice [M]. USA: Academic Press, 2009.
- [9] Baldo N, Zorzi M. Fuzzy logic for cross-layer optimization in cognitive radio networks [J]. IEEE Communications Magazine, 2008, 46(4): 64 – 71.
- [10] Fangwen Fu, Mihaela van der Schaar. Learning to compete for resources in wireless stochastic games [J]. IEEE Transactions on Vehicular Technology, 2009, 58(4): 1904 – 1919.
- [11] Ana Galindo-Serrano, Lorenza Giupponi. Distributed Q-learning for aggregated interference control in cognitive radio networks [J]. IEEE Transactions on Vehicular Technology, 2010, 59(4): 1823 – 1834.
- [12] M Bogatinovski, L Gavrilovska. Overview of cross-layer optimization methodologies for cognitive radio [A]. Proceedings of the 16th Telecommunications Forum Telfor [C]. Serbia, 2008. 254 – 257.
- [13] 韩冰, 高新波, 姬红兵. 基于模糊粗糙集的新闻视频镜头边界检测方法 [J]. 电子学报, 2006, 34(6): 1085 – 1089.  
Han bing, Gao xin bo, ji hong bing. A shot boundary detection method for news video based on rough fuzzy sets [J]. Acta Electronica Sinica, 2006, 34(6): 1085 – 1089. (in Chinese)
- [14] Zhang L, Zhou X W, Wu H Y. A rough set comprehensive performance evaluation approach for routing protocols in cognitive radio networks [A]. Global Mobile Congress [C]. Shanghai: IEEE Press, 2009. 1 – 5.
- [15] Katidiotis A, Tsagkaris K, Demestichas P. Performance evaluation of artificial neural network-based learning schemes for cognitive radio systems [J]. Computers & Electrical Engineering, 2010, 36(3): 518 – 535.
- [16] Hea A, Gaedderta J. Development of a case-based reasoning cognitive engine for IEEE 802.22 WRAN applications [J]. Mobile Computing and Communications Review, 2008, 13(2): 34 – 48.
- [17] K Thangavel, A Pethalakshmi. Dimensionality reduction based on rough set theory: A review [J]. Applied Soft Computing, 2009, 9(1): 1 – 12.
- [18] 江峰, 杜军威, 葛艳, 等. 基于粗糙集理论的序列离群点检测 [J]. 电子学报, 2011, 39(2): 345 – 350.  
Jiang Feng, Du Junwei, Ge Yang, et al. Sequence outlier detection based on rough set theory [J]. Acta Electronica Sinica, 2011, 39(2): 345 – 350. (in Chinese)
- [19] Hameed A Q, Aboul E H, Ajith Abraham. Discovering stock price prediction rules using rough sets [J]. Neural Network World Journal, 2008, 18(3): 181 – 198.
- [20] Bazan J G, Hung S N, Nguyen S H, et al. Rough set algorithms in classification problem [A]. Rough Set Methods and Applications [M]. Heidelberg, Germany: Physica-Verlag GmbH, 2000. 49 – 88.
- [21] Baldo N, M Zorzi. Cognitive network access using fuzzy decision making [J]. IEEE Transactions on Wireless Communications, 2009, 8(7): 3523 – 3535.

### 作者简介



江 虹 男, 1969 年出生于重庆. 博士, 教授, 主要从事认知无线电智能学习和无线网络资源管理技术研究.

E-mail: jianghong@swust.edu.cn



伍 春 男, 1978 年出生于绵阳. 博士生, 主要从事认知无线技术研究.