

# 一种最大化网络吞吐量的认知无线 Ad Hoc 网络 跨层优化算法

杨双懋 郭 伟 唐 伟

(电子科技大学通信抗干扰技术国家级重点实验室 成都 611731)

**摘 要** 认知无线 Ad hoc 网络(cognitive wireless ad hoc networks)是由一组具有认知决策能力的节点以多跳无线方式组成的智能网络. 网络容量的求解与网络吞吐量的优化是该类网络研究的难点. 作者首先推导了混叠模式下认知无线 Ad hoc 网络容量上界的闭合表达式, 并指出该上界只与用户空间分布特性相关; 然后提出了一种新的基于遗传算法的跨层优化算法, 通过联合优化邻居选择与功率分配实现网络吞吐量的最大化; 最后仿真验证了该算法的有效性, 结果表明网络吞吐量能较好地逼近网络容量上界.

**关键词** 物联网; 认知无线 Ad hoc 网络; 网络容量; 遗传算法

中图法分类号 TP393 DOI号: 10.3724/SP.J.1016.2012.00491

## A Cross-Layer Throughput-Maximization Algorithm for Cognitive Wireless Ad hoc Networks

YANG Shuang-Mao GUO Wei TANG Wei

(National Key Laboratory of Science and Technology on Communications,  
University of Electronic Science and Technology of China, Chengdu 611731)

**Abstract** Cognitive wireless ad hoc networks are smart networks formed by multiple cognitive nodes in a distributed and multi-hop fashion. The analysis of network capacity and optimization of network throughput are key problems in the research field of such networks. In this paper, we first derive the close-form expression of the upper bound of network capacity for cognitive wireless ad hoc networks in the underlay spectrum access mode, and show that this upper bound is only determined by the spatial distribution of the nodes. Then we present a novel cross-layer optimization algorithm for maximizing network throughput, which adopts genetic algorithm (GA) to achieve the optimal neighbor selection and power allocation. Lastly, numerical simulation is conducted to verify the proposed scheme, and it is shown that the obtained network throughput achieves a performance closely approximate to the upper bound of network capacity.

**Keywords** Internet of Things; cognitive wireless ad hoc networks; network capacity; genetic algorithm

## 1 引 言

未来的无线网络将呈现出高速化、宽带化、异构

化、泛在化的趋势, 目前的数据网络技术不具备足够的适应能力, 这使网络性能经常处于次优状态. 认知网络<sup>[1]</sup>是具有认知特性的通信网络, 网络中的节点能够感知当前的网络环境, 并根据感知结果和当前

用户需求进行学习、决策与执行. 认知网络能够自适应地学习和推理并且以端到端性能为目标进行决策. 认知无线 Ad hoc 网络<sup>[2]</sup>是由一组具有认知决策能力的节点以多跳无线方式组成的智能网络, 能为用户智能动态地接入物联网提供基础通信平台. 与传统 Ad hoc 网络相比, 认知无线 Ad hoc 网络采用动态频谱接入, 即当节点感知到网络环境中具有空闲频谱时, 在保障主用户通信不受影响的条件下, 节点可以自适应地调整无线参数以接入到空闲频谱. 认知网络的频谱共享模式可以被分为覆盖 (overlay) 模式和混叠 (underlay) 模式. 在覆盖模式下认知用户采用机会式频谱接入方式占用主用户空闲频谱; 而混叠模式则允许认知用户和主用户同时使用同频信道. 在混叠模式下, 认知用户不仅需要感知频谱是否空闲, 还需要估计其传输对主用户造成的干扰大小, 这样就增加了算法复杂度. 本文将重点研究在混叠模式下认知无线 Ad hoc 网络的容量问题.

无线 Ad hoc 网络的网络容量问题近年来得到了广泛的研究, 文献[3]建立了经典的 Ad hoc 网络模型, 明确了无线 Ad hoc 网络的吞吐容量和网络容量的定义, 得出了不同干扰模型下网络容量的界限. 其后的文献[4-8]在不同的网络条件和假设下也得出了类似的结论, 但是文献[3-8]的结论都只是得出网络容量在渐近意义下的同阶表达式或者上下界, 并没有给出逼近网络容量的方法. 文献[9-10]采用蒙特卡罗方法得到了均匀分布网络的容量. 文献[11]进一步得到同类网络容量的闭合表达式, 但是文献[9-11]对网络条件的假设过于理想化, 且没有考虑节点功率控制. 文献[12-17]主要研究了认知无线电网络的容量问题, 采用一对主用户和一对认知用户的经典认知无线电机机会频谱接入模型, 这种网络容量本质上依然是有干扰的认知点到点的链路容量. 文献[18-20]研究了认知用户单发多收的广播模式下的链路容量. 文献[21-22]采用了认知无线中继网络模型, 中继节点采用协同方式转发数据, 且同时只能有一个主用户和一个认知用户通过中继网络转发数据. 文献[23]研究了多个主用户为认知用户协同转发数据的方式, 但这与认知无线 Ad Hoc 网络的多跳环境和多业务源模式有很大的区别, 不能直接参考和利用其结论. 文献[24]基于蜂窝小区研究认知无线电背景下的多跳无线网络系统容量, 其得到的结论依然是与认知用户传输距离相关的同阶表达式. 文献[25]综合考虑了功率和时隙分配的优化, 但是其网络模型要求所有的认知用户通信都借助认知

基站来转发, 属于中心控制的认知网络. 文献[26]在混叠模式下提出了一种自适应的信道分配算法, 依然没有考虑节点功率分配和并存多个主用户的情况. 文献[27]基于信干噪比 (Signal to Interference plus Noise Ratio, SINR) 模型来描述信道干扰, 综合考虑了多信道分配、节点功率限制和多径路由流量限制, 采用了混合整数线性规划 (Mixed Integer Linear Programming, MILP) 方法来优化路由问题. 文献[28]和文献[27]类似, 运用混合整数非线性规划 (Mixed Integer None Linear Programming, MINLP) 方法来对一些实际网络路由规划进行数值计算. 这两项工作都没有从理论上推导出具体网络场景下的容量. 此外, 文献[27-28]经过数值优化计算后所获得的吞吐量并不一定与网络容量相符.

从总体看来, 现有的网络容量研究存在如下几个问题: (1) 大部分针对无线 Ad hoc 网络容量的研究都只得到了渐近意义下的同阶表达式或者上下界, 而这些表达式中都包含了一些未知的常数, 因而在不同网络场景下, 即使同阶表达式或者上下界相同, 也无法获得实际的网络容量; (2) 在较强假设下对网络容量进行研究, 当假设条件不再成立时, 就不能正确估算实际的网络容量; (3) 对于某个网络场景, 其网络容量是一个客观存在的理论值, 如何得到网络容量与网络参数之间的显式、确定的关系还具有很大的挑战性; (4) 研究如何根据推导出的理论网络容量来调度网络资源以尽量逼近网络容量? 目前, 研究的较少.

针对上述问题, 本文将研究在具体网络场景下, 如何最大化网络吞吐量以逼近网络容量的问题. 为最大化网络吞吐量, 本文采用跨层优化机制, 考虑了主用户与认知用户之间的同频干扰和认知用户间的互干扰, 并使用遗传算法来搜索最优解, 充分利用认知用户的空分复用优势进行数据传输, 达到混叠利用主用户空闲频谱的目的. 本文第 2 节介绍认知无线 Ad hoc 网络的系统模型; 第 3 节提出最大化网络吞吐量的目标函数, 推导出网络容量的上界以及提出基于遗传算法的最大化网络吞吐量的跨层优化算法; 第 4 节通过仿真实验验证所提出的优化算法和理论网络容量; 第 5 节总结全文.

## 2 系统模型

### 2.1 网络模型

如图 1 所示, 本文考虑的认知无线 Ad hoc 网络

由  $N$  个认知用户 (Cognitive Radio user, CR) 和  $Q$  个主用户接收机 (Primary User, PU) 组成. 其中 CR 用户间以多跳无线方式通信, CR 用户通过占用主用户的空闲频段传输数据; 假设主用户发射机与 CR 用户间的距离足够大, 主用户发射机对 CR 用户的干扰可以忽略不计.

径传播衰减因子, 取值范围通常为  $2 \leq \alpha \leq 4$ , 则  $p_i d_{ij}^{-\alpha}$  是用户  $j$  接收机的信号功率, 而  $p_m d_{mj}^{-\alpha}$  ( $m \in N, m \neq i$ ) 是用户  $j$  接收机收到的干扰功率, 则有如下主用户接收机和认知用户接收机处的 SINR 简化计算公式<sup>[3]</sup>:

$$\gamma_k = \frac{\mu_k \eta W}{\eta W + \sum_{i \in N} p_i d_{ik}^{-\alpha}},$$

$$\beta_{ij} = \frac{p_i d_{ij}^{-\alpha}}{\eta W + \sum_{m \in N, m \neq i} p_m d_{mj}^{-\alpha}}.$$

假设认知用户具有相同的最大传输功率  $p_{\max}$ . 一方面为了保证主用户的正常通信, 认知用户需要在  $[0, p_{\max}]$  的范围内动态地调整自身的传输功率, 以保证主用户的 SINR 满足门限值  $\Gamma_p$  的限制, 另一方面, 为了保证认知用户之间的成功传输和达到合理的通信速率, 认知用户接收端的 SINR 必须满足门限值  $\Gamma_s$  限制.

### 2.3 链路层和网络层模型

为最大化网络吞吐量, 本文将链路层功率控制和网络层路径选择进行了联合优化. 本文假设网络具有一个如图 1 中的认知辅助代理基站, 该基站由计算能力最强的认知用户 (也可以是一个辅助计算的基站或者专司控制的代理节点, 简称为决策用户) 充当. 决策用户通过全局公共控制信道交互每个认知用户的位置和通信需求、主用户的位置和主用户当前 SNR 值 (主用户的位置和 SNR 值有多种办法可以获知, 一种是主用户和认知用户进行协作, 主用户主动报告自身的一些参数, 另一种是使用无线电测向技术获知主用户位置, 或者根据电子侦查技术获知主用户相关参数), 进行优化运算后将结果通过全局公共控制信道下发给认知用户, 最后网络中各认知用户开始依照优化的功率策略和路径传输数据. 当认知用户的位置和通信需求发生改变时, 重复这个决策过程. 本文重点考察理想认知网络环境下可获得的最大网络吞吐量, 因此没有考虑交互过程带来的时延, 也不考虑优化算法的计算时延和下发时延.

在多跳无线网络中, 如果多个发射接收节点对可以同时进行数据传输, 那么称这些同时发送数据的节点为并发传输节点. 本文考虑如下的链路层控制方式: 将节点的传输时间划分为时隙, 对每个节点可以分配不同的时隙来发送数据, 使得在任意时刻, 网络中并发传输节点的数据率之和最大.

为了获得最大的网络吞吐量并且在此基础上使

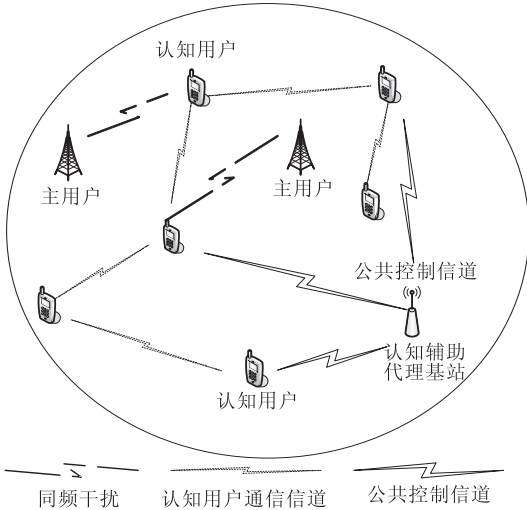


图 1 网络结构示意图

由于 CR 用户必须严格控制功率以防止对 PU 造成不可接受的干扰, 因而需要一个或者多个具有很强计算能力的 CR 用户作为认知辅助代理基站 (Cognitive Agent Base-station). 该基站与其它 CR 用户之间有一个使用授权频段的全局公共控制信道 (common control channel). 该信道可用于可靠的交换传输控制、路由以及功率控制等跨层优化信息. 在认知网络中, 该公共控制信道可被看作是一个交互认知流的专用信道.

### 2.2 干扰模型

目前无线网络中存在两种被广泛使用的干扰关系描述的模型, 分别是物理模型和协议模型<sup>[3]</sup>. 由于物理模型能够更准确地反映网络的实际情况, 因而本文将使用该模型中的信噪比 (Signal to Interference plus Noise Ratio, SINR) 来描述认知用户对主用户的同频干扰以及认知用户之间的相互干扰. 假设在没有受到认知用户干扰时主用户接收机  $k$  的信噪比 (Signal-to-Noise Ratio, SNR) 为  $\mu_k$ , 存在认知用户干扰时主用户接收机  $k$  的 SINR 为  $\gamma_k$ , 而当认知用户  $i$  向认知用户  $j$  发送数据时, 记认知用户  $j$  接收机处的 SINR 为  $\beta_{ij}$ , 采用  $\eta$  表示加性高斯白噪声功率谱密度,  $W$  表示系统通信频段的带宽, 则接收机处的背景噪声功率是  $\eta W$ ;  $p_i$  表示认知用户  $i$  的发射功率,  $d_{ij}$  表示用户  $i$  和  $j$  之间的距离,  $\alpha$  表示路

数据能正确到达目的地,本文的分析基于如下的路由选择策略:如图2所示,认知用户  $S$  有数据报文需要传输到认知用户  $D$ ,  $\tau_{\max}$  是不考虑对主用户的同频干扰和不考虑对主用户互干扰时认知用户  $S$  的最大传输半径,则  $\tau_{\max} = (\Gamma_s \eta W / p_{\max})^{-1/\alpha}$ , 定义图2中 Region1 部分中的认知用户是  $S$  的邻居节点, 记为  $V_S$ , 若节点  $i \in V_S$ , 即满足  $d_{iD} < d_{SD}$  且  $d_{Si} < \tau_{\max}$ . 当 Region1 中没有包含认知用户时, 定义 Region2 中的认知用户是  $S$  的邻居节点, 记为  $\tilde{V}_S$ , 若节点  $u \in \tilde{V}_S$ , 即满足  $d_{uD} > d_{SD}$  且  $d_{Su} < \tau_{\max}$ .




图2 节点邻居选择示意图

当认知用户  $i \in N$  有通信需求时, 决策用户从认知用户的邻居集合  $V_i (V_i \neq \emptyset)$  中选择一个节点  $a_i$ , 若  $V_i = \emptyset$ , 则从  $\tilde{V}_i$  中选择一个节点  $a_i$ ,  $a_i$  负责为节点  $i$  进行数据缓存转发. 为了最大化网络吞吐量和保证主用户的正常通信, 决策用户的选择应使网络中存在尽可能多的高速率并行传输. 当数据到达  $a_i$  后, 决策用户继续为数据选择下一跳节点, 直到数据到达目的节点.

在实际应用中, 可以通过如下步骤实现: (1) 网络中的各认知用户通过全局公共控制信道向决策用户报告各自的通信需求和位置、主用户的 SNR 值和位置; (2) 由决策用户发起跨层优化算法, 获得网络中当前通信需求下各个认知用户的功率控制方案、时隙分配方案和路由选择策略; (3) 决策用户将决策结果公布到全网; (4) 网络中各认知用户分时隙开始传输数据, 并依照优化的功率方案和路径传输数据.

### 3 认知无线 Ad Hoc 网络最大化网络吞吐量问题

#### 3.1 问题描述

多跳无线网络的容量问题是近年来一个研究热点, 网络容量与节点的数量、节点的分布以及节点的密度和传输范围等因素密切相关, 因此难以获得网络容量的闭合表达式. 为此本文采用跨层算法优

化网络吞吐量, 使之尽量逼近网络容量.

如图3所示, 网络中存在两条数据流, 节点  $S_1 \rightarrow D_1$  和  $S_2 \rightarrow D_2$ , 存在4个中间节点  $i, j, r$  和  $k$  为其转发数据, 且满足  $d_{jD_1} < d_{kD_1}$ ,  $d_{S_1 k} < d_{S_1 j}$ ,  $d_{iD_2} < d_{rD_2}$ ,  $d_{S_2 r} < d_{S_2 i}$ ,  $d_{S_1 i} < d_{S_1 r}$  和  $d_{S_2 j} < d_{S_2 k}$ , 按照传统的基于地理位置的路由协议 GPSR<sup>[29]</sup>, 数据流的转发路径为  $S_1 \rightarrow j \rightarrow D_1$  和  $S_2 \rightarrow i \rightarrow D_2$ , 很明显在这种转发策略下, 无论是否采用发射功率控制, 由于满足  $d_{S_1 i} < d_{S_1 r}$  和  $d_{S_2 j} < d_{S_2 k}$ , 则可以得到  $\beta_{S_1 k} > \beta_{S_1 r}$  且  $\beta_{S_2 r} > \beta_{S_2 i}$ , 即  $S_1$  的发射会在节点  $i$  处产生大于节点  $r$  处的干扰,  $S_2$  的发射会在节点  $j$  处产生大于节点  $k$  处的干扰, 这种转发策略下, 网络中同时能传输的数据率不能达到最大化. 若采用数据流的转发路径为  $S_1 \rightarrow k \rightarrow D_1$  和  $S_2 \rightarrow r \rightarrow D_2$ , 由于中间节点  $r$  和  $k$  的距离相对较大, 互干扰就会下降, 网络中并行传输的数据率将大于 GPSR 策略下的数据率.




图3 数据流转发节点选择示意图

基于以上对网络容量和网络吞吐量的分析, 本文参照文献[3]给出无线认知 Ad hoc 网络的网络吞吐量的定义: 考虑一个由  $N$  个认知用户和  $Q$  个主用户接收机组成的认知无线 Ad hoc 网络, 按照一定的时空分配方案和存储转发机制, 在  $[(i-1)T, iT]$  时间段内 ( $T < \infty$ ), 网络中每个认知用户发送到相应目的节点的比特数为  $\sum_{j \in N} T \lambda_j$ , 那么称网络的吞吐量为  $\sum_{j \in N} \lambda_j$  bit/s. 同时, 定义网络容量  $C$  为网络吞吐量的最大值, 即  $C := \max \sum_{j \in N} \lambda_j$  bit/s.

由于认知用户的通信需求是一个动态变化的过程, 因此网络吞吐量也是一个动态变化的量. 为了简化分析, 假定每个时隙内, 认知网络的通信需求和主用户状态不发生改变. 因此最大化网络吞吐量就变为最大化每个时隙内网络成功接收的数据量. 当主用户状态或者认知网络通信需求发生变化时, 进入下一时隙, 决策用户重新计算当前时隙最优传输分配方案.

在一个时长为  $T$  的时隙内, 设  $L$  个认知用户有通信需求, 用  $T_L$  代表有通信需求的发送节点集合, 定义  $x_{ij}$  为链路调度变量, 当节点  $i$  向节点  $j$  发送数据时,  $x_{ij} = 1$ , 否则  $x_{ij} = 0$ . 即

$$x_{ij} = \begin{cases} 1, & \text{在时隙 } T \text{ 内, 节点 } i \text{ 向节点 } j \text{ 发送数据} \\ 0, & \text{其它} \end{cases},$$

此时通信节点对  $(i, j)$  间的传输速率记为  $\lambda_{ij}$ , 其中  $i \in T_L, j \in V_i \cup \tilde{V}_i$ , 考虑主用户的干扰限制条件、认知用户的功率限制条件以及认知用户的互干扰限制条件下, 认知无线 Ad hoc 网络最大化网络吞吐量问题的目标函数, 即时隙  $T$  内网络成功传输的数据量, 可以表示为

$$\max \sum_{i \in T_L, j \in V_i \cup \tilde{V}_i} T \lambda_{ij} x_{ij} \quad (1)$$

$$\text{s. t. } \gamma_k = \frac{\mu_k \eta W}{\eta W + \sum_{i \in T_L} p_i d_{ik}^{-\alpha}} \geq \Gamma_p, \quad k \in Q, p_i \leq p_{\max} \quad (2)$$

$$\sum_{j \in V_i \cup \tilde{V}_i} x_{ij} \leq 1, \quad i \in T_L \quad (3)$$

$$\sum_{i \in T_L} x_{ij} \leq 1, \quad j \in N \quad (4)$$

$$\beta_{ij} = \frac{p_i d_{ij}^{-\alpha}}{\eta W + \sum_{m \in T_L, m \neq i} p_m d_{mj}^{-\alpha}} \geq \Gamma_s,$$

$$i \in T_L, j \in V_i \cup \tilde{V}_i, p_m \leq p_{\max}, p_i \leq p_{\max} \quad (5)$$

$$\lambda_{ij} \leq W \log_2(1 + \beta_{ij}), \quad i \in T_L, j \in V_i \cup \tilde{V}_i \quad (6)$$

### 3.2 随机网络容量的上界

最大化网络吞吐量可以实现逼近网络容量, 在上一节中把最大化网络吞吐量转化为一个带约束条件的数学优化问题, 但是为了验证某个算法是否能逼近网络容量的前提是必须事先知道某个具体场景的网络容量, 而当前对网络容量的研究只得到了渐近意义下的同阶表达式, 对于网络节点数不是特别大的场景下具有很大的误差, 因此有必要推导出一个比较紧的网络容量上界, 用来验证算法的正确性和指导相关协议的设计。

为了方便推导, 做出如下假设: (1) 某个矩形区域内均匀放置  $N$  个认知用户, 其中  $L$  个用户有通信需求, 显然有  $L \leq N/2$ ; (2) 有通信需求用户的目的节点在网络中随机均匀分布, 用户的下一跳节点按照上一节中给的方法选定; (3) 网络容量是  $C$ , 则在  $T$  时间段内网络能传输的最大比特数为  $CT$ ; (4) 源节点和下一跳节点的平均距离是  $\bar{D}$ , 最小距离是  $D_{\min}$ ; (5) 干扰节点与下一跳转发节点间的最大距离是  $D_{\max}$ 。

**引理 1.** 函数  $f(\beta) = \log_2^a(1 + \beta)$ ,  $a > 1$  在区间  $[0, e^{a-1} - 1]$  上是严格凸函数, 在区间  $[e^{a-1} - 1, \beta_{\max}]$  上是严格凹函数。

证明. 令函数  $f(\beta)$  的二阶导数  $f''(\beta) = 0$ , 可以求得拐点为  $e^{a-1} - 1$ , 则当  $\beta \in [0, e^{a-1} - 1]$  时,

$f''(\beta) > 0$ , 当  $\beta \in [e^{a-1} - 1, \beta_{\max}]$ ,  $f''(\beta) < 0$ , 由函数凹凸性的定义可以证明引理 1. 证毕.

**引理 2.** 多元函数  $f(\beta_1, \beta_2, \dots, \beta_L) = \sum_{\beta_i \in L} \log_2^a(1 + \beta_i)$ ,  $a > 1$  的最大值在定义域的边界处取得, 即  $f_{\max}(\beta_1, \beta_2, \dots, \beta_L) = \log_2^a(1 + \beta_{\max})$ , 其中  $\beta_i = \frac{c_i p_i}{n_0 + \sum_{m \neq i} c_m p_m}$ ,  $c_i$  和  $c_m$  是常数, 其中最小值是  $c_{\min}$ ,  $n_0 \approx 0$ ,  $p_i \in [0, p_{\max}]$ , 且满足  $\frac{c_{\min} p_{\max}}{n_0} > \left(\frac{L}{L-1}\right)^{\sqrt{L}} - 1$ .

证明. 在区间  $[e^{a-1} - 1, \beta_{\max}]$  内任取两点  $(\beta_1, \beta_2, \dots, \beta_L)$  和  $(\beta'_1, \beta'_2, \dots, \beta'_L)$ , 则有

$$\begin{aligned} & \frac{1}{2} (f(\beta_1, \beta_2, \dots, \beta_L) + f(\beta'_1, \beta'_2, \dots, \beta'_L)) \\ &= \frac{1}{2} \sum_{i=1}^L (\log_2^a(1 + \beta_i) + \log_2^a(1 + \beta'_i)) \\ &\leq \sum_{i=1}^L \log_2^a\left(1 + \frac{\beta_i + \beta'_i}{2}\right) \\ &= f\left(\frac{\beta_1 + \beta'_1}{2}, \frac{\beta_2 + \beta'_2}{2}, \dots, \frac{\beta_L + \beta'_L}{2}\right). \end{aligned}$$

因此多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  在区间  $[e^{a-1} - 1, \beta_{\max}]$  上是一个严格的凹函数, 同理可证明在区间  $[0, e^{a-1} - 1]$  上多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  是一个严格凸函数, 由严格凹(凸)函数的性质, 多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  在定义域内只能最多有一个驻点. 易知, 当  $\beta_1 = \beta_2 = \dots = \beta_L = c$  时, 点  $(c, c, \dots, c)$  是多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  的驻点, 其函数值为  $L \log_2^a(1 + c)$ , 由  $\beta_i$  的性质可知, 当  $\beta_1 = \beta_2 = \dots = \beta_L = c$  时, 一定有  $c_1 p_1 = c_2 p_2 = \dots = c_L p_L = c_0$ , 则此时  $c = \frac{c_0}{n_0 + (L-1)c_0}$ , 所以多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  在

其驻点处的函数值为  $L \log_2^a\left(1 + \frac{c_0}{n_0 + (L-1)c_0}\right) \approx L \log_2^a\left(\frac{L}{L-1}\right)$ . 又根据有界闭区间上的连续函数的性质, 多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  一定有最大值, 其最大值在边界处或者驻点处取得, 对于函数的边界点  $(\beta_{\max}, 0, \dots, 0)$ , 其函数值为  $\log_2^a(1 + \beta_{\max})$ , 其中  $\beta_{\max} = \frac{c_{\min} p_{\max}}{n_0}$ , 由已知条件  $\frac{c_{\min} p_{\max}}{n_0} > \left(\frac{L}{L-1}\right)^{\sqrt{L}} - 1$  可以推导出  $\log_2^a(1 + \beta_{\max}) > L \log_2^a\left(\frac{L}{L-1}\right)$ . 综上所述, 多元函数  $f(\beta_1, \beta_2, \dots, \beta_L)$  的最大值为  $\log_2^a(1 + \beta_{\max})$ .

证毕.

下面考虑物理干扰模型式(5)的另外一种形式:

$$\frac{p_i d_{ij}^{-\alpha}}{\eta W + \sum_{m \in T_L} p_m d_{mj}^{-\alpha}} \geq \frac{\Gamma_s}{\Gamma_s + 1}.$$

可以得到

$$\begin{aligned} d_{ij}^{\alpha} &\leq \frac{\Gamma_s + 1}{\Gamma_s} \frac{p_i}{\eta W + \sum_{m \in T_L} p_m d_{mj}^{-\alpha}} \\ &\leq \frac{\Gamma_s + 1}{\Gamma_s} \frac{p_i}{\eta W + D_{\max}^{-\alpha} \sum_{m \in T_L} p_m}. \end{aligned}$$

对所有的收发节点求和得到

$$\begin{aligned} \sum_{i \in T_L} d_{ij}^{\alpha} &\leq \frac{\Gamma_s + 1}{\Gamma_s} \frac{\sum_{i \in T_L} p_i}{\eta W + D_{\max}^{-\alpha} \sum_{m \in T_L} p_m} \\ &\leq \frac{\Gamma_s + 1}{\Gamma_s} D_{\max}^{\alpha} \end{aligned} \quad (7)$$

有了上面两个引理、式(7)以及赫尔德不等式,可以推导出随机网络容量的上界  $C_{up}$ . 假设在时间段  $T$  内发送的某个比特  $b$  经过的距离为  $d_b$ , 则由假设条件式(3)和(4)得到

$$CT\bar{D} \leq \sum_{b=1}^{CT} d_b.$$

由于某一时间段内网络中存在多个并行的传输,而这些传输的数据率是不同的,所以又可以根据数据率对所有的  $CT$  个比特进行分类求和,得到

$$\begin{aligned} CT\bar{D} &\leq \sum_{b=1}^{CT} d_b \\ &= \sum_{i \in T_L} [TW \log_2(1 + \beta_i) d_i] \\ &\leq TW \left[ \sum_{i \in T_L} \log_2^{\frac{\alpha}{\alpha-1}}(1 + \beta_i) \right]^{\frac{\alpha-1}{\alpha}} \left( \sum_{i \in T_L} d_i^{\alpha} \right)^{\frac{1}{\alpha}} \\ &\leq TW \left[ \log_2^{\frac{\alpha}{\alpha-1}}(1 + \beta_{\max}) \right]^{\frac{\alpha-1}{\alpha}} \left( D_{\max}^{\alpha} \frac{\Gamma_s + 1}{\Gamma_s} \right)^{\frac{1}{\alpha}} \\ &= TWD_{\max} \left( \frac{\Gamma_s + 1}{\Gamma_s} \right)^{\frac{1}{\alpha}} \log_2 \left( 1 + \frac{D_{\min}^{-\alpha} p_{\max}}{\eta W} \right). \end{aligned}$$

对上式化简可以得到网络容量的上界

$$C_{up} = W \frac{D_{\max}}{\bar{D}} \left( \frac{\Gamma_s + 1}{\Gamma_s} \right)^{\frac{1}{\alpha}} \log_2 \left( 1 + \frac{p_{\max}}{\eta W D_{\min}^{\alpha}} \right) \quad (8)$$

式(8)中干扰节点与接收节点间的距离采用  $D_{\max}$  来估计,收发节点对之间的距离采用  $D_{\min}$  来估计,这两个估计都会造成  $C_{up}$  大于网络容量,所以式(8)与网络容量之间会有一定的差距. 式(8)中虽然没有显式的表达出网络容量与节点个数的关系,但实际上节点个数  $N$  和有通信需求的节点个数  $L$  是隐含在式(8)中的. 不失一般性,假定网络中所有节点都有通信需求,即  $L = N/2$ , 则随着网络中节点个数的增加,  $\bar{D}$  和  $D_{\min}$  都是呈现减小趋势,平均来看  $\bar{D}$

$\propto 1/\sqrt{N}$ , 因此随着  $N$  的增大,  $C_{up} \propto \sqrt{N}$ , 这与文献[3]中的经典结论相一致.

### 3.3 GA-MT 算法

在 3.1 节中把最大化网络吞吐量转化成了如式(1)到式(6)表述的最优化问题,在 3.2 节推导出了这个优化问题的理论上界,但是可以发现该优化是一个混合整数非线性规划问题,通常情况下是一个 NP-Hard 问题<sup>[30]</sup>, 该问题中需要优化的变量包括  $x_{ij}$  和  $p_i$ . 根据文献[31]中关于节点连接度的概率分布结果,网络中绝大部分节点的邻居数量都不少于 2, 随着网络规模和有通信需求发送方数量的增加,  $x_{ij}$  的取值空间将不小于  $2^L$ , 当  $x_{ij}$  选定后,  $p_i$  的选择又是一个连续的非线性规划问题,具有很高的复杂度,因此通常的穷举搜索的办法是不可行的. 由于本文所涉及到的优化问题是一类 NP 完全问题,算法复杂度与优化效果之间始终是一对矛盾. 但是目前高速处理器的发展趋势能够在一定程度上缓解这一矛盾,所以本文采用现代启发式算法中比较成熟的遗传算法<sup>[32]</sup>来求解 3.1 节中的最优化问题,并提出了 GA-MT (Genetic Algorithm-based Maximum Throughput) 算法. 遗传算法是通过大量备选解的变换、迭代和变异,在解空间中并行动态地进行全局搜索的最优化方法. 由于遗传算法具有比较完备的数学模型和理论,在解决很多 NP-Hard 问题上具有良好的性能.

#### 3.3.1 编码方法

由于所考察问题是一个混合整数非线性规划问题,采用常用的二进制 0-1 编码会造成极大的搜索空间,所以定义决策向  $\mathbf{A} = [\mathbf{B}, \mathbf{P}]$ , 其中  $\mathbf{B}$  是邻居选择向量,  $\mathbf{P}$  是功率选择向量,

$\mathbf{B} = (b_1, b_2, \dots, b_L)$ , 其中  $b_i (i \in T_L)$  代表节点  $i$  所选择的邻居节点的编号,

$\mathbf{P} = (p_1, p_2, \dots, p_L)$ , 其中  $p_i (i \in T_L)$  代表节点  $i$  所选择的发射功率.

于是问题转化为对决策向量  $\mathbf{A}$  进行编码,对  $b_i$  的编码可以直接采用节点的编号,为了克服汉明悬崖和缩小搜索空间,对  $p_i$  的编码采用格雷码,将  $[0, p_{\max}]$  的可行功率集合均匀分成  $M$  级,这样  $p_i$  就用  $\log_2 M$  位的格雷码进行表示. 这样的编码方法使得  $\mathbf{B}$  的各分量相互独立,而  $\mathbf{P}$  的各分量全部满足最大功率约束,对决策向量采用两段式交叉和变异运算之后,所得到的仍然是满足物理意义的决策向量,同时又简化了变换之后的维护操作和缩小了搜索空间.

### 3.3.2 初始群体的选择

通过将向量  $\mathbf{B}$  的每一个分量在对应节点的邻居中进行随机均匀选择,将向量  $\mathbf{P}$  在 0-1 空间中进行随机均匀选择,可以产生一组在解空间中均匀随机分布的决策向量  $\mathbf{A}$ . 群体的规模决定了算法的收敛速度和复杂度. 太小的群体会导致算法搜索范围狭窄,容易陷入局部最优,降低算法性能;而太大群体的规模会导致算法收敛过慢. 仿真实验表明,当群体规模和节点数量  $N$  在一个数量级上时,算法性能较好,能够很快地逼近最优解.

### 3.3.3 适应度函数和选择方法

根据优化问题的目标函数,定义决策向量的适应度函数  $Fitness(\mathbf{A})$ ,表示为

$$Fitness(\mathbf{A}) = \frac{1}{W} \sum_{i \in T_L, j \in V_i \cup \bar{V}_i} \lambda_{ij} x_{ij},$$

其中  $x_{ij}$  为链路调度变量. 为了简化遗传算法的运算,在编码的时候采用的是长度为  $L$  邻居选择向量  $\mathbf{B}$ ,因此在计算适应度函数  $Fitness(\mathbf{A})$  时需要将  $\mathbf{B}$  变换成等效的,大小为  $N \times N$  的链路调度矩阵  $(x_{ij})$ ,例如节点  $r$  选择其邻居  $k$  为其转发数据,则  $x_{rk} = 1, x_{rj} = 0, j \in N, j \neq k$ .

在 GA-MT 算法中采用决策向量所对应的单位带宽的速率作为适应度,单位带宽的速率越大,相同通信带宽下的网络吞吐量就越大,对应的决策向量越适合于继续生存到下一代. 在遗传算法中,选择操作的主要目的是为了避免优良遗传信息的丢失,提高全局收敛性和算法效率. 因此 GA-MT 算法中采用轮盘赌选择,群体中每个个体进入下一代的概率就等于它的适应度值与整个种群的适应度之和的比例,适应度值越高,进入下一代个体的概率越高. 在选择过程中,为了更好地保证遗传算法的收敛性,采用了最优保存策略,即精英模型 (elitist model),找出上一代群体中适应度最高的个体,如果该个体适应度值大于新一代群体中的最高适应度,则用该个体替代新一代群体中适应度值最低的个体.

### 3.3.4 交叉操作

遗传算法中交叉操作是指对两个相互配对的染色体按照某种方式相互交叉部分基因,从而形成两个新的个体,该操作有利于增加新老两代个体之间的差异性以及同一代群体中个体之间的多样性. 由于决策向量  $\mathbf{A}$  可以分为两个不同的向量,所以算法中采用两段式交叉的方法对邻居选择向量  $\mathbf{B}$  和功率选择向量  $\mathbf{P}$  进行交叉,即分别在功率选择向量  $\mathbf{P}$

和邻居选择向量  $\mathbf{B}$  中随机选择一个交叉点,交换两个向量在交叉点前后的染色体. 例如,  $\mathbf{A}_1$  和  $\mathbf{A}_2$  代表两个即将配对的决策向量,其中选择向量  $\mathbf{B}$  采用节点编号直接编码,功率选择向量  $\mathbf{P}$  采用格雷码进行编码,设  $L=4$  和  $M=16$ ,则有

$$\mathbf{A}_1 = [b_1, b_2, |b_3, b_4, 0001, 11|10, 1010, 0011],$$

$$\mathbf{A}_2 = [b_1^*, b_2^*, |b_3^*, b_4^*, 0100, 01|00, 1101, 1011],$$

其中“|”代表所选定的两个随机交叉点,则配对交叉后新决策向量  $\mathbf{A}_1^*$  和  $\mathbf{A}_2^*$  分别为

$$\mathbf{A}_1^* = [b_1, b_2, |b_3^*, b_4^*, 0100, 01|10, 1010, 0011],$$

$$\mathbf{A}_2^* = [b_1^*, b_2^*, |b_3, b_4, 0001, 11|00, 1101, 1011].$$

交叉操作是在遗传算法性能中起主导地位的关键步骤,它决定了遗传算法的全局搜索能力. 为了避免算法收敛于局部最优解,并保持一个连续的解空间,以增大找到全局最优解的可能性增大,GA-MT 算法对交叉概率  $p_c$  采用随迭代次数增加而减少的方式,即随着迭代次数增加,  $p_c$  由 0.99 减小到 0.4.

### 3.3.5 变异操作

在遗传算法中,变异操作是指将个体染色体编码串中的某些基因座上的基因值用该基因座的其它等位基因来替换,从而形成一个新的个体. 变异运算是产生新个体的辅助方法,但它也是必不可少的一个步骤,因为它决定了遗传算法的局部搜索能力. 变异运算与决定全局搜索能力的交叉运算相互配合,共同完成对解空间的全局搜索和局部搜索. 算法中对邻居选择向量  $\mathbf{B}$  和功率选择向量  $\mathbf{P}$  分别变异,采用单点变异方式,  $\mathbf{B}$  中随机选择一个分量,按照变异概率  $p_m$  替换为可行解空间中另一个邻居的编号,  $\mathbf{P}$  中随机选择一个点按照变异概率  $p_m$  进行取反运算. 例如,  $\mathbf{A}_3$  代表即将变异的决策向量,设  $L=4$  和  $M=16$ ,则有

$$\mathbf{A}_3 = [b_1, b_2, b_3, b_4, 0001, 1110, 1010, 0011],$$

其中下划线“  ”代表所选定的两个随机变异点,变异概率  $p_m$  则控制本次变异操作是否进行,如果本次需要变异,则变异后的新决策向量  $\mathbf{A}_3^*$  为  $[b_1, \underline{b_2^*}, b_3, b_4, 0001, 1110, \underline{1110}, 0011]$ .

在求解过程中采用可变的  $p_m$ ,即算法早期  $p_m$  取值较大,扩大搜索空间;算法后期  $p_m$  取值较小,加快收敛速度. 即随着迭代次数增加,  $p_m$  由 0.3 减小到 0.03.

### 3.3.6 约束条件的处理

在遗传算法中必须对约束条件进行处理,但目前尚无处理各种约束条件的一般方法,为了提高遗

传算法的效率,本文采用搜索空间限定法来处理约束条件.搜索空间限定法的基本思想是对遗传算法的搜索空间的大小加以限制,使得搜索空间中表示一个个体的点与解空间中表示一个可行解的点有一一对应的关系.具体来讲就是在进行交叉、变异操作后对新个体的可行性进行判断,如果满足式(2)到式(5)的约束条件,则该新个体保留,如果不满足就需要重新进行交叉或者变异操作,如果在多次操作后均不能生成满足约束条件的个体,则放弃该次操作.

### 3.3.7 算法收敛性

在文献[33]中使用马尔可夫链式模型对采用精英模型的遗传算法的收敛性进行了研究,证明了在精英模型下遗传算法能够收敛到全局最优解.于是有如下定理.

**定理 1.** GA-MT 采用的遗传算法能够收敛到全局最优解.

从仿真实验中可以发现,算法在所选择参数下能够在不多于网络规模  $N$  两倍的迭代次数内收敛,并由此可以获得所用遗传算法的时间复杂度.

### 3.3.8 算法时间复杂度分析

**定理 2.** GA-MT 采用的遗传算法的时间复杂度为  $O(N^2)$ .

证明. GA-MT 算法中的种群数量为  $O(N)$ ,交叉概率为  $p_c$ ,变异概率为  $p_m$ ,因此算法每次迭代需要  $O(p_c N)$  次交叉操作,  $O(p_m N)$  次变异操作以及  $O(N)$  次选择操作,且  $p_c < 1$ ,  $p_m < 1$ ,所以算法每次迭代需要  $O(N)$  次操作.又注意到算法的迭代次数为  $2N$ ,因而 GA-MT 算法总的时间复杂度为  $O(N^2)$ . 证毕.

## 4 仿真验证

文献[27-28]与本文虽然都采用了 SINR 干扰模型,都综合考虑了路由选择和功率分配,然而文献[27-28]采用覆盖模式实现频谱共享,而本文采用了混叠模式,因此本文更侧重同频信道上不同节点的功率分配.而文献[27-28]侧重不同节点上的信道分配,这与本文的网络场景不尽相同.目前考虑混叠模式的且与本文网络场景比较接近的是文献[26],该文献提出一种 ACUCHA (Adaptive Cognitive Underlay Channel Assignment) 算法,能够控制接入主用户同频信道的认知用户数量,但是该文只考虑了存在一个主用户的情况,且认知用户采用恒定功率传输数据.目前认知网络中综合考虑混叠模式、

节点功率控制和路由选择的跨层算法还不多见,而传统的路由算法又没有考虑对主用户的干扰.所以在仿真中主要将 GA-MT 算法性能与网络容量上界进行比较,同时与存在主用户干扰限制时的 ACUCHA 算法进行了对比,同时也与传统的 GPSR,最短路径 Dijkstra 算法进行参考对比.

### 4.1 场景设置

本文中仿真实验采用 PC 机,软硬件环境为 Intel Core 2 Duo E6400 2.0 GHz、2 GB 内存、Windows XP Sp3 操作系统、Matlab R2008a 仿真工具.所使用的仿真方案如图 4 所示:包括场景参数模块、随机网络生成器模块、算法实现模块以及结果统计与分析模块.网络场景参数模块提供仿真所需要的配置参数,如网络规模和分布特性、路径衰减和各种门限等.随机网络生成器模块主要负责根据指定的网络范围以及节点数量等参数生成随机网络拓扑.算法实现模块对本文中所提的理论界、遗传算法及比对算法进行实现,并根据网络参数与拓扑的输入获得算法的性能.结果统计与分析模块收集所获得的算法性能,并对结果进行统计平均等操作,并以曲线形式呈现.




图 4 仿真方法示意图

仿真着重分析了本文所推导的网络容量的理论上界与吞吐量的关系,同时考察了不同参数下 GA-MT 算法的性能,指出本文所推导的网络容量理论上界与算法所能实现的网络吞吐量非常接近,说明了 GA-MT 算法具有良好的性能.

文献[26]的 ACHCUA 算法的核心思想是对主用户的接收机附近的干扰温度 (interference temperature<sup>[34]</sup>) 进行控制,使其不超过主用户要求的门限.把有通信需求的认知用户产生的干扰温度从小到大进行排序,依次加入待发的用户队列,使累计的干扰温度达到主用户接收机的门限值时,算法停止,然后待发用户开始传输数据.为了与 ACHCUA 算法作对比,仿真时本文考虑将式(2)等效为干扰温度,将主用户  $k$  处的干扰功率  $p_i d_{ik}^{-\alpha}$  从小到大进行排序,然后依次利用式(2)进行累加,直到累加后的



主用户 SNR 达到门限值,被成功累加的这些认知用户将被选定为待发用户。

本文采用如下的场景参数:在  $1000\text{ m} \times 1000\text{ m}$  的矩形区域内随机均匀放置  $40 \sim 90$  个认知用户,其中随机选择  $5 \sim 20$  用户作为有通信需求的节点,所有认知用户的最大通信功率为  $64\text{ mW}$ ,路径传播衰减因子  $\alpha=4$ 。同时随机均匀放置  $1 \sim 12$  个主用户接收机在相同的区域内,其中主用户接收机的 SNR 值设为  $20\text{ dB}$ ,主用户最低接收 SINR 门限  $\Gamma_p$  设为  $12\text{ dB}$ ,认知用户最低接收 SINR 门限  $\Gamma_s$  设为  $-5\text{ dB}$ 。认知用户和主用户共享的系统通信频段的带宽  $W$  是  $8\text{ MHz}$ ,加性高斯白噪声功率谱密度  $\eta$  为  $10^{-18}\text{ W/Hz}$ 。所绘曲线均为  $20$  个随机场景下仿真结果的平均值,同时满足引理 2 中的条件,而且所有场景都不出现孤立节点,以保证 GA-MT 算法能够正确运行。

#### 4.2 仿真结果

图 5 显示了一个随机网络场景中 GA-MT 算法的结果。其中,实线代表 GA-MT 算法所选择的链路,而带空心箭头的长虚线代表 GPSR 算法所选择的链路,带箭头的短虚线代表最短路径 Dijkstra 算法所选择的链路,而带菱形箭头的点划线代表 ACUCHA 算法选择的链路。从图中可以看出,本文所提出的算法性能不仅优于传统的 GPSR 算法和最短路径 Dijkstra 算法,也优于 ACUCHA 算法。其中,GA-MT 算法所选择的并行传输节点对数量为  $9$  对;ACUCHA 选择的并行传输节点是  $4$  对;GPSR 算法和最短路径 Dijkstra 算法所选择的节点对数量都只有  $3$  对。GA-MT 算法性能大致是 ACUCHA 算法的两倍,是另外两种算法的三倍左右,并且在空间分布上更加的均匀化。这说明算法能够利用不同

收发节点对在空间分布上的差异,提高网络并行复用传输能力。而传统算法,例如最短路径 Dijkstra 算法,以跳数最短为路径选择准则,没有考虑空间复用;GPSR 算法以最靠近目的地为目标选择下一跳,没有考虑对相邻节点的干扰;而 ACUCHA 算法都集中在图中的右下角,说明只有远离主用户的那些节点才可能得到传输机会,由于缺少功率控制机制,靠近主用户的节点几乎不会得到传输机会;而 GA-MT 则是依次考察多个下一跳节点,选择其中能够实现最大吞吐率的链路,这就使得该算法能够较好地网络吞吐量性能进行优化。

图 6 和图 7 对比了几种算法在不同认知用户节点数量下的单位带宽速率与容量上界。其中横坐标是认知用户的个数  $40 \sim 90$ ,纵坐标是单位带宽速率,单位是  $\text{bps/Hz}$ 。有通信需求认知用户个数  $L$  的取值分别为  $10$  和  $20$ ,以显示不同网络通信负载对算法的影响,另一方面由于传统算法没有考虑对主用户的干扰约束,因此针对两个传统算法的仿真设置中主用户接收机的数量  $Q$  取  $0$ ,而 ACUCHA 算法和 GA-MT 算法的主用户设置为  $1$ 。从图中可以看出,随着认知用户个数  $N$  的增大,GA-MT 算法实现的单位带宽速率呈现逐渐上升的趋势,这是因为当有通信需求的认知用户个数一定时,网络中可供选择的链路和认知用户数量成正比,认知用户数量越多,空间复用率越高,单位带宽速率上升。而当有通信需求认知用户个数增加时,网络的通信负载增加,需要选择的链路更多,单位带宽速率上升明显,同时式(8)计算出的理论上界与 GA-MT 算法性能比较接近。通过上一节对式(8)讨论可知,式(8)是对网络容量上界的一个估计值,和网络容量之间还有一定的距离,GA-MT 算法与  $C_{up}$  只有  $6\% \sim 10\%$  的差距,因此 GA-MT 算法实际上为我们指出式(8)所获得的理论上界  $C_{up}$  与网络容量是非常接近的,同时又可以认为 GA-MT 算法性能逼近了当前网络场景下的网络容量。而对于 GPSR 算法和最短路径 Dijkstra 算法来讲,无论是认知用户个数  $N$  的增大还是网络通信负载增大,单位带宽速率基本稳定在同一数值附近,这是因为这两个算法是传统无功率控制的算法,在同一个冲突域范围内,最多只能容纳一对成功的收发节点进行通信,在面积和冲突域半径都确定的网络环境下,空间上能够容纳的成功通信对也基本确定,所以与网络用户个数和网络通信负载基本无关。而 ACUCHA 算法能够把那些远离




图 5 典型网络中 GA-MT 算法示意图

主用户的认知用户都调度起来传输数据,只需要保证干扰不超过门限值即可,因此 ACUCHA 能够获得远高于传统算法的性能.而 GPSR 的下一跳选择与节点的地理位置相关,在某些场合下容易形成网络中的瓶颈节点,同时 Dijkstra 算法仅以路径长度为标准,当通信负载过大时,依然有可能在部分节点上形成瓶颈,这两种算法在下一跳选择时都有局限,同样的对于 ACUCHA 算法,由于缺少功率控制算法,靠近主用户的认知用户无法获得接入频谱的机会,这 3 个算法都不能充分考虑节点间的空分优势.由于 GA-MT 算法同时考虑了功率控制和下一跳节点的选择,对单位带宽速率具有很大的提升,明显优于其它 3 种算法. GA-MT 算法中的单位带宽速率,在  $L=10$  时,相对于 GPSR 和最短路径 Dijkstra 算法具有 300%~550% 的性能提升,相对于 ACUCHA 具有 200% 左右性能提升;在  $L=20$  时,相对于 GPSR 和最短路径 Dijkstra 算法具有 400%~750% 的性能提升,相对于 ACUCHA 具有 200%~300% 性能提升.

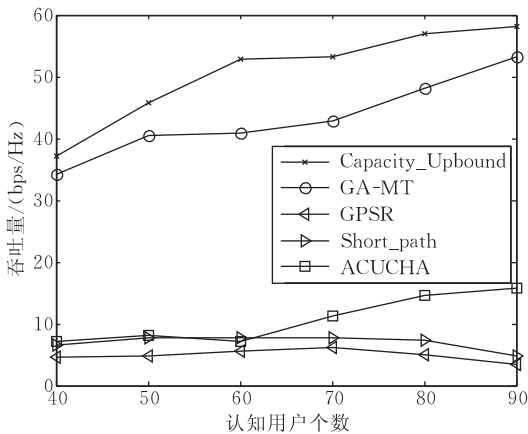


图 6 3 种算法下的单位带宽速率图示(10 个通信节点)

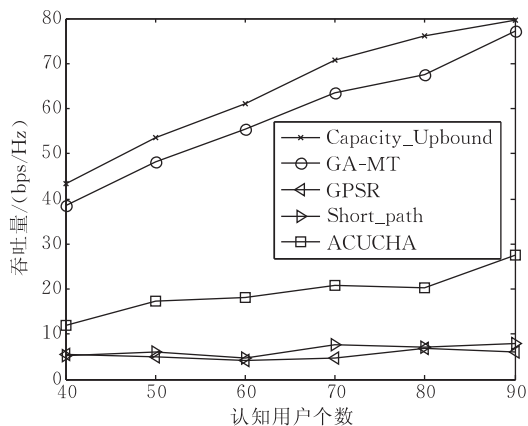


图 7 3 种算法下的单位带宽速率图示(20 个通信节点)

图 8 显示了在满通信负载下 GA-MT 算法和 ACUCHA 算法的单位带宽速率与网络容量上界的对比,其中横坐标是认知用户的个数 40~90,有通信需求认知用户个数  $L$  的取值分别为认知用户的个数的一半.由于 ACUCHA 算法只能工作在一个主用户下,图 8 的仿真设置时主用户接收机的数量  $Q$  取 1.从图中可以看出,随着认知用户个数  $N$  的增大,GA-MT 算法和 ACUCHA 算法的单位带宽速率和式(8)计算出的网络容量上界都呈现逐渐上升的趋势.图 8 的仿真结果充分说明了两点:(1)虽然  $D_{\max}$  和  $D_{\min}$  参量的引入导致式(8)的  $C_{up}$  大于网络容量,但是仿真结果中 GA-MT 算法和  $C_{up}$  差距很小,只有 5%~12% 的差距,说明网络容量的曲线就位于这两根曲线之间,即 GA-MT 算法能从下往上逼近网络容量,因此可以把 GA-MT 算法的结果作为当前网络场景下网络容量的下界;(2) ACUCHA 算法距离理论容量还有很大的差距,基本上只有理论上界的 30% 左右,因此算法还有继续提高的空间.

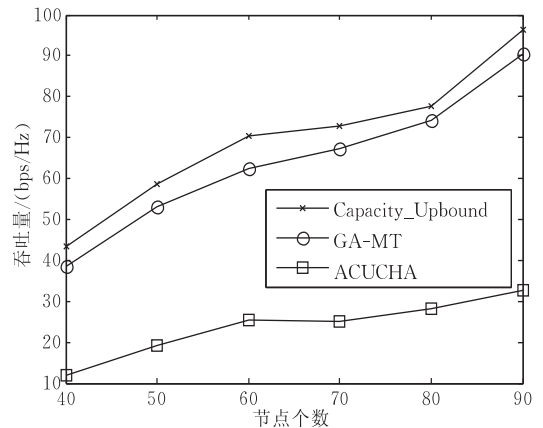


图 8 满负载下的 GA-MT 算法单位带宽速率

图 9 是在不同通信负载下单位带宽速率的仿真结果对比图,有通信需求认知用户个数  $L$  的取值为 5~20,以显示不同网络通信负载对算法的影响,主用户接收机的数量  $Q$  取为 1,即只有一个随机分布的主用户.从图中可以看出,随着认知用户个数  $N$  的增大,GA-MT 算法实现的单位带宽速率呈现逐渐上升的趋势,同时当有通信需求认知用户个数  $L$  增加时,单位带宽速率呈现出快速上升的趋势,这是因为随着通信负载的增加,通过控制功率和选择下一跳节点,GA-MT 算法能找到更多的并行通信对,在认知用户个数  $N$  达到最大值 90 时,每个节点可选择的下一跳节点也达到最大,所以此时单位带宽速率随  $L$  的增加最为显著,基本上每当  $L$  增加 5 个节点时,单位带宽速率就有 20%~30% 的提升.




图9 不同通信负载下的单位带宽速率

图 10 显示了在不同主用户接收机数量下单位带宽速率的对比结果. 主用户接收机数量  $Q$  的取值为 2~12, 以显示不同干扰限制水平对算法的影响, 而有通信需求认知的用户个数  $L$  的取值为 10. 由于式(8)在推导过程中并没有考虑主用户对认知用户的干扰限制门限, 相当于  $Q=0$  的情况, 所以在图 10 中系统能提供的吞吐量远低于理论上界, 并且随着主用户个数的增加, 这种吞吐量的减少也是非常明显的, 最大可达到 15%~50%. 由此可以预见, 随着主用户个数的急剧增加, 无论认知用户等用何种功率进行通信都会对主用户产生不可忍受的干扰, 此时认知用户在混叠模式下的通信容量将迅速下降.




图10 不同主用户接收机数量下的单位带宽速率

为了研究 GA-MT 算法的收敛性质, 本文定义了算法的归一化适应度, 即每一代中个体的最优适应度同算法收敛时最优解的适应度的比值, 这个比值随着算法迭代次数的增加而逐渐增加, 并在算法收敛时变为 1. 图 11 和图 12 显示了 GA-MT 算法的迭代次数与算法归一化适应度之间的关系. 图 11 中认知用户的个数是 40~90, 有通信需求认知用户个数  $L$  的取值为 10. 图 12 中认知用户的个数是 90, 有通信需求认知用户个数  $L$  的取值为 10~40, 两个

图中主用户接收机的数量  $Q$  都取 2. 从图中可以看出, 随着认知用户个数的增加或者随着有通信需求认知用户个数的增加, 算法收敛所需要的迭代次数也逐渐增加. 这是因为随着网络规模的增加, 搜索空间不断增长, 算法往往需要经过更多的迭代次数才能达到收敛. 总的来说, 算法在所考虑的场景和参数下, 都能够在不多于 2 倍网络规模的迭代次数内收敛.




图11 不同通信节点下 GA-MT 算法的收敛特性




图12 不同通信负载下 GA-MT 算法的收敛特性

## 5 总结


本文提出了一种逼近网络容量的认知无线 Ad hoc 网络跨层优化算法 GA-MT. 该算法综合考虑了节点功率控制、邻居节点选择和干扰约束限制条件, 通过一个决策用户收集当前认知用户的通信需求, 然后由决策用户发起跨层优化算法, 为认知用户选择下一跳节点和分配合理的发射功率, 认知用户再通过最优传输分配方案的路径和功率传输数据报文, 该算法可以应用在物联网的无线接入上, 为用户的接入提供理论指导. 同时, 本文针对具体的网络场

景,获得了只与认知用户分布特性相关的网络容量上界的闭合表达式,该上界能比较准确地估计出当前网络的容量,因而可以指导物联网相关通信协议的设计。由于网络最大吞吐量的求解是一个混合整数非线性规划问题,本文采用了遗传算法在搜索空间对决策向量进行全局搜索,算法的时间复杂度为 $O(N^2)$ 。仿真结果表明该算法比现有算法显著地提高了网络吞吐量并且与理论上界只有 10%左右的差距,很好地逼近了目标网络的网络容量。

### 参 考 文 献

- [1] Thomas R W, DaSilva L A, MacKenzie A B. Cognitive networks//Proceedings of the 1st IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks. Baltimore, USA, 2005: 352-360
- [2] Akyildiz I F, Lee W-Y, Chowdhury K R. CRAHNS: Cognitive radio ad hoc networks. *Ad hoc Networks*, 2009, 7(5): 810-836
- [3] Gupta P, Kumar P R. The capacity of wireless networks. *IEEE Transactions on Information Theory*, 2000, 46(2): 388-404
- [4] Grossglauser M, Tse D N C. Mobility increases the capacity of ad-hoc wireless networks. *IEEE/ACM Transactions on Networking*, 2002, 10(4): 477-486
- [5] Aurelie C L, Sanjeev R K, Pramod V. Throughput scaling in wireless networks with restricted mobility. *IEEE Transactions on Wireless Communications*, 2007, 6(2): 670-679
- [6] Gupta P, Kumar P R. Towards an information theory of large networks: An achievable rate region. *IEEE Transactions on Information Theory*, 2003, 49(8): 1877-1894
- [7] Bansal N, Liu Z. Capacity, delay and mobility in wireless ad-hoc networks//Proceedings of the 22nd Annual Joint Conference of the IEEE Computer and Communications. San Francisco, USA, 2003: 1553-1563
- [8] Ganti R K, Andrews J G, Haenggi M. High-SIR transmission capacity of wireless networks with general fading and node distribution. *IEEE Transactions on Information Theory*, 2011, 57(5): 3100-3116
- [9] Ebrahimrezagah R, Mohammadi A. The capacity of wireless ad hoc networks using statistical techniques//Proceedings of the IEEE International Conference on Communications. Istanbul, Turkey, 2006: 337-342
- [10] Rezagah R E, Mohammadi A. Characterization of the scalability of wireless ad hoc networks under channel limitations//Proceedings of the Innovations in Information Technology. Dubai, United Arab Emirates, 2006: 1-5
- [11] Rezagah R E, Mohammadi A. Analyzing the capacity of wireless ad hoc networks//Proceedings of the 17th International Conference on Software, Telecommunications and Computer Networks. Hvar, Korea, 2009: 206-210
- [12] Devroye N, Mitran P, Tarokh V. Achievable rates in cognitive radio channels. *IEEE Transactions on Information Theory*, 2006, 52(5): 1813-1827
- [13] Kang Xin, Liang Ying-Chang, Nallanathan A et al. Optimal power allocation for fading channels in cognitive radio networks: Ergodic capacity and outage capacity. *IEEE Transactions on Wireless Communications*, 2009, 8(2): 940-950
- [14] Akin S, Gursoy M C. Effective capacity analysis of cognitive radio channels for quality of service provisioning. *IEEE Transactions on Wireless Communications*, 2010, 9(11): 3354-3364
- [15] Rini S, Tuninetti D, Devroye N. The capacity region of the gaussian cognitive radio channels at high snr//Proceedings of the IEEE Information Theory Workshop. Sicily, Italy, 2009: 505-509
- [16] Maric I, Goldsmith A, Kramer G, Shamai S. On the capacity of interference channels with a cognitive transmitter//Proceedings of the Information Theory and Applications Workshop. La Jolla, USA, 2007: 268-273
- [17] Giorgetti A, Varrella M, Chiani M. Analysis and performance comparison of different cognitive radio algorithms//Proceedings of the 2nd International Workshop on Cognitive Radio and Advanced Spectrum Management. Aalborg, Denmark, 2009: 127-131
- [18] Li Liang, Pesavento M, Gershman A B. On ergodic sum capacity of underlay cognitive broadcast channels//Proceedings of the IEEE 21st International Symposium on Personal Indoor and Mobile Radio Communications. Istanbul, Turkey, 2010: 2710-2714
- [19] Li Liang, Pesavento M. The sum capacity of underlay cognitive broadcast channel//Proceedings of the 6th International ICST Conference on Cognitive Radio Oriented Wireless Networks and Communications. Osaka, Japan, 2011: 390-394
- [20] Bansal G, Duval O, Gagnon F. Joint overlay and underlay power allocation scheme for OFDM-based cognitive radio systems//Proceedings of the IEEE 71st Vehicular Technology Conference. Taipei, China, 2010: 1-5
- [21] Huang Chu-Hsiang, Lai Yen-Chieh, Chen Kwang-Cheng. Network capacity of cognitive radio relay network. *Physical Communication*, 2008, 1(2): 112-120
- [22] Luo Changqing, Yu F R, Ji Hong. Optimal capacity in underlay paradigm based cognitive radio network with cooperative transmission//Proceedings of the IEEE 72nd Vehicular Technology Conference Fall. Ottawa, Canada, 2010: 1-5
- [23] Manosha K B S, Rajatheva N, Latva-aho M. Overlay/Underlay spectrum sharing for multi-operator environment in cognitive radio networks//Proceedings of the IEEE 73rd Vehicular Technology Conference. Yokohama, Japan, 2011: 1-5
- [24] Santivanez Cesar. Transport capacity of opportunistic spectrum access (OSA) MANETs//Proceedings of the 2nd International Conference on Cognitive Radio Oriented Wireless Networks and Communications. Orlando, USA, 2007: 9-18

- [25] Xie Renchao, Ji Hong, Si Pengbo et al. Optimal joint power and transmission time allocation in cognitive radio networks//Proceedings of the IEEE Wireless Communications and Networking Conference. Sydney, Australia, 2010: 1-5
- [26] Shadi E A, Bahman A. Achieving secondary capacity under interference from a primary base station//Proceedings of the 9th International Conference on Next Generation Wired/Wireless Networking. St. Petersburg, Russia, 2009: 365-376
- [27] Ma Miao, Tsang D H K. Joint spectrum sharing and fair routing in cognitive radio networks//Proceedings of the 5th IEEE Consumer Communications and Networking Conference. Las Vegas, USA, 2008: 978-982
- [28] Shi Y, Hou Y T, Kompella S, Sherali H D. Maximizing capacity in multi-hop cognitive radio networks under the SINR model. IEEE Transactions on Mobile Computing, 2011, 10 (7): 954-967
- [29] Karp B, Kung H T. GPSR: Greedy perimeter stateless routing for wireless networks//Proceedings of the Annual International Conference on Mobile Computing and Networking. Boston, USA, 2000: 243-254
- [30] Garey M R, Johnson D S. Computers and Intractability: A Guide to the Theory of NP-Completeness. New York: W. H. Freeman and Company, 1979
- [31] Onat F A, Stojmenovic I, Yanikomeroglu H. Generating random graphs for the simulation of wireless ad hoc, actuator, sensor, and internet networks. Pervasive and Mobile Computing, 2008, 4(5): 597-615
- [32] Lee K Y, El-Sharkawi M A. Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems. Hoboken: Wiley-IEEE Press, 2008
- [33] Suzuki J. A Markov chain analysis on simple genetic algorithms. IEEE Transactions on Systems, Man, and Cybernetics, 1995, 25(4): 655-650
- [34] Federal Communications Commission. Spectrum policy task force report. Washington, DC: Federal Communications Commission, ET Docket No. 02-135, 2002



**YANG Shuang-Mao**, born in 1981, Ph. D. candidate. His research interests include MAC and routing protocol in cognitive wireless networks.

**GUO Wei**, born in 1964, professor, Ph. D. supervisor. His research interests include mobile networks, signal and information processing techniques.

**TANG Wei**, born in 1980, Ph. D., lecturer. His research interest is routing algorithm over cognitive wireless.

## Background

Ubiquity and intelligence are the key characteristics of Internet of things (IoT). As an important component of IoT, cognitive wireless networks (CWNs) provide a solution for the conflict between static networking models and dynamic requirements. By introducing the new “cognitive plane” that is separated from the traditional user and control planes, CWNs can coordinate various intra- and inter-network cognitive actions, such as learning, orienting, planning, integration, and decision, realize the reasonable separation and close cooperation between cognitive, control and traffic flows, and hence give wireless networks more degrees of freedom. This unified network architecture fully demonstrates the adaptability of CWN, which is very important for the evolution of the present wireless networks and the design of the next generation wireless networks. The latest research outcomes have obtained the upper/lower bounds and the asymptotic same-order expression of cognitive network capacity, but the accu-

rate network capacity of a specific network scenario still remains unknown. Supported by the National Science and Technology Major Project of the Ministry of Science and Technology of China (Grant No. 2010ZX03005-002) and the National Basic Research Program of China (973 Program) of China (No. 2009CB320405), the present project is devoted to designing various methods for approximating the capacity bounds of CWNs, investigating the self-adaptive theories and methods of cognitive wireless transmission to dynamic environment and resources, achieving the full utilization of network resources, and hence improving the end-to-end utility of CWNs. The present paper focuses upon the design of transmission approaches of CWNs for approaching the accurate theoretic network capacity bounds and, meanwhile, provides the basic theories and algorithms to support the significant performance improvement of IoT wireless access platform.