



基于深度学习的家庭基站下行链路功率分配

吕亚平¹, 贾向东^{1,2}, 路 艺¹, 叶佩文¹

(1. 西北师范大学 计算机科学与工程学院, 兰州 730070; 2. 南京邮电大学 江苏省无线通信重点实验室, 南京 210003)

摘 要: 为提高室内无线通信服务质量以满足用户需求, 基于深度 Q 学习 (DQL) 算法进行家庭基站的下行链路功率分配, 旨在最大化系统吞吐量。在办公区域密集部署家庭基站的系统模型中, 将家庭基站的物理位置建模为泊松点过程, 移动用户随机分布在各个位置。在此基础上, 构建含有两层隐藏层的深度神经网络, 优化网络的非线性, 提高网络的拟合能力。仿真结果表明, DQL 算法相较于贪婪算法和 Q 学习算法能有效提高系统吞吐量和收敛速度。

关键词: 家庭基站; 密集部署; 功率分配; 神经网络; 深度学习

开放科学 (资源服务) 标志码 (OSID):



中文引用格式: 吕亚平, 贾向东, 路艺, 等. 基于深度学习的家庭基站下行链路功率分配 [J]. 计算机工程, 2020, 46(10): 188-192.

英文引用格式: LÜ Yaping, JIA Xiangdong, LU Yi, et al. Downlink power allocation of home base station based on deep learning [J]. Computer Engineering, 2020, 46(10): 188-192.

Downlink Power Allocation of Home Base Station Based on Deep Learning

LÜ Yaping¹, JIA Xiangdong^{1,2}, LU Yi¹, YE Peiwen¹

(1. College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China;

2. Wireless Communication Key Lab of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

[Abstract] In order to improve the service quality of indoor wireless communication to meet user demand, the downlink power allocation of home base station based on Deep Q Learning (DQL) algorithm is carried out to maximize system throughput. In the system model of densely deploying home base stations in office areas, the physical location of home base stations is modeled as a Poisson point process, and mobile users are randomly distributed in each location. On this basis, a deep neural network with two hidden layers is constructed to optimize the nonlinearity of the network and improve its fitting ability. Simulation results show that DQL algorithm can effectively improve the system throughput and convergence speed compared with greedy algorithm and Q learning algorithm.

[Key words] home base station; intensive deployment; power allocation; neural network; deep learning

DOI: 10.19678/j.issn.1000-3428.0055640

0 概述

据调查显示,在欧洲 20% ~ 40% 的移动电话发生于室内,在美国为 40% ~ 50%,在中国则高达 60%,同时,超过 50% 的语音服务和 70% 的数据流量服务发生于室内^[1]。近年来出现的家庭基站技术,在增加无线网络容量、解决室内覆盖问题以及从宏基站上卸载流量等方面具有较大优势^[2]。随着 5G 时代的到来以及智能终端设备的爆炸式增长,现有的室内无线通信网络已经很难满足移动用户对各种数据服务的需求。因此,如何提高室内无线网络的容量,为室内移动用

户提供更好的数据服务变得十分重要。

室内无线通信是无线通信中不可或缺的一部分,目前室内无线通信的主要实现方式有家庭基站和 WiFi 2 种。在国外,室内通信使用家庭基站比较多,而在国内,室内通信大多使用 WiFi,家庭基站更多用于商用。商用区域内家庭基站是处理室内无线网络容量和覆盖的重要技术,与 WiFi 相比,家庭基站在授权的频段内能提供较好的语音服务质量,并且更简单实用,有较好的安全性能。此外,其还具有功耗少、电池寿命长、不需要 WiFi 双模手机或其他设备等优点,同时还具有服务等同性,即

基金项目: 国家自然科学基金 (61261015, 61561043)。

作者简介: 吕亚平 (1994—), 女, 硕士研究生, 主研方向为移动通信; 贾向东, 教授、博士; 路 艺、叶佩文, 硕士研究生。

收稿日期: 2019-08-05 **修回日期:** 2019-09-26 **E-mail:** jiaxd@nwnu.edu.cn

支持多种服务在家庭基站上无缝工作。

为解决室内无线网络的容量问题,众多研究人员从不同角度对家庭基站进行了研究与分析。文献[3]提出一种功率控制和覆盖(Power Control and Coverage, PCC)算法,以增加网络效用和降低能量消耗,并建立了PPC算法对最优解的收敛性,但该算法在移动用户密集区域不一定适用。文献[4]提出带宽-功率模型来减少移动用户使用的带宽总和,并最大限度地降低噪声对传输速率的影响,但该算法并未考虑家庭基站密集部署的情况。文献[5-6]研究了双层毫微微蜂窝网络中的全双工通信,通过博弈理论共同考虑上下行优化问题,但没有考虑用户的移动性和用户密集聚集的情况。文献[7]使用Q学习算法来最大化宏小区和毫微微小区的容量。文献[8]通过减少干扰和平衡数据下载这两方面来最大化网络容量。文献[9]根据干扰和服务因素,调整主要家庭基站的传输功率,执行基于概率的资源分配算法,以安排每个家庭基站的传输时间和频率,进一步增强整体频谱重用。这样可以有效地避免相邻家庭基站之间的干扰,从而更好地满足服务质量连接,以提高网络的吞吐量。

尽管目前深度学习在无线通信领域尚处于初步探索阶段,但是已有众多学者对其进行研究并取得一些成果,文献[10]使用深度学习算法解决了状态空间连续与动作空间连续的问题,文献[11]使用深度学习算法达到了能效优化的目的,文献[12]使用深度强化学习有效地降低了用户的任务执行总时延,文献[13]使用强化学习算法解决了窄带物联网实时优化的问题。

受文献[7]和深度学习算法的启发,本文建立一个在办公区域密集部署家庭基站的系统模型,基于深度Q学习(Deep Q Learning, DQL)算法对家庭基站的下行链路功率分配方法进行设计,使其能够自适应网络变化,从而提高室内无线通信网络的吞吐量。

1 系统模型与假设

图1为在办公区域密集部署家庭基站的一个系统模型。该系统模型借用文献[14]的路径损耗模型。在该系统模型中,考虑家庭基站的下行传输。假设有 N 个家庭基站, M 个移动用户;家庭基站的空间物理位置遵循空间位置强度为 λ ($\lambda = 3/4 \times 30/100^3 \pi$)的泊松点过程;用户随机分布在该办公区域内;所有的家庭基站共享频谱带宽;一个移动用户只能与一个基站进行连接。考虑到实际情况,该网络模型中移动用户受到的干扰来自所有的家庭基站,如图1中实线箭头所示。




图1 办公区域家庭基站密集部署的网络模型

Fig. 1 Network model of intensive deployment of home base stations in office area

假设 $n = \{1, 2, \dots, i, \dots, N\}$ 表示家庭基站的集合, $m = \{1, 2, \dots, j, \dots, M\}$ 表示办公区域内用户的集合。基站 i 与移动用户 m 通信时,受到的干扰信号为:

$$I_{i,m} = \sum_{n=1, n \neq i}^N \sum_{m=1}^M D_{i,n} P_{i,n} G \quad (1)$$

其中: $D_{i,m}$ 表示移动用户 m 是否接入基站 i ,如果 $D_{i,m} = 0$,则表示移动用户 m 成功接入基站 i ,反之则没有; $P_{i,m}$ 表示移动用户 m 与基站 i 通信时,基站 i 的发射功率; G 表示移动用户与基站通信时的链路增益。 G 由下式所得:

$$G_{n,m} = W h_{n,m} Z_{n,m} \gamma_{n,m}^{-\varphi} \quad (2)$$

其中, $h_{n,m}$ 、 $Z_{n,m}$ 、 φ 分别是基站 n 与移动用户 m 通信时的多径衰落、阴影衰落以及路径损耗因子,而 $\gamma_{n,m}$ 则代表基站 n 和移动用户 m 两者之间的距离。

假设移动用户与基站通信时接收的高斯白噪声的方差 δ^2 是固定值,且信道状况已知,则系统的信号与干扰加噪声比(SINR)可表示为:

$$\text{SINR}_{i,m} = \frac{D_{i,m} P_{i,m} G}{\sum_{n=1, n \neq i}^N I_{i,n} + \delta^2} \quad (3)$$

由香农公式可得系统的总吞吐量 C 为:

$$C = B \sum_{n=1, n \neq i}^N \sum_{m=1}^M \text{lb}(1 + \text{SINR}_{i,m}) \quad (4)$$

其中, B 是家庭基站的带宽。

根据最大化网络吞吐量这一优化目标,家庭基站的发射功率必须不大于其最大发射功率,则目标优化问题可表述如下:

$$\max_{\{P_{n,m}\}} C \quad (5)$$

约束条件为:

$$\begin{aligned} P_{n,m} &\leq P_{\max} \\ \forall n &\in \{1, 2, \dots, i, \dots, N\}, \forall m \in \{1, 2, \dots, j, \dots, M\} \end{aligned} \quad (6)$$

其中, P_{\max} 是家庭基站的发射功率。

2 基于深度强化学习的功率分配算法

深度学习具有较强的感知能力,但是缺乏一定的决策能力;而强化学习具有决策能力,但是难以解决感知问题^[15]。深度强化学习可以把深度学习的感知能力和强化学习的决策能力结合起来^[16],优势互补,通过不断地试错,与环境进行交互,最大化累积奖赏从而获得最优策略^[17]。因此,本文使用同时具备感知能力和决策能力的深度 Q 学习算法来解决家庭基站的下行链路功率分配问题。

DQL 算法是 Q 学习算法的一种变体,其利用深度卷积神经网络估计值函数、经验回放进行学习,并且设置了目标网络来独立处理时间差分算法中的时间差(Time Difference, TD)。图 2 展示了本文基于深度 Q 学习的功率分配算法框架。

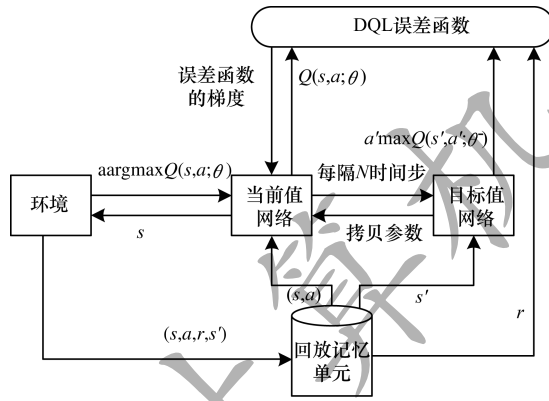


图 2 基于深度 Q 学习的功率分配算法框架

Fig. 2 Framework of power allocation algorithm based on deep Q learning

如图 2 所示,该框架包含回放记忆单元、当前值网络、目标值网络、环境和 DQL 误差函数五大模块。回放记忆单元存放经验回放,经验回放是指在代理与环境交互过程中,经验会以 (s, a, r, s') 的形式存放在回放记忆单元中,每次训练会从回放记忆单元中随机抽取一批数据进行训练,可以在一定程度上消除样本之间的相关性。DQL 中使用两个值网络:一个网络是当前值网络,与环境交互,并且不断更新;另一个网络是目标值网络,它既不与环境交互,也不在每个时间步进行更新,而是每隔一定时间步才会更新,每次更新都把当前值网络参数直接赋值给它。 s 是算法的观测, a 表示在观测 s 下执行的动作, r 表示动作 a 执行后得到的奖罚^[18], s' 为执行动作 a 后的观测值, a' 为在观测值 s' 下执行的动作, θ 表示网络的权重和偏置, θ^- 为 θ 的赋值。

本文所采用的深度 Q 学习算法是基于与环境不断实时交互的多代理(代理、状态、动作、奖励)算法。对多代理功能定义如下:

代理人:基站 $n, 1 \leq n \leq N$ 。

状态: $s_n = \{M_n, P_n\}$, M_n 表示连接到基站 n 的移动用户数量, P_n 表示基站 n 的发射功率。

动作: $a_n = \{n, \Delta P_n\}$, n 表示基站, ΔP_n 表示基站 n 的发射功率调整值。

奖励函数:

$$r_{n,m} = \begin{cases} 1 - e^{-(C_{n,m})}, & P_{n,m} \leq P_{\max} \\ -1, & \text{otherwise} \end{cases} \quad (7)$$

当用户 m 与基站 n 连接时, $r_{n,m}$ 表示对基站 n 的奖励, $C_{n,m}$ 表示基站 n 的吞吐量。每个代理经过不断的迭代学习来更新行为状态值函数,迭代式如下:

$$\theta_{i+1} = \theta_i + \alpha [r + \beta a'_{\max} Q(s', a'; \theta^-) - Q(s, a; \theta)] \nabla Q(s, a; \theta) \quad (8)$$

其中, $\alpha \in [0, 1]$ 是学习率, $\beta \in (0, 1)$ 是折扣因子, $\nabla Q(s, a; \theta)$ 是误差函数梯度。

深度神经网络(Deep Neural Network, DNN)是一种深度学习模型,拥有较高的准确度^[19]。如图 3 所示,本文设计的 DNN 由输入层、2 层隐藏层、输出层构成,并将 DQN 作为动作状态值函数 $Q(s, a; q)$ 。




图 3 DNN 网络的基本架构

Fig. 3 Basic architecture of DNN network

在该深度神经网络中,输入层数据为 $[M_1, M_2, \dots, M_i, \dots, M_N, P_{1,1}, P_{1,2}, \dots, P_{i,j}, \dots, P_{n,m}]$, 隐藏层是为了优化网络的非线性,提高网络的拟合能力,输出层数据为基站 n 发射功率的调整值。为防止过拟合,隐藏层随机丢弃一些节点。深度神经网络的损失函数如下:

$$L = r + \beta a'_{\max} Q(s', a'; \theta^-) - Q(s, a; \theta) \quad (9)$$

3 仿真结果及分析

对家庭基站的下行链路功率控制算法进行仿真与数值分析^[20]。仿真参数设置如表 1 所示,其中的多径衰落和阴影衰落使用文献[14]所采用的参数值,分别服从指数分布和对数正态分布。

表 1 仿真参数

Table 1 Simulation parameters

参数名	参数值
学习率	0.001
带宽/MHz	20
隐藏层 1 的丢弃率	0.5
家庭基站覆盖半径/m	30
家庭基站最大发射功率/dBm	23
多径衰落	1
阴影衰落/dB	8 ($\mu=0$)
高斯白噪声的方差	10^{-7}
隐藏层 2 的丢弃率	0.4
用户最大移动速度/($\text{m} \cdot \text{s}^{-1}$)	2

分别使用贪婪算法、Q 学习算法和 DQL 算法得到办公区域网络的总吞吐量 C 与迭代更新次数之间的关系,如图 4 所示。可以看出,Q 学习算法和 DQL 算法的网络总吞吐量远大于贪婪算法,并且 DQL 算法的网络总吞吐量优于 Q 学习算法。




图 4 3 种算法的网络吞吐量的比较

Fig. 4 Comparison of network throughput of three algorithms

图 5 对比了 Q 学习算法和 DQL 算法的收敛速度。可以看出,随着更新迭代次数的增加,DQL 算法的收敛速度逐渐加快,且始终优于 Q 学习算法。这是因为对于每次迭代以及用户的移动,Q 学习算法需要重新计算网络总吞吐量和收敛。虽然 DQL 算法也存在波动,但相较于 Q 学习算法是更稳定的。此外,随着深度神经网络的不断强化,深度 Q 学习算法显著地提高了网络总吞吐量。




图 5 Q 学习算法和 DQL 算法的收敛速度对比

Fig. 5 Comparison of convergence rates between Q learning algorithm and Deep Q learning algorithm

4 结束语

为提高在办公区域密集部署的家庭基站网络的无线通信质量,本文提出基于深度 Q 学习算法的网络模型,用以对家庭基站的下行链路进行功率分配,最大化系统吞吐量。仿真实验表明,与贪婪算法和 Q 学习算法相比,DQL 算法具有更高的网络吞吐量和更快的收敛速度,验证了本文模型的有效性。下一步将在不影响用户服务质量的前提下,基于深度 Q 学习算法研究宏基站覆盖下家庭基站的下行链路发射功率问题。

参考文献

- [1] HAN Song, LI Xinbin, LIU Zhixin, et al. Distributed hierarchical game-based algorithm for downlink power allocation in OFDMA femtocell networks[J]. Computer Networks, 2016, 94: 176-188.
- [2] CHANDRASEKHAR V, ANDREWS J, GATHERER A, et al. Femtocell networks: a survey [J]. IEEE Communications Magazine, 2008, 46(9): 59-67.
- [3] ARISTOMENOPOULOS G, KASTRINOIANNIS T, LAMPRIKAKOU S, et al. Optimal power control and coverage management in two-tier femtocell networks[J]. EURASIP Journal on Wireless Communications and Networking, 2012(1): 1-13.
- [4] ESTRADA R, JARRAY A, OTROK H, et al. Base station selection and resource allocation in macro-femtocell networks under noisy scenario [J]. Wireless Networks, 2014, 20(1): 115-131.
- [5] LIU Z, ZHANG P, CHAN K Y, et al. Robust resource allocation for rates maximization using fuzzy estimation of dynamic channel states in OFDMA femtocell networks[J]. Computer Networks, 2019, 159: 110-124.
- [6] MU Shiyao. Research on resource allocation algorithm based on disturbance coordination in home base station system[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2014. (in Chinese)
- [7] SAAD H, MOHAMED A, ELBATT T, et al. Cooperative Q-learning techniques for distributed online power allocation in femtocell networks [J]. Communications and Mobile Computing, 2015, 15: 1929-1944.
- [8] SHIN D, CHOI S. Power control for data load balancing with coverage in dynamic femtocell networks [J]. Wireless Networks, 2016, 22(4): 1145-1159.
- [9] WANG C, KUO W H, CHU C Y, et al. QoS-aware cooperative power control and resource allocation scheme in LTE femtocell networks [J]. Computer Communications, 2017, 110: 164-174.
- [10] LIU Dongyu. Research on routing and resource allocation algorithm based on reinforcement learning in D2D network[D]. Beijing: Beijing University of Posts and Telecommunications, 2019. (in Chinese)

刘东煜. D2D 网络中基于强化学习的路由选择与资源分配算法研究[D]. 北京:北京邮电大学, 2019.

- [11] LI Han. Resource allocation scheme under self-powered UDN network based on deep reinforcement learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019. (in Chinese)
李瀚. 基于深度强化学习的自供能 UDN 网络下资源分配方案 [D]. 北京: 北京邮电大学, 2019.
- [12] CHENG Baichuan. Research on MEC computing unloading and resource allocation based on deep reinforcement learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019. (in Chinese)
程百川. 基于深度强化学习的 MEC 计算卸载和资源分配研究 [D]. 北京: 北京邮电大学, 2019.
- [13] JIANG N, DENG Y, NALLANATHAN A, et al. Reinforcement learning for real-time optimization in NB-IoT networks [J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1424-1440.
- [14] ZHENG Xiangquan, ZHANG Xianlu, HE Xiang. A resource allocation algorithm to maximize throughput gain in D2D communications [J]. Mobile Communications, 2018, 42(6): 26-33. (in Chinese)
郑相全, 张先禄, 何香. 一种最大化吞吐量增益的 D2D 通信资源分配算法 [J]. 移动通信, 2018, 42(6): 26-33.
- [15] TANG Zhen, TAO Shaokun, ZHAO Dongbin, et al. Deep reinforcement learning progress: from AlphaGo to AlphaGo Zero [J]. Control Theory and Applications, 2017, 34(12): 1529-1546. (in Chinese)
唐振, 韬邵坤, 赵冬斌, 等. 深度强化学习进展: 从 AlphaGo 到 AlphaGo Zero [J]. 控制理论与应用, 2017, 34(12): 1529-1546.
- [16] CHENG Siyu, LIN Feng. The influence of computer AlphaGo algorithm on human go algorithm [J]. China Science and Technology Information, 2019(2): 40-41. (in Chinese)
程思雨, 林锋. 计算机围棋 AlphaGo 算法对人类围棋算法的影响 [J]. 中国科技信息, 2019(2): 40-41.
- [17] ZHOU Yi, MA Xiaoyong, GAO Fuxiao, et al. Autonomous deployment and energy efficiency optimization strategy of UAV based on deep reinforcement learning [J]. Chinese Journal on Internet of Things, 2019, 3(2): 47-55. (in Chinese)
周毅, 马晓勇, 郜富晓, 等. 基于深度强化学习的无人机自主部署及能效优化策略 [J]. 物联网学报, 2019, 3(2): 47-55.
- [18] LIAO Xiaomin, YAN Shaohu, SHI Jia, et al. Deep reinforcement learning based resource allocation algorithm in cellular networks [J]. Journal on Communications, 2019, 40(2): 11-18. (in Chinese)
廖晓闽, 严少虎, 石嘉, 等. 基于深度强化学习的蜂窝网资源分配算法 [J]. 通信学报, 2019, 40(2): 11-18.
- [19] ZHANG Liangliang, FENG Jing, HU Guyu. Deep learning method for community structure based on compressive sensing [J]. Computer Engineering, 2014, 40(9): 190-195. (in Chinese)
张梁梁, 冯径, 胡谷雨. 基于压缩感知的社团结构深度学习方法 [J]. 计算机工程, 2014, 40(9): 190-195.
- [20] XIE Mangang, JIA Xiangdong, ZHOU Meng, et al. Analysis for outage probability of two-hop relay cooperative heterogeneous networks [J]. Computer Engineering, 2019, 45(4): 61-65. (in Chinese)
颀满刚, 贾向东, 周猛, 等. 双跳中继协作异构网络中断概率分析 [J]. 计算机工程, 2019, 45(4): 61-65.

编辑 任欣平