

基于图神经网络的联合用户调度与波束成形优化算法

何世文^{1,2,3}, 袁军¹, 安振宇³, 张敏⁴, 黄永明^{2,3}, 张尧学⁵

(1. 中南大学计算机学院, 湖南 长沙 410083; 2. 东南大学移动通信国家重点实验室, 江苏 南京 210096;
3. 紫金山实验室, 江苏 南京 211111; 4. 湖南邮电职业技术学院信息通信学院, 湖南 长沙 410015;
5. 清华大学计算机科学与技术系, 北京 100084)

摘要: 协作多点 (CoMP) 传输技术具有降低同频干扰和提高频谱效率的特点。对于 CoMP, 用户调度与波束成形是 2 个分别位于媒体访问接入层和物理层的基本研究问题。在考虑用户服务质量需求下, 重点研究用户调度与波束成形的联合优化问题, 并以网络吞吐量最大化为目标。为了克服传统优化算法计算开销大且未有效利用网络历史数据信息的问题, 提出了一种基于图神经网络联合用户调度与功率分配模型, 并结合波束向量的解析公式, 以实现联合用户调度与波束成形优化。仿真分析表明, 所提算法能够以较低的计算开销实现与传统优化算法相匹配, 甚至更优的性能表现。

关键词: 跨层优化; 图神经网络; 协作多点; 用户调度; 波束成形

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2022133

GNN-based optimization algorithm for joint user scheduling and beamforming

HE Shiwen^{1,2,3}, YUAN Jun¹, AN Zhenyu³, ZHANG Min⁴, HUANG Yongming^{2,3}, ZHANG Yaoxue⁵

1. School of Computer Science and Engineering, Central South University, Changsha 410083, China

2. National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China

3. Purple Mountain Laboratories, Nanjing 211111, China

4. School of Information and Communication, Hunan Post and Telecommunication College, Changsha 410015, China

5. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China

Abstract: The coordinated multi-point (CoMP) transmission technology has the characteristics of reducing co-channel interference and improving spectral efficiency. For the CoMP technology, user scheduling (US) and beamforming (BF) design are two fundamental research problems located in the media access control layer and the physical layer, respectively. Under the consideration of user service quality requirements, the joint user US-BF optimization problem was investigated with the goal of maximizing network throughput. To overcome the problem that the traditional optimization algorithm had high computational cost and couldn't effectively utilize the network historical data information, a joint US and power allocation (M-JEEPON) model based on graph neural network was proposed to realize joint US-BF optimization by combining the beam vector analytical solution. The simulation results show that the proposed algorithm can achieve the performance matching or even better than traditional optimization algorithms with lower computational overhead.

Keywords: cross-layer optimization, graph neural network, coordinated multi-point, user scheduling, beamforming

收稿日期: 2022-04-20; 修回日期: 2022-05-30

基金项目: 国家自然科学基金资助项目 (No.62171474, No.61720106003); 东南大学移动通信国家重点实验室开放研究基金资助项目 (No.2022D03); OPPO 广东移动通信有限公司研究基金资助项目 (No.CN05202112160224)

Foundation Items: The National Natural Science Foundation of China (No.62171474, No.61720106003), The Open Research Fund of National Mobile Communications Research Laboratory of Southeast University (No.2022D03), OPPO Guangdong Mobile Communication Co., Ltd. Research Fund (No.CN05202112160224)

0 引言

近年来,随着智能手机与新兴高清多媒体应用的普及,网络流量呈指数级增长。为了满足用户对这些新兴业务的服务质量需求,无线网络的部署呈现越来越密集化与小型化趋势。然而,网络密集化不仅会提高基础通信设施的建设成本,还将加剧小区间的同频信号干扰,使小区边缘用户面临相对较弱的小区与较强的小区间的信号干扰问题。因此,无线密集网络亟须一种先进的干扰缓解技术来提高频谱效率与增强网络和速率^[1]。近年来,协作多点 (CoMP, coordinated multi-point) 传输作为一种频谱效率优化技术,通过将多小区通信单元组成一个分布式协作集群系统以降低小区间的同频信号干扰,从而提高无线网络的覆盖率与小区边缘用户的服务质量^[2]。

CoMP 技术主要包含 2 种模式^[3],即联合发送 (JT, joint transmission) 和协同调度/波束成形 (CS/CB, coordinated scheduling/beamforming)。2 种传输模式的主要区别在于, JT 模式下的用户可以由多个基站共同服务,而 CS/CB 模式下同一用户只能接受一个基站的服务^[4]。在现有的工作中,2 种传输模式均被广泛采用以提高网络的频谱效率^[5]。例如,文献[6]利用 JT-CoMP 模式与非正交多址接入 (NOMA, nonorthogonal multiple access) 技术相结合的方式对用户调度与功率分配优化。文献[7]研究了基于 CS/CB-CoMP 模式的非正交多址接入 (NOMA) 用户选择和迫零波束成形 (ZFBF, zero-forcing beamforming) 策略,以实现单小区调度增益与多小区干扰惩罚平衡。在 CoMP 技术中,用户调度与波束成形是分别位于媒体访问接入层和物理层的 2 个基本问题,其通常被单独研究,包括不考虑波束成形的用户调度问题^[8],以及基于固定用户集的波束成形问题^[9]。

随着网络架构及硬件设备的发展,不同网络层级的跨层优化^[10]有望进一步提高网络性能和资源利用率。研究者开始考虑用户调度与波束成形的跨层 (媒体访问接入层和物理层) 优化问题。例如,文献[11]提出了一种基于 CS/CB-CoMP 模式的联合用户调度与波束成形策略,以支持超密集网络的海量设备互联场景服务。文献[12]利用正交随机波束成形技术,研究了基于 JT-CoMP 模式的大规模多输入多输出 (MIMO, multi-input multi-output) 系统的联合波束激活和用户调度问题。文献[13]提出了基

于迫零波束成形和用户调度 (ZFBF-US, zero-forcing beamforming and user scheduling) 的贪婪优化算法,以及基于连续凸近似理论的用户调度与波束成形 (SCA-USBF, successive convex approximation based user scheduling and beamforming) 的优化算法,但是两者均存在局限性,即前者计算效率过低,而后者性能不足。此外,这些基于凸优化理论 (模型驱动) 的优化算法不仅计算复杂度高,难以适应无线网络的低时延要求,而且当网络环境发生变化时,需要重新运行算法,未能有效利用网络历史数据信息。

随着人工智能技术,特别是图神经网络 (GNN, graph neural network) 在无线通信领域的发展应用^[14],越来越多的研究人员开始探索无线传输智能优化理论^[15]。例如,针对设备到设备 (D2D, device-to-device) 网络中的无线资源优化问题,文献[16]尝试引入 GNN 来解决干扰信道中的用户功率分配问题,与经典的最小化加权均方误差 (WMMSE, weighted minimum mean square error) 功率分配算法相比,该模型更具性能和计算效率优势。文献[17]设计了一种基于图嵌入的 D2D 网络链路调度算法,但是它并不适于衰落信道模型。为此,文献[18]提出了一种适于衰落信道的基于 GNN 的监督学习框架,并且在 D2D 网络的链路调度问题和联合信道与功率分配问题中验证了算法的性能与泛化性优势。文献[19]研究了密集网络中的功率分配和波束成形 2 个优化问题,并将固定的调度用户集的链路状态建模为图,进而将其转换为图优化问题。针对所考虑的图优化问题,文献[19]设计了一种适用于大规模用户场景的无线信道图卷积网络算法,该算法的性能表现能够匹配甚至优于传统优化算法。文献[20]研究了密集异构网络的联合用户调度与功率分配问题,并提出了一种基于 GNN 的半监督图表示学习算法,但是该问题没有考虑用户的服务质量 (QoS, quality of service) 需求。文献[21]针对具有不同类型设备的多小区多用户蜂窝网络的功率分配问题,设计了一种能够在异构图上进行学习的 HetGNN (heterogeneous GNN) 模型,其拥有比传统的深度神经网络更低的训练时间开销和计算复杂度。值得注意的是,在上述所讨论的有关 GNN 模型的无线传输优化方案的研究中,均没有考虑用户调度与波束成形的联合优化问题,而是将它们作为 2 个子问题进行单独讨论。

在考虑用户服务质量需求的条件下,通过结合

上下行对偶理论和图神经网络，本文提出一种智能优化算法，用于解决多小区多用户 JT-CoMP 网络的联合用户调度与波束成形问题。相比于传统优化算法^[13]，所提算法不仅实现了更低的计算复杂度，还具有与其相匹配甚至更优的性能表现。本文主要的研究工作如下。

1) 建立多小区多用户 JT-CoMP 网络的下行链路协作通信系统模型，旨在降低跨小区用户的同频信号干扰并提高频谱效率。具体地，在满足用户最小速率需求和基站最大发射功率约束的基础上，本文研究用户调度与波束成形的联合优化问题，并以网络和速率最大化为目标。该问题是一个非凸的混合整数连续变量组合优化问题，难以求解。

2) 利用上下行对偶理论与基础的数学转换，将原始优化问题转换为虚拟上行链路的联合用户调度与波束成形问题。为了利用图神经网络进行学习及优化，对多小区协作系统的用户链路状态进行图表示，将无线传输方案优化问题表示为一个图优化问题。针对该图优化问题，设计一种基于空间域 GNN 的 M-JEEPON 模型用于用户调度与虚拟上行链路功率分配，并结合波束成形的解析公式，进而设计联合用户调度与波束成形的智能优化算法。

3) 为了验证所设计的 M-JEEPON 模型的有效性，将其与传统优化算法进行性能比较。仿真分析表明，所提算法能够实现与传统算法相匹配甚至更优的性能表现。此外，通过对所提算法理论计算复杂度的分析，发现其在计算效率上也具有优势。

1 系统模型

考虑一个多小区多用户下行链路联合发送无线通信系统，其包括 M 个具有 N_t 根天线的基站 (BS, base station) 和 K 个待服务的单天线用户设备 (UE, user equipment)，如图 1 所示。为了表示方便，令 $\mathcal{M} = \{1, 2, \dots, M\}$ 表示协作系统中的基站集合， $\mathcal{K} = \{1, 2, \dots, K\}$ 与 $\mathcal{S} = \{1, 2, \dots, K^*\} \subseteq \mathcal{K}$ 分别表示总用户集与调度用户集；令 $p_k \geq 0$ 表示协作系统中分配给用户 k 的下行链路传输功率， $\mathbf{h}_k \in \mathbb{C}^{MN_t \times 1}$ 与 $\mathbf{w}_k \in \mathbb{C}^{MN_t \times 1}$ 分别表示用户 k 的级联信道向量与单位波束向量，即 $\|\mathbf{w}_k\|_2 = 1, \forall k \in \mathcal{S}$ 。基于以上表述，用户 k 的接收基带信号 y_k 可表示为

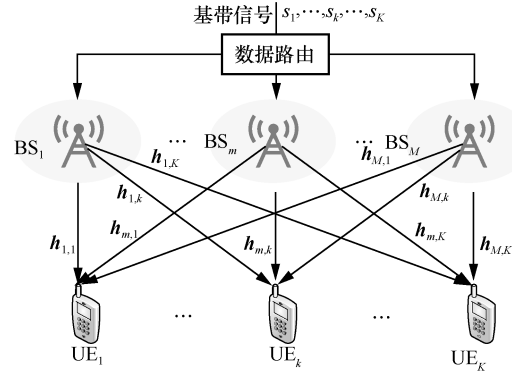


图1 多小区多用户下行链路联合发送无线通信系统

$$y_k = \sum_{l \in \mathcal{S}} \sqrt{p_l} \mathbf{h}_k^H \mathbf{w}_l s_l + n_k, \forall k \in \mathcal{S} \quad (1)$$

其中， s_l 和 n_k 分别表示用户 k 的基带信号和高斯白噪声，并且 $n_k \sim \mathcal{N}(0, \sigma_k^2)$ 服从正态分布。式(1)中， $\mathbf{h}_k = [\mathbf{h}_{k,1}^H, \mathbf{h}_{k,2}^H, \dots, \mathbf{h}_{k,M}^H]^H$ 为信道向量， $\mathbf{w}_k = [\mathbf{w}_{k,1}^H, \mathbf{w}_{k,2}^H, \dots, \mathbf{w}_{k,M}^H]^H$ 为波束向量，其中 $\mathbf{h}_{k,m} \in \mathbb{C}^{N_t \times 1}$ 和 $\mathbf{w}_{k,m} \in \mathbb{C}^{N_t \times 1}$ 分别表示基站 $m \in \mathcal{M}$ 关于用户 k 的信道向量和波束向量。令 $\bar{\mathbf{h}}_k = \frac{\mathbf{h}_k}{\sigma_k}$ ，则用户 k 的信干噪比可以表示为

$$\gamma_k = \frac{p_k |\bar{\mathbf{h}}_k^H \mathbf{w}_k|^2}{\sum_{l \neq k, l \in \mathcal{S}} p_l |\bar{\mathbf{h}}_k^H \mathbf{w}_l|^2 + 1} \quad (2)$$

本文以最大化多小区协作系统的和速率为目标，研究联合用户调度与波束成形优化问题，同时考虑调度用户最小速率需求与基站最大发射功率约束。因此，该联合优化问题被建模为

$$\begin{aligned} & \max_{\{S, p_k, \mathbf{w}_k\}_{k \in \mathcal{S}}} \sum_{k \in \mathcal{S}} R_k \\ & \text{s.t. } C_1: p_k > 0, \forall k \in \mathcal{S} \\ & \quad C_2: r_k \leq R_k, \|\mathbf{w}_k\|_2 = 1, \forall k \in \mathcal{S} \\ & \quad C_3: \sum_{k \in \mathcal{S}} p_k \|A_m \mathbf{w}_k\|_2^2 \leq P_m, \forall m \in \mathcal{M} \end{aligned} \quad (3)$$

其中， P_m 表示协作系统中基站 $m \in \mathcal{M}$ 的最大发射功率； $R_k = \text{lb}(1 + \gamma_k)$ 与 $r_k > 0$ 分别表示用户 $k \in \mathcal{S}$ 的速率与最小速率需求； p_k 表示调度用户集 \mathcal{S} 中的用户下行链路功率且 $p_k > 0$ ； A_m 表示协作系统中第 $m \in \mathcal{M}$ 个基站的置换矩阵，定义为

$$A_m[i, j] = \begin{cases} 1, & i = j = (m-1)N_t + 1, \dots, mN_t \\ 0, & \text{其他} \end{cases} \quad (4)$$

优化问题式(3)具有一个非凸的和速率最大化目标,其调度用户集 \mathcal{S} 是关于 0-1 用户选择的整数变量优化,而用户速率约束和基站发射功率约束是关于功率向量和波束向量的连续变量优化。因此,优化问题式(3)是一个非凸的混合整数连续变量组合优化问题。优化问题式(3)的求解涉及多个子问题的联合优化,包括调度用户集 \mathcal{S} 的选择、下行链路功率 $\{p_k\}$ 的分配,以及波束向量 $\{\mathbf{w}_k\}$ 的设计。类似于文献[13],优化问题式(3)被改写为

$$\begin{aligned} & \max_{\{\kappa_k, p_k, \mathbf{w}_k\}} \sum_{k \in \mathcal{K}} \kappa_k \bar{R}_k \\ \text{s.t. } & C_4: p_k \geq 0, \forall k \in \mathcal{K} \\ & C_5: \kappa_k \in \{0, 1\}, \forall k \in \mathcal{K} \\ & C_6: \kappa_k r_k \leq \bar{R}_k, \|\mathbf{w}_k\|_2 = 1, \forall k \in \mathcal{K} \\ & C_7: \sum_{k \in \mathcal{K}} p_k \|\mathbf{A}_m \mathbf{w}_k\|_2^2 \leq P_m, \forall m \in \mathcal{M} \end{aligned} \quad (5)$$

其中, $\boldsymbol{\kappa} = [\kappa_1, \kappa_2, \dots, \kappa_k, \dots, \kappa_K]^T$ 为二元指示向量,用于表示用户的调度状态,即 $\kappa_k = 1$ 表示用户 k 被调度, $\kappa_k = 0$ 表示用户 k 未被调度; $\bar{R}_k = \text{lb}(1 + \bar{\gamma}_k)$ 表示用户 $k \in \mathcal{K}$ 的下行链路速率, $\bar{\gamma}_k$ 表示用户 $k \in \mathcal{K}$ 的下行链路信干噪比,即

$$\bar{\gamma}_k = \frac{p_k |\bar{\mathbf{h}}_k^H \mathbf{w}_k|^2}{\sum_{l \neq k, l \in \mathcal{K}} p_l |\bar{\mathbf{h}}_k^H \mathbf{w}_l|^2 + 1} \quad (6)$$

引入二元指示向量 $\boldsymbol{\kappa}$, 使原始优化问题的用户集范围从不确定的调度用户集 \mathcal{S} 转变为确定的总用户集 \mathcal{K} 。进一步地,将优化问题式(5)的指示向量 $\boldsymbol{\kappa}$ 由离散值转换为连续值,得到优化问题式(7),即

$$\begin{aligned} & \max_{\{\kappa_k, p_k, \mathbf{w}_k\}} \sum_{k \in \mathcal{K}} \kappa_k \bar{R}_k \\ \text{s.t. } & C_4, C_6, C_7 \\ & C_8: \sum_{k \in \mathcal{K}} (\kappa_k - \kappa_k^2) \leq 0 \\ & C_9: 0 \leq \kappa_k \leq 1, \forall k \in \mathcal{K} \end{aligned} \quad (7)$$

为了简化求解,将下行链路优化问题式(7)转换成虚拟上行链路对偶优化问题式(8)^[13],即

$$\begin{aligned} & \max_{\boldsymbol{\lambda}} \min_{\{\kappa_k, q_k, \mathbf{w}_k\}} - \sum_{k \in \mathcal{K}} \kappa_k \bar{R}_k \\ \text{s.t. } & C_8, C_9 \\ & C_{10}: q_k \geq 0, \forall k \in \mathcal{K} \\ & C_{11}: \kappa_k r_k \leq \bar{R}_k, \|\mathbf{w}_k\|_2 = 1, \forall k \in \mathcal{K} \\ & C_{12}: \sum_{k \in \mathcal{K}} q_k \leq \sum_{m \in \mathcal{M}} \lambda_m P_m \end{aligned} \quad (8)$$

其中, $\boldsymbol{\lambda} = \{\lambda_1, \lambda_2, \dots, \lambda_M\}$ 表示非负的对偶向量; q_k 和 $\bar{R}_k = \text{lb}(1 + \bar{\gamma}_k)$ 分别表示协作系统中用户 $k \in \mathcal{K}$ 的虚拟上行链路功率和速率,且 $\mathbf{q} = [q_1, q_2, \dots, q_K]^T$, $\bar{\gamma}_k$ 表示用户 $k \in \mathcal{K}$ 的虚拟上行链路信干噪比,即

$$\bar{\gamma}_k = \frac{q_k |\bar{\mathbf{h}}_k^H \mathbf{w}_k|^2}{\sum_{l \neq k, l \in \mathcal{K}} q_l |\bar{\mathbf{h}}_l^H \mathbf{w}_k|^2 + \|\mathbf{A} \mathbf{w}_k\|_2^2} \quad (9)$$

其中,矩阵 $\mathbf{A} = \sum_{m \in \mathcal{M}} \sqrt{\lambda_m} \mathbf{A}_m$ 。对偶优化问题式(8)包括内层优化和外层优化 2 个部分。其中,内层优化部分是求解 $\boldsymbol{\lambda}$ 固定时的问题式(10),即

$$\begin{aligned} & \min_{\{\kappa_k, q_k, \mathbf{w}_k\}} - \sum_{k \in \mathcal{K}} \kappa_k \bar{R}_k \\ \text{s.t. } & C_8, C_9 \\ & C_{10}: q_k \geq 0, \forall k \in \mathcal{K} \\ & C_{11}: \kappa_k r_k \leq \bar{R}_k, \|\mathbf{w}_k\|_2 = 1, \forall k \in \mathcal{K} \\ & C_{12}: \sum_{k \in \mathcal{K}} q_k \leq \sum_{m \in \mathcal{M}} \lambda_m P_m \end{aligned} \quad (10)$$

在优化问题式(10)中,系统最优的波束向量 $\mathbf{W}^* = \{\mathbf{w}_k^* | k \in \mathcal{K}\}$ 是关于上行链路功率向量 \mathbf{q} 的解析式,即

$$\mathbf{w}_k^* = \frac{\left(\mathbf{A} + \sum_{l \in \mathcal{K}} q_l \bar{\mathbf{h}}_l \bar{\mathbf{h}}_l^H \right)^{-1} \bar{\mathbf{h}}_k}{\left\| \left(\mathbf{A} + \sum_{l \in \mathcal{K}} q_l \bar{\mathbf{h}}_l \bar{\mathbf{h}}_l^H \right)^{-1} \bar{\mathbf{h}}_k \right\|_2} \quad (11)$$

注意到,优化问题式(10)与优化问题式(7)的不同之处不仅是问题所考虑的传输链路不同,还包括波束向量 \mathbf{W} 的求解方式不同。其中,在下行链路优化问题式(7)中, \mathbf{W} 需要迭代优化,而在优化问题式(10)中, \mathbf{W} 是通过关于虚拟上行链路功率的解析公式求解得到的,不需要迭代优化。考虑对偶问题式(8)的外层优化部分时,固定内层的优化向量 $\{\boldsymbol{\kappa}, \mathbf{q}\}$ 和波束向量 \mathbf{W} ,通过次梯度法更新对偶向量 $\boldsymbol{\lambda}$,即

$$\lambda_m = \lambda_m + \varepsilon_\lambda \chi_c^{\leq} \left(\sum_{k \in \mathcal{K}} p_k \|\mathbf{A}_m \mathbf{w}_k\|_2^2 - P_m \right) \quad (12)$$

其中, $\varepsilon_\lambda \in \mathbb{R}^+$ 表示对偶向量 $\boldsymbol{\lambda}$ 的更新步长, $\chi_c^{\leq}(z) = \max\{z, 0\}$ 表示基于约束违背度的惩罚函数^[22],其采用逐元素比较的运算方式。值得注意的是,式(12)中的下行链路功率可以通过上行链路功率转换得到^[23],即

$$\mathbf{p} = \boldsymbol{\Psi}^{-1} \mathbf{1} \quad (13)$$

其中, $\mathbf{p} = [p_1, p_2, \dots, p_{K^*}]^T$ 表示下行链路功率向量, $\mathbf{1} \in \mathbb{R}^{K^* \times 1}$ 表示维度为 K^* 的全一向量, K^* 表示调度用户集 $\mathcal{S} = \{1, 2, \dots, K^*\}$ 中的用户索引最大值。矩阵 Ψ 定义为

$$[\Psi]_{k,l} = \begin{cases} \frac{|\bar{\mathbf{h}}_k^H \mathbf{w}_k|^2}{\tilde{\gamma}_k}, & k=l \\ -|\bar{\mathbf{h}}_k^H \mathbf{w}_l|^2, & k \neq l \end{cases} \quad (14)$$

经过上述的数学推导和转换, 相较于原始优化问题式(3), 对偶优化问题式(8)不仅解决了调度用户集 \mathcal{S} 的不确定性问题, 还将波束成形优化转变为虚拟上行链路功率分配优化。

2 联合用户调度与波束成形智能优化算法

前述工作通过上下行对偶理论与基础的数学转换, 将原始下行链路优化问题式(3)转换为虚拟上行链路对偶优化问题式(8), 但是其内层优化部分式(10)仍然是非凸优化问题, 难以直接求解。虽然文献[13]提出了用于求解该优化问题的基于 ZFBF-US 的贪婪优化算法, 以及基于 SCA-USBF 的优化算法, 但是 2 种优化算法均存在局限性, 即前者计算效率低, 而后者性能不足。值得注意的是, 以上 2 种基于模型驱动的优化算法均没有充分利用用户历史信道状态信息的统计学特性, 一旦无线网络环境发生变化, 就需要重新运行算法。

为了充分利用用户历史信道状态信息, 以及降低优化问题求解的计算开销, 本文借助图神经网络理论设计了一种联合用户调度与功率分配网络 (M-JEEPON, multi-cell joint user scheduling and power allocation network) 模型, 并结合波束向量 \mathbf{W} 的解析式, 进而提出一种联合用户调度与波束成形的智能优化算法, 具体实现过程如算法 1 所示。其中, $\mathcal{D} = \{\mathbf{h}_k | k \in \mathcal{K}\}$ 表示协作系统中总用户集 \mathcal{K} 的信道状态信息, Θ 表示 M-JEEPON 模型的网络参数集, $\Phi(\mathcal{D}, \Theta) = \{\boldsymbol{\kappa}, \mathbf{q}\}$ 表示 M-JEEPON 模型输出的关于样本 \mathcal{D} 的用户调度指示向量 $\boldsymbol{\kappa}$ 和虚拟上行链路功率向量 \mathbf{q} , 而波束向量 \mathbf{W} 通过解析式计算得到。接下来, 本文将介绍算法 1 的步骤 2) 中有关 M-JEEPON 模型的架构及训练算法。

算法 1 联合用户调度与波束成形智能优化算法

- 1) 采集系统用户信道样本数据 $\mathcal{D} = \{\mathbf{h}_k | k \in \mathcal{K}\}$;
- 2) 将用户信道样本数据 \mathcal{D} 输入训练后的

M-JEEPON 模型, 输出关于样本 \mathcal{D} 的联合用户调度和虚拟上行链路功率分配策略 $\Phi(\mathcal{D}, \Theta) = \{\boldsymbol{\kappa}, \mathbf{q}\}$, 并通过式(11)计算得到用户的波束向量 \mathbf{W} ;

3) 通过虚拟上行链路功率向量 \mathbf{q} 、用户波束向量 \mathbf{W} 和式(13)计算得到下行链路功率向量 \mathbf{p} , 求解下行链路的网络速率值。

2.1 拉格朗日对偶问题

对偶优化问题式(8)的内层优化问题式(10)是一个具有多约束的组合优化问题。为了将优化问题式(10)转变为一个无约束的优化问题, 本文将其约束项分为可投影约束集 $\mathcal{C}_1 = \{\mathcal{C}_9, \mathcal{C}_{10}, \mathcal{C}_{12}\}$ 和不可投影约束集 $\mathcal{C}_2 = \{\mathcal{C}_8, \mathcal{C}_{11}\}$ 。其中, 对于可投影约束集 \mathcal{C}_1 , 后续将采用合适的投影公式使其满足约束条件; 对于不可投影约束集 \mathcal{C}_2 , 通过引入非负的拉格朗日乘子将 \mathcal{C}_2 中的约束作为惩罚项加入目标函数。具体地, 引入非负的拉格朗日乘子 $\{\mu, \nu \in \mathbb{R}^+\}$ (对偶变量), 内层优化问题式(10)的部分拉格朗日松弛函数表示为

$$\mathcal{L}(\boldsymbol{\kappa}, \mathbf{q}, \mu, \nu) = -\sum_{k \in \mathcal{K}} \kappa_k \bar{R}_k + \mu \chi_c \leq \left(\sum_{k \in \mathcal{K}} \kappa_k - \kappa_k^2 \right) + \nu \chi_c \leq \left(\sum_{k \in \mathcal{K}} \kappa_k \tilde{\gamma}_k - \tilde{\gamma}_k \right) \quad (15)$$

其中, $\tilde{\gamma}_k = 2^{\tilde{r}_k} - 1$ 表示用户 $k \in \mathcal{K}$ 的最小速率所对应的信干噪比。用户速率约束被简化为上行链路信干噪比约束。进一步, 对偶优化问题式(8)可表示为

$$\max_{\{\boldsymbol{\lambda}, \mu, \nu\}} \min_{\{\boldsymbol{\kappa}, \mathbf{q}\}} \mathcal{L}(\boldsymbol{\kappa}, \mathbf{q}, \mu, \nu) \quad (16)$$

相应地, 对偶变量 $\{\mu, \nu\}$ 的更新方式为

$$\begin{cases} \mu = \mu + \varepsilon_\mu \chi_c \leq \left(\sum_{k \in \mathcal{K}} \kappa_k - \kappa_k^2 \right) \\ \nu = \nu + \varepsilon_\nu \chi_c \leq \left(\sum_{k \in \mathcal{K}} \kappa_k \tilde{\gamma}_k - \tilde{\gamma}_k \right) \end{cases} \quad (17)$$

其中, $\varepsilon_\mu, \varepsilon_\nu \in \mathbb{R}^+$ 分别表示对偶变量 μ, ν 的更新步长。为了方便表示, 令 Ω 表示优化问题式(8)中可投影约束的可行域, 其定义为

$$\Omega \triangleq \left\{ \boldsymbol{\kappa}^{(*)}, \mathbf{q}^{(*)} : 0 \leq \kappa_k^{(*)} \leq 1, q_k^{(*)} \geq 0, \sum_{k \in \mathcal{K}} q_k^{(*)} \leq \sum_{m \in \mathcal{M}} \lambda_m P_m, \forall k \in \mathcal{K} \right\} \quad (18)$$

其中, $\{\boldsymbol{\kappa}^{(*)}, \mathbf{q}^{(*)}\}$ 表示经过投影后的优化向量, 且

投影公式定义为

$$\begin{cases} \kappa_k^{(s)} = F(\kappa_k, 1), q_k' = F\left(q_k, \sum_{m \in \mathcal{M}} \lambda_m P_m\right) \\ q_k^{(s)} = \frac{\sum_{m \in \mathcal{M}} \lambda_m P_m}{\max\left\{\sum_{m \in \mathcal{M}} \lambda_m P_m, \sum_{k \in \mathcal{K}} q_k'\right\}} q_k' \end{cases} \quad (19)$$

其中, $F(z, t) = \max\{\min\{z, 0\}, t\}, t > 0$ 为区间 $[0, t]$ 的投影函数。基于以上的约束转换, 对偶优化问题式(16)已经成为一个无约束优化问题。考虑内层子优化问题时, 固定对偶变量 $\{\lambda, \mu, \nu\}$, 不断更新原始向量 $\{\kappa, q\}$ 和波束向量 W , 以使松弛函数 \mathcal{L} 最小; 当考虑外层子优化问题时, 固定 $\{\kappa, q\}$ 和 W , 并以次梯度方式更新 $\{\lambda, \mu, \nu\}$ 。

不同于传统优化算法通过多次迭代的方式更新优化变量以寻求目标函数最优化, M-JEEPON 模型通过学习用户历史信道及网络拓扑数据与目标函数的映射关系, 不断优化网络参数集以最优化目标值。在后续部分, 将介绍无线网络图表示和 M-JEEPON 模型。

2.2 多小区联合发送网络的图表示

本节通过设计一个无线网络图表示模块以结合用户历史信道状态信息和网络拓扑信息, 并将组合优化问题转换为图优化问题。为了减少无线网络用户信道构图的复杂度, 本节在构图过程中考虑将多小区联合发送网络中的多条用户通信链路及干扰链路进行合并, 即系统内每个用户只有一条通信链路及多条干扰链路。为了描述方便, 将无线网络的用户信道图表示为 $\mathcal{G}(\mathcal{V}, \mathcal{E})$, 其中 \mathcal{V} 表示图的节点集合, \mathcal{E} 表示图的边集合, 且节点表示用户设备与联合基站的通信链路, 而边则表示用户设备间的干扰链路。

图 $\mathcal{G}(\mathcal{V}, \mathcal{E})$ 中的节点 $v \in \mathcal{V}$ 和边 $\mathcal{E}_{u,v} \in \mathcal{E}$ 分别具有特征信息, 定义为 $\mathbf{x}_v = |\bar{\mathbf{h}}_v^H \mathbf{h}_v|$ 和 $\mathbf{e}_{u,v} = |\bar{\mathbf{h}}_u^H \mathbf{h}_v|$, 其中 $u \in \mathcal{V}$ 为节点 v 的一阶邻居节点。如图 2 所示, 多小区联合发送网络被转换为一个虚拟的多用户干扰信道完全有向图。 $\mathcal{G}(\mathcal{V}, \mathcal{E})$ 中的节点特征和边特征分别反映当前用户的通信链路特征与干扰链路特征。此外, 通过构图方式可以发现, $\mathcal{G}(\mathcal{V}, \mathcal{E})$ 的规模与协作系统内的用户数 K 相关, 图表示过程的计算复杂度为 $\mathcal{O}(K^2 MN_l)$, 其中 $\mathcal{O}(\cdot)$ 表示通过 Big-O 表示法统计的理论计算复杂度。




图 2 多小区协作系统的用户图表示

2.3 多小区联合用户调度与功率分配模型

前述工作将优化问题式(8)转换成无约束的拉格朗日对偶优化问题式(16)。在对偶优化问题式(16)的内层优化子问题中, 传统优化算法通过多次迭代更新 $\{\kappa, q\}$ 直至问题收敛, 进而通过式(11)计算 W 。本节通过设计 M-JEEPON 模型替代传统优化算法的迭代求解过程。在训练过程中, M-JEEPON 模型不断更新网络参数集来调整输出的 $\{\kappa, q\}$, 以使内层优化子问题的目标函数最小。

M-JEEPON 模型本质上可以看作输入的用户信道及网络拓扑数据与输出的 $\{\kappa, q\}$ 及 W 的映射函数。作为一种空间域类型的图卷积网络, M-JEEPON 模型被设计用于图上进行学习与优化, 其具有多个图卷积层, 各图卷积层之间采用基于消息传递机制的方式进行节点的消息聚合与嵌入表示向量更新^[24]。具体地, 节点 v 在 M-JEEPON 模型的第 ℓ 个图卷积层的优化向量更新规则定义为

$$\begin{cases} \mathbf{g}_v^{(\ell)} = G\left(\left\{M_\theta^{(\ell)}\left(\phi_u^{(\ell-1)}, \mathbf{x}_u, \mathbf{e}_{u,v}\right), \forall u \in \mathcal{N}_v\right\}\right) \\ \phi_v^{(\ell)} = U_\theta^{(\ell)}\left(\phi_v^{(\ell-1)}, \mathbf{x}_v, F_{\text{norm}}\left(\mathbf{x}_v, \mathbf{g}_v^{(\ell)}\right)\right) \end{cases} \quad (20)$$

其中, \mathcal{N}_v 表示节点 v 的一阶邻域节点集; $\phi_v^{(\ell)} = [\kappa_v, q_v] \in \mathbb{R}^2$ 表示节点 v 在图卷积层 ℓ 的优化向量, 且 $\phi_v^{(0)}$ 被初始化为全零向量, 当图卷积层 ℓ 的消息传递过程完成后, 节点 v 的嵌入表示向量更新为 $[\phi_v^{(\ell)}, \mathbf{x}_v]$; $F_{\text{norm}}(\cdot)$ 表示聚合消息标准化函数, 即

$$F_{\text{norm}}\left(\mathbf{x}_v, \mathbf{g}_v^{(\ell)}\right) = \|\mathbf{x}_v\|_2 \frac{\mathbf{g}_v^{(\ell)}}{\|\mathbf{g}_v^{(\ell)}\|_2} \quad (21)$$

通过对节点聚合消息进行标准化处理, 能够减轻由样本数据差异带来的影响, 使 M-JEEPON 模型在训练过程中保持稳定的学习^[25]。 $M_\theta^{(\ell)}(\cdot)$ 与 $U_\theta^{(\ell)}(\cdot)$ 分别表示节点消息生成函数与状态更新函数, 通过具有不同结构的神经网络模块实现。 $G(\cdot)$ 表示消息聚合

函数，用于汇聚属于各个节点与边的特征消息，其通过集合函数实现，如 $\max(\cdot)$ 与 $\text{mean}(\cdot)$ 函数等。图 3 展示了智能优化算法架构 (M-JEEPON 模型架构和波束向量求解层) 和训练框架。M-JEEPON 模型架构包含图表示层、 L 个图卷积层与约束投影层，以捕获图中节点 v 的邻域节点与边特征信息。注意到，M-JEEPON 模型以用户信道数据输入 $\mathcal{D} = \{\mathbf{h}_k | k \in \mathcal{K}\}$ ，输出无线用户调度和虚拟上行链路用户功率分配策略 $\Phi(\mathcal{D}, \Theta) = \{\kappa_k, q_k\}$ 及波束向量 \mathbf{W} 。

M-JEEPON 模型的训练过程反映的是无约束拉格朗日对偶问题式(16)的求解过程，其通过内层优化和外层优化交替迭代的方式不断更新 M-JEEPON 模型的网络参数集 Θ ，直至训练阶段结束。M-JEEPON 模型的训练过程如算法 2 所示，其包括两层循环步骤，分别为训练循环和样本遍历循环。算法 2 中的步骤 2) 表示 M-JEEPON 模型的图表示层，其在循环外部生成用户信道图表示，避免重复计算；步骤 5) 和步骤 6) 分别表示 M-JEEPON 模型的图卷积层和波束向量求解层。一旦 M-JEEPON 模型完成训练，就能够直接应用于算法 1 的步骤 2)。

算法 2 M-JEEPON 模型的训练过程

1) 初始化 M-JEEPON 模型的网络参数集 Θ 、图卷积层数 L ，以及训练的次数 \hat{N} ；

2) 采集训练用户信道样本 $\hat{\mathcal{D}} = \{\mathcal{D}_i\}_{i=1}^{\hat{N}}$ ，针对每个训练样本 \mathcal{D}_i 生成用户信道图表示 $\mathcal{G}_i(\mathcal{V}, \mathcal{E})$ ，并初始化图中各节点的优化向量 $\{\phi^{(0)}, \forall v \in \mathcal{V}\}$ ；

3) 循环开始，训练迭代次数从 1 遍历至 \hat{N} ；

4) 循环开始，样本迭代次数从 \mathcal{G}_i 遍历至 $\mathcal{G}_{\hat{N}}$ ；

5) 输入图 \mathcal{G}_i 至图卷积层，通过式(20)更新节点优化向量 $\{\phi^{(l)}, \forall v \in \mathcal{V}\}$ ，并将其作为下一层的输入，直至获得由图卷积层 L 输出的 $\{\phi^{(L)}, \forall v \in \mathcal{V}\}$ ；

6) 输入 $\{\phi^{(L)}, \forall v \in \mathcal{V}\}$ 至投影函数层，获得图 \mathcal{G}_i 的无线资源管理策略 $\Phi(\mathcal{D}_i, \Theta)$ ，并通过式(11)计算波束向量 \mathbf{W} ；

7) 通过 $\Phi(\mathcal{D}_i, \Theta)$ 和波束向量 \mathbf{W} 计算式(15)的目标函数值，并更新网络参数集 Θ ，同时记录对偶变量 $\{\lambda, \mu, \nu\}$ 的约束违背度；

8) 循环结束；

9) 外层优化部分，通过式(12)、式(17)和记录的约束违背度，更新 $\{\lambda, \mu, \nu\}$ ；

10) 循环结束；

11) 保存训练完成后的 M-JEEPON 模型。

3 仿真分析

本节通过仿真实验比较 ZFBF-US 算法、SCA-USBF 算法和 M-JEEPON 模型的性能表现，并

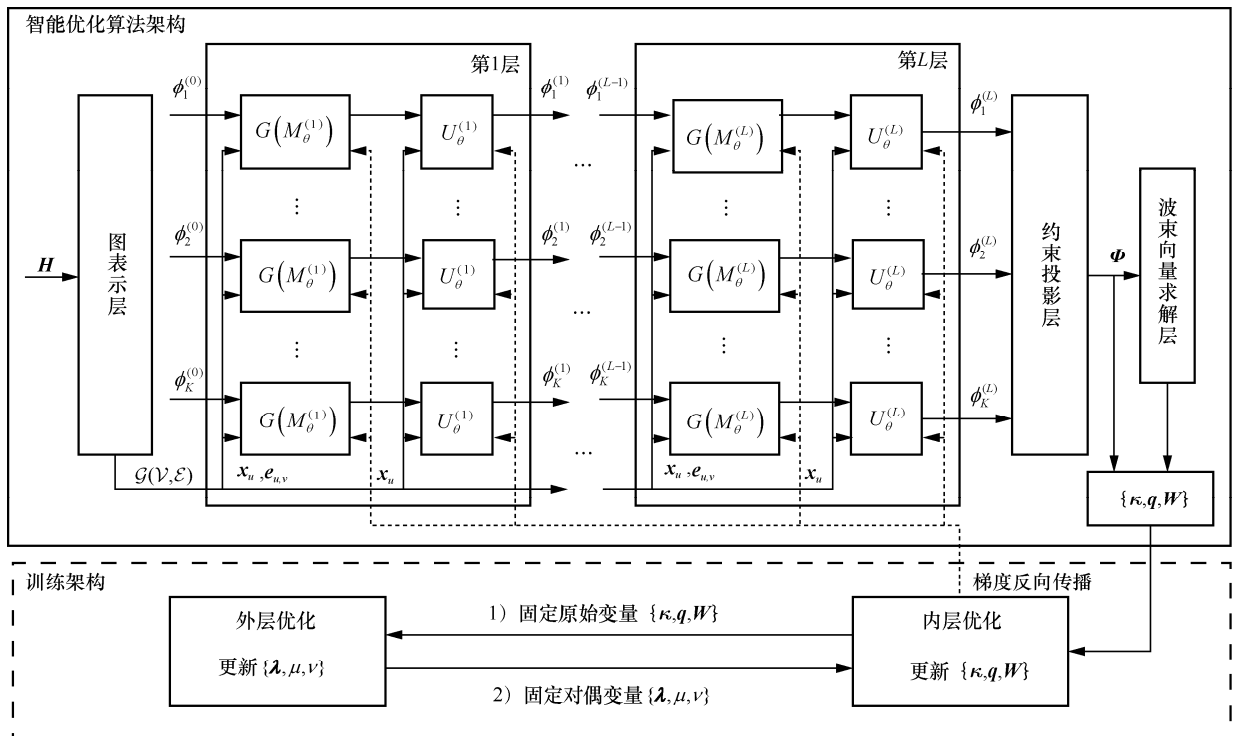


图 3 智能优化算法架构和训练框架

在小规模系统场景验证 3 种算法和用户调度与波束成形的穷举搜索 (BFS-USBF, brute force search for user scheduling and beamforming) 算法的性能差距。为了确保比较的公平性, 传统优化算法收敛精度保持相同, 并且以测试样本的平均和速率为比较目标, 以平均调度用户数为参考目标, 算法的结果分别表示为 R_1 与 R_2 。对于 M-JEEPON 模型, 其训练样本与测试样本也在相同的系统参数中被独立生成。此外, 各算法的理论计算复杂度也将被讨论, 以衡量算法的综合性能表现。

3.1 多小区信道模型与系统参数

考虑一个由多个相邻小区组成的蜂窝网络场景, 其中各小区基站均位于本小区中心且由同一个协作系统进行联合管理与调度。具体地, 协作系统所包含的小区数量为 $M = 3$, 各个小区具有规则的六边形网格布局并且小区半径为 $d_r = 300$ m。如图 4 所示, 协作系统中的 K 个用户随机分布在各相邻小区的协作区域中, 其半径为 $d_c = 100$ m。本文将协作系统中基站 $m \in \mathcal{M}$ 与协作区中用户 $k \in \mathcal{K}$ 的信道状态向量表示为 $\bar{\mathbf{h}}_k = \sqrt{\rho_k} \tilde{\mathbf{h}}_k \in \mathbb{C}^{N_r \times 1}$ 。其中, $\tilde{\mathbf{h}}_k$ 表示小尺度衰落, 服从 $\tilde{\mathbf{h}}_k \sim \mathcal{CN}(\mathbf{0}, \mathbf{I}_{N_r})$ 的正态分布; $\rho_k \in \mathbb{R}^+$ 表示大尺度衰落系数, 具体值可参考文献[13]。假设协作系统中所有用户具有相同的噪声方差, 即 $\sigma_k^2 = \sigma^2, k \in \mathcal{K}$ 。因此, 基站 $m \in \mathcal{M}$ 的信噪比为 $\text{SNR} = 10 \log_{10} \left(\frac{P_m}{\sigma^2} \right)$ dB。此外, 为了方便比较, 统一协作系统中用户的最小速率需求 $r_k = r_{\min}, k \in \mathcal{K}$, 其中 r_{\min} 的数值依据实验设定。




图 4 多小区协作系统的用户分布

在实验中, M-JEEPON 模型的设计与实现基于 Pytorch 深度学习库, 并采用学习率为 $\eta = 1 \times 10^{-5}$ 的 Adam 优化器^[26]进行网络参数的更新。在训练过程中, 设置训练迭代次数为 200, 而对偶变量 $\{\lambda, \mu, \nu\}$ 的更新步长为 $\varepsilon_\lambda, \varepsilon_\mu, \varepsilon_\nu = 1 \times 10^{-5}$ 。为了评估 M-JEEPON 模型与其他算法的性能, 设置测试样本大小为 500, 训练样本大小为 2 000, 训练样本与测试样本相互独立且样本比例为 4:1。此外, 如无特殊说明, 多小区协作系统的默认仿真参数如表 1 所示。

表 1 多小区协作系统的默认仿真参数

系统默认参数	参数值
基站总数 M	3
基站天线数 N_r	8
系统用户数 K	20
基站信噪比 SNR/dB	10
用户最小速率需求 $\gamma_{\min}/(\text{bit} \cdot (\text{s} \cdot \text{Hz})^{-1})$	2
优化算法的收敛精度	5×10^{-3}

3.2 M-JEEPON 模型训练阶段的收敛性分析

本节探讨 M-JEEPON 模型在训练阶段的目标函数和约束违背度的收敛情况。具体地, 实验采用默认的系统参数进行仿真, 测试 M-JEEPON 模型在训练阶段的目标函数曲线, 以及不可投影约束集 $\mathcal{C}_2 = \{C_8, C_{11}\}$ 的约束违背度曲线, 结果如图 5 所示。从图 5 可知, 随着迭代次数的增加, M-JEEPON 模型的网络参数集被不断更新, 致使模型输出的优化变量所对应的目标函数 (和速率) 值增大, 并逐渐趋于稳定状态, 这表明算法 2 的有效性。此外, 随着迭代次数的增加, M-JEEPON 模型逐渐向约束违背度减小的方向发展, 约束 C_8 和约束 C_{11} 的违背度均逐渐趋于 0。需要指出的是, M-JEEPON 模型并不能总是使输出的优化变量满足约束集 \mathcal{C}_2 。一旦出现此情况, 解决方案是先将用户调度向量 κ 稀疏化为 0 或 1, 再根据优化向量 $\{\kappa, \mathbf{q}\}$ 和波束向量 \mathbf{W} 剔除不满足用户最小速率约束的用户, 最后输出满足约束集 \mathcal{C}_2 的 $\{\kappa, \mathbf{q}\}$ 和 \mathbf{W} , 并计算目标函数值。基于上述分析, M-JEEPON 模型在训练过程中能够使目标函数收敛, 但是无法使输出的优化向量总满足约束集 \mathcal{C}_2 , 仍需要进一步处理, 以使其满足约束条件。




图 5 训练阶段的目标函数和约束违背度曲线

3.3 不同用户数场景的算法比较

本节探讨协作系统中不同用户数 K 对算法性能的影响。具体地，采用 2 种实验场景进行比较：1) 小规模场景，验证 ZFBF-US 算法、SCA-USBF 算法、M-JEEPON 模型与 BFS-USBF 算法的性能差距；2) 大规模场景，测试前 3 种算法的性能表现。在小规模用户场景下，设置基站信噪比 $SNR = 0$ ，基站天线数 $N_t = 2$ ，用户最小速率需求 $r_{\min} = 1 \text{ bit/(s·Hz)}$ 与用户数 $K \in \{4, 6, 8, 10\}$ ；在大规模场景下，按照用户数 $K \in \{5, 10, 20, 30\}$ 与系统其他默认参数进行实验仿真。其中，小规模场景下不同用户数的算法结果如表 2 所示。对比 BFS-USBF 算法，M-JEEPON 模型与 SCA-USBF 算法都能够实现与其相接近的性能表现 (R_1 值超过 BFS-USBF 算法的 92%)，而 ZFBF-US 算法则与其有着显著的差距。对比 SCA-USBF 算法，虽然 M-JEEPON 模型的 R_1 值相对较低 (R_1 值高于 SCA-USBF 算法的 93%)，但是随着 K 的增加，M-JEEPON 模型的性能逐渐接近 SCA-USBF 算法。此外，表 2 的结果也表明由 K 值增加所带来的多用户分集增益会使算法的 R_1 值与 R_2 值均得到提升。

表 2 小规模场景下不同用户数的算法结果

K	BFS-USBF		ZFBF-US		SCA-USBF		M-JEEPON	
	R_1	R_2	R_1	R_2	R_1	R_2	R_1	R_2
4	12.362	3.162	10.358	2.330	12.096	3.614	11.257	3.032
6	14.912	3.790	12.536	2.852	14.054	4.040	13.565	3.778
8	16.299	4.202	13.764	3.168	15.219	4.392	14.952	4.046
10	17.950	4.497	15.412	3.602	16.567	4.672	16.510	4.140

在大规模场景下，由于 BFS-USBF 算法的计算复杂度过高，故不参与比较，其他 3 种算法的结果如表 3 所示。从表 3 中可以发现，随着 K 的增加，M-JEEPON 模型的 R_1 值逐渐接近并超过 SCA-USBF 算法的结果，并且始终优于 ZFBF-US 算法。特别是，当 $K \geq 20$ 时，ZFBF-US 算法的性能趋于稳定，但是它的 R_1 值显著低于其他 2 种算法的结果。这是因为 SCA-USBF 算法与 M-JEEPON 模型是针对当前优化问题专门设计的，而 ZFBF-US 算法则是利用迫零波束成形与半正交用户选择以实现网络和速率最大化，无法保证结果最优。此外，表 3 中的算法结果还反映了另一个现象，即当 $K \geq 10$ 时，相较于另外 2 种算法，M-JEEPON 模型虽然系统平均和速率更高，但是它所对应的平均调度用户数却并不是最多的。基于上述比较，在大规模场景下，M-JEEPON 模型更具性能优势。

表 3 大规模场景下不同用户数的算法结果

K	ZFBF-US		SCA-USBF		M-JEEPON	
	R_1	R_2	R_1	R_2	R_1	R_2
5	31.756	4.664	33.098	4.924	32.196	4.980
10	50.821	8.754	53.245	9.886	53.221	9.608
20	67.523	15.326	74.392	17.224	77.148	14.764
30	68.598	19.928	81.598	20.129	89.140	16.724

3.4 不同天线数场景的算法比较

本节探讨基站不同天线数 N_t 对算法性能的影响。为了避免用户规模可能对算法造成的影响，采用 2 种 K 值的实验场景进行比较。具体地，实验设置基站天线数 $N_t \in \{4, 6, 8, 10, 12\}$ 与用户数 $K \in \{10, 20\}$ ，而其他参数采用默认值，结果如图 6 所示。

从图 6 可知，当 K 相同时，增大 N_t 值能够带来显著的多天线增益，使算法的 R_1 值得到提升。当 $K = 10$ 时，M-JEEPON 模型能够保持与 SCA-USBF 算法相近的性能表现，并且此时系统内的绝大部分用户可以被调度。当 $K = 20$ 时，系统的资源无法支持调度所有用户，M-JEEPON 模型的 R_1 值随着 N_t 值的增大逐渐接近并超过 SCA-USBF 算法的结果，并且其性能一直优于 ZFBF-US 算法。通过实验结果也可以观察到，ZFBF-US 算法在 $N_t = 4$ 场景下的 R_1 值接近另外 2 种算法的结果。这是因为基站天线数越少，ZFBF-US 算法越容易找到一组信道近似正交的用户组合，使其获得与另外 2 种算法相近的性能表现。当 N_t 相同时，通过增大 K 值能够给 3 种

算法带来显著的性能增益,尤其是对于 $N_t = 12$ 的算法结果。这是因为当系统资源有限时,适当增加 K 值的大小,能够提高调度用户集的可选择性,有利于实现高的网络和速率。基于上述比较,通过增加基站天线数能够提高网络和速率,并且 M-JEEPON 模型相对另外 2 种算法更能利用好天线增益。

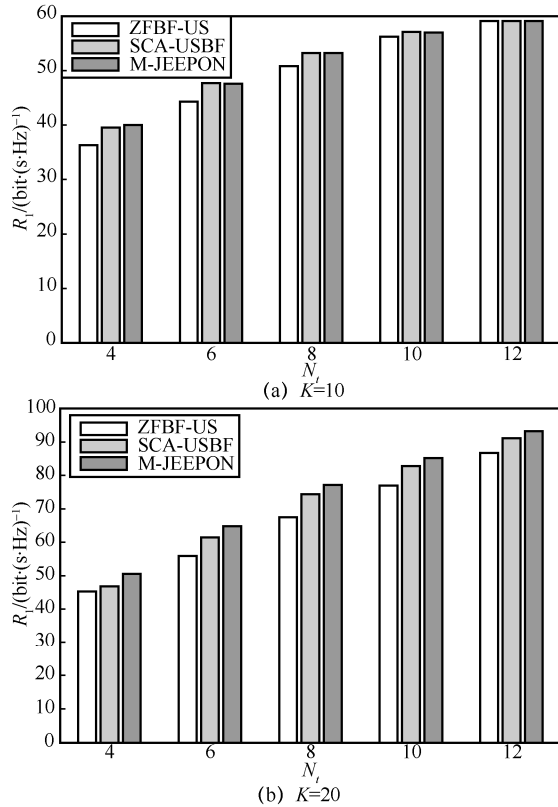


图 6 基站不同天线数场景的算法 R_1 值结果

3.5 不同信噪比场景的算法比较

本节探讨协作系统中基站不同信噪比对算法性能的影响。具体地,设置基站 $SNR \in \{0, 5, 10, 15, 20, 25\}$ dB,而其他系统参数保持默认设置,算法 R_1 值结果如图 7 所示。从图 7 可知, M-JEEPON 模型的 R_1 值始终高于另外 2 种算法,并且能够与 SCA-USBF 算法保持一个稳定的状态。对比 ZFBF-US 算法,当 SNR 低于 10 dB 时, M-JEEPON 模型更具性能优势;当 SNR 超过 10 dB 时, ZFBF-US 算法与 M-JEEPON 模型的 R_1 值差距减小,但仍不高于后者 R_1 值的 94%。对比 ZFBF-US 算法与 SCA-USBF 算法可以发现,随着 SNR 的增加,前者逐渐接近后者的 R_1 值,但始终未曾超过后者。这表明,即使系统资源增加使优化问题的解空间增大,但是 ZFBF-US 算法获得的依然是优化问题的局部解,而 SCA-USBF 算法的解是近优解。

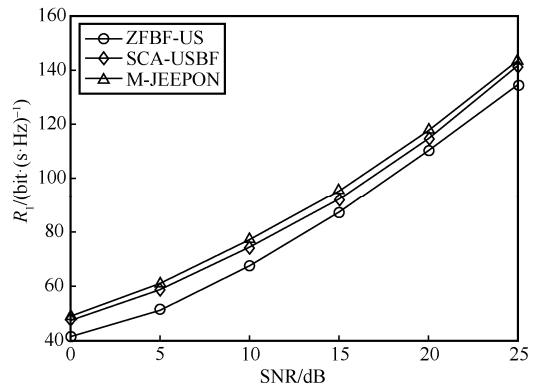


图 7 基站不同信噪比场景的算法 R_1 值结果

3.6 不同用户速率场景的算法比较

本节探讨协作系统中用户最小速率需求对算法性能的影响。具体来说,设置不同的用户最小速率需求 $r_{\min} \in \{1, 2, 3, 4, 5\}$ bit/(s·Hz),而其他系统参数均保持默认设置,算法结果如表 4 所示。从表 4 可以看到, M-JEEPON 模型的 R_1 值可以在不同的 r_{\min} 值设置中取得更优的性能表现,并且 SCA-USBF 算法的 R_1 值也同样优于 ZFBF-US 算法。

表 4 用户不同最小速率需求场景的算法结果

r_{\min}	ZFBF-US		SCA-USBF		M-JEEPON	
	R_1	R_2	R_1	R_2	R_1	R_2
1	64.607	15.458	66.953	19.992	73.248	14.718
2	67.523	15.326	74.392	17.224	77.148	14.764
3	71.765	15.174	76.033	14.85	80.955	14.540
4	77.013	14.998	80.755	14.342	84.051	14.314
5	82.885	14.304	84.124	13.272	88.101	13.112

此外,表 4 的结果也表明,当协作系统的总功率固定时,通过增大 r_{\min} 能够提高 3 种算法的 R_1 值,但是相应的 R_2 值将降低。这是因为 r_{\min} 值的增加会导致协作系统能够调度的用户数减少,这间接减小了用户间的干扰,有利于算法获得更高的 R_1 值。但是这并不意味着 r_{\min} 值的无限增大会一直带来正向效果。可以预测的是,这最终会导致协作系统因为无法满足用户最小速率需求而无法调度任何一个用户,使算法获得的 R_1 值为 0。基于上述比较, M-JEEPON 模型在不同用户最小速率需求场景中能够取得更优的系统平均和速率表现。

3.7 不同算法的计算复杂度比较

本节通过 Big-O 表示法分析算法的理论计算复杂度。为了表示方便,令 $\hat{k} \leq K$ 表示调度用户集 S 的用户数, $\bar{N} = BN_t$ 表示系统总天线数。具体地, ZFBF-US 算法主要包括用户选择与波束向量优化

2 个部分，其计算复杂度分别为 $\mathcal{O}((K - \hat{k})\hat{k}\bar{N})$ 和 $\mathcal{O}(\hat{k}^3 + \hat{k}^2\bar{N} + \xi_1 \text{It}_1(\hat{k}M\bar{N}^2))$ ，其中 It_1 与 ξ_1 分别为迭代次数和集合 \mathcal{S} 是否存在可行解的指示变量。因此，ZFBF-US 算法的计算复杂度为 $\mathcal{O}\left(\sum_{k=1}^K \hat{k}k\bar{N} + \hat{k}^3 + \xi_1 \text{It}_1(\hat{k}M\bar{N}^2)\right)$ 。BFS-USBF 算法主要包括可行用户组合遍历和波束向量优化 2 个部分，其复杂度分别为 $t_1 = \mathcal{O}(\text{It}_2(\hat{k}^2\bar{N} + \hat{k}\bar{N}))$ 和 $t_2 = \mathcal{O}(\text{It}_3(\hat{k}\bar{N}^2 + \hat{k}^2\bar{N} + \bar{N}^3))$ ， It_2 与 It_3 分别为这 2 个部分的迭代次数。因此，BFS-USBF 算法的计算复杂度为 $\mathcal{O}\left(\sum_{k=1}^K \frac{\hat{k}!}{\hat{k}!(K - \hat{k})!}(t_1 + \xi_2 t_2)\right)$ ，其中 ξ_2 为集合 \mathcal{S} 是否存在可行解的指示变量。

SCA-USBF 算法主要包括对偶问题的内层与外层优化 2 个部分，其复杂度分别为 $\mathcal{O}(\text{It}_4(K^2\bar{N} + \bar{N}^3))$ 和 $\mathcal{O}(\text{It}_5(K\bar{N}^2 + K^2))$ ，其中 It_4 与 It_5 分别为 2 个部分的迭代次数。因此，SCA-USBF 算法的计算复杂度为 $\mathcal{O}(\text{It}_4(K^2\bar{N} + \bar{N}^3 + \text{It}_5(K\bar{N}^2 + K^2)))$ 。M-JEEPON 模型主要包括图表示模块、图卷积模块和波束向量模块 3 个部分。为了表示方便，假设图卷积模块均由维度为 $\{h_j \in \mathcal{H}\}$ 的多层感知机构成。其中，图表示模块的复杂度为 $\mathcal{O}(K^2\bar{N})$ ，波束向量模块的复杂度为 $\mathcal{O}(K\bar{N}^2)$ ，而图卷积模块的复杂度为 $\mathcal{O}\left(K \sum_{\ell=1}^L \sum_{j=1}^{|\mathcal{Z}|} h_{\ell,j-1} h_{\ell,j}\right)$ 。因此，M-JEEPON 模型的复杂度为 $\mathcal{O}\left(K^2\bar{N} + K\bar{N}^2 + K \sum_{\ell=1}^L \sum_{j=1}^{|\mathcal{Z}|} h_{\ell,j-1} h_{\ell,j}\right)$ 。

为了直观地比较，本节讨论不同用户数 K 场景下各算法计算复杂度数量级，而其他系统参数保持默认设置，结果如图 8 所示。其中，BFS-USBF 算法的计算复杂度受 K 的影响极大，ZFBF-US 算法和 SCA-USBF 算法次之，而 M-JEEPON 模型最小。这是因为 BFS-USBF 算法需要遍历所有可行用户组合，SCA-USBF 算法和 BFS-USBF 算法的主要计算开销是波束优化部分，而 M-JEEPON 模型的主要计算开销是神经网络模块，但其受 K 的影响并不明显，且波束向量通过解析公式求解，故其计算复杂度最低。基于以上分析，M-JEEPON 模型在算法计算效率方面也具有优势。




图 8 各算法计算复杂度数量级

4 结束语

本文在考虑用户最小速率需求和基站最大发射功率的约束条件下，研究了多小区协作系统的联合用户调度与波束成形优化问题。为了降低传统优化算法的计算复杂度，本文将无线网络资源优化问题转换为图优化问题，进而设计了一种基于空间域 GNN 的 M-JEEPON 模型，并结合波束向量解析公式提出了一种联合用户调度和波束成形智能优化算法。仿真分析表明，所提算法不仅在大规模系统场景具有更优的性能表现，同时也拥有比 SCA-USBF 算法和 ZFBF-US 算法更低的计算复杂度。在后续的研究中，将进一步探讨其他无线网络资源优化问题的智能化解决方案，以达到提高网络频谱效率和用户服务质量的目的。

参考文献：

- [1] BHUSHAN N, LI J Y, MALLADI D, et al. Network densification: the dominant theme for wireless evolution into 5G[J]. IEEE Communications Magazine, 2014, 52(2): 82-89.
- [2] BASSOY S, FAROOQ H, IMRAN M A, et al. Coordinated multi-point clustering schemes: a survey[J]. IEEE Communications Surveys & Tutorials, 2017, 19(2): 743-764.
- [3] 3GPP. Coordinated multi-point operation for LTE physical layer aspects, v11.2.0[R]. TR 36.19 R11, 2013.
- [4] SOLAJIJA M S J, SALMAN H, KIHHERO A B, et al. Generalized coordinated multipoint framework for 5G and beyond[J]. IEEE Access, 2020, 9: 72499-72515.
- [5] QAMAR F, DIMYATI K B, HINDIA M N, et al. A comprehensive review on coordinated multi-point operation for LTE-A[J]. Computer Networks, 2017, 123: 19-37.
- [6] MUHAMMED A J, MA Z, DING Z G, et al. Resource allocation for energy-efficient NOMA system in coordinated multi-point networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(2): 1577-1591.
- [7] LI M, COLLINGS I B, HANLY S V, et al. Multicell coordinated scheduling with multiuser zero-forcing beamforming[J]. IEEE Transactions on Wireless Communications, 2016, 15(2): 827-842.
- [8] ZHAI D S, ZHANG R N, CAI L, et al. Energy-efficient user scheduling


and power allocation for NOMA-based wireless networks with massive IoT devices[J]. IEEE Internet of Things Journal, 2018, 5(3): 1857-1868.

- [9] LI Z D, CHEN W, WU Q Q, et al. Robust beamforming design and time allocation for IRS-assisted wireless powered communication networks[J]. IEEE Transactions on Communications, 2022, 70(4): 2838-2852.
- [10] FU B, XIAO Y, DENG H M, et al. A survey of cross-layer designs in wireless networks[J]. IEEE Communications Surveys & Tutorials, 2014, 16(1): 110-126.
- [11] CHEN Q M, YANG K X, JIANG H, et al. Joint beamforming coordination and user selection for CoMP enabled NR-U networks[J]. IEEE Internet of Things Journal, 2021, PP(99): 1.
- [12] KIM Y, JEONG J, AHN S, et al. Energy and delay guaranteed joint beam and user scheduling policy in 5G CoMP networks[J]. IEEE Transactions on Wireless Communications, 2022, 21(4): 2742-2756.
- [13] HE S W, AN Z Y, ZHU J Y, et al. Cross-layer optimization: joint user scheduling and beamforming design with QoS support in joint transmission networks[J]. arXiv Preprint, arXiv: 2203.00934, 2022.
- [14] HE S W, XIONG S W, OU Y Y, et al. An overview on the application of graph neural networks in wireless networks[J]. IEEE Open Journal of the Communications Society, 2021, 2: 2547-2565.
- [15] 伏玉笋, 杨根科. 人工智能在移动通信中的应用: 挑战与实践[J]. 通信学报, 2020, 41(9): 190-201.
FU Y S, YANG G K. Application of artificial intelligence in mobile communication: challenge and practice[J]. Journal on Communications, 2020, 41(9): 190-201.
- [16] SHEN Y F, SHI Y M, ZHANG J, et al. A graph neural network approach for scalable wireless power control[C]//Proceedings of 2019 IEEE Globecom Workshops. Piscataway: IEEE Press, 2019: 1-6.
- [17] LEE M Y, YU G D, LI G Y. Graph embedding-based wireless link scheduling with few training samples[J]. IEEE Transactions on Wireless Communications, 2021, 20(4): 2282-2294.
- [18] CHEN T R, ZHANG X R, YOU M L, et al. A GNN-based supervised learning framework for resource allocation in wireless IoT networks[J]. IEEE Internet of Things Journal, 2022, 9(3): 1712-1724.
- [19] SHEN Y F, SHI Y M, ZHANG J, et al. Graph neural networks for scalable radio resource management: architecture design and theoretical analysis[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1): 101-115.
- [20] ZHANG X Y, ZHANG Z M, YANG L X. Joint user association and power allocation in heterogeneous ultra dense network via semi-supervised representation learning[J]. arXiv Preprint, arXiv: 2103.15367, 2021.
- [21] GUO J, YANG C Y. Learning power allocation for multi-cell-multi-user systems with heterogeneous graph neural networks[J]. IEEE Transactions on Wireless Communications, 2022, 21(2): 884-897.
- [22] FIORETTO F, MAK T W K, VAN HENTENRYCK P. Predicting AC optimal power flows: combining deep learning and Lagrangian dual methods[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020: 630-637.
- [23] HE S W, AN Z Y, ZHU J Y, et al. Beamforming design for multiuser uRLLC with finite blocklength transmission[J]. IEEE Transactions on Wireless Communications, 2021, 20(12): 8096-8109.
- [24] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry[C]//Proceedings of International Conference on Machine Learning. New York: PMLR, 2017: 1263-1272.
- [25] ZHOU K X, HUANG X, LI Y N, et al. Towards deeper graph neural networks with differentiable group normalization[J]. Advances in Neural Information Processing Systems, 2020, 33: 4917-4928.
- [26] KINGMA D P, BA J. Adam: a method for stochastic optimization[J]. arXiv Preprint, arXiv: 1412.6980, 2014.

[作者简介]



何世文(1978-),男,湖南汝城人,博士,中南大学教授、博士生导师,主要研究方向为无线通信与网络、分布式学习与优化计算理论、智能物联网(AIoT)和大数据分析的基础理论研究与无线通信网络平台开发及先进理论技术验证。



袁军(1997-),男,安徽六安人,中南大学硕士生,主要研究方向为图神经网络理论及其应用。



安振宇(1988-),男,安徽蚌埠人,博士,网络通信与安全紫金山实验室高级工程师,主要研究方向为超可靠低时延通信、跨层优化、智能优化等。



张敏(1974-),女,湖南平江人,湖南邮电职业技术学院教授,主要研究方向为多用户通信、协作通信、绿色通信、大规模多输入多输出通信。



黄永明(1977-),男,江苏吴江人,东南大学教授、博士生导师,主要研究方向为MIMO无线通信、协作无线通信、微波无线通信及应用。



张尧学(1956-),男,湖南常德人,中国工程院院士,清华大学教授、博士生导师,主要研究方向为计算机网络、操作系统以及普适计算。