

DOI: 10.13382/j.jemi.B2307009

柔性双工网络功率分配:边剪枝加速的 GNN 计算*

王子威¹ 陶旭² 李晖^{1,2,3} 史振婷¹ 张见² 徐钰龙¹

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 无锡学院江苏省集成电路可靠性技术及检测系统工程研究中心 无锡 214105; 3. 中国航空研究院研究生院 扬州 225006)

摘要: 由于用户间干扰的存在,无线通信网络中的功率分配问题往往是非凸的、计算量巨大。当前图神经网络(graph neural network, GNN)成为一种有效的计算方法被用来解决这个问题。为了最大限度地提高网络传输速率的同时降低计算复杂度,提出一种将设备属性和通信连接属性纳入 GNN 的柔性双工网络图表示方法,并构建了相应的柔性双工图神经网络(flexible duplex GNN, FD-GNN)模型,首次将节点对之间的距离、信道增益和邻居作为动态阈值引入到 FD-GNN 中,以适应动态环境。排除 GNN 中邻居的信道状态信息,通过修剪 FD-GNN 中的边来减少计算时间降低网络时间复杂度。仿真表明,所提出的基于信道增益邻居的阈值设定方法,性能最优且达到加权最小均方误差(weighted minimum mean square error, WMMSE)的 97%,相较于 Full-GNN 所需的训练时间下降 24%。提出的基于阈值的边剪枝有效降低了 GNN 运算的时间复杂度,提高了算法有效性。

关键词: 图神经网络;柔性双工网络;功率分配;动态阈值;时间复杂度

中图分类号: TN915.81 **文献标识码:** A **国家标准学科分类代码:** 510.5030

Power allocation in flexible duplex networks: GNN computation accelerated by edge pruning

Wang Ziwei¹ Tao Xu² Li Hui^{1,2,3} Shi Zhenting¹ Zhang Jian² Xu Yulong¹

(1. College of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Jiangsu Integrated Circuit Reliability Technology and Testing System Engineering Research Center, Wuxi University, Wuxi 214105, China; 3. Graduate School of Chinese Aeronautical Establishment, Yangzhou 225006, China)

Abstract: Due to the presence of interference between users, power allocation problems in wireless communication networks are often non convex and require a huge amount of computation. The current graph neural network (GNN) has become an effective computational method used to solve this problem. In order to maximize network transmission speed while reducing computational complexity, a flexible duplex network graph representation method that incorporates device and communication connection attributes into GNN is proposed, and a corresponding flexible duplex graph neural network (FD-GNN) model is constructed. For the first time, the distance between node pairs, channel gain, and neighbors are introduced as dynamic thresholds into FD-GNN to adapt to dynamic environments. Excluding channel state information of neighbors in GNN, pruning edges in FD-GNN reduces computation time and network complexity. Simulation results show that the proposed threshold setting method based on channel gain neighbors has the best performance and reaches 97% of the weighted minimum mean square error (WMMSE), reducing the training time required by 24% compared to Full GANN. The proposed threshold based effectively reduces the time complexity of GNN operations and improves the effectiveness of the algorithm.

Keywords: GNN; flexible duplex networks; power allocation; dynamic threshold; time complexity

收稿日期: 2023-10-29 Received Date: 2023-10-29

* 基金项目: 国家自然科学基金项目(61661018)、江苏省基础研究计划青年基金项目(BK20210064)、无锡市科技创新创业资金项目(WX03-02B0137-022200-34)

0 引言

随着第五代(5th generation, 5 G)通信技术的迅猛发展,面对有限的频谱资源,5 G 大规模机器通信面临着巨大的挑战。为了缓解频谱短缺问题,采用 D2D(device to device)技术来支持两个设备间的直接通信^[1]。

在 D2D 通信中,时分双工(time division duplex, TDD)由于上下行数据速率不对称的优异性能^[2],其上行和下行时隙是预定义的。如果放宽这种预定义的特性,允许通信双方动态调度来提高时隙的利用率,就可以构建出柔性双工网络^[3],其可以动态分配上下行链路资源,具有更大的灵活性^[4]。但是,D2D 网络中的功率分配通常是一个非凸问题^[5],而新兴的图神经网络(graph neural networks, GNN)可被应用于解决此类问题^[6]。

在无线网络中,一些不确定因素(如用户移动性、流量模式的改变和网络资源的调整等)引起网络拓扑动态变化,可从非欧几何域收集的链路通信数据表示的图结构数据表现出来,这些图结构数据具有高维特征和通信设备之间的相互依赖性。为了解决上述问题,一种直接的解决方法是将网络拓扑信息纳入神经网络的体系结构中^[7]。GNN 利用全局参数化、公共坐标系统、向量空间结构或移位不变性,可以有效地处理图结构数据^[8]。无线网络固有的图结构使得 GNN 比全连接神经网络和卷积神经网络更适合解决无线网络优化问题^[8]。

目前,在柔性双工网络中通过功率分配对传输速率进行优化的问题中,学者们提出了多种网络框架和算法。Fanjul 等^[9]提出了一种具有灵活双工的最小发射功率算法进行速率问题优化。Dayarathna 等^[10]在柔性双工网络中调度发射机与接收机的发射功率,实现最大化和速率。还有学者提出一种 NAFD-CF(network assisted full duplex-cell free)系统,用户和接入点可以灵活的选择双工模式,并进一步提出了柔性双工网络和功率分配的联合问题^[11]。虽然这些工作在速率性能上有所提升,但提出的基于欧氏距离的模型不再适用于现实中动态的网络拓扑结构,且往往只考虑到单一性能优化,而未考虑到时间复杂度问题。为了解决这个问题,Shen 等人提出基于固定距离的阈值,以减少 GNN 的训练工作量,根据发射机和非配对接收机之间的距离设置 GNN 阈值,当距离超过特定阈值时,排除 GNN 中的信道状态信息(channel state information, CSI),删除收发机对的邻居来减少计算时间^[12]。类似地,在文献[13]中,作者设置了基于信道增益的阈值,如果信道增益小于该阈值,则断开与邻居节点的连接,删除收发机对的邻居来降低时间复杂度。Chen 等^[14]分析了阈值方法和时间复杂度之间的关系,并证明合适的阈值可以显著降低预期的时间复杂度,同时保持

良好的性能。虽然以上工作达到了降低时间复杂度的目的,但这些固定阈值是静态的,不适用于现实的动态网络环境。

本文考虑一种动态设置阈值的方法,提出四种阈值设定方法,分别是基于:距离、距离邻居、信道增益和信道增益邻居的方法,并设置 3 种阈值为:25%、50%和 75%。接收机接受阈值内的干扰以降低时间复杂度。鉴于干扰衰减的距离依赖性和信道增益依赖性,消除远程和低信道增益节点之间的连接似乎是一种降低计算复杂性的逻辑方法,同时不会显著影响性能。

本文首次将动态阈值应用到基于 GNN 构建的 D2D 柔性双工网络中,主要贡献为:

1) 提出了一种新的基于 GNN 的 D2D 柔性双工网络模型 FD-GNN(Flexible Duplex Networks GNN),该模型采用无监督学习策略联合优化“通信方向”和“功率”,使 FD-GNN“加权和速率”最大化。此外,本文还分析了该模型的可扩展性和泛化能力。

2) 首次将设置动态阈值方法引入到 FD-GNN 中,提出了四种动态阈值设定方法,设置通过减少节点间的连接降低时间复杂度,并通过仿真比较了这 4 种方法兼顾速率与时间复杂度情况下的性能。

3) 本文证明了在动态的网络环境下,FD-GNN 算法在性能方面优于目前比较热门的算法,且本文模型中基于 CSI 邻居的阈值是更好的。仿真结果表明,通过选择合适的基于 CSI 邻居的阈值,可以实现高性能,同时大大降低时间复杂度。

1 系统模型和优化问题

1.1 系统模型

本系统模型考虑一个具有干扰信道的 D2D 柔性双工网络,包括 T 对收发机节点,如图 1 所示。图 1 中给出了具有相邻索引值的节点作为用户对($1 \leftrightarrow 2, \dots, 2t-1 \leftrightarrow 2t, \dots, 2T-1 \leftrightarrow 2T$)。

1.2 问题描述

由于 D2D 对采用 TDD 工作模式,没有固定的接收机与发射机,用 $\Gamma = \{1, 2, \dots, 2T\}$ 表示发射机集合。对于 $t \in \Gamma$,定义 $r(t)$ 作为 D2D 配对接收机的索引,其中 $r(t) = 2(t \bmod 2) + t - 1$,则接收机 $r(t)$ 处信噪比表示为:

$$\Phi_{r(t)} = \frac{p_t d_t |h_{t,r(t)}|^2}{\sum_{k \neq r(t)}^{2N} p_k d_k |h_{k,r(t)}|^2 + \sigma_{r(t)}^2}, t \in \Gamma \quad (1)$$

其中, $h_{t,r(t)}$ 表示第 t 台发射机与预定接收机 $r(t)$ 之间的期望链路增益, $h_{k,r(t)}$ 表示第 k 台发射机与接收机 $r(t)$ 干扰链路增益。 $\sigma_{r(t)}^2$ 表示噪声功率。本文首次将通

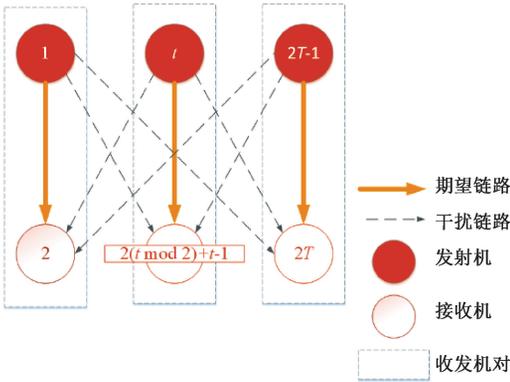


图 1 具有干扰信道的 D2D 柔性双工网络模型
Fig. 1 D2D flexible duplex network model with interference channels

信方向纳入问题优化中,其中 $d_t = 1 - d_{r(t)}$, $d_{r(t)} \in \{0, 1\}$, $d_k \in \{0, 1\}$, 当 $d_{r(t)} = 0$ 时, $d_t = 1$, 表示此用户对中的发射机和接收机处于工作状态; 当 $d_{r(t)} = 1$ 时, $d_t = 0$ 表示此用户对中的发射机和接收机处于非工作状态, 且 $\Phi_{r(t)} = 0$ 。第 t 台发射机的传输数据用 s_t 表示, p_t 表示发射机 t 的发射功率, 定义为 $p_t = E[|s_t|^2]$, p_k 表示发射机 k 的发射功率, 定义为 $p_k = E[|s_k|^2]$ 。此外, 为了符合现实的网络环境, 将信道建模为非互反信道环境, 即 $h_{i,r(t)} \neq h_{r(t),i}$ 。

发射机 t 与接收机 $r(t)$ 之间的信道传输速率 C_t (Bits/s/Hz) 由 Shannon 公式得到:

$$C_t = \log_2(1 + \Phi_{r(t)}), t \in \Gamma \quad (2)$$

目前大部分工作仅限于发射功率的分配, 而如何同时联合“发射功率”与“传输方向”来降低干扰从而提升传输速率是本文优化核心。

1.3 优化问题

本文联合优化 D2D 柔性双工网络的功率分配和通信方向, 以在最大功率限制下实现加权和速率最大化, 该优化问题定义为:

$$\max_{p_t, d_t, t \in \Gamma} \sum \omega_t C_t \quad (3)$$

$$s. t. 0 \leq p_t \leq P_{\max}, t \in \Gamma$$

$$r(t) = 2(t \bmod 2) + t - 1, t \in \Gamma$$

$$d_t = 1 - d_{r(t)}, t \in \Gamma$$

$$d_{r(t)} \in \{0, 1\}, t \in \Gamma$$

其中, P_{\max} 表示发射机的最大发射功率, $\omega_t \in [0, 1]$ 表示第 t 台发射机的权重。

2 基于动态阈值的功率分配 GNN

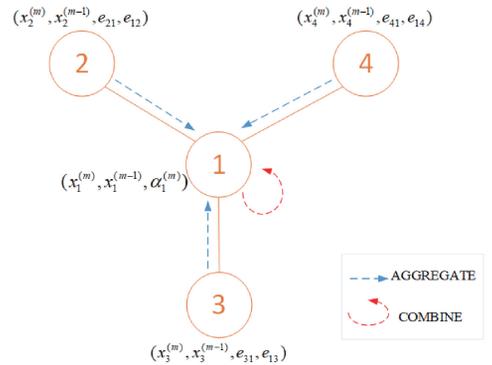
在本节中, 首先提出 FD-GNN 网络的图表示方法。然后, 给出基于信道增益、距离和邻居的图, 并将它们应

用于 FD-GNN 的功率分配问题。

2.1 FD-GNN 图表示方法

FD-GNN 联合优化发射功率 P 和通信方向 D 使得加权和速率最大化: 首先, 将柔性双工网络建模为具有无向边和有向边的图; 然后, 将距离和 CSI 作为节点特征和边特征; 接着该图作为 GNN 模型的输入, 其中的节点表示发射机或接收机。

GNN 具有多层结构, 其中每个节点通过聚集其邻居节点的特征进行更新^[15-16]。在每一层中, 中心节点将自身特征与邻居节点的特征进行组合。通过迭代地完成聚合 (Aggregate) 和组合 (Combine) 操作, GNN 能够逐渐更新每个节点的特征, 首先, 将中心节点属性、邻居节点属性 and 与之链接的边属性输入到图神经网络中, 输出结果为考虑邻居信息的中心节点属性, 见式 (4), 接着, 将其与中心节点属性进行拼接实现节点属性的更新, 见式 (5), 如图 2 所示。节点 v , 其中 $v \in V$, 在第 m 层的更新规则为^[17]:



$$\alpha_1^{(m)} = \text{Aggregate}(\{x_1^{(m-1)}, x_2^{(m-1)}, x_3^{(m-1)}, x_4^{(m-1)}, e_{12}, e_{13}, e_{14}, e_{21}, e_{31}, e_{41}\})$$

$$x_1^{(m)} = \text{Combine}(x_1^{(m-1)}, \alpha_1^{(m)})$$

图 2 GNN 中每个节点更新过程

Fig. 2 Update process for each node in GNN

$$\alpha_v^{(m)} = \text{Aggregate}^{(m)}(\{x_u^{(m-1)}, x_v^{(m-1)}, e_{uv}, e_{vu} : u \in N(v)\}) \quad (4)$$

$$x_v^{(m)} = \text{Combine}^{(m)}(x_v^{(m-1)}, \alpha_v^{(m)}) \quad (5)$$

其中, $\alpha_v^{(m)}$ 表示节点 v 在 m 层从邻居节点聚集的特征, $N(v)$ 表示节点 v 的邻居集合, $x_v^{(m)}$ 表示节点 v 在 m 层的特征, e 表示边的特征属性。而且, Aggregate 函数和 Combine 函数的不同选择可以构成不同的 GNN 网络。

FD-GNN 的图模型共包含 T 对收发机节点, 每个发射机发送的信号对非预期的接收机产生干扰, 将其表示为图 3。

网络中的 T 对收发机节点由图中的 $2T$ 个节点表示, 任意两个节点之间都有联系, 通过边连接起来, 如图 3 所示。由式 (1) 可知, 信噪比公式中包含信道增益 $|h_{t,r(t)}|^2$, 且考虑到匹配的收发机间距离 $d_{t,r(t)}$ 。因此,

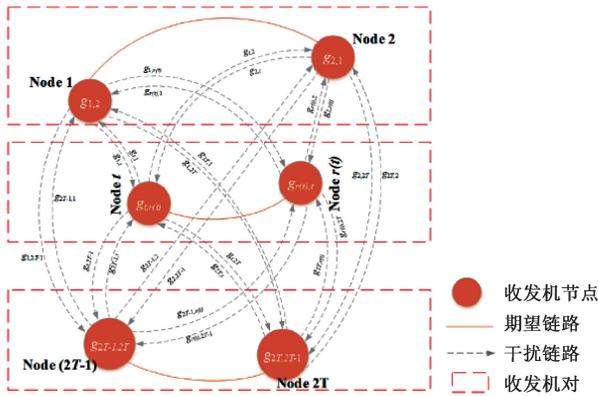


图3 T对收发机节点构成的D2D柔性双工网络
Fig.3 D2D flexible duplex network composed of T-pair transceiver nodes

定义第 t 个节点的属性包含处于同一收发机对中信道增益和距离 $g_{i,r(t)} = [|h_{i,r(t)}|^2, d_{i,r(t)}]$, 并作为此节点的特征。图中连接每个节点的边分为两种:第1种,连接发射机和接收机的期望链路用无向边表示,记为 e_d ;第2种,来自于外界发射机的潜在干扰用有向边表示,记为 e_i 。有向边之所以被称作潜在干扰是因为只有当这条有向边的起始节点表示为发射机时,这条边才会称为干扰,由图3可知,通过 e_i 发射机可以聚合到来自于其他发射机的节点信息。因此,本模型定义从产生干扰的发射机节点到接收机之间边 e_i 的边特征为 $g_{k,r(t)} = [|h_{k,r(t)}|^2, d_{k,r(t)}]$,其中 $d_{k,r(t)}$ 表示干扰发射机 k 于接收机 $r(t)$ 间的距离。由式(5)可知将 $g_{i,r(t)}$ 、 $g_{k,r(t)}$ 、 e_d 和 e_i 进行汇聚得到包含邻居信息的 t 节点属性 α_t ,将其与 $g_{i,r(t)}$ 进行拼接,实现 t 节点的属性更新。

如今社会处于万物互联的时代,每一个通信设备数据更新都会受到其他设备的干扰。在现有工作中,设备数据的更新只能通过全局更新,无法做到每个设备实时更新。之所以考虑使用 GNN 与柔性双工网络相结合,是因为 GNN 能够结合邻居信息实时处理节点数据对中心节点进行更新。

2.2 传统图神经网络

在 D2D 网络中,将一个收发机对视为 GNN 的一个节点^[17]。图4中的连接表示收发机对之间的干扰关系,在通常情况下,由于收发机对之间存在干扰,这种描述方式会形成一个全连接图。然而,这种描述方式存在几个缺点:首先,未配对的发射机和接收机通常在空间上距离较远,由于距离的衰减,它们对功率分配的影响可以忽略不计。此外,这个全连接图的复杂度取决于边的数量^[17],由于全连接每个节点需要考虑每一个邻居和连接边,其中也包含可以忽略不计的干扰,具有较高的复杂性。

2.3 基于动态阈值图神经网络

1) 图表示

由图3和4可知,本文是将配对的发射机与接收机视为图中的一个节点。将两图中的节点集和边集分别定义为 V 和 E 。对于任意给定的节点 $v \in V$,它的邻居集被定义为 $N(v)$ 。设 V_v 和 $E_{v,u}$ 分别表示节点 v 的节点特征和节点 v 与节点 u 之间边的特征,则 V_v 可定义为:

$$V_v = \{ h_{v,r(v)}, \omega_v, d_{v,r(v)} \} \quad (6)$$

其中, $h_{v,u}$ 和 $d_{v,u}$ 分别表示节点 v 与节点 u 之间的期望链路增益和距离, ω_v 表示发射机 v 的权重。则 $E_{v,u}$ 定义为:

$$E_{v,u} = \{ h_{v,u}, d_{v,u} \} \quad (7)$$

2) 动态阈值设置

与文献[2]和[3]不同,本文在仿真前不会将阈值作为超参数设置,这些静态阈值不再适合于现有的复杂动态环境,而是根据具体的动态网络环境进行阈值大小的设置。本文提出四种阈值设定方法,分别是基于:距离、距离邻居、信道增益和信道增益邻居的方法,并设置3种阈值为:25%、50%和75%。

(1) 在基于距离的动态阈值设置方法中,由于传输过程中存在路径衰落,规定在阈值范围之内的节点才会与节点 v 建立连接、进而产生干扰。首先,得到各个节点之间边的特征 $E_{v,u}$,通过计算得到 $E_{v,u}$ 中最大的节点距离 $d_{(v,u)\max}$,最后通过对 $d_{(v,u)\max}$ 调整,得到基于距离的动态阈值 $T_{D,\alpha}$:

$$T_{D,\alpha} = \alpha d_{(v,u)\max} \quad (8)$$

其中, $\alpha = [25\%, 50\%, 75\%]$,并依次取值。

(2) 在基于距离邻居的阈值设置方法中,规定节点 v 仅连接最近的 n 个邻居节点。首先,得到各个节点之间边的特征 $E_{v,u}$,通过对每个节点间按照距离从小到大进行排序,得到 $n(d_{v,u})$,然后选取前 α 个节点作为邻居,得到基于距离邻居的动态阈值 $T_{D,neig,\alpha}$:

$$T_{D,neig,\alpha} = \alpha n(d_{v,u}) \quad (9)$$

(3) 在基于信道增益的阈值设置方法中,从式(1)中可以看出,接收机接收到的干扰与干扰增益成正比,所以在这个方法中将低于阈值的信道增益进行过滤,既能保持高性能也能降低复杂度。首先,根据节点之间的边的特征 $E_{v,u}$,得到 $E_{v,u}$ 中最大的信道增益 $h_{(v,u)\max}$,最后通过对 $h_{(v,u)\max}$ 调整,得到基于信道增益的动态阈值 $T_{C,\alpha}$:

$$T_{C,\alpha} = \alpha h_{(v,u)\max} \quad (10)$$

(4) 在基于信道增益邻居的阈值设置方法中,规定节点 v 只来连接信道增益最大的前 n 个邻居节点。首先,根据节点之间的边的特征 $E_{v,u}$,得到信道增益 $h_{v,u}$,通过对每个节点按照 $h_{v,u}$ 从大到小进行排序得到 $n(h_{v,u})$,最后选取前 α 个节点作为邻居。得到基于信道增益邻居的动态阈值 $T_{C,neig,\alpha}$:

$$T_{C_neig_a} = \alpha n(h_{v,u}) \quad (11)$$

3) 基于阈值的 GNN 结构

本文提出的 4 种 GNN 算法包括 3 个步骤:修剪、聚合和组合。首先,根据阈值对目标节点的边进行修剪。然后,目标节点从它当前的邻居节点那里收集信息。本文采用多层感知器(multi-layered perceptron, MLP)域的信息进行聚合,并将其自身特征与聚合信息相结合。此外,本文使用池化运算来保持 FD-GNN 的排列不变性。所提出的基于阈值的 GNN 在第 m 层的更新规则由式给出:

(1) 基于距离的阈值 T_{D_a} :

$$N_{intf}(v) = \{u \in V; d_{v,u} \leq T_{D_a}\} \quad (12)$$

(2) 基于距离邻居的阈值 $T_{D_neig_a}$:

$$N_{intf}(v) = \{u \in V; u \in T_{D_neig_a}\} \quad (13)$$

(3) 基于信道增益的阈值 T_{C_a} :

$$N_{intf}(v) = \{u \in V; h_{v,u} \geq T_{C_a}\} \quad (14)$$

(4) 基于信道增益邻居的阈值 $T_{C_neig_a}$:

$$N_{intf}(v) = \{u \in V; u \in T_{C_neig_a}\} \quad (15)$$

$$\alpha_{v;intf}^{(m)} = [\phi(W_{u;intf}^{(m)} \mathcal{X}_u^{(m-1)} + W_{v;intf}^{(m)} \mathcal{X}_v^{(m-1)} + W_{e;intf}^{(m)} e_{u,v} + W_{e;intf}^{(m)} e_{v,u}; u \in N_{intf}(v))] \quad (16)$$

$$c_v^{(m)} = (x_v^{(1)} \parallel \alpha_{v;intf}^{(m)}) \quad (17)$$

$$\alpha_{v;dsr}^{(m)} = \xi[\phi(W_{u;dsr}^{(m)} c_u^{(m)} + W_{v;dsr}^{(m)} c_v^{(m)}; u \in N_{dsr}(v))] \quad (18)$$

$$x_v^{(m)} = (x_v^{(1)} \parallel \alpha_{v;dsr}^{(m)}) \quad (19)$$

其中, ξ 表示一个具有置换不变性的求和池化函数; ϕ 表示一个非线性激活函数,本模型采用 ReLU 函数(层间)和 Sigmoid 函数(输出层); $x_v^{(m)}$ 表示第 m 层中节点 v 的节点特征; W 表示可训练的权重矩阵; $N_{intf}(v)$ 表示通过 e_i 边连接到节点 v 的邻居集合,下标 intf 表示干扰; $N_{dsr}(v)$ 表示通过 e_d 边连接到节点 v 的相邻节点的集合,下标 dsr 表示期望; $e_{u,v}$ 表示从节点 u 到 v 的 e_i 边的特征; $x_v^{(1)}$ 表示第一层的节点特征,即所需信道增益; $\alpha_{v;intf}^{(m)}$ 表示在无干扰情况下节点 v 在第 m 层更新的节点特征; $c_v^{(m)}$ 表示节点 v 在第 m 层无干扰情况下的节点特征; $\alpha_{v;dsr}^{(m)}$ 表示考虑干扰情况下节点 v 在第 m 层更新的节点特征。式(19)表示从第一层到第 m 层的残差连接,用于减少在反向传播过程中梯度消失或梯度爆炸的风险。经验证明,残差连接能显著提高深度神经网络的性能。符号 \parallel 表示向量的拼接。此外,与式(4)和(5)中描述的图神经网络架构不同,FD-GNN 架构能够通过两个聚合步骤来确定生成节点的特征,运算结果的精确性更高。

在完成上述多层的聚合和组合步骤后,最后一层的输入被用于预测节点对中发射机的功率值:

$$p_n = P_{\max} \text{Sigmoid}\left(\frac{1}{T_p} \text{MLP}(x_n^{(final)})\right) \quad (20)$$

其中,Sigmoid 表示 S 型函数函数,这个过程中引入了一个温度的缩放参数 T_p ,并采用可训练的 MLP。 $x_n^{(final)}$ 表示第 n 个节点的最终层输入。使用较低的温度值可以使功率值更加极端,一般倾向使用于 0 或 P_{\max} 。

考虑由 e_d 相连节点 v 的相邻节点的特征,可以确定期望链路的方向,见式(1)。式(1)中由于通信方向的二值表述方法缺乏可微性,使用二值函数约束来优化网络是困难的。因此,本模型对二进制约束进行了放宽,将其视为 0 和 1 之间的实数。然后,同时考虑两节点 u 和 v 的特征来决定边的方向:

$$d_{u,v} = \text{Sigmoid}\left(\frac{1}{T_d} \text{MLP}(x_u^{(final)} \parallel x_v^{(final)})\right) \quad (21)$$

这个过程中引入了温度参数 T_d ,以及节点特征 $x_u^{(final)}$ 和 $x_v^{(final)}$ 。与功率分配类似,将松弛的二值约束在 $[0,1]$ 内,通过使用较低的温度值完成正则化运算。

本文使用适应性矩估计(adaptive moment estimation, ADAM)优化网络可训练参数,将加权和速率的负值作为损失函数进行优化。使用 ADAM 算法,能够自适应地调整梯度下降的步长,从而更快地收敛到损失函数的最优解。采用这种方法,能够提高 GNN 对数据的理解能力,从而为进一步应用打下更好的基础。

3 仿真和结果分析

3.1 仿真设置

假设在一个 $4 \text{ km} \times 4 \text{ km}$ 区域的 D2D 柔性双工网络^[18],如表 1 所示,设备在二维空间中服从泊松分布,在 FD-GNN 模型中,设备之间的最小距离为 100 m,设备可被随机配对以形成必要的连接。

表 1 实验参数设置

参数名称	参数值
区域面积	4 km×4 km
收发机数量	[8, 16, 24, 32, 40]
设备间最小间距	100 m
节点分布模型	泊松分布
信道模型	瑞利衰落
载波频率	5 GHz
对数正态阴影衰落因子	9.5 dB
训练样本数量	10 000
测试样本数量	2 000
GNN 层数	3
初始化功率	P_{\max}

为了生成 CSI,本模型考虑网络的大尺度衰落和小尺度衰落效应^[19]。在 5 GHz 载波频率下,采用了自由空间路径损耗模型,并考虑对数正态阴影衰落(衰落因子为 9.5 dB)。此外,假设使用瑞利衰落信道模型,该模型适

用于模拟城市环境中的衰落效应,常用于评估资源分配方法的性能。通过考虑这些衰落效应,能够更准确地模拟实际通信环境中的信道特性。分别对 {8, 16, 24, 32, 40} 不同数量的用户场景进行仿真,为了制定有效的无线网络功率分配策略,采用负加权和速率作为目标损失函数:

$$L(\theta) = -\widehat{E}_H \left\{ \sum_{t \in \Gamma} \omega_t \log_2 \left(1 + \frac{p_t d_t |h_{t,r(t)}|^2}{\sigma_{r(t)}^2 + \sum_{k \neq t, r(t)} p_k d_k |h_{k,r(t)}|^2} \right) \right\} \quad (22)$$

在实验中,生成了 10 000 个训练样本用于计算经验损失,同时还生成了 2 000 个测试样本用于评估。本实验假设只有部分 CSI(完整 CSI 的一个子集)用于本算法。FD-GNN 模型使用 3 层全连接神经网络,初始化功率 $p_v^{(0)} = P_{\max}$ 。为了验证阈值设置方法的有效性,对以下 6 种算法进行仿真:

Full-GNN:未设置阈值的 FD-GNN 网络,如图 4 所示。

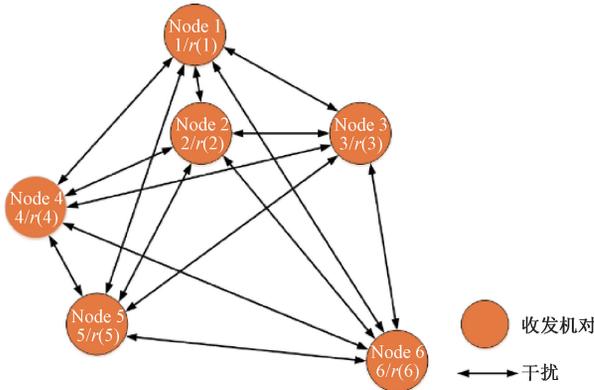


图 4 D2D 通信网络

Fig. 4 D2D communication network

D-GNN:基于距离阈值 $T_{D_{-\alpha}}$ 的 FD-GNN 网络。

D-neig-GNN:基于距离邻居阈值 $T_{D_{-neig_{-\alpha}}}$ 的 FD-GNN 网络。

C-GNN:基于信道增益阈值 $T_{C_{-\alpha}}$ 的 FD-GNN

C-neig-GNN:基于信道增益邻居阈值 $T_{C_{-neig_{-\alpha}}}$ 的 FD-GNN 网络。

WMMSE^[20]:无线网络中基于优化的高级功率分配算法^[12,21]。

Max-Power:最大功率算法,选择具有信道增益最大值的方向作为通信方向,并使用 P_{\max} 作为传输功率。

3.2 FD-GNN 性能分析

由 3.1 节可知,FD-GNN 网络模型采用全连接图 Full-GNN,对 FD-GNN 网络模型的性能与常用方法进行了对比。由表 2 可知,WMMSE 算法在一定条件下能够

保证收敛到局部最优解或全局最优解,尤其在干扰较大的情况下,该算法能够收敛到较优解,虽然这种算法可以接近最佳性能,但是由于时间复杂度高,很难应用于大规模网络场景。Max_Power 策略,选择具有信道状态信息最大值的方向作为通信方向,并使用 P_{\max} 作为传输功率,跳过功率和方向的优化过程,使得时间复杂度最低,发射机运行在最佳工作状态,但是却忽略了能耗和干扰带来的影响。

表 2 实验中对比的算法

Table 2 Algorithms compared in the experiment

算法	时间复杂度
WMMSE	$O(n^3)$
FD_GNN	$O(n^2)$
Max_Power	$O(n)$

通过仿真结果对这 3 种算法性能进行分析,如图 5 所示。

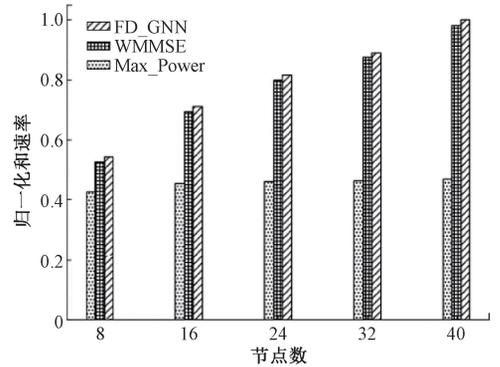


图 5 FD-GNN、WMMSE 和 Max-Power 3 种算法归一化和速率随节点数变化

Fig. 5 The normalization rate of FD-GNN, WMMSE, and Max Power algorithms varies with the number of nodes

从图 5 中可以看出,本文提出的网络模型,随着节点数量的增加,在和速率性能方面优于 WMMSE 算法,平均性能可以达到 WMMSE 方法 102%,且随着网络中节点数量增加,FD-GNN 性能能保持稳定。FD-GNN 能够有效地捕捉图结构中节点之间的复杂关系和依赖关系并实时更新节点属性,以适应不同的通信场景,很好地应用于动态网络或大规模的通信系统中。同时说明了本文提出的网络模型具有较强的可扩展性和泛化能力,能够适应不同用户数量的网络,能够在数据噪声、节点故障或网络拓扑变化等方面表现出较好的性能。相对而言,WMMSE 更倾向于在假设条件明确的情况下优化性能。

3.3 阈值算法性能与时间复杂度分析

对 3.1 节中六种算法进行仿真,对和速率与时间复杂度进行分析与比较。动态阈值设置方法见 2.3 节 2) 中,动态阈值参数如表 3 所示。

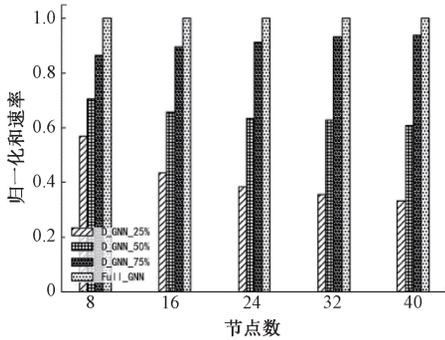
表 3 动态阈值设置

Table 3 Dynamic threshold setting

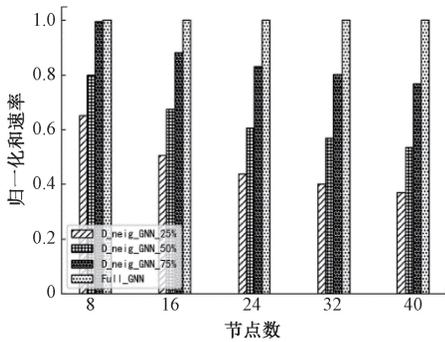
算法	$\alpha = 25\%$	$\alpha = 50\%$	$\alpha = 75\%$
D-GNN	$0.25d_{(v,u)max}$	$0.5d_{(v,u)max}$	$0.75d_{(v,u)max}$
D-neig-GNN	$0.25n(d_{v,u})$	$0.5n(d_{v,u})$	$0.75n(d_{v,u})$
C-GNN	$0.25h_{(v,u)max}$	$0.5h_{(v,u)max}$	$0.75h_{(v,u)max}$
C-neig-GNN	$0.25n(h_{v,u})$	$0.5n(h_{v,u})$	$0.75n(h_{v,u})$

1) 距离阈值方法比较

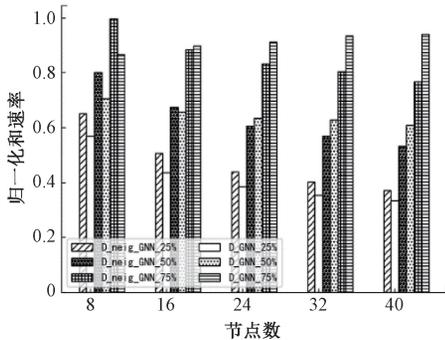
D-GNN 和 D-neig-GNN 这两种距离阈值算法运行结果如图 6 所示。从式(8)和(9)可知,D-GNN 通过距离对邻居进行选择,具有邻居数不确定性,D-neig-GNN 通过排序选择固定邻居。这两个阈值方法通过将大于距离阈



(a) Full-GNN和D-GNN算法
(a) Full-GNN and D-GNN algorithms



(b) Full-GNN和D-neig-GNN算法
(b) Full-GNN and D-neig-GNN algorithms



(c) D-GNN和D-neig-GNN算法
(c) D-GNN and D-neig-GNN algorithms

图 6 距离阈值方法归一化和速率随节点数变化
Fig. 6 Normalization of distance threshold method and rate variation with node number

值的 CSI 设置为 0,进行边剪枝优化,随后进行节点属性更新,见式(4)和(5)。随着网络节点数量增加,D-neig-GNN 的固定邻居导致和速率性能下降幅度明显,而 D-GNN 可以保持相对稳定,当 α 取 75%时,D-GNN 和速率性能随着节点数量的增加而上升的增加,当节点数量达到 40 时 D-GNN 的性能可以达到 Full-GNN 的 94%。

由于通过边剪枝忽略部分邻居信息,使得计算时间减少。通过比较 D-neig-GNN 和 D-GNN 的运行时间,如图 7 所示,可以看出,设备的随机分布使得 D-GNN 处理时间虽然略高率 D-neig-GNN,但是仍然低于 Full-GNN,这表明 D-GNN 起到了减少 GNN 计算时间的效果。

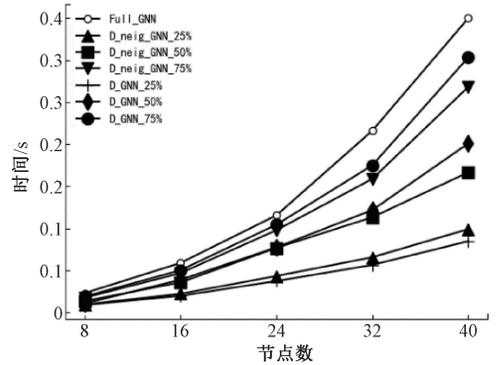


图 7 Full-GNN、D-GNN 与 D-neig-GNN 运行时间随节点数变化

Fig. 7 The runtime of full GNN, D-GNN and D-neig-GNN varies with the number of nodes

通过计算这两个算法的性能平均期望,如图 8 所示,D-GNN 平均和速率性能超过 D-neig-GNN。综上所述,D-GNN 在兼顾性能和时间复杂度方面优于 D-neig-GNN。

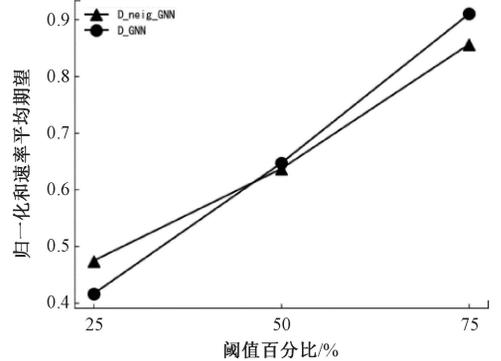


图 8 D-GNN 与 D-neig-GNN 归一化和速率平均期望随阈值百分比变化

Fig. 8 Normalization and rate average expectation of D-GNN and D-neig-GNN as a percentage change with threshold

2) 信道增益阈值方法比较

C-GNN 和 C-neig-GNN 这两种距离阈值算法通过将

小于信道增益阈值的 CSI 设置为 0,进行边剪枝优化,如式(10)和(11)所示,随后进行节点属性更新。运行结果如图 9 所示,随着网络节点数量的增加,C-GNN 的和速率性能快速下降,且远远低于 C-neig-GNN。当 α 取 75% 时,C-neig-GNN 由于拥有固定邻居使得和速率性能不仅能保持稳定,且平均达到 Full-GNN 的 98%。通过比较 C-GNN 与 C-neig-GNN 的运行时间,如图 10 所示,可以看出,虽然 C-GNN 在运行时间方面优于 C-neig-GNN,但是以低性能为代价,这种优化就没有任何意义。最后,通过比较这两个算法的平均期望(如图 11 所示)也可以看出 C-neig-GNN 远远优于 C-GNN。

3) 最优阈值算法选择

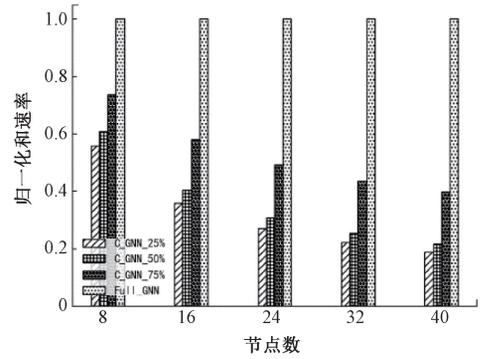
从 3.3 节 1) 和 2) 可知,D-GNN 和 C-neig-GNN 在兼顾和速率与计算时间方面更有优势。从图 12 中可以看出,随着网络节点数量的增加 C-neig-GNN 和速率性能总是优于 D-GNN 且能够达到 WMMSE 性能的 97%。通过比较这两种算法的计算时间,如图 13 所示,当 α 和节点数量去不同值时,C-neig-GNN 的计算时间都低于 D-GNN。且 C-neig-GNN 平均时间甚至不及 Full-GNN 网络的 80%。当节点数量为 8 时,C-neig-GNN 处理时间仅为 Full-GNN 网络的 62%,相比于 D-GNN 下降了 10%,且在性能方面略优于 WMMSE 的性能。

通过比较这 4 种算法,可以看 C-neig-GNN 不仅保持高性能,也降低了时间复杂度,虽然 D-GNN 算法仅次于 C-neig-GNN,但是 D-GNN 的邻居选择依赖于设备的随机分布,具有不稳定性,综合考虑性能、稳定性、时间复杂度等问题使得 C-neig-GNN 成为本文提出的 4 种算法中的最优算法。C-neig-GNN 的仅为 $O(|\mathcal{E}| \cdot |n|)$,其中 n 表示节点数量, \mathcal{E} 表示邻居数,将时间复杂度从二次降低到线性。

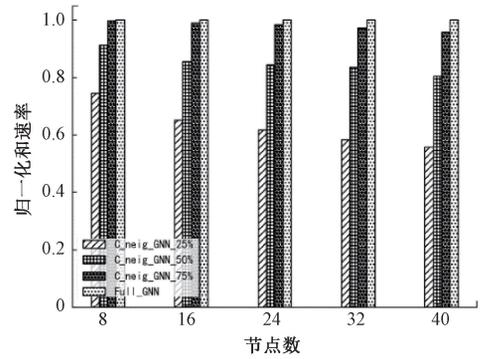
4 结论

本文对灵活双工网络中的联合功率分配和通信方向选择问题进行了探究,并通过设置合理的阈值降低时间复杂度等问题进行了探究。考虑了一个能够动态调度的 TDD 网络的系统模型,以最大化网络总传输速率性能为目的,提出了一种基于 GNN 的全新模型 FD-GNN,并首次将动态阈值引入到基于 GNN 的柔性双工网络中。本文的方法在解决灵活双工网络中联合功率分配和通信方向选择问题上具有很高的实用性和有效性,通过使用 C-neig-GNN 方法,能更好地优化网络性能,降低时间复杂度,从 $O(|n^2|)$ 下降到 $O(|n|)$,并且适用于不同规模和特征的柔性双工网络。

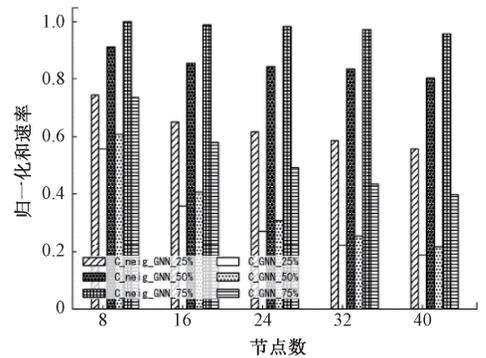
未来 GNN 的发展和改进方向可以从以下几个方面来考虑:1) 模型结构改进:针对不同的应用场景和任务,



(a) FD-GNN和C-GNN算法
(a) FD-GNN and C-GNN algorithms



(b) Full-GNN和G-neig-GNN算法
(b) Full-GNN and G-neig-GNN algorithms



(c) C-GNN与C-neig-GNN
(c) C-GNN and C-neig-GNN

图 9 信道增益阈值方法归一化和速率随节点数变化
Fig. 9 Normalization of channel gain threshold method and rate variation with the number of nodes

可以提出更加灵活和高效的 GNN 模型结构。例如,设计可自适应的注意力机制、跨图卷积、多尺度图卷积等,以提高模型的表达能力和泛化能力。2) 大规模图学习:目前大多数 GNN 方法在处理大规模图时会遇到计算和内存上的限制。未来的研究可以借鉴图采样、分布式计算等方法,提高 GNN 在大规模图上的可扩展性和效率。3) 迁移学习和泛化能力:GNN 在应用于新领域或未见过的数据上的泛化能力仍然有待提高。未来的研究可以探索

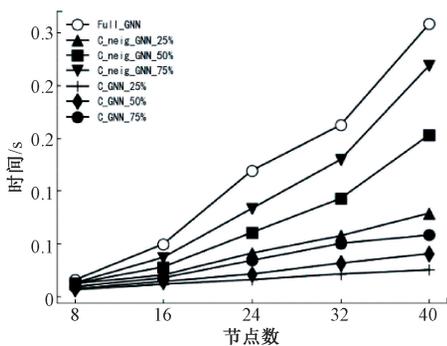


图 10 Full-GNN、C-GNN 与 C-neig-GNN 运行时间随节点数变化

Fig. 10 The running time of Full GNN, C-GNN and C-neig-GNN varies with the number of nodes

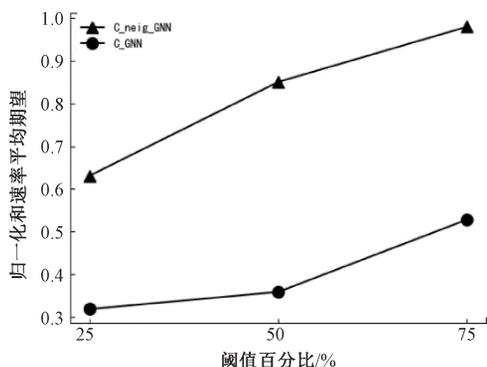


图 11 C-GNN 与 C-neig-GNN 归一化和速率平均期望随阈值百分比变化

Fig. 11 Normalization and rate average expectation of C-GNN and C-neig-GNN as a percentage change with threshold

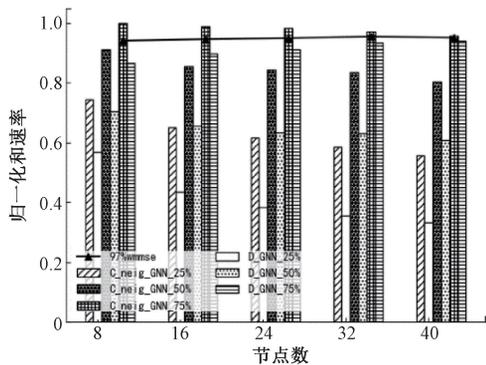
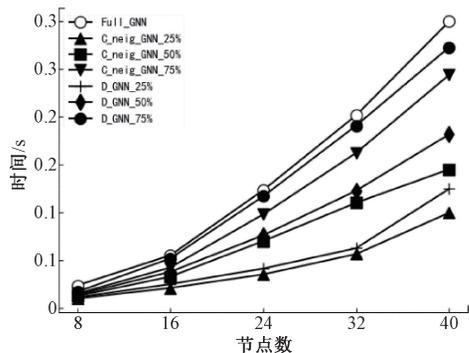
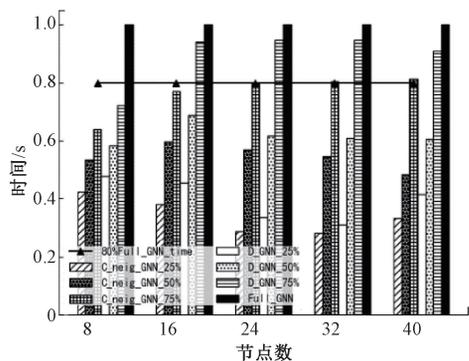


图 12 D-GNN 与 C-neig-GNN 性能比较

Fig. 12 Performance comparison between D-GNN and C-neig-GNN



(a) 时间随节点数变化
(a) Time varies with number of nodes



(b) 归一化时间随节点数变化
(b) Normalization time varies with number of nodes

图 13 D-GNN 与 C-neig-GNN 运行时间随节点数变化 (Full-GNN、C-neig-GNN 和 D-GNN)

Fig. 13 The running time of D-GNN and C-neig-GNN varies with the number of nodes (Full-GNN, C-neig-GNN and D-GNN)

参考文献

[1] 彭艺,付晓霞,刘煜恒,等. 高原山区 D2D 网络能量效率优化算法研究 [J]. 电子测量与仪器学报, 2021, 35(9) :150-156.
PENG Y, FU X X, LIU Y H, et al. Research on energy efficiency optimization algorithm of D2D network in plateau and mountain area [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (9) : 150-156.

[2] LIU H, JIAO Y, GAO Y, et al. Performance evaluation of flexible duplex implement based on radio frame selection in LTE heterogeneous network [C]. 22nd International Conference on Telecommunications, IEEE, 2015: 308-312.

[3] DAYARATHNA S, RAZLIGHI M, SENANAYAKE R, et al. Centralized scheduling with sum-rate optimization in flexible half-duplex networks [C]. IEEE Wireless Communications and Networking Conference, IEEE,

如何通过迁移学习或元学习等方法,使得 GNN 能够更好地适应不同的任务和数据分布。

- 2020; 1-6.
- [4] WAN L, ZHOU M, WEN R. Evolving LTE with flexible duplex [C]. IEEE Globecom Workshops, IEEE, 2013: 49-54.
- [5] 沈国丽,李君,李正权. D2D 通信中基于深度强化学习的资源分配[J]. 电子测量技术, 2022, 45(24): 76-84.
SHEN G L, LI J, LI ZH Q. Resource allocation based on deep reinforcement learning in D2D communication [J]. Electronic Measurement Technology, 2022, 45 (24): 76-84.
- [6] EISEN M, RIBEIRO A. Optimal wireless resource allocation with random edge graph neural networks [J]. IEEE Transactions on Signal Processing, 2020, 68(9): 2977-2991.
- [7] ZHANG S, YIN B, ZHANG W, et al. Topology aware deep learning for wireless network optimization [J]. IEEE Transactions on Wireless Communications, 2022, 21(11): 9791-9805.
- [8] BRONSTEIN M M, BRUNA J, LECUN Y, et al. Geometric deep learning: going beyond Euclidean data [J]. IEEE Signal Processing Magazine, 2017, 34(4): 18-42.
- [9] FANJUL J, SANTAMARIA I. Power minimization in multi-tier networks with flexible duplexing [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE, 2019: 4699-4703.
- [10] DAYARATHNA S, SENANAYAKE R, EVANS J. Sum-rate optimization in flexible half-duplex networks with transmitter/receiver scheduling [J]. IEEE Transactions on Wireless Communications, 2021, 21 (7): 4711-4724.
- [11] DENG D, WANG C, ZHANG Z, et al. Joint flexible duplexing and power allocation with deep reinforcement learning in cell-free massive MIMO system [J]. China Communications, 2023, 20(4): 73-85.
- [12] SHEN Y, SHI Y, 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, 2020, 39(1): 101-115.
- [13] WANG Z, EISEN M, RIBEIRO A. Learning decentralized wireless resource allocations with graph neural networks [J]. IEEE Transactions on Signal Processing, 2022, 70: 1850-1863.
- [14] CHEN L, ZHU J, EVANS J. Graph neural networks for power allocation in wireless networks with full duplex nodes [J]. ArXiv Preprint, 2023, ArXiv:2303.16113.
- [15] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80.
- [16] ZHANG Z, CUI P, ZHU W. Deep learning on graphs: A survey [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(1): 249-270.
- [17] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks [J]. ArXiv Preprint, 2018, ArXiv:1810.00826.
- [18] PERERA T, ALAPALLU S, FANG Y, et al. Flex-Net: A graph neural network approach to resource management in flexible duplex networks [C]. IEEE Wireless Communications and Networking Conference, IEEE, 2023: 1-6.
- [19] GREGOR K, LECUN Y. Learning fast approximations of sparse coding [C]. 27th International Conference on Machine Learning, 2010: 399-406.
- [20] SHI Q, RAZAVIYAYN M, LUO Z Q, et al. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel [J]. IEEE Transactions on Signal Processing, 2011, 59(9): 4331-4340.
- [21] LIANG F, SHEN C, YU W, et al. Towards optimal power control via ensembling deep neural networks [J]. IEEE Transactions on Communications, 2019, 68(3): 1760-1776.

作者简介



王子威, 2022 年于南京信息工程大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为无线网络优化、AI 在通信系统中应用、图神经网络等。

E-mail: 1151821037@qq.com

Wang Ziwei received his B. Sc. degree from Nanjing University of Information Science and Technology in 2022. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interests include wireless network optimization, AI application in communication systems and graph neural networks.



陶旭(通信作者), 2014 年于天津大学获得学士学位, 2020 年于南京大学硕博连读获得博士学位, 现为无锡学院讲师, 主要研究方向为功率器件电子学、光子检测技术及其应用等。

E-mail: tx_tju_nju@163.com

Tao Xu received his B. Sc. degree from Tianjin University in 2014, and a M. Sc. degree and a Ph. D. degree from Nanjing University in 2020, respectively. Now he is a lecturer in Wuxi University. His main research interests include rate device electronics and photon detection technology and Its applications.



李晖, 2000 年于哈尔滨工业大学获得学士学位, 2002 年于哈尔滨工业大学获得硕士学位, 2005 年于哈尔滨工业大学获得博士学位, 现为无锡学院教授, 主要研究方向为无线通信、AI 在通信系统中应用、空天信息网络技术等。

E-mail: hitlihui1112@163.com

Li Hui received his B. Sc. degree, a M. Sc. degree and a Ph. D. degree from Harbin Institute of Technology in 2000, 2002 and 2005, respectively. Now he is a professor in Wuxi University. His main research interests include wireless communication, application of AI in communication systems, and aerospace information network technology.



史振婷, 2022 年于金陵科技学院获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为人工智能、神经网络等。

E-mail: sz19981026@163.com

Shi Zhenjing received her B. Sc. degree from Jinling Institute of Technology in 2022. Now she is a M. Sc. candidate in Nanjing University of Information Science and Technology. Her main research interests include artificial intelligence and neural networks.



张见, 2012 年于曲阜师范大学获得学士学位, 2020 年于中国科学院上海微系统与信息技术研究所硕博连读获得工学博士学位, 现为无锡学院讲师, 主要研究方向为光通信材料与器件、通信信号处理等。

E-mail: 408677197@qq.com

Zhang Jian received his B. Sc. degree from Qufu Normal University in 2012, a M. Sc. degree and a Ph. D. degree from Shanghai Institute of Microsystem and Information Technology in 2020, respectively. Now he is a lecturer in Wuxi University. His main research interests include optical communication materials and devices, and communication signal processing.



徐钰龙, 2022 年于南京信息工程大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为无线通信、深度强化学习、资源分配。

E-mail: 1372433241@qq.com

Xu Yulong received his B. Sc. degree from Nanjing University of Information Science and Technology in 2022. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interests include wireless communication, deep reinforcement learning and resource allocation.