

DOI:10.19651/j.cnki.emt.2005590

# 基于图卷积网络的车联网资源管理<sup>\*</sup>

王晓昌<sup>1,2,3</sup> 朱文星<sup>1,2,3</sup> 孙彦贊<sup>1,2,3</sup> 吴雅婷<sup>1,2,3</sup> 王涛<sup>1,2,3</sup>(1. 上海大学 上海先进通信与数据科学研究院 上海 200444; 2. 上海大学 特种光纤与光接入网重点实验室 上海 200444;  
3. 上海大学 特种光纤与先进通信国际合作联合实验室 上海 200444)

**摘要:** 车辆到一切(V2X)通信是有效地提高交通安全性和移动性的解决方案。为了解决深度学习在功率分配中存在的需要大量训练数据和泛化性问题,减少车辆网络信道干扰,提出了基于图卷积神经网络(GCN)的总用户速率最大化,总用户能效最大化的两种准则下的功率分配框架。所提出的框架首先将无线干扰信道转化为图数据结构,证明了干扰信道的无序性;其次根据不同功率分配准则的特点,构建了GCN网络结构,同时提出相应的损失函数。通过与基于加权最小均方误差(WMMSE)算法训练的多层感知器(MLP)网络对比,仿真数据表明,在小样本训练、可扩展性、可泛化性几个方面,所提出方案优于对比算法。

**关键词:** 车辆网络;能源效率;图卷积神经网络;功率分配;深度学习

中图分类号: TN929.5 文献标识码: A 国家标准学科分类代码: 510.5015

## Resource management of vehicle network based on graph convolutional neural network

Wang Xiaochang<sup>1,2,3</sup> Zhu Wenxing<sup>1,2,3</sup> Sun Yanzan<sup>1,2,3</sup> Wu Yating<sup>1,2,3</sup> Wang Tao<sup>1,2,3</sup>(1. Shanghai Institute for Advanced Communication and Data Science, Shanghai University, Shanghai 200444, China;  
2. Key Laboratory of Specialty Fiber Optics and Optical Access Networks, Shanghai University, Shanghai 200444, China;  
3. Joint International Research Laboratory of Specialty Fiber Optics and Advanced Communication, Shanghai University,  
Shanghai 200444, China)

**Abstract:** Vehicle to everything (V2X) communication is an effective solution to improve traffic safety and mobility. In order to solve the problems of deep learning that requires a large amount of training data and generalization in power allocation, this paper proposes a power distribution framework that based on graph convolutional network (GCN) under the three criteria of maximizing the total user rate, maximizing the total user energy efficiency. The proposed framework first converts the wireless interference channel into a graph data structure, which proves the disorder of the interference channel. Secondly, according to the characteristics of different power distribution, the GCN network structure is constructed, and the corresponding loss function is proposed. Compared with the multilayer perceptron (MLP) network trained based on the weighted minimum mean square error (WMMSE) algorithm, the simulation data shows that the proposed scheme is better than the comparison algorithm in terms of small sample training, scalability and generalizability.

**Keywords:** vehicle network; energy efficiency; graph convolutional neural network; power control; deep learning

## 0 引言

近年来,车辆到一切(vehicle-to-everything, V2X)通信由于能提高道路安全性、交通效率和车辆娱乐体验已被认为第五代(5th Generation, 5G)无线通信网络中关键应用场景之一<sup>[1]</sup>。

在未来的道路上,车辆需要提供更多的娱乐和交通相关应用,如视频流和人群感应,因此需要通过大容量车对网(vehicle to network, V2N)链路通信访问互联网或V2X服务器<sup>[2]</sup>。同时,未来的无线网络将以前所未有的复杂性为特征,这使得传统的网络设计、部署和操作方法等不

收稿日期:2020-12-22

\*基金项目:国家重点研发计划(2017YFE0121400)、国家自然科学基金(61501289, 61671011, 61420106011)项目资助

再适用<sup>[3]</sup>。

有效的资源配置对无线网络的性能优化起着至关重要的作用。然而,典型的资源配置问题是非凸的,如功率控制<sup>[4-5]</sup>,并且在计算上具有挑战性。文献[6]提出在超密集网络场景下,联合功率控制和用户调度的策略对网络能效进行优化。文献[7]中利用V2V(vehicle-to-vehicle)链路的CSI延迟反馈进行频谱复用和功率分配,使V2N链路的总吞吐量最大化。文献[8]中在保证V2V链路中断概率的前提下,使V2N链路的总容量最大化。文献[9]提出由车辆分组、频谱复用选择和功率分配组成的框架来提高V2V链路的吞吐量。文献[10]中在限制V2V链路的传输延迟和中断概率下,使V2N链路的总吞吐量最大化。为了适应无线信道的时变特性,需要对其进行实时求解。对于实际的网络场景,有效的无线资源配置算法可以通过凸优化方法获得可行解。然而,考虑到无线网络密度的不断增加和车联网应用对延迟的要求越来越严格,此类算法存在时间复杂度过高等问题。为了减小无线优化算法的时间复杂度,基于机器学习的无线资源配置越来越受到关注<sup>[11-12]</sup>。

当前研究表明基于深度学习方法的功率分配算法性能优异,然而现有基于深度学习的方法中还存在着许多待解决的问题。如当前基于深度学习的方法为数据驱动,需要大量的训练数据<sup>[13]</sup>;随着无线网络的规模增大,基于多层感知器(multilayer perceptron, MLP)和卷积神经网络(convolutional neural network, CNN)等神经网络模型的方法将会出现性能下降,因此可扩展性能较差;最重要的一个问题是当前的神经网络模型对动态的网络场景不具有泛化性<sup>[14]</sup>。另外MLP和CNN适用于处理欧几里得数据结构,然而无线干扰信道模型最佳的表示方式为非欧几里得数据结构,即图数据结构。文献[15]中提出了一种图卷积神经网络(graph convolutional network, GCN),利用干扰信道的图结构最大化用户总和速率。图论在传统的车联网资源配置方法中被广泛应用,同时最近GCN在自然语言处理和推荐系统等领域取得的成功<sup>[16-17]</sup>,使其也受到通信领域研究者的广泛关注<sup>[18-19]</sup>。综上所述,面向动态车联网场景,本文将研究基于GCN的总用户速率最大化,总用户能效最大化的两种准则下的功率分配框架,并与MLP在多个方面进行对比。

本文研究内容主要包括:首先分析干扰信道在功率分配问题中的排列不变性,提出了GCN在车联网中不同功率分配准则下分配问题中的可行性。其次,根据在干扰信道表示的图模型基础上,根据功率分配准则的特点,提出了一种节点的更新机制,构建了对应的GCN的网络结构。对于GCN的训练,使用了无监督的方式,在不需要训练样本标签的情况下,就可以得到功率分配结果。最后,在小样本训练、可扩展性、可泛化性几个方面,对比了GCN和MLP在功率分配上的性能。

## 1 系统模型及优化问题

### 1.1 系统模型

考虑具有K个小区的多小区通信系统。相邻小区中心之间的距离设定为200 m,在每个小区中,一个具有单个天线的基站(base station, BS)放置在小区的中心,并且移动的用户车辆(vehicle user equipment, VUE)随机均匀的分布。为了简化分析,每个小区中有1个单辆车和1条共享的单链路,如图1所示。该系统可被看为用户单天线干扰信道模型。每个VUE与每个BS之间的V2N信道是根据0均值,方差为 $(200/d)^3 L$ 的瑞利衰落分布随机生成,其中d表示基站和用户之间的距离,阴影衰落数值表示为服从均值为0、方差为64的对数归一化分布。

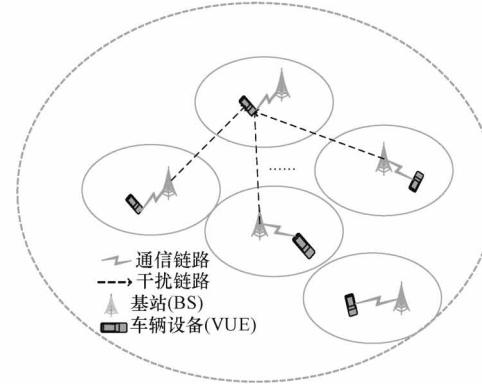


图1 多小区通信干扰示意图

### 1.2 问题建模

假设所有的发射机接收机对都共享相同的窄带频谱并且是同步的,第k个用户VUE在离散时间接收到的基带信号为:

$$y_k = h_{kk}x_k + \sum_{j \in \mathcal{K}/\{k\}} h_{kj}x_j + n_k \quad (1)$$

式中: $\mathcal{K} = \{1, 2, \dots, K\}$ 表示的是车辆用户VUE发射接收对的集合; $\mathcal{K}/\{k\}$ 表示不包含第k对的发射机接收机对的集合; $x_k$ 表示第k个VUE发送的信号; $h_{kk}$ 表示对于第k个用户的直接连接信道; $h_{kj}$ 表示第j个基站和第k个车辆用户VUE之间的干扰链路信道; $n_k \sim \mathcal{CN}(0, \sigma_k^2)$ 表示车辆用户接受的噪声,该噪声变量对于时间和用户而言,都是独立的。

根据以上的假设,VUE用户k的SINR可以被表示为:

$$\text{SINR}_k = \frac{|h_{kk}|^2 p_k}{\sum_{j \neq k} |h_{kj}|^2 p_j + \sigma_k^2} \quad (2)$$

式中: $p_k$ 是第k个BS的发射功率; $\sigma_k^2$ 表示第k个VUE用户处的附加噪声功率。为了简单起见,假设所有用户的噪声功率 $\sigma^2$ 都相同,并且所有的BS都具有归一化带宽。那么,第k个VUE的传输速率可以被表示为:

$$R_k(\mathbf{P}) = \log_2(1 + \text{SINR}_k) \quad (3)$$

式中:向量  $\mathbf{P} = (P_1, P_2, \dots, P_K)^\top$  来表示所有用户的联合功率。

最大化总用户速率问题可表达为如下形式:

$$\begin{aligned} & \text{maximize}_{\mathbf{P}} \sum_{k=1}^K R_k(\mathbf{P}) \\ & \text{subject to } 0 \leqslant P_k \leqslant P_{\max}, \quad \forall k \in \mathcal{K} \end{aligned} \quad (4)$$

在各种功率分配问题中该问题是简单的一种表达形式,但仍然具有非凸非线性的性质,是一个 NP-hard 问题。

每个 VUE 用户的能效可以表示为:

$$EE_k(\mathbf{P}) = \frac{R_k(\mathbf{P})}{\mu_k P_k + P_{c,k}} \quad (5)$$

式中:  $\mu_k$  为基站  $k$  的逆效率系数(即功率放大器效率系数的倒数);  $P_{c,k}$  为基站  $k$  的静态功率消耗。

最大化总用户能效问题可表达为如下形式:

$$\begin{aligned} & \text{maximize}_{\mathbf{P}} \sum_{k=1}^K EE_k(\mathbf{P}) \\ & \text{subject to } 0 \leqslant P_k \leqslant P_{\max}, \quad \forall k \in \mathcal{K} \end{aligned} \quad (6)$$

能效性能准则具有天然的分式特性,因此传统的凸优化理论不能直接用于处理能效的功率分配问题。一些数学框架如分数规划可以提供一些合适的优化方法。然而,当分数规划最大程度的满足各种数学假设条件,这些优化算法具有非常多的限制。

## 2 基于图卷积神经网络的功率分配框架

上述  $K$  用户多小区干扰场景的多种功率分配准则问题是非凸且 NP-hard 的。使用传统的优化算法,如凸优化、拉格朗日对偶分解等,会随着未来网络规模庞大,拓扑结构复杂,使算法的计算复杂度难以控制。通过深度学习 MLP 和 CNN 来学习经典的加权最小均方误差 (weighted minimum mean square error, WMMSE) 算法,可以降低算法的复杂度。但是深度学习 MLP 和 CNN 方法对无线信道中的非欧几里得信道数据处理具有局限性,同时当前的神经网络模型对于动态的网络场景不具有对应的泛化性,针对不同的场景需要训练出新的神经网络模型,本文提出了基于 GCN 的多项功率分配准则框架以优化网络性能。在本小节中,首先给出了 GCN 网络的基本结构,引出 GCN 在功率分配问题的可行性。然后基于干扰信道的图模型表示,提出节点更新机制,构建对应的 GCN 的网络结构来解决上述多种功率准则的优化问题。

### 2.1 图卷积网络基本结构

和 MLP 或者 CNN 一样,GCN 也有层的结构。GCN 中第  $k$  层顶点  $v$  处的更新规则表述如下:

$$a_v^{(k)} = \text{AGGREGATE}^{(k)}(\{h_u^{(k-1)} : u \in \mathcal{N}(v)\}, \{\gamma_x : x \in \epsilon(v)\}) \quad (7)$$

$$h_v^{(k)} = \text{COMBINE}^{(k)}(h_v^{(k-1)}, a_v^{(k)}) \quad (8)$$

式中:  $\mathcal{N}(v)$  表示节点  $v$  的邻居节点的集合;  $\epsilon(v)$  表示将  $v$  作为一个端点的所有边的集合; AGGREGATE( $\cdot$ ) 和

COMBINE( $\cdot$ ) 分别表示汇聚函数和聚合函数;  $\gamma_x$  表示边  $x$  的特征;  $h_v^{(k)}$  表示在第  $k$  层顶点  $v$  的输出特征;  $a_v^{(k)}$  为一个中间变量。

### 2.2 基于 GCN 网络的功率分配框架

将 GCN 应用于无线资源分配问题中,一个重要的因素是考虑到干扰信道的几何属性。根据信道矩阵到最优功率分配之间的映射关系可验证干扰信道的几何属性。对于给定的  $k$ ,令  $f_k(\cdot)$  表示信道矩阵与第  $k$  个 VUE 发射功率之间的映射关系,则  $p_k^* = f_k(\mathbf{H})$ ,然后邻  $\mathbf{\Pi} \in \{0,1\}^{K \times K}$  表示任意一个置换矩阵,满足  $(\mathbf{\Pi}^\top \mathbf{H} \mathbf{\Pi})_{kk} = h_{kk}$ ,则:

$$p_k^* = f_k(\mathbf{H}) = f_k(\mathbf{\Pi}^\top \mathbf{H} \mathbf{\Pi}) \quad (9)$$

式(9)表明干扰信道具有无序性或置换不变性,即重要的是干扰信道系数的集合,而不是这些系数的顺序。功率分配中信道矩阵的排列不变性表明考虑相邻元素是没有意义的,因为元素经过排列后没有相关性。在基于 MLP 和 CNN 的功率分配中,干扰信道通常被表示为欧几里得数据结构的信道矩阵。从图数据结构的介绍可知,节点  $v$  同样只关注邻近节点的集合  $\mathcal{N}(v)$ ,不关注顺序,这说明干扰信道适合使用非欧几里得的图数据结构表示。

如图 2(a)所示为一种无线干扰信道的图表示方法,BS 和 VUE 都被看作为一个节点,每条链路视为一条边,每条边的权重是信道增益。将每个传输对作为一个节点,每条干扰链路作为一条边,从而为无线干扰信道构造出一个图模型,如图 2(b)所示。节点特征和边的权值分别取决于相应通信链路信道增益和干扰链路两个节点之间的信道增益。这样任意两节点间都有两条有方向的边,如  $e(1,2)$  表示的是从  $T_1$  到  $R_2$  的干扰链路,方向为节点 1 到节点 2;  $e(2,1)$  表示的从  $T_2$  到  $R_1$  的干扰链路,方向为节点 2 到节点 1。通过这种方式,可以将原始的干扰信道模型表示为图 2(b)中有权重的有向完全图,其中  $h_{u,v}$  的含义为:

$$h_{u,v} = \begin{cases} \text{基站 } u \text{ 用户 } v \text{ 的干扰链路, } u \neq v \\ \text{基站 } u \text{ 用户 } v \text{ 的通信链路, } u = v \end{cases} \quad (10)$$

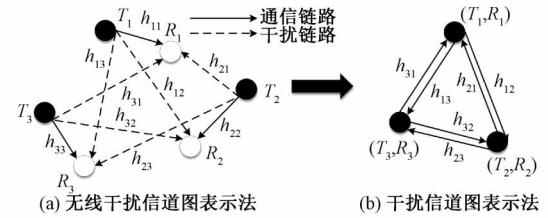


图 2 干扰图数据结构

基于上述无线干扰信道的图模型,可采用 GCN 进行功率分配。以节点  $v$  的更新为例,使用图卷积神经网络进行功率分配的过程描述如下:

$$\gamma_{u,v}^{(k)} = \text{MLP1}(h_{u,v}, h_{v,u}, h_{u,u}, \beta_u^{(k-1)}) \quad (11)$$

$$\alpha_v^{(k)} = \sum_u (\{\gamma_{u,v}\}), u \in \mathcal{N}(v) \quad (12)$$

$$\beta_v^{(k)} = \text{MLP2}(\alpha_v^{(k)}, h_{v,v}, \beta_v^{(k-1)}) \quad (13)$$

式中:  $\sum(\{\cdot\})$  表示对集合中的元素求和; MLP1 和 MLP2 表示两个不同的全连接网络;  $\gamma_{u,v}^{(k)}$  表示连接顶点  $u$  和  $v$  之间的边更新得到的特征向量;  $\beta_v^{(k)}$  表示的是在 GCN 第  $k$  层在顶点  $v$  上的输出特征。功率分配问题中,就是将最后得到的  $\beta_v$  表示为节点  $v$  的输出功率。对于  $\beta_v$  的初始值  $\beta_v^{(0)}$ , 可初始化为  $P_{\max}$ 。MLP1 和 MLP2 的网络结构分别如表 1、2 所示。

表 1 汇聚函数的 MLP1 网络结构

神经网络层	类型	输出维度
输入层	邻居节点的节点特征和边特征	10
隐藏层 1	Linear(4,16)+ReLU	16
隐藏层 2	Linear(16,12)	12
输出层	ReLU	12

表 2 聚合函数的 MLP2 网络结构

神经网络层	类型	输出维度
输入层	汇聚函数的输出与节点的节点特征	$12+2=14$
隐藏层 1	Linear(14,16)+ReLU	16
隐藏层 2	Linear(16,1)	1
输出层	Sigmoid	1

GCN 的最终输出为节点表示的传输对的发射功率,故设定设为输出维度为 1。同时为了将输出功率限制在最大输出功率之内,MLP2 的输出层激活函数采用的是 Sigmoid 激活函数。而 MLP1 和 MLP2 的其他层的激活函数则是线性整流函数(rectified linear unit, ReLU)。

在本文中,将在两种功率分配准则下验证图卷积神经网络的性能,即总用户速率最大化,总用户能效最大化及在 QoS 约束下的总用户速率最大化。采用的训练方式为无监督方式,因此在训练过程中只需要信道矩阵,不需要标签,每种准则对应损失函数的定义分别为:

$$\mathcal{L}_{\mathcal{H}_1} = -\frac{1}{|\mathcal{H}|} \sum_{h \in \mathcal{H}} Rate(\mathbf{h}, \mathbf{P}) \quad (14)$$

$$\mathcal{L}_{\mathcal{H}_2} = -\frac{1}{|\mathcal{H}|} \sum_{h \in \mathcal{H}} EE(\mathbf{h}, \mathbf{P}) \quad (15)$$

式中:  $Rate(\mathbf{h}, \mathbf{P})$  和  $EE(\mathbf{h}, \mathbf{P})$  分别表示在信道  $\mathbf{h}$  和功率  $\mathbf{P}$  下的总用户速率和总用户能效;  $\mathcal{H}$  表示一个批次下的信道向量;  $Rate_k(\mathbf{h}, \mathbf{P})$  表示第  $k$  个用户的速率。

与基于 MLP 的方式不同之处在于,基于 GCN 的方法需要将信道矩阵转换为图的数据结构。本文 GCN 模型的搭建、训练和测试都是基于德国多特蒙德工业大学提出的 PyTorch Geometric<sup>[20]</sup> 图神经网络框架。在 PyTorch Geometric 中,用节点特征矩阵  $\mathbf{X} \in \mathbb{R}^{(N \times F)}$  和稀疏邻接元组  $(I, E)$  来表示一张图  $\mathcal{G} = (\mathbf{X}, (I, E))$ , 其中  $I \in$

$\mathbb{N}^{2 \times |E|}$  为坐标格式编码边索引,  $E \in \mathbb{R}^{|E| \times D}$  表示的是  $D$  维的边特征。基于该框架,GCN 的功率控制具体的算法流程如算法 1 所示。

#### 算法 1 基于 GCN 网络的功率分配框架

1. 初始化神经网络各隐藏层和输出层的线性关系矩阵  $\mathbf{W}$  和偏置向量  $\mathbf{b}$  为一个随机值
2. 初始化网络场景,根据设置的信道模型生成训练数据集,即信道矩阵集合
3. 对应的信道矩阵转化为节点特征矩阵  $\mathbf{X} \in \mathbb{R}^{(N \times F)}$  和稀疏邻接元组  $(I, E)$
4. **for** episode = 1 : M :
5. 从训练集  $\mathbf{D}$  中随机抽取批量样本  $\mathcal{B}$
6. **for** 训练集中的每个批次数据  $\mathcal{B}$  :
7. 根据式(11),  $\mathbf{X} \in \mathbb{R}^{(N \times F)}$  和  $(I, E)$  作为 MLP1 网络的输入  $x_i$
8. MLP1 输出  $\gamma_{u,v}^{(k)}$  根据式(12)进行求和,与  $h_{v,v}$  和  $\beta_v^{(k-1)}$  作为 MLP2 的输入
9. 根据不同功率分配准则,通过式(14)和(15)最小化损失函数,更新网络参数  $\mathbf{W}$  和  $\mathbf{b}$
10. **end**
11. **end**

### 3 系统仿真与分析

本节对所提算法进行仿真,以验证所提方法在 2 种功率分配准则下的有效性。在系统模型中采用了  $K$  小区干扰信道,仿真实验系统参数中小区半径为 200 m,考虑了基站数量  $K \in \{5, 10, 15, 20, 25\}$  的场景,  $P_{\max} = 1 \text{ W}$ ,  $\sigma_k^2 = 1 \text{ W}$ ,  $\mu_k = 1$  和  $P_{c,k} = 0.5 \text{ W}$ 。

为了更好地说明所提算法的性能,仿真对比方法是基于广泛应用的 WMMSE 算法和基于其进行训练的 MLP 的算法。采用的网络结构是 1 个三层的 GCN 结构,对比的 MLP 每层的神经元个数为  $\{K^2, 100, 100, K\}$ 。GCN 和 MLP 的训练参数如表 3 所示。

表 3 仿真参数

参数名	参数值	
	GCN	MLP
训练回合数	50	
批次大小	20	500
训练数据集大小	{1 000, 2 000, 4 000, 10 000, 50 000}	
测试数据集大小	1 000	
学习率	0.001	
学习衰减率	0.5/(20 epochs)	
优化器	Adma 优化器	

图 3 和 4 分别表示的是在基站数为 10, GCN 和 MLP 在不同训练样本下得到的总用户速率和总用户能效的性能。由图 3 和 4 可知, 对于这两种准则而言, 与 MLP 这种基于数据驱动的学习方式相比, 将信道矩阵表示为图数据结构的 GCN 在 1 000 个带有图特征信息的训练样本中可得到更好的实验结果。而且 GCN 算法的效果也能在小样本数量下对传统算法 WMMSE 拟合效果比较好, 但是整体的算法复杂度要比传统 WMMSE 算法低。所以, 本文算法可以在小样本量下有效地提升网络总用户速率和能效。

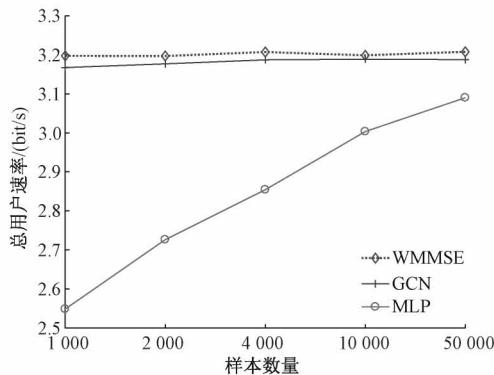


图 3 不同样本数量下总用户速率性能

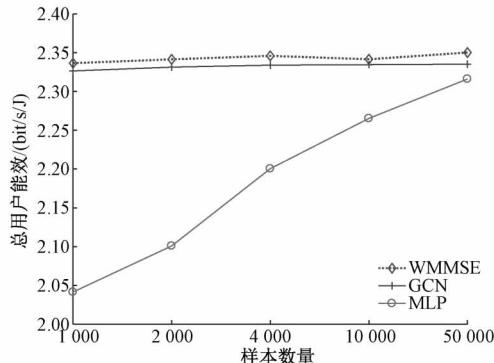


图 4 不同样本数量下总用户能效

同时, 当样本数增加时, 基于 GCN 的网络性能趋于平稳, 表明在样本数量较少时, GCN 就已经训练出有效的功率分配策略。随着训练样本数量的增加, MLP 的性能会有明显的提升, 与所提出的 GCN 算法的效果差距在逐渐缩小。但是 GCN 相比于 MLP 在小样本场景下的性能指标要好。

如图 5 所示, BS 数量不同训练出的 GCN 网络应用到不同基站数量下的总用户能效性能。由于泛化能力不强, 在 MLP 这种训练方式下的网络性能会严重下降。GCN 的机制是对每个节点做迭代的求解, 所以每个节点的求解方式是一致的。当图中对应基站数量增加时, 对于 GCN 而言, 只是增加了节点特征迭代的次数, 而没有改变网络的参数。从图 5 中可以看出, 每条性能曲线的趋势基

本是一致, 这表明在某个特定基站数量下训练得到的 GCN 可以直接应用在其他基站数量下的场景中, 不同的训练场景下性能是基本相似的。证明对于不同场景下的泛化性能比较好。

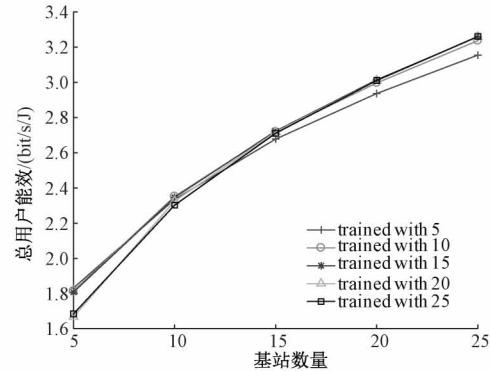


图 5 GCN 对不同基站数量泛化性能

#### 4 结论

本文讨论了 GCN 在多小区  $K$  车辆用户干扰信道模型中采用分别在总用户速率最大化, 总用户能效最大化两种准则下学习最优的功率分配策略。为了解决传统深度学习在功率分配中的小样本、泛化性以及动态场景中存在的问题, 提出了将无线干扰信道转化为对应的图数据结构, 使用无监督学习的图卷积神经网络进行功率分配。实验结果表明对于总用户速率最大化, 总用户能效最大化这两个性能准则下, GCN 在少量训练样本, 基站数量的扩展性和泛化性上要优于 MLP。下一步将研究利用图卷积神经网络在车联网场景中对于复用信道下的 QoS 约束提升网络能效。

#### 参考文献

- [1] BOBAN M, KOUSARIDAS A, MANOLAKIS K, et al. Connected roads of the future: Use cases, requirements, and design considerations for vehicle-to-everything communications [J]. IEEE Vehicular Technology Magazine, 2018, 13(3): 110-123.
- [2] LIU P, WANG C, FU T, et al. Exploiting opportunistic coding in throwbox-based multicast in vehicular delay tolerant networks [J]. IEEE Access, 2019, 7: 48459-48469.
- [3] BUZZI S, CHIH-LIN I, KLEIN T E, et al. A survey of energy-efficient techniques for 5G networks and challenges ahead [J]. IEEE Journal on Selected Areas in Communications, 2016, 34(4): 697-709.
- [4] 刘微, 郁进明, 穆欣. 基于 LTE-A 异构网络功率控制技术的研究 [J]. 电子测量技术, 2016, 39(12): 155-158, 163.
- [5] SHI Y, ZHANG J, LETAIEF K B. Group sparse beamforming for green cloud-RAN [J]. IEEE

- Transactions on Wireless Communications, 2014, 13(5): 2809-2823.
- [6] SAMARAKOON S, BENNIS M, SAAD W, et al. Energy-efficient resource management in ultra dense small cell networks: A mean-field approach[C]. 2015 IEEE Global Communications Conference(GLOBECOM), IEEE, 2015: 1-6.
- [7] LIANG L, KIM J, JHA S C, et al. Spectrum and power allocation for vehicular communications with delayed CSI feedback[J]. IEEE Wireless Communications Letters, 2017, 6(4): 458-461.
- [8] LIANG L, LI G Y, XU W. Resource allocation for D2D-enabled vehicular communications[J]. IEEE Transactions on Communications, 2017, 65(7): 3186-3197.
- [9] REN Y, LIU F, LIU Z, et al. Power control in D2D-based vehicular communication networks[J]. IEEE Transactions on Vehicular Technology, 2015, 64(12): 5547-5562.
- [10] SUN W, STRÖM E G, BRÄNNSTRÖM F, et al. Radio resource management for D2D-based V2V communication[J]. IEEE Transactions on Vehicular Technology, 2015, 65(8): 6636-6650.
- [11] 郑冰原,孙彦赞,吴雅婷,等.基于深度强化学习的超密集网络资源分配[J].电子测量技术,2020,43(9):133-138.
- [12] SINAN NASIR Y, GUO D. Deep actor-critic learning for distributed power control in wireless mobile networks[J]. ArXiv E-Prints, 2020, ArXiv: 2009.06681.
- [13] LIANG L, YE H, YU G, et al. Deep-learning-based wireless resource allocation with application to vehicular networks[J]. Proceedings of the IEEE, 2019, 108(2): 341-356.
- [14] SUN H, CHEN X, SHI Q, et al. Learning to optimize: Training deep neural networks for interference management[J]. IEEE Transactions on Signal Processing, 2018, 66(20): 5438-5453.
- [15] SHEN Y, SHI Y, ZHANG J, et al. A graph neural network approach for scalable wireless power control[C]. 2019 IEEE Globecom Workshops (GC Wkshps), IEEE, 2019: 1-6.
- [16] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24.
- [17] LEE M, YU G, LI G Y. Graph embedding based wireless link scheduling with few training samples[J]. ArXiv Preprint, 2019, ArXiv: 1906.02871.
- [18] LIU Y, LIU Y, YANG C. Modulation recognition with graph convolutional network[J]. IEEE Wireless Communications Letters, 2020, 9(5): 624-627.
- [19] EISEN M, RIBEIRO A. Large scale wireless power allocation with graph neural networks[C]. 2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC), IEEE, 2019: 1-5.
- [20] FEY M, LENSSSEN J E. Fast graph representation learning with PyTorch Geometric[J]. ArXiv Preprint, 2019, ArXiv: 1903.02428.

### 作者简介

**王晓昌**(通信作者),硕士研究生,主要研究方向为车辆通信、资源管理。

E-mail: emailforwang@shu.edu.cn

**朱文星**,硕士研究生,主要研究方向为超密集网络,能效优化。

E-mail: wenxingzhu@shu.edu.cn

**孙彦赞**,副教授,主要研究方向为无线通信资源管理、干扰协调、绿色通信。

E-mail: yanzansun@shu.edu.cn

**吴雅婷**,副教授,主要研究方向无线通信 OFDM、MIMO 系统资源管理。

E-mail: yt-wu@shu.edu.cn

**王涛**,教授,主要研究方向为无线通信资源管理、Relay 通信、绿色通信。

E-mail: twang@shu.edu.cn