

超密集蜂窝网络 智能干扰协调算法

Intelligent Interference Coordination Algorithm in Ultra Dense Cellular Networks

秦爽/QIN Shuang¹, 董星辰/DONG Xingchen², 冯钢/FENG Gang¹

(1. 电子科技大学,中国 成都 611731; 2. 南京船舶雷达研究所,中国 南京 211153) (1. University of Electronic Science and Technology of China, Chengdu 611731, China; 2. Nanjing Marine Radar Institute, Nanjing 211153, China)

摘要:提出了一种面向超密集蜂窝网智能干扰协调的动态功率控制算法。从网络动态决策的 角度出发,在动态干扰环境下,将超密集蜂窝网络中的小基站发送功率的动态调整问题建模为 一个马尔科夫决策过程。在此基础上,设计了一种基于Actor-Critic(AC)方法的小基站功率 智能控制算法,并通过仿真实验验证了所提算法的性能。仿真结果显示,与传统的干扰协调算 法相比,所提出的智能功率控制算法能有效降低网络中基站间的干扰,提升网络传输性能。

关键词:超密集蜂窝网络;干扰协调;功率控制;强化学习;AC算法

Abstract: An intelligent power control algorithm for interference coordination in ultra dense cellular networks (UDN) is proposed. By considering the impact of dynamical interference between different base stations, the problem of dynamical power control for small base stations in UDN is modeled as a Markov decision process (MDP). Then, an intelligent power control algorithm based on Actor-Critic (AC) method is designed, and the performance of the proposed algorithm by using simulation experiments is validated. The numerical results show that, comparing with the traditional interference coordination algorithms, the proposed intelligent power control algorithm can reduce the inter-cell interference and improve transmission performance in UDN.

Keywords: UDN; interference coordination; power control; reinforcement learning; AC algorithm

近年来,随着智能移动终端的快速发展和普及,移动通信业务呈现出了爆炸式增长。有研究发现¹¹,在移动通信网中,存在大量的业务热点区域,特别是以住宅、商场、办公楼等为代表的室内热点区域,集中了超过70%的数据业务和50%的语音业务。因此,为了提升热点区域的网络覆盖并增加网络容量,研究者提出了在已有宏基站(MBS)的覆盖范围内,通过部署大量低功耗、低成本的小基站(SBS),形成重叠异构覆盖

的超密集蜂窝网络(UDN),来解决移动网络中热点区域弱覆盖的相关问题^[2]。

在 UDN 中, SBS 部署密集,站点 之间距离很近,一个小基站会同时受 到来自 MBS 和周围其他 SBS 的干扰。 网络中干扰问题十分严重,且干扰环 境也很复杂,严重影响了网络用户获 得的传输服务质量。因此,如何通过 有效的干扰协调,降低网络中不同接 入站点之间的干扰,提升网络传输性 能是 UDN 网络需要解决的一个重要 问题[3]。

近年来,集中化无线接入网(C-RAN)技术作为一种移动接入网的新型组网和部署方式,引起了研究者的 广泛关注^[4]。在C-RAN网络架构下, 移动接入网络由1个中心控制的基带 处理单元(BBU)与多个分布式的射 频单元(RRH)组成,每个RRH相当 于1个SBS。利用C-RAN技术可以方 便部署即插即用的SBS,构建UDN, 实现对热点区域的密集覆盖^[5]。因 此,如何在基于C-RAN网络架构的

DOI:10.12142/ZTETJ.202005009

网络出版日期:2020-09-24

收稿日期:2020-08-14

网络出版地址:https://kns.cnki.net/kcms/detail/ 34.1228.TN.20200923.1758.004.html UDN中进行高效的干扰协调,是一个 值得深入研究的问题。

干扰协调一直是移动通信网络 领域的热点研究问题,而功率控制是 实现干扰协调的有效手段。已有很 多研究[6-7]关注了如何在UDN中,通 过优化的功率控制,来实现网络中高 效的干扰协调。但在移动网络场景 下,用户移动会使网络中的干扰情况 不断变化。在以室内热点覆盖为典 型应用场景的UDN中,复杂的室内 结构和密集部署的SBS也使得网络 中的干扰环境十分复杂。传统的静 态优化算法和博弈论等启发式算法 难以适应 UDN 中复杂多变的干扰情 况,因此,在动态网络环境下,基站需 要根据网络状态和干扰环境的变化, 动态调整自己的发送功率,从而降低 网络中的干扰,提升传输性能。近 来,基于机器学习,特别是强化学习 的人工智能算法在移动通信网络中 的应用引起了研究者的广泛关注[8-9]。 在基于强化学习的智能算法中,网络 中的智能决策者可以通过对网络环 境的观察和交互,不断改进和优化自 身的策略。这为在UDN中,通过动 态的功率控制策略实现优化的干扰 协调和管理,提供了一种有效的解决 手段。

本文主要研究在超密集覆盖蜂 窝网中,通过智能高效的动态功率控 制,实现优化的网络干扰协调。首 先,从网络动态决策的角度出发,将 UDN 网络中的动态干扰环境下,基站 发送功率的动态控制决策问题建模 为一个马尔科夫决策过程(MDP)^[89]。 进一步地,基于强化学习的思想,采 用 Actor-Critic (AC)算法^[8]对 MDP 模 型进行求解,并在此基础上,设计了 基于 AC 方法的智能功率控制算法。 最后,通过仿真实验验证了提出算法 的性能。数值结果显示:与传统的干 扰协调算法相比,本文提出的智能功 率控制算法能有效降低UDN网络中 基站间的干扰,提升网络传输性能。

1系统模型

1.1 网络模型

本研究考虑的是如图 1 所示的C-RAN 架构下的超密集蜂窝网络。如 图 1 所示,网络由 1 个宏基站(MBS)和 *M*个小站(SBS)组成,网络中有 *N*个 SBS 用户。在室内覆盖等典型的超密 集蜂窝网应用场景下,可以方便地采 用 C-RAN 架构来实现 *M* 个 SBS 的部 署,网络由 1 个中心控制的基带处理 单元(BBU)与*M*个射频单元(RRH)组 成。网络中的用户接入到 RRH,实现 无线射频信号的接入,每个 RRH可以 看作一个接入小站。BBU 为与其相 连的 RRH提供基带处理资源,实现中 心控制的基带信号处理与无线网络 资源的分配与优化。为了提高频谱 效率,考虑所有的接入站点采用同频 部署,每个基站的可用下行传输带宽 为B,划分为K条相同带宽的正交子 信道,那么每条子信道的带宽可以表 示为b = B/K。同一时刻,任一子信道 只能分配给一个用户。

为了便于分析,考虑用户在某一时刻只能通过一个接入站点的一条 子信道接入网络,设用户n通过基站 m的子信道 k 接入网络,则在 t 时刻用 户获得的服务速率为:

$$v_{n,m}^{k}(t) = b \log_2(1 + SINR_{n,m}^{k}(t)), \quad (1)$$

其中,*SINR^k_{n,m}(t*)为用户n在基站m子 信道k上的信干噪比,可以表示为:

$$SINR_{n,m}^{k}(t) =$$

$$\frac{p_m^{\kappa}(t)g_{n,m}^{\kappa}(t)}{\sum_{j=1,j\neq m}^{M}I_j^{k}(t)+I_{MBS}^{k}(t)+N_0b},$$
 (2)

其中, $I_{j}^{k}(t) = p_{j}^{k}(t)g_{n,j}^{k}(t)$ 和 $I_{MBS}^{k}(t) = p_{MBS}^{k}(t)g_{n,MBS}^{k}(t)分别为当前时刻其他$ SBS和MBS在子信道 k上对用户 n产



▲图1基于集中化无线接入网架构的超密集蜂窝网络

专题

生的干扰。 $g_{n,i}^{k}(t)$ 为用户 n 在基站 i 的 子信道 k 上的信道增益, 而 $p_{i}^{k}(t)$ 为基 站 i 在子信道 k 上的发送功率, 其中 $i \in \{1, 2, ..., M\} \cup MBS$ 。 N_{0} 表示噪声 功率谱密度。

1.2 理论模型

从式(2)可以看出,在密集覆盖 的蜂窝网中,用户获得的下行传输速 率受其接入站点的发送功率、信道增 益,以及其他站点产生的干扰的影 响;而其他站点对用户的干扰,又由 站点的发送功率和用户到该站点的 信道增益决定。在动态场景下,用户 移动带来信道增益的变化。因此,为 了满足用户服务需求,在本研究中, 考虑通过动态地调整基站的发送功 率,来降低网络中的干扰,提升网络 的整体传输性能。

在传统网络中,常常以最大化系 统吞吐量作为网络的优化设计目标。 但在本文考虑的UDN场景下,不同站 点间干扰情况复杂。如果单纯地以 最大化系统吞吐量为优化设计目标, 可能由于小区边缘用户的信道衰落 大,且距离干扰源更近,造成网络为 了提升系统整体吞吐量,牺牲边缘用 户的传输性能,从而为边缘用户分配 较少的发送功率,使得网络中资源分 配不公平。在本研究中,我们希望在 提升系统整体吞吐量的同时能够兼 顾网络的公平性。因此,考虑采用与 文献[9]类似的方法,以α公平作为公 平性度量,设计一个兼顾网络性能和 公平性的效用函数:

$$U(v_{t}) = \frac{1}{1 - \alpha} \sum_{n=1}^{N} (v_{n,m_{n}}^{k_{n}}(t))^{1 - \alpha}, \quad (3)$$

其中, $v_t = (v_{1,m_1}^{k_1}(t), v_{2,m_2}^{k_2}(t), ..., v_{N,m_N}^{k_N}(t))$ 为当前时刻t、网络中n个用户获得的 服务速率所组成的向量,并且有: $k_n \in \{1, 2, ..., N\}$ 和 $m_n \in (1, 2, ..., M)$ 。 $v_{nm}^{k_n}(t)$ 表示用户 n 接入基站 m_n 的子 信道k,获得的传输速率,可以由式 (1)计算得到。α为公平性参数,反应 了系统中资源分配的公平性。α取值 越大,公平性越高,反之亦然。如果 $\alpha = 0$, 对应的系统公平性最低, 从式 (3)可以看出,此时最大化效用函数 等效于最大化系统吞吐量。而当α= ∞,对应的系统公平性最高,网络中将 通过功率分配使得所有用户获得尽 可能相同的服务速率。因此,在实际 系统中,可以通过调节α的取值来进 行传输性能和公平性地优化和折中。 在本文中,为了便于分析,考虑设定 α=1来兼顾系统的传输性能和公平 性。由于 $\lim_{\alpha \to 1} x^{1-\alpha}/(1-\alpha) = \ln(x), 则$ 式(3)可以写为:

$$U(v_{t}) = \sum_{n=1}^{N} \ln \left(v_{n,m_{n}}^{k_{n}}(t) \right)_{0}$$
(4)

在动态网络场景下,需要通过不断地调整基站发送功率来降低网络中的干扰,提升网络传输性能。因此,不能简单地以某个时刻系统的最大化效用函数来优化设计网络中的功率分配,而应该以最大化系统的长期效用为目标,设计网络中的功率动态优化控制策略。由此,根据式(4)可以将一段较长时间T内,网络中的功率优化分配问题建模为:

$$\max\sum_{t \in T} U(v_t), \tag{5}$$

s.t.
$$\frac{\sum_{k=1}^{K} p_m^k(t) < P_{\max}^m}{\forall m \in \{1, \cdots, M\}},$$
(6)

 $SINR_{n,m}^{k}(t) > SINR_{\min}, \ \forall n \in \{1, \dots, N\},$ $\exists 1 \le m \le M, 1 \le k \le K \ _{\circ}$ (7)

其中,约束条件(6)表示,任一时刻, 某一基站 m 在所有子信道上的发送 功率总和不能超过该基站的最大可 用功率 P^m_{max}。而约束条件(7)表示,用 户获得的信干噪比不能低于最小接入门限SINR_{min}。

我们注意到,在问题(5)中,由于 信号与干扰加噪声比(SINR)的表达 式中包含了其他站点的干扰信号,目 标效用函数是非凸函数,并且优化目 标为效用函数在时间维度上的累积 值,难以采用传统优化方法对该问题 进行求解。因此,考虑将问题(5)对 应的密集覆盖蜂窝网中的功率动态 优化分配问题建模一个马尔可夫决 策过程,系统根据网络状态的动态变 化来周期性地调整网络中的功率分 配策略。在此基础上,采用强化学习 的方法对MDP进行求解。

2 MDP 建模

在C-RAN网络架构下,BBU可以 方便地获得各个分布式RRH的资源 使用情况以及接入用户的状态信息, 因此,考虑将所有SBS组成的网络系 统看作一个智能决策主体,将网络中 的基站发送功率的动态优化控制决 策建模为一个MDP问题,并用元组 (*S,A,P,R*)表示。其中,*S*为系统状态 空间,*A*为采取的动作空间,*P*为状态 转移概率,*R*为回报函数。MDP的各 个组成元素具体可以表示为:

(1)系统状态。 $s \in S$ 表示在当前 智能体观察到的系统状态,定义s =(SINR^{k_1}, $_{2m_2}$,...,SINR^{k_n}, $_{Nm_n}$, g^{k_1} , $_{2m_2}$, ..., g^{k_n} , $_{Nm_n}$,sSINR^{k_n}, $_{nm_n}$ 表示用户n通过基 站 m_n 的子信道 k_n 接入网络所获得的 信干噪比,可以由式(2)得到。而 g^{k_n} , 则为用户在接入信道上的信道增益。 其中, $k_n \in \{1,2,...,K\}$, $m_n \in \{1,2,...,M\}$ 。我们注意到,根据 式(2)可知,SINR^{k_n},由基站的发送功 率、用户信道增益和用户受到的干扰 等因素共同决定。在每个决策周期, 用户将自己当前的信干噪比反馈给 ZTE TECHNOLOGY JOURNAL

接入的 RRH,再由 RRH 上报给 BBU。 而用户在接入信道上获得的信道增益,与用户和基站的距离以及之间是 否存在阻挡物等条件相关。在动态 网络环境下,这些条件主要受用户行 为特征的影响。虽然用户信干噪比 受用户信道增益的影响,能够在一定 程度上反映信道增益对用户获得的 服务性能的影响,但在系统状态中增 加信道增益,能够更加直接地反映用 户移动带来的网络动态特性对资源 分配策略和网络传输性能的影响。 由此,系统状态s将随网络中的基站 资源使用情况、用户行为以及网络干 扰条件的变化而变化。

(2)动作。用 $a \in A$ 表示智能体 采取的动作。定义在每个决策周期, 智能体采取的动作为决定每个 SBS 的发送功率,即 $a = \{p_1^1,...,p_m^k,...,p_M^K\}$ 。 其中, p_m^k 为基站m在子信道 k上的发 送 功 率 , 有 $k \in \{1,2,...,K\}$, $m \in \{1,2,...,M\}$ 。 p_m^k 是连续可调的,且 如果当前时刻基站m的子信道 k上没 有接入用户,则对应的 $p_m^k = 0$ 。

(3) 状态转移概率。用 $P = \{p_{s,s}^{a}|s,s' \in S, a \in A\}$ 表示状态转移概率集合。其中, $p_{s,s'}^{a}$ 为当系统处于状态s时,执行动作a后,转移到的状态s'的概率。

(4)回报函数。考虑到优化目标 为最大化系统的长期效用函数,因此 将智能体在每个决策时刻,根据当前 状态*s*采取动作*a*后取得的即时回报 表示为:

$$\begin{split} R(s,a) &= \\ \begin{cases} U(v), if all \ the \ conditions \ are \ met \\ -1, \ if \ SINR_{n,m_a}^{k_a} < SINR_{\min}, \ \forall n \in \{1,2,...,N\} \\ -1, \ if \ \sum_{k=1}^{K} p_m^k > P_{\max}, \ \forall m \in \{1,2,...,M\}, \end{split}$$

其中, U(v)可从式(4)得到。v= {v₁,v₂,...,v_N}为采取动作a后,系统中 所有用户获得的传输速率构成的向量,可由式(1)得到。式(8)中后两项为惩罚项,对应(6)和(7)的限制条件。当前决策时刻采取动作 a时,如果有用户获得的接入信干噪比低于最低门限 SINR_{min},或某个基站分配给所有子信道的功率之和超过基站的最大可用功率 P_{max},则获得的即时回报为惩罚值-1。

由此,将UDN中的功率动态优化 控制问题建模为了一个MDP,所有 SBS构成的网络系统作为一个智能决 策主体,周期性地根据观察到的网络 状态,进行基站发送功率分配的智能 决策,以最大化网络的长期累积 效用。

在 MDP 框架下,定义状态值函数 来反映当前状态下,智能体采取策略 π获得的长期回报,表示为:

$$V_{\pi}(s) = E_{\pi} \left[\sum_{i=0}^{\infty} \gamma^{i} R_{i+i} | s_{i} = s \right], \quad (9)$$

其中,γ为折扣因子,表明未来的回报 相对于长期回报的重要程度。相应 地,定义动作值函数来表示某一状态 下采取某一动作的长期回报,可以表 示为:

 $Q_{\pi}(s,a) = E_{\pi} \left[\sum_{i=0}^{\infty} \gamma^{i} R_{i+i} | s_{i} = s, a_{i} = a \right],$ (10)

其中, $E_{\pi}[x]$ 表示在策略 π 下变量x的均值。对于给定的策略 π ,观察式(9)和(10)可以得到:

$$V_{\pi}(s) = \sum_{a \in A} \pi(a|s) Q_{\pi}(s,a), \qquad (11)$$

$$Q_{\pi}(s,a) = R(s,a) + \gamma \sum_{s' \in S} p_{s,s'}^{a} V_{\pi}(s'), (12)$$

其中, $\pi(als)$ 为采用策略 π 的情况下, 系统处于状态s时采取动作a的概 率。在MDP模型下,系统决策的目标 就是找到一个最优的策略 π^* ,使得对 应的 $V_{\pi}(s)$ 和 $Q_{\pi}(s,a)$ 最优。

3问题求解

在我们定义的MDP模型中,系统 状态空间和动作空间都是连续的,且 状态转移概率 $p_{s,s'}^a$ 难以获取,因此考 虑采用 Model-free 的 AC 算法^[8]来对 MDP模型求解。AC 算法是一种将值 函数迭代和策略迭代相结合的强化 学习算法,其基本框架如图 2 所示。 AC 算法主要包括两个执行部分:一 个是 Actor,用于改进并生成当前执行 策略;一个是 Critic,用于评估策略执 行结果,指导 Actor进行策略改进。

(1)Actor_o

 π

在AC算法中,Actor通过不断调整策略以改进决策的回报。本文考虑采用高斯正态分布来近似策略分布,则有Actor的参数化策略可以表示为:

$${}_{\theta}(a|s) = \frac{1}{\sqrt{2\pi} \sigma_{\theta}(s)} \exp\left(-\frac{(a - \mu_{\theta}(s))^2}{2(\sigma_{\theta}(s))^2}\right), \qquad (13)$$

其中, $\mu_{\theta}(s)$ 和 $\sigma_{\theta}(s)$ 分别为正态分布 的均值和方差。考虑采用输入为系 统状态s,输出为 $\mu_{\theta}(s)$ 和 $\sigma_{\theta}(s)$ 的神经 网络来对均值和方差进行近似拟合, 参数 θ 对应神经网络全连接层的权重 参数。由此,策略的调整就转化为参 数的更新,我们期望参数朝着最大化 MDP长期累积效用的方向更新。在 强化学习框架下,常常使用梯度下降 的方法来进行参数更新,可以得到:

$$\theta_{new} = \theta_{old} + \alpha_a \nabla_\theta \log \pi_\theta(a|s) A_\pi(s,a), (14)$$

其中, α_a 为Actor的学习速率, $A_{\pi}(s,a)$ 为优势函数。

(2)Critic_o

在AC算法中,Critic的作用是通 过估计状态值函数来对Actor策略的 改进提供指导。在考虑的MDP模型 中,由于系统状态空间是连续的,因

ZTE TECHNOLOGY JOURNAL

此同样采用输入为系统状态s、输出 为V_e(s)的神经网络来进行状态值函 数的近似拟合, ξ为神经网络全连接 层的权重参数。通过参数化的近似 后, 值函数的更新也可以通过参数的 迭代更新来实现。

为了对参数ξ进行更新,时序差 分(TD)算法误差被引入:

$$\delta_t = V(s_t) - V_{\xi}(s_t), \qquad (15)$$

其中,s,为决策周期t的系统状态,且 有 $V(s_t) = R_{t+1} + \gamma V_{\varepsilon}(s_{t+1})_{\circ}$ Critic 的 目标是尽可能准确地估计值函数,因 此其优化目标应该是最小化TD误 差,可以表示为:

$$\min f(\xi) = \frac{1}{2} \cdot (\delta_t)^2, \qquad (16)$$

同样使用梯度下降法更新参数 ξ,得到:

$$\begin{aligned} \xi_{new} &= \xi_{old} + \alpha_c \nabla_{\xi} f(\xi) = \xi_{old} + \\ \alpha_c \delta_t \nabla_{\xi} V_{\xi}(s_t), \end{aligned} \tag{17}$$

其中, α ,为Critic的学习速率。

(3)基于AC算法的基站功率分 配机制。

在 AC 算法中, 往往采用公式 (13)中的TD误差作为Actor参数更 新过程中的优势函数,即令 $A_{\pi}(s_{\iota},a)$ = δ_{i} ,那么公式(12)可以改写为:

$$\theta_{new} = \theta_{old} + \alpha_a \nabla_\theta \log \pi_\theta(a_t | s_t) \delta_t, \quad (18)$$

由此,在UDN中,可以利用式 (17)和(18),通过参数的迭代更新来 优化系统中所有 SBS 基站的功率分 配策略,具体的功率控制算法流程如 算法1所示。

算法1:ACP算法 输入:N、M、K、T、 γ 、 α_a 、 α_c ; 输出:基站功率分配策略 π_{a} ;

初始化:决策周期t = 0,策略参数 $\theta =$

 θ_0 ,值函数参数 $\xi = \xi_0$,得到初始状态 $s = s_0$ Repeat: 1:动作选择:以概率 $\pi_{\theta}(a_{t}|s_{t})$ 选择动

作a,;

2:执行动作a,,系统转移到新的状态 *s*_{*i*+1},并获得即时回报*R*_{*i*+1};

3:根据公式(13),计算TD误差
$$\delta_t = R_{i+1} + \gamma V_{\epsilon}(s_{i+1}) - V_{\epsilon}(s_{i});$$

4:更新 Actor 与 Critic 参数:
$$\theta \leftarrow \theta + \alpha_a \nabla_{\theta} \log \pi_{\theta}(a_i | s_i) \delta_i;$$

$$\boldsymbol{\xi} \leftarrow \boldsymbol{\xi} + \boldsymbol{\alpha}_{c} \boldsymbol{\delta}_{t} \nabla_{\boldsymbol{\xi}} V_{\boldsymbol{\xi}}(\boldsymbol{s}_{t});$$

5:t = t + 1;

End until: t > T;

6:输出功率分配策略 π_{μ} 。 α_a:Actor的学习速率 α_{c} :Critic的学习速率 α_t :智能体在时刻t采取的动作 ν·折扣因子

ACP:基于AC的基站功率控制 K:子信道数量 M:SBS 数量 N:SBS用户数 T: 周期 TD:时序差分 V:值函数

4 数值结果分析

在本节中,将通过 仿真实验验证提出的智 能功率控制算法 ACP 的 性能。

4.1 仿真设置

考虑采用如图1所 示的密集覆盖蜂窝网络 覆盖场景,网络中包含1 个MBS和20个SBS。在 仿真中,考虑模拟室内 覆盖的典型应用场景, 所有的SBS位于一栋建 筑物内。为了模拟楼层 天花板和墙体对无线信 号的阻挡,仿真中采用 二层住宅楼的建筑结 构,而在每一层采用图3中的双线建 筑模型[10]。如图3所示,每层包含两 排房间,每排5个套房,中间走廊宽度 5m,每个套房的尺寸为10m×5m× 5m。每个套房内部结构如图4所示, 分为多个房间,用墙体隔开。

考虑到网络中存在一定数量的 MBS用户和SBS用户,所有SBS用 户位于建筑物内,以平均1 m/s的速 度随机移动: 而 MBS 用户以平均速





▲图3 双线建筑模型







度 5 m/s 在建筑物外, MBS 的覆盖范 围内随机移动。移动过程中, 用户随 机选定移动方向, 当遇到阻碍或到达 边界时重新选定移动方向。仿真中 具体参数设置如表 1 所示, 同时参考 文献[11], 无线信道路损模型如表 2 所 示。在表 2 中, d为用户到基站的直 线距离, d_{in} 为基站到用户的水平距 离。设 L_{av} = 20 dB 为建筑外墙穿透 损耗, L_{iw} = 5 dB 为室内穿墙损耗。 n_{w} 为用户和基站之间间隔的楼层数。 同时, 设置 AC 算法中学习速率 α_{a} = α_{c} = 0.01, 折扣因子 γ = 0.2。本节所 有的数值结果都是 50 次独立随机仿 真结果的平均值。

在仿真中,选取平均功率分配和 软频率复用两种典型的算法作为对 比,验证提出的基于AC的基站功率 控制(ACP)的性能。两种对比算法

▼表1 仿真参数列表

的基本思路如下:

(1)平均功率分配(EDP):每个 基站将可用功率平均分配给所有接 入用户。

(2)软频率复用(SFR):将基站的 可用频带分为主载波和副载波两部 分。主载波服务于边缘用户,副载波 服务于非边缘接入用户,根据接入边 缘用户的数量确定主副载波所占比 例。主副载波具有不同的最大发送 功率门限,仿真中限制副载波的最大 发送功率门限为主载波一半。

4.2 数值结果

图 5 给出了 ACP 算法的收敛情况。如图 5 所示,智能算法具有明显的收敛特性。在仿真初期,智能算法处于探索阶段。由于经验不足,智能体获得的收益较低,系统性能较差。随着训练次数的增加,算法通过对用

仿真参数	仿真值
噪声功率 N _{0.} (dBm/Hz)	-173
SBS最大发送功率/dBm	20
MBS最大发送功率/dBm	40
系统带宽 B/MHz	10
决策周期/s	1
SBS 数量 M	20
SBS用户数N	50
MBS用户数	30
子信道数量K	100
用户最小接收信干噪比(SINR _{min} (dB))	-10

MBS:宏基站 SBS:小基站 SINR:信号与干扰加噪声比

▼表2 路损模型

场景	路径损耗/dB	
MBS与室外UE	PL = 15.3 + 37.6lgd	
MBS与室内UE	$PL = 15.3 + 37.6 \text{lg}d + L_{ow}$	
SBS与室内UE	$PL = 38.46 + 20 \lg d + 0.7 d_{in} + 18.3 r$	$n_w^{(n_w + 2)(n_w + 1) - 0.46} + qL_{iw}$
SBS与室外UE	$PL = \max \{ 15.3 + 37.6 \lg d, \\ 38.46 + 20 \lg d + 0.7 d_{in} + 18.3 n_w^{(n_w + 2)(n_w + 1) \cdot 0.46} + qL_{iw} + L_{ow} \}$	
MBS:宏基站 SBS:小基站 SINR:信号与干扰加躁声比 d _n :基站到用户的水平距离 L _{ow} :建筑外墙穿透损耗	L _w :室内穿墙损耗 n _w :用户和基站之间间隔的楼层数 d:用户到基站的直线距离 MBS:宏基站 PL:路径损耗	q:用户和 SBS 之间的室内墙壁的 数量 SBS:小基站 UE:用户设备

户行为与传输环境的探索,逐渐学习 到更好的功率分配策略,智能体获得 的收益增加,系统性能提升,并最终 收敛。从图中可以看到,算法大概在 迭代训练5000次后达到收敛。

图 6 比较了 3 种不同算法下,网 络中所有 SBS 用户获得的服务速率 的概率分布函数。从图中可以看出, 与另外两种算法相比,运行ACP算法 的 SBS 用户能够获得更高的服务速 率,系统的整体吞吐量也会更高。这 是因为在ACP算法中,系统能够通过 感知到的网络状态和用户信道条件 的动态变化特征,智能地调整基站的 发送功率,从而降低网络中干扰,提 升用户获得的服务速率。而SFR算 法中,采用设置门限的方式,降低了 非边缘用户的发送功率,从而降低了 网络中的干扰,特别是网络边缘用户 受到的干扰:因此,用户能够获得比 EDP算法更高的服务速率。

在本文考虑的仿真场景中,采用 智能算法的SBS和传统的MBS共存, 且相互干扰。图7比较了不同算法 下,网络中不同类型用户获得的平均 服务速率。如图7所示,采用ACP智 能功率分配算法的所有 SBS 用户的 平均传输速率明显优于 EDP 和 SFR 算法。同时,虽然MBS没有采用智能 功率分配算法,但运行ACP算法的 SBS可以根据网络中干扰条件的动态 变化,调整自身的发送功率,从而降 低对MBS用户的干扰。所以ACP算 法下,MBS用户获得传输速率依然高 于其他两种算法。由此,在ACP算法 下,网络中所有用户的平均传输速率 同样优于EDP和SFR算法。

图 8 为所有 SBS 用户平均服务速 率随网络中基站数量的变化情况。 考虑到实际系统中,由于管理权限、 部署先后顺序等,在有些情况下可能 无法在所有的 SBS 上采用统一的智 专题

超密集蜂窝网络智能干扰协调算法 ZTE TECHNOLOGY JOURNAL





▲图7 用户平均服务速率

MBS:宏基站

ACP:基于AC的基站功率控制

能功率控制算法,网络中智能SBS和 传统 SBS 共存。在仿真中,为了验证 智能基站和传统基站混合部署情况 下网络中的传输性能,增加了一种称 为Mix算法的混合功率控制方案。在 Mix 算法下,一半的SBS采用智能的 ACP 算法,一半的 SBS 采用 EDP 算 法。从图8可以看到,当基站数量较 少时,随着SBS数量的增加,4种算法 下用户获得的平均服务速率增大;但 随着基站数量增加,网络中干扰逐渐 增大,导致在基站数量较多时,用户 获得的平均服务速率反而下降。不

UE

SBS:小基站

SFR:软频率复用

EDP:平均功率分配

UE:用户设备

论是在哪种情况下,ACP算法获得的 用户平均服务速率总是优于其他3种 算法。而 Mix 算法的性能优于 EDP 和SFR算法,说明智能和非智能SBS 混合部署情况下,网络中的传输性能 依然优于完全不使用智能功率分配 算法的情况。值得注意的是,SFR算 法和EDP算法的性能曲线随着基站 数量的增加发生了交叉。这是因为, 在基站数量较少时,小区间干扰较 低,而SFR限制了非边缘用户发送功 率,这会导致用户获得的服务速率较 低。随着基站数量的增加,小区间干

扰变得严重,EDP算法没有任何干扰 协调机制,这导致用户的服务速率受 到较大影响;而SFR算法限制了非边 缘用户的发送功率,降低了网络中的 干扰。

EDP:平均功率分配

SFR:软版率复用

5 结束语

ACP:基于AC的基站功率控制

SBS:小基站

▲图8 用户平均服务速率 vs.基站数量

本文研究了超密集蜂窝网中的 智能干扰协调问题。考虑到移动网 络的动态特征,将基站的动态功率控 制建模为一个马尔科夫决策过程,并 采用强化学习的方法,利用AC算法

超密集蜂窝网络智能干扰协调算法

对其进行求解。在此基础上,设计了 一个基于 AC 的基站功率动态智能控 制算法。仿真实验结果证明, 该算法 能够有效降低超密集蜂窝网络中基站 间的相互干扰,提升网络传输性能。

参考文献

- [1] CHANDRASEKHAR V, ANDREWS J, GATHER-ER A. Femtocell networks: a survey [EB/OL]. [2020-09-10]. https://arxiv.org/abs/0803.0952
- [2] SHAFI M, MOLISCH A F, SMITH P J, et al. 5G: a tutorial overview of standards, trials, challenges deployment and practice [J] IEEE journal on selected areas in communications, 2017, 35(6): 1201-1221. DOI:10.1109/ isac.2017.2692307
- [3] LIU J Y, SHENG M, LIU L, et al. Interference management in ultra-dense networks: challenges and approaches [J]. IEEE network, 2017, 31(6): 70-77. DOI:10.1109/ mnet.2017.1700052
- [4] WU J, ZHANG Z F, HONG Y, et al. Cloud radio access network (C-RAN): a primer [J]. IEEE network, 2015, 29(1): 35-41. DOI:10.1109/

mnet.2015.7018201

- [5] PAN C H, ELKASHLAN M, WANG J Z, et al. User-centric C-RAN architecture for ultra-dense 5G networks: challenges and methodologies [EB/OL].[2020-09-10], https:// arxiv.org/abs/1710.00790
- [6] ZHENG J C, WU Y, ZHANG N, et al. Optimal power control in ultra-dense small cell networks: a game-theoretic approach [J]. IEEE transactions on wireless communications, 2017, 16(7); 4139-4150, DOI:10.1109/ twc.2016.2646346
- [7] YANG C G, LI J D, NI Q, et al. Interference-aware energy efficiency maximization in 5G ultra-dense networks [J]. IEEE transactions on communications, 2017, 65(2): 728-739. DOI:10.1109/tcomm.2016.2638906
- [8] GRONDMAN I, BUSONIU L, LOPES G A D, et al. A survey of actor-critic reinforcement learning: standard and natural policy gradients [J]. IEEE transactions on systems, man, and cybernetics, part C (applications and reviews), 2012, 42(6): 1291-1307. DOI:10.1109/ tsmcc.2012.2218595
- [9] GHADIMI E, CALABRESE F D, PETERS G, et al. A reinforcement learning approach to power control and rate adaptation in cellular networks [EB/OL]. [2020-09-10]. https://arxiv.org/ abs/1611 06497
- [10] E-UTRA. Small cell enhancements for E-UTRA and E- UTRAN physical layer aspects: TR37.840[S]. 3GPP, 2003
- [11] 3GPP. Further advancements for E-UTRA physical layer aspects: TR 36.814 V9.2.0 [S]. 3GPP, 2017



← 上接第 38 页

- [5] JOUPPI N P, YOUNG C, PATIL N, et al. In-datacenter performance analysis of a tensor processing unit [C]//The 44th Annual International Symposium on Computer Architecture. Toronto, Canada: ISCA, 2017
- [6] GAMATIE A, DEVIC G, SASSATELLI G, et al. Towards energy-efficient heterogeneous multicore architectures for edge computing [J]. IEEE access, 2019, 7: 49474-49491. DOI: 10.1109/ACCESS.2019.2910932
- [7] 肖汉,李彩林,李琦,等. CPU+GPU 异构并行的 矩阵转置算法研究 [J]. 东北师大学报 (自然科学 版), 2019, 51(4): 70-77
- [8] Gentsch P. Al business: framework and maturity model [M]. 2019
- [9] WANG L, GUO S, HUANG W L, et al. Places205-VGGNet models for scene recognition [J]. Computer science, 2015
- [10] GIRSHICK R. Fast R-CNN [J]. Computer science, 2015. DOI: 10.1109/ICCV.2015.169
- [11] 中国信息通信研究院,国家广播电视总局广播 电视科学研究院,中国新闻出版传媒集团有限公 司,等. 云游戏产业发展白皮书 [R/OL]. (2019-12)[2020-08-07]. http://www.199it.com/archives/988193.html
- [12] 华为技术有限公司.5G应用立场白皮书 [R/ OL]. [2020-08-07]. http://www.lddoc.cn/ p-12956741.html
- [13] 唐洁,刘少山.面向无人驾驶的边缘高精地图服 务 [J]. 中兴通讯技术, 2019, 25(3): 58-67+81. DOI: 10.12142/ZTETJ.201903009



宽带通信、SDN/NFV、新一代网络编排技术的

研究;发表论文20余篇,获授权专利10余项。



李奥,中国联通研究院 助理工程师; 主要从事 人工智能在网络边缘应 用的研究。

