

# 柔性双工网络中基于图神经网络的能源效率 联合优化方法\*

王子威<sup>1</sup> 李 晖<sup>1,2</sup> 史振婷<sup>1</sup> 张 见<sup>2</sup> 陶 旭<sup>2</sup>

(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)

**摘 要:**在绿色通信和双碳目标的背景下,提升网络能源效率(energy efficiency, EE)是当前无线通信系统设计和可靠运行的关键技术之一。首先,针对柔性双工网络(flexible duplex networks, Flex-Net)的“和能源效率”最大化的问题,构建了一个具有成对固定通信链路的网络;接着,鉴于图神经网络在通信网络资源优化中的优势,提出了一种新的基于图神经网络(GNN)架构的柔性双工网络(GFlex-Net),以联合优化“通信方向”和“传输功率”,达到网络能效最大化。仿真结果表明,与传统的算法相比,所提出的架构有近乎最优的性能表现,达到穷举法性能的95%,但保持了较低的计算复杂度 $O(n^2)$ ,同时算法揭示了GNN在资源优化中面对样本复杂性、可扩展性和泛化能力方面的优势。

**关键词:**柔性双工网络;能源效率;无线通信;图神经网络;联合优化

**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

## Joint energy efficiency optimization based on graph neural network approach in flexible duplex networks

Wang Ziwei<sup>1</sup> Li Hui<sup>1,2</sup> Shi Zhenting<sup>1</sup> Zhang Jian<sup>2</sup> Tao Xu<sup>2</sup>

(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)

**Abstract:** In the context of green communication and the carbon peaking & carbon neutrality goals, enhancing network energy efficiency (EE) is one of the key technologies for the design and reliable operation of wireless communication systems. Firstly, this article presents the construction of a network consisting of paired fixed communication links to address the problem of maximizing energy efficiency in flexible duplex networks (Flex-Net). Subsequently, taking into account the benefits of graph neural networks in optimizing communication network resources, we propose a new architecture called GFlex-Net based on the graph neural network (GNN) framework. This architecture aims to jointly optimize communication direction and transmission power, thereby achieving maximum network energy efficiency. Simulation results demonstrate that, when compared to traditional algorithms, the proposed architecture achieves nearly optimal performance, reaching 95% of the performance of exhaustive methods, while maintaining a lower computational complexity of  $O(n^2)$ . Furthermore, the algorithm showcases the advantages of GNN in resource optimization, including reduced sample complexity, improved scalability, and enhanced.

**Keywords:** flexible duplex networks; energy efficiency; wireless communication; GNN; joint optimization

收稿日期:2023-10-09

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

## 0 引言

在无线通信中,双工方式主要分为时分双工(time division duplex, TDD)和频分双工(frequency division duplex, FDD)。由于时分双工在上行数据速率与下行数据速率不对称时的优异性能,其成为当前新的研究热点<sup>[1]</sup>。通常在时分双工网络中,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,称为柔性双工网络<sup>[2]</sup>。但是,时分双工和频分双工各具优缺点,单一一种方式无法满足新的业务发展需求,因此出现了两种双工方式融合的趋势。柔性双工网络被认为是两种双工方式融合的重要一步<sup>[3]</sup>,其主要目标是动态分配上下行链路资源,具有更大的灵活性。

近年来,由于深度学习(deep learning, DL)在计算机相关领域的成功应用,越来越多的研究者采用深度学习方法来研究无线网络中的问题<sup>[4-6]</sup>。但在这些任务中收集的数据通常在欧几里得域中进行表示。尽管欧几里得域中DL模型在小规模网络中取得了一些改进,但它们未能利用无线网络的底层拓扑。当网络规模变大时,其性能会急剧下降<sup>[7-8]</sup>。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)引起的网络拓扑高度动态性是一个明显的特点,而且从非欧几里得域收集的无线数据可以表示为具有高维特征和通信设备之间相互依赖的图结构数据。

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(根据特定节点索引描述为邻接矩阵)纳入神经网络的体系结构中。然而,无线网络中通信设备可能会由于资源的重新分配和通信设备的移动而发生变化——动态的图结构数据。这促使科研人员设计一种新的学习模型,以考虑通信设备之间的相关性和无线网络动态特性<sup>[9]</sup>。

图神经网络(graph neural network, GNN)使用全局参数化、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<sup>[10]</sup>。近年来,学者们利用GNN来挖掘隐藏在图结构数据中的深层信息,以进一步提高学习和模拟节点间交互的能力。无线网络固有的图结构使得GNN比全连接神经网络(fully connected neural network, FCNN)或卷积神经网络(convolutional neural network, CNN)更适合解决无线网络问题<sup>[10]</sup>。相较于经典方法,有学者使用GNN对功率控制<sup>[11-12]</sup>、链路调度<sup>[13]</sup>、信道估计<sup>[14]</sup>、蜂窝网络流量预测<sup>[15]</sup>和网络定位<sup>[16]</sup>问题等进行了研究,GNN均具有非常好的表现,同时也能降低某些计算的复杂性。

目前,对于柔性双工网络(flexible duplex networks, Flex-Net)中资源分配优化问题,学者们提出了多种网络框架和算法。文献[17]提出了一种在多输入多输出(multiple input and multiple output, MIMO)异构网络(heterogeneous networks, HetNets)中具有灵活双工的最小发射功率算法。Dayarathna等<sup>[18]</sup>通过对灵活的调度发射机与

接收机,在柔性双工网络中实现最大化和速率。Deng等<sup>[19]</sup>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。Fanjul等<sup>[20]</sup>给出了在MIMO-HetNets环境下最大化下行速率性能的算法。除此之外,还涉及Flex-Net的无线电选帧算法<sup>[1]</sup>、用于联合上下行资源分配的柔性双工框架<sup>[21]</sup>、窄带物联网(narrow band-internet of things, NB-IoT)中柔性双工的资源优化<sup>[22]</sup>等。在流量负载均衡的假设下,文献[23]提出了具有固定节点对的灵活双工网络。但是对于以上这些工作,网络的优化仅限于传输速率,而且提出的网络模型都是基于欧氏距离,无法应对动态的网络拓扑环境。

受到GNN在无线通信网络中成功应用的启发,本文首次提出了使用GNN在Flex-Net中的能效联合优化问题。

考虑到现实的网络环境的复杂性,首次提出了一种能表示柔性双工网络的动态图结构,并成功搭建起在图结构中具有非固定性节点的通信网络背景环境。该图结构可以表示期望链路和潜在干扰链路(包括链路方向),从而有效地学习柔性双工网络的几何和数值特征。提出了一种新的基于GNN的柔性双工网络模型(GFlex-Net),该模型采用无监督学习策略联合优化“通信方向”和“和网络能效”,使Flex-Net“和网络能效”最大化。将使用所提出的架构进行大量模拟获得的数值结果与3种常用方法进行了比较。结果表明,所提出的方法在性能和时间复杂度方面优于常用方法。此外,本文还分析了该方法的样本复杂度、可扩展性和泛化能力。

## 1 系统模型和优化问题

### 1.1 系统模型

本文考虑一个具有干扰信道的柔性双工网络,其中包括 $2N$ 个收发器对节点,如图1所示。为了方便起见,节点的索引被标记为 $1\sim 2N$ 。在 $2N$ 个收发器节点中,均包含 $N$ 个发射器节点和 $N$ 个接收器节点,如图1所示。图1中,实线和虚线分别表示期望链路和干扰链路,实心圆和空心圆分别表示接收机和发射机。不损失一般性,模型中定义了具有相邻索引的节点作为用户对( $1\leftrightarrow 2, \dots, 2n-1\leftrightarrow 2n, \dots, N-1\leftrightarrow N$ )。由于本文考虑的网络属于双工网络,所以每一个用户对中,只有一个节点会处于接收模式,而对应的另一个节点则会处于发送模式。网络中一共存在 $N$ 对用户,在每个用户对中的接收机都会受到其他 $(N-1)$ 个发射机的干扰。

### 1.2 问题描述

由于没有固定的接收机与发射机,因此需要计算出每个节点的信噪比(signal to noise ratio, SINR),Flex-Net中第 $n$ 个节点的信噪比如式(1)。




图1 具有干扰信道的柔性双工网络模型

$$\gamma_n = \frac{p_m d_m |h_{n,m}|^2}{\sigma_n^2 + \sum_{k \neq m, n} p_k d_k |h_{n,k}|^2}, \forall n = 1, 2, \dots, 2N \quad (1)$$

式中：下标  $n, m$  和  $k$  分别表示属于同一个用户对的接收机、发射机和处于此用户对之外对接收机  $n$  造成干扰的发射机。其中， $m = 2(n \bmod 2) + n - 1, d_m = 1 - d_n, d_n \in \{0, 1\}, d_k \in \{0, 1\}, p_m$  表示发射机  $m$  的发射功率， $p_k$  表示发射机  $k$  的发射功率， $h_{n,m}$  和  $h_{n,k}$  分别表示期望链路和干扰链路的信道状态信息 (channel state information, CSI)， $\sigma_n^2$  表示噪声功率。当  $d_n = 0$  时， $d_m = 1$  表示此用户对中的发射机和接收机处于工作状态；当  $d_n = 1$  时， $d_m = 0$  表示此用户对中的发射机和接收机处于非工作状态，且  $\gamma_n = 0$ 。若某个节点没有数据需要继续传输，将其信道状态信息设置为 0，以确保不分配资源给该节点。此外，为了符合现实复杂的网络环境，将信道建模为非互反信道环境<sup>[24]</sup>，即  $h_{n,m} \neq h_{m,n}$ 。

发射机  $m$  与接收机  $n$  之间的信道传输速率  $C_n$  由香农公式得到：

$$C_n = \log_2(1 + \gamma_n), \forall n = 1, 2, \dots, 2N \quad (2)$$

将式(2)中的下行数据速率除以下行功率  $p_m$ ，得到“和网络能效” $R$  (单位为 bit/s/dBm)为：

$$R = \frac{\sum_{n=1}^{2N} R_n}{\sum_{n=1}^{2N} p_n} \quad (3)$$

其中， $\varphi_n$  表示发射机的工作状态， $R_n$  为：

$$R_n = C_n / p_n \quad (4)$$

式中：当  $\gamma_n \neq 0$  时， $\varphi_n = 1$ ；当  $\gamma_n = 0$  时， $\varphi_n = 0$ 。功率单位“dBm”与“W”之间的换算记为：

$$P[\text{in dBm}] = 10 \lg \left( \frac{P[\text{in W}]}{1[\text{in mW}]} \right) \quad (5)$$

### 1.3 优化问题

网络的优化目标旨在联合优化 Flex-Net 的功率分配和通信方向。为此，和网络能效的最大化问题定义为：

$$\begin{aligned} \max \quad & \sum_{p_n, d_n, \forall n} R \\ \text{s. t.} \quad & 0 \leq p_n \leq P_{\max}, \forall n \\ & m = 2(n \bmod 2) + n - 1, \forall n \\ & d_m = 1 - d_n, \forall n \end{aligned} \quad (6)$$

$$d_n \in \{0, 1\}, \forall n$$

$$\varphi_n \in \{0, 1\}, \forall n$$

式中： $P_{\max}$  为发射机最大发射功率。此优化问题对于任意数量的用户对都是 NP-hard 问题<sup>[24]</sup>。

## 2 联合功率和通信方向联合优化

本文联合优化问题需要优化两个量，功率分配向量以及通信方向向量，分别表示为  $\mathbf{P} = [p_1, p_2, \dots, p_{2N}]^T$  和  $\mathbf{D} = [d_1, d_2, \dots, d_{2N}]^T$ 。针对坐标下降法的缺陷，提出 GFlex-Net 模型，以共同优化功率分配和通信方向，使得和网络能效最大化。

### 2.1 启发式算法——坐标下降法

坐标下降法作为一种非梯度算法，其核心思想是将多维度问题化为单维度问题，从而可以使得多变量优化问题转变成多个单变量优化问题；它每次沿着单维度方向进行函数最小值搜索，当得到当前维度的目标值以后进行迭代转换为不同的唯轴方向，最终收敛得到最优解。

本文采用文献[25]提出的直接搜索机制来优化离散整数变量  $D$ ，同时保持  $P$  不变。然后使用加权最小均方误差 (weighted minimum mean square error, WMMSE) 算法<sup>[26]</sup>重新计算功率向量  $P$ 。重复上述步骤，直到在最后迭代中实现的和网络能效与目标值的差值小于用户定义的常数  $\epsilon$ ，收敛得到最优解。尽管这个算法具有接近最优的和网络能效性能，但该方法的计算复杂度为  $O(n^4)$ 。这使得该算法难以应用于大规模网络中的实时资源分配，需要克服该算法的计算复杂性问题。

### 2.2 GFlex-Net 表示方法

GFlex-Net 联合优化发射功率  $P$  和通信方向  $D$  使得和网络能效最大化：首先，将柔性双工网络表示为具有两种边的图，这两种边分别为无向边和有向边；然后，将期望链路和交联的信道状态信息分别作为顶点特征和边缘特征；接着所创建的图被用作所提出的 GNN 模型的输入，其中节点表示每个收发机。

GNN 最初被提出是为了扩展现有的神经网络来处理图域中的数据<sup>[27]</sup>。在本文的优化问题中，选择使用空间 GNN 作为底层网络框架来优化目标函数，这是因为空间 GNN 能够更好地捕捉图的局部结构和节点之间的关系，从而在求解问题时具有更强的表达能力<sup>[28-29]</sup>。利用空间 GNN 的优势，可以有效地处理目标函数，并获得更好的优化结果。

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。在每一层中，中心节点将其自身特征与从邻居节点聚集的特征进行组合。通过迭代地进行聚合和组合操作，GNN 能够逐渐更新每个节点的表示，如图 2 所示。节点  $v$ ，其中  $v \in V$ ，在第  $m$  层的更新规则为<sup>[28]</sup>：

$$\alpha_v^{(m)} = \text{AGGREGATE}^{(m)}(\{x_u^{(m-1)}, x_v^{(m-1)}, e_{uv}, e_{vu} : u \in$$

$N(v)\}$

$$x_v^{(m)} = \text{COMBINE}^{(m)}(x_v^{(m-1)}, a_v^{(m)}) \quad (7)$$

式中： $\alpha_v^{(m)}$  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。而且，AGGREGATE 函数和 COMBINE 函数的不同选择可以构成不同的 GNN 网络。

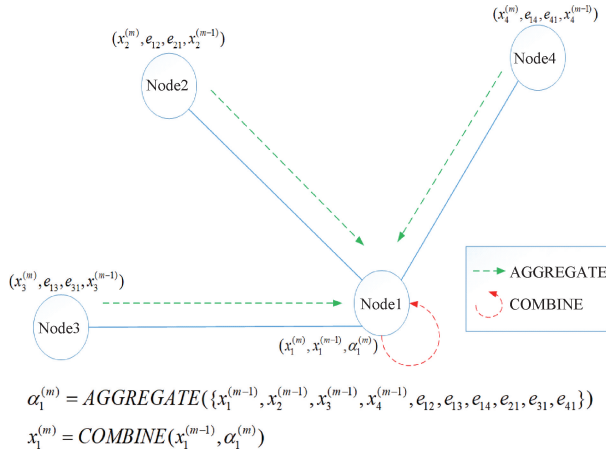


图2 GNN中每个节点更新过程示意图

Flex-Net 的图模型包含  $2N$  个收发器节点，每个发射器发送的信号对非预期的接收器产生干扰。网络结构如图3所示，通过观察这种物理网络结构，可以帮助更好地理解和分析系统中不同节点之间的关系。

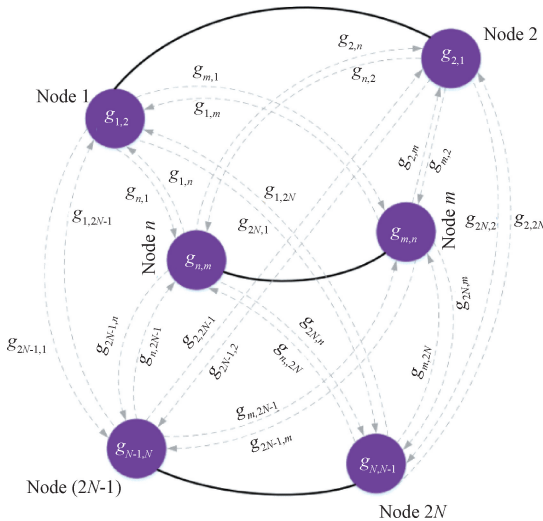


图3  $2N$  个收发器顶点构成的柔性双工网络

网络中的每一个收发器节点由图中的每一个顶点表示。由于网络中共有  $2N$  个收发器，因此，图3中有  $2N$  个顶点。任意两个顶点之间都有一定的联系，通过边连接起来。接下来，对顶点和边的属性进行定义。由于在和网络能效公式的分子项中包含了信道状态信息的平方值，因此，定义第  $n$  个节点的属性包含处于同一用户对中收发器之间信道状态信息的平方值  $g_{n,m} = |h_{n,m}|^2$ ，并作为此顶

点的特征。图3为具有  $2N$  个收发器顶点的柔性双工网络，其中连接每个顶点的边分为两种：1) 每个用户对内连接发射机和接收机的期望链路用无向边表示，记为  $e_d$ ；2) 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顶点表示为发射机时，这条边才会称为干扰，由图2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，本文模型定义从产生干扰的发射机顶点到接收机之间边  $e_i$  的边缘特征为  $g_{u,k} = |h_{u,k}|^2$ 。

### 2.3 GFlex-Net 架构

通常情况下，GNN 可以执行 3 种类型的任务，分别为节点级任务、边级任务和图级任务。在图级任务中，GNN 对整个图进行分析和处理，能够获得对整个图的全局认知，因此本文选择在网络图上执行两种类型的任务。边级任务旨在找到节点间所需连接的方向。通过分析节点之间的边和拓扑结构，能够确定连接的方向，从而实现更有效的网络通信和信息传递。除了边级任务，本文模型还进行了节点级任务，即预测每个节点的最佳功率值。通过对节点属性、邻居节点和连接关系的深入分析和学习，能够确定每个节点的最佳功率，以最大化和网络能效。

本文 GNN 有两个信息聚合步骤组成，由期望链路  $e_d$  和干扰链路  $e_i$  表示连接(图2和3)。通过对这两类边执行如下操作：

$$\begin{aligned} \alpha_{v;\text{intf}}^{(m)} &= \gamma[\theta(\mathbf{W}_{u;\text{intf}}^{(m)} x_u^{(m-1)} + \mathbf{W}_{v;\text{intf}}^{(m)} x_v^{(m-1)} + \mathbf{W}_{e;\text{intf}}^{(m)} e_{u,v} + \mathbf{W}_{e;\text{intf}}^{(m)} e_{v,u}; u \in N_{\text{intf}}(v))] \\ c_v^{(m)} &= (x_v^{(1)} \parallel \alpha_{v;\text{intf}}^{(m)}) \\ \alpha_{v;\text{dsr}}^{(m)} &= \gamma[\theta(\mathbf{W}_{u;\text{dsr}}^{(m)} c_u^{(m)} + \mathbf{W}_{v;\text{dsr}}^{(m)} c_v^{(m)}; u \in N_{\text{dsr}}(v))] \\ x_v^{(m)} &= (x_v^{(1)} \parallel \alpha_{v;\text{dsr}}^{(m)}) \end{aligned} \quad (8)$$

式中： $\gamma$  表示一个具有置换不变性的池化函数，例如最大值函数或求和函数； $\theta$  表示一个非线性激活函数，例如 Sigmoid 函数或 Relu 函数； $x_v^{(m)}$  表示第  $m$  层中顶点  $v$  的节点特征； $\mathbf{W}$  表示可训练的权重矩阵； $N_{\text{intf}}(v)$  表示通过  $e_i$  边连接到顶点  $v$  的相邻顶点的集合； $N_{\text{dsr}}(v)$  表示通过  $e_d$  边连接到顶点  $v$  的相邻顶点的集合； $e_{u,v}$  表示从顶点  $u$  到  $v$  的  $e_i$  边的边缘特征； $x_v^{(1)}$  表示第 1 层的节点嵌入，即所需信道状态信息的平方值； $\alpha_{v;\text{intf}}^{(m)}$  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； $\alpha_{v;\text{dsr}}^{(m)}$  表示考虑干扰情况下节点  $v$  在第  $m$  层更新的节点特征。从第 1 层到第  $m$  层的跳跃连接被称为残差连接。这种残差连接可以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，残差连接显著提高了深度神经网络的性能<sup>[30]</sup>。符号  $\parallel$  表示向量的拼接。此外，与先前研究中描述的图神经网络不同，GFlex-Net 架构能够通过使用两个聚合步骤来准确生成 Flex-Net 的节点嵌入，这使其在该领域具备出色的性能。

在完成上述多层的聚合和组合步骤后，最后一层的嵌

入被用于预测节点的功率值:

$$p_n = P_{\max} \text{SIGMOID} \left( \frac{1}{T_p} \text{MLP}(x_n^{(final)}) \right) \quad (9)$$

这个过程引入了一个称为温度的缩放参数  $T_p$ , 并采用可训练的 MLP.  $x_n^{(final)}$  表示第  $n$  个节点的最终层嵌入. 使用较低的温度值可以使得功率值更加极端, 一般倾向使用于 0 或  $P_{\max}$ .

通过考虑通过  $e_d$  相连的相邻节点的嵌入, 可以确定期望链路的方向. 如系统模型中描述的那样, 使用二进制变量表示方向. 然而, 由于缺乏可微性, 使用二进制约束来优化网络是困难的. 因此, 本文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, 通过同时考虑两端节点的嵌入来决定边的方向.

$$d_{u,v} = \text{SIGMOID} \left( \frac{1}{T_d} \text{MLP}(x_u^{(final)} \parallel x_v^{(final)}) \right) \quad (10)$$

这个过程中引入了温度参数  $T_d$ , 并使用由  $e_d$  连接的相邻节点的节点嵌入  $x_u^{(final)}$  和  $x_v^{(final)}$ . 与功率分配类似, 将松弛的二进制约束在 0 和 1 内, 通过使用较低的温度值作为正则化器.

本文使用 ADAM 优化网络可训练参数. 将优化目标的负值作为损失函数进行优化, 这种优化过程是一种无监督学习机制, 无需使用标签进行训练. 通过按照该方法生成的数据, 能够优化网络的可训练参数, 从而提高网络的性能和泛化能力. 使用 ADAM 算法, 能够自适应地调整梯度下降步长, 从而更快地收敛到损失函数的最优解, 采用这种方法, 能够提高网络对数据的理解能力, 从而为进一步的应用和任务提供更好的基础.

### 3 仿真和结果分析

将所提出的方法与不同的现有算法在性能、时间复杂度和泛化能力方面进行比较.

#### 3.1 仿真设置

假设在一个  $4 \text{ km} \times 4 \text{ km}$  区域的 Flex-Net<sup>[31]</sup>, 这能够更好地研究和评估网络在真实城市环境中的性能. 这个尺寸大小与现实城市环境中的区域相当, 可以容纳多个基站、终端设备和用户, 提供一个相对真实的网络拓扑和业务流量, 能够提供一定的模拟真实性. 设备在二维空间中分布, 但在本文的 GFlex-Net 模型中, 设备可以在任意维度的空间中分布. 所以假设设备的分布服从泊松分布, 但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. 所有实验采用 NVIDIA RTX 1060 (8GB 内存) 和 Intel i7 8750 CPU, 使用 Python 3.8, PyTorch 2.0.1 和 CUDA 11.8 在 Windows 10 系统上实现了实验代码.

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<sup>[32]</sup>. 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 {4, 8, 12, 16, 20, 24, 28, 32} 不同数量的用户场景进行仿真, 将本文提出的方法与表 1 中的 3 种常用方法进行比较. 在穷举搜索方面, 采用了 WMMSE 算法, 该算法应用于所有方向组合能够全面地考虑问题, 找到最佳的解决方案, 但是由于穷举法需要考虑所有可能的情况, 问题的复杂度可能呈指数级增长、运算量巨大. 对于最大功率策略<sup>[31]</sup>, 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. 对于启发式算法而言 (2.1 节), 本文选用其中的坐标下降法作为比较方法, 这个方法的核心思想是控制变量法, 在优化过程中每次只优化一个变量, 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<sup>[31]</sup>. 此外, 如果存在至少一个交联, 也就是至少有两个节点之间建立了通信链路. 其接收功率是所需链路的 2 倍, 这意味着接收器收到的信号强度是发送信号所需的链路的 2 倍. 则静默节点策略将关闭相应的发射机, 以最大限度地减少干扰.

表 1 实验中对比的算法<sup>[31]</sup>

算法	时间复杂度
穷举法 (Exhaustive Search)	$O(2^n)$
坐标下降法 (Heuristic Search)	$O(n^4)$
本文算法 (GFlex-Net)	$O(n^2)$
最大功率策略 (Max Power)	$O(n)$

#### 3.2 GNN 超参数调整

神经网络的性能受到不同超参数的影响, 因此对实验中对几个关键超参数进行分析.

首先, 测试训练样本数量对模型性能的影响, 以验证文献<sup>[33]</sup>提出的 GNN 相对于传统的全连接神经网络需要更少训练样本的假设. 基于 32 个用户的训练样本数量进行了性能测试, 每个模型都经过了 100 次迭代的训练, 并进行了性能评估.

接着, 评估 GNN 中层数对性能的影响, 分别设置样本数量 {2 000, 5 000, 10 000, 15 000, 20 000} 和 GNN 层数 {1, 2, 3, 4, 5}, 结果如图 4 所示. 在不同样本数量的情况下, 尽管性能随着层数的增加而提高, 但 Flex-Net 即使只有 3 个 GNN 层, 也能优于传统方法. 在后续的模拟实验中使用了 3 个 GNN 层.

在选定 GNN 层数为 3 的情况下, 可以发现即使使用了只有  $10^4$  个样本的训练集, 该模型的性能也能达到 99% 以上, 如图 5 所示. 同使用 FCNN 或 CNN 提出的功率控制方法相比, 本文所提算法所需的训练样本数量非常少. 综上所述, 在后续的模拟实验中统一采用 3 个 GNN 层,

10 000 个样本进行网络参数的训练。




图 4 不用样本数量下 GNN 中层数对性能的影响




图 5 GNN 层数为 3 训练样本数量对性能的影响

最后,通过使用参数网格搜索来选择批量大小和学习率,如图 6 所示,可以发现较小的批量大小结合较小的学习率可以获得更好的性能。相反,较高的学习率会导致过度调节,从而导致不稳定的训练和较差的性能。基于实验结果,选择了批量大小为 32 和学习率为 0.002,并在后续的仿真中使用这些参数。




图 6 批量大小和学习率对算法性能影响

在本文的 GNN 体系结构中,节点嵌入是递归地逐层更新的。作为汇聚函数的池化函数,使用映射多集函数,

sum-pooling 函数优于 max-pooling 函数<sup>[34-35]</sup>。在本文实验中,发现两种池化函数的性能几乎相同。所以,接下来的实验选择 sum-pooling 函数作为汇聚函数的池化函数。

上述超参数的分析,能够帮助本文模型找到合适的参数配置方式,以期获取更好的神经网络性能,这些实验结果为本文模型设计和优化提供了帮助。

### 3.3 性能分析

对 GFlex-Net 模型平均网络能效性能与所有常用方法进行了对比,通过模拟结果的分析,如图 7 所示。GFlex-Net 模型能够达到穷举法性能的 95%,节点数为 24 时,从图 7 可以看出,本文算法表现出来的性能仅比穷举法低了 4%,而比坐标下降法高出 6%,比最大功率策略高出 40%。由于穷举法是遍历每一种方案逐个比较,不遗漏任何一个选项并找到最佳的解决方案,但这都是巨大的时间复杂度为代价的,实际问题中往往需要运用更高效的算法和优化方法。

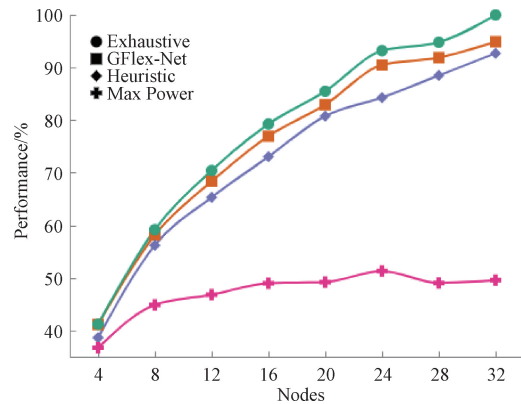


图 7 算法性能随节点数量变化

### 3.4 时间复杂度分析

在对于更高的数据传输速率和更低的延迟需求日益增长的情况下,无线网络需要能够以最小的处理开销来控制数千个用户。在这一方面,GNN 的优势显现出来,它能够在保持显著较低的时间复杂度的同时,达到与传统算法相当的性能。将 GNN 的平均运行时间与其他基准方法进行了比较,使用了 10<sup>4</sup> 个测试样本,仿真结果如图 8 所示。

从图 8 可以看到,当节点数为 4 的时候,GNN 的运行时间略高于启发式算法和穷举法,这是因为 GNN 中需要经过神经网络的计算,而启发式算法和穷举法却不需要。但是随着节点数量的增加,从图 8 可以明显的看出启发式算法和穷举法的运行时间也随之上升,当节点数达到 32 时,启发式算法的运行时间达到 GNN 的 40 倍,穷举法的运行时间甚至达到 GNN 的 10<sup>4</sup> 倍,而 GNN 一直保持低运行时间。但是,最大功率策略的运行时间远低于这 3 个算法,这是因为在最大功率策略中未涉及到功率与方向的优化,虽然时间复杂度低,也是以低性能为代价(图 7)。

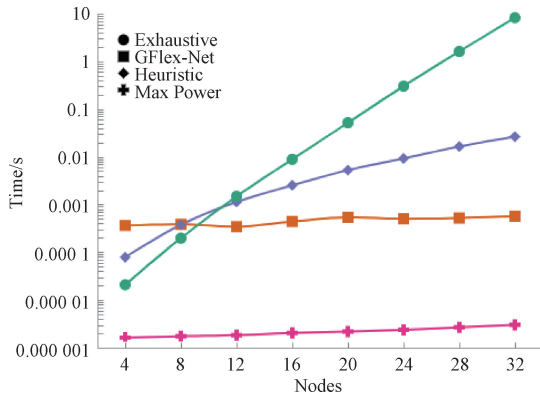


图8 各种算法时延性能随节点数量变化




图9 综合能源效率随节点数量变化

由此可见,GNN 在运行时间上明显优于穷举法和启发式算法,这使得 GNN 方法非常适合在具有低延迟要求的实时网络环境中使用。

通过对比实验,可以发现 GNN 方法在控制大量用户并保持低延迟方面表现出众。GNN 方法的优势在于其相对较低的时间复杂度,这意味着它能够快速处理大规模的数据。

从图 7 和 8 可以看出,穷举法和最大功率策略对于性能和效率这两项指标不可兼得。虽然,坐标下降法在兼顾性能和效率方面远优于这两种算法,但是相比于本文所提出的 GFlex-Net 架构还有不足。

通过与 3 种常用方法的比较,可知本文提出的方法在性能上的优势以及在时间复杂度上的优势。本文方法考虑了更多的因素,如信道状态信息、干扰等级和对静默节点的控制策略,以达到更好的资源分配和网络性能。通过比较实验结果,可以判断本文的方法是否能够更有效地提高系统的容量和覆盖范围,并提供更稳定和可靠的通信服务。在未来的实际部署中,相信所提出的方法能够为无线网络的优化提供一个切实可行的解决方案。

### 3.5 泛化能力分析

GNN 的操作既不依赖于网络中的节点数量,也不依赖于边的数量。这与传统的 FCNN 不同,传统的 FCNN 需要重新训练以适应不同的输入大小。因此,GNN 在无线网络中处理具有可变用户数量的场景时,表现出了令人难以置信的实用性,可以轻松地应用同一个已训练好的 GNN 模型来处理不同节点数量的无线网络。

为了研究 GNN 的泛化能力,并没有针对不同节点数量训练多个模型,而是只训练了一个模型,并在具有 4~32 个用户的网络中测试其性能。在训练过程中,使用了具有不同节点数量的样本。通过实验数据,如图 9 所示,可以看出 GFlex-Net 在用户数量变化时的性能保持稳定,这进一步证明了 GNN 的泛化能力。

这一发现对于在实际应用中具有不同用户规模的无线网络非常重要。采用 GNN,可以避免为不同用户规模

训练不同的模型,节省了时间和计算资源,这为无线网络的部署和扩展性带来了极大的便利。未来,可以进一步研究和探索 GNN 的适应性和泛化能力,以应对更广泛的网络场景和应用需求。

## 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,考虑了一个能够动态调度的 TDD 网络的系统模型,针对最大化网络总能效性能的目标,产生了一个 NP-hard 优化问题。为了解决这一问题,本文提出了一种基于 GNN 的全新模型。首先,将柔性双工网络建模为一个图,作为所设计的 GNN 模型的输入。然后,通过对生成的图数据进行无监督的优化,来对 GNN 模型进行训练和调整。为了获得最大可能的网络能效,本模型采用网格搜索方法来寻找适合 GNN 的最佳超参数。最后,将本文提出的方法与其他 3 种常用方法进行了比较。数值结果表明,与 3 种常用方法相比,本文提出的 GFlex-Net 模型能够在大大降低时间复杂度的同时产生接近最优的结果。

进一步的分析验证了本文所提出方法的优势,包括样本复杂性、可扩展性和泛化能力。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 GNN 方法,能更好地优化网络性能,并且适用于不同规模和特性的灵活双工网络。

未来,将继续深入研究和改进 GNN 方法。1)模型结构,科研人员可以探索不同的 GNN 模型结构,包括图卷积网络、图注意力网络等,以提高模型的表示能力和学习效果。2)聚合策略,改进 GNN 中的信息聚合策略,如使用不同的聚合函数、注意力机制或采样方法,以更好地捕捉节点之间的关系和全局信息。3)特征表示,研究如何更好地表示节点和边的特征,包括结合节点属性、边属性和图结构信息等,以提高模型的表达能力。4)动态图更新,灵活双工网络中的拓扑结构可能会随时间变化,因此需要研究如何在动态图中更新 GNN 模型,以适应网络拓扑的变化。

## 参考文献

- [1] 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 (ICT). IEEE, 2015: 308-312.
- [2] DAYARATHNA S, RAZLIGHI M, SENANAYAKE R, et al. Centralized scheduling with sum-rate optimization in flexible half-duplex networks [C]. Wireless Communications and Networking Conference (WCNC). IEEE, 2020: 1-6.
- [3] WAN L, ZHOU M, WEN R. Evolving LTE with flexible duplex[C]. 2013 IEEE Globecom Workshops (GC Wkshps). IEEE, 2013: 49-54.
- [4] ZHANG C, PATRAS P, HADDADI H. Deep learning in mobile and wireless networking: A survey[J]. IEEE Communications Surveys & Tutorials, 2019, 21(3): 2224-2287.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] LEE W, KIM M, CHO D H. Deep power control: Transmit power control scheme based on convolutional neural network [J]. IEEE Communications Letters, 2018, 22(6): 1276-1279.
- [9] 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.
- [10] 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.
- [11] EISEN M, RIBEIRO A. Large scale wireless power allocation with graph neural networks [C]. 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). IEEE, 2019: 1-5.
- [12] 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.
- [13] LEE M, YU G, LI G Y. Graph embedding-based wireless link scheduling with few training samples[J]. IEEE Transactions on Wireless Communications, 2020, 20(4): 2282-2294.
- [14] TEKBIYIK K, KURT G K, HUANG C, et al. Channel estimation for full-duplex RIS-assisted HAPS backhauling with graph attention networks [C]. International Conference on Communications. IEEE, 2021: 1-6.
- [15] ZHAO S, JIANG X, JACOBSON G, et al. Cellular network traffic prediction incorporating handover: A graph convolutional approach[C]. 17th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON). IEEE, 2020: 1-9.
- [16] YAN W, JIN D, LIN Z, et al. Graph neural network for large-scale network localization[C]. International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2021: 5250-5254.
- [17] FANJUL J, SANTAMARIA I. Power minimization in multi-tier networks with flexible duplexing[C]. International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2019: 4699-4703.
- [18] 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.
- [19] 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.
- [20] FANJUL J, SANTAMARIA I. Flexible duplexing for maximum downlink rate in multi-tier MIMO networks [C]. 26th Telecommunications Forum (TELFOR). IEEE, 2018: 1-6.
- [21] LIAO Q. Dynamic uplink/downlink resource management in flexible duplex-enabled wireless networks[C]. 2017 IEEE International Conference on Communications Workshops (ICC Workshops). IEEE, 2017: 625-631.
- [22] MALIK H, ALAM M M, PERVAIZ H, et al. Radio resource management in NB-IoT systems: Empowered by interference prediction and flexible duplexing[J]. IEEE Network, 2019, 34(1): 144-151.
- [23] POPOVSKI P, SIMEONE O, NIELSEN J J, et al. Interference spins: Scheduling of multiple interfering two-way wireless links[J]. IEEE Communications



- Letters, 2014, 19(3): 387-390.
- [24] MURDOCK J N, RAPPAPORT T S. Consumption factor: A figure of merit for power consumption and energy efficiency in broadband wireless communications[C]. 2011 IEEE Globecom Workshops (GC Wkshps). IEEE, 2011: 1393-1398.
- [25] DAYARATHNA S, RAZLIGHI M, SENANAYAKE R, et al. Centralized scheduling with sumrate optimization in flexible half-duplex networks [C]. Wireless Communications and Networking Conference (WCNC). IEEE, 2020: 1-6.
- [26] 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.
- [27] 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.
- [28] 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.
- [29] 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.
- [30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [31] PERERA T, ALAPALLU S, FANG Y, et al. Flex-Net: A graph neural network approach to resource management in flexible duplex networks [C]. Wireless Communications and Networking Conference (WCNC). IEEE, 2023: 1-6.
- [32] GREGOR K, LECUN Y. Learning fast approximations of sparse coding[C]. Proceedings of the 27th International Conference on International Conference on Machine Learning, 2010: 399-406.
- [33] XU K, LI J, ZHANG M, et al. What can neural networks reason about? [EB/OL]. (2020-02-15) [2023-07-11]. <https://arxiv.org/abs/1905.13211>.
- [34] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [EB/OL]. (2019-02-22) [2023-07-11]. <https://arxiv.org/abs/1810.00826>.
- [35] GARG V, JEGELKA S, JAAKKOLA T. Generalization and representational limits of graph neural networks[C]. International Conference on Machine Learning, 2020: 3419-3430.

## 作者简介

王子威, 硕士, 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

李晖(通信作者), 博士, 教授, 主要研究方向为无线网络优化、AI在通信系统中应用、空天信息网络技术等。

E-mail: hitlihui1112@163.com

史振婷, 硕士, 主要研究方向为人工智能、神经网络等。

E-mail: szt19981026@163.com

张见, 博士, 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

陶旭, 博士, 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

# 融合 Transformer 和语义图卷积的三维人体姿态估计方法\*

李功浩 贾振堂

(上海电力大学电子与信息工程学院 上海 201306)

**摘要:**为了进一步提升从单目二维人体姿态预测三维人体姿态的方法性能,提出一种融合 Transformer 和语义图卷积的三维人体姿态估计模型,模型由 4 个部分组成,Transformer 编码网络、语义图卷积编码网络、姿态坐标预测模块和姿态坐标错误回归模块。首先,Transformer 编码网络对关节特征进行全局特征编码,以增强人体姿态的全局关联性。其次,语义图卷积编码网络专注于局部关节特征提取,以加强局部关节特征之间的关联性。接下来,姿态坐标预测模块和姿态坐标错误回归模块将关节全局和局部编码特征融合,以增强对三维姿态的准确建模能力。通过在 Human3.6M 数据集上进行实验表明,方法在估计性能方面取得了较好的改进,以真实的二维人体姿态作为输入,在 MPJPE 和 PA-MPJPE 值分别为 32.7 和 25.9 mm,与实验对照方法相比,性能分别提升了 3.82% 和 1.14%。

**关键词:**三维人体姿态;语义图卷积;Transformer

**中图分类号:** TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.20

## 3D human pose estimation method fusing Transformer and semantic graph convolution

Li Gonghao Jia Zhentang

(College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 201306, China)

**Abstract:** In order to enhance 3D human pose prediction from monocular 2D poses, we propose a model that combines Transformer and semantic graph convolution. The model consists of four components: Transformer encoding network, semantic graph convolutional encoding network, pose coordinate prediction module, and pose coordinate error regression module. The Transformer network captures global joint features to improve posture relevance, while the Semantic Graph Convolutional Encoding Network focuses on local joint feature extraction to enhance correlations. The pose prediction and error regression modules fuse global and local joint features, improving 3D pose accuracy. Experimental results on Human3.6M dataset show significant improvements, achieving MPJPE and PA-MPJPE values of 32.7 and 25.9 mm, respectively, representing a 3.82% and 1.14% improvement over the control method.

**Keywords:** 3D human pose estimation; semantic graph convolution; Transformer

### 0 引言

三维人体姿态估计是计算机视觉领域的一个研究热点,涉及从图像或视频中准确估计人体的三维姿态信息。这项技术在许多应用领域都有广泛应用,例如运动分析<sup>[1]</sup>、人机交互<sup>[2]</sup>、虚拟现实<sup>[3]</sup>和增强现实<sup>[4]</sup>等。

当前三维人体姿态估计方法大部分基于深度神经网络。

现有的三维人体姿态估计方法按照模型处理阶段分为两类。一类是单阶段直接从图像中预测三维姿态。另一类是将三维姿态估计的任务分解为两个独立的阶段:首先,采用基于深度卷积神经网络<sup>[5]</sup>(convolutional neural network, CNN)的二维姿态估计方法<sup>[6-8]</sup>,通过该方法预测图像空间中的关节位置。随后,从二维姿态中学习三维人体姿态。针对两阶段三维姿态估计任务,文献<sup>[9]</sup>利用全

收稿日期:2023-09-27

\* 基金项目:国家自然科学基金(62105196)项目资助