

车联网V2I场景下基于GNN的SC-FDMA 智能信道估计

廖勇, 尹子松, 田肖懿

(重庆大学微电子与通信工程学院, 重庆 400044)

摘要: 随着车联网的迅猛发展, 车对路基础设施 (Vehicle to Infrastructure, V2I) 通信对车联网的可靠性和时延提出了更高的要求, 而信道估计是接收机高可靠低时延通信的重要保障. 为解决传统信道插值算法不能有效拟合V2I信道快时变特性、自适应多普勒频移能力弱和传统神经网络可解释性不强的问题, 本文提出基于图神经网络 (Graph Neural Network, GNN) 的单载波频分多址 (Single Carrier-Frequency Division Multiple Access, SC-FDMA) 智能信道估计算法. 该算法将信道频率响应中的数据点作为图的节点、符号间时域相关性作为边, 将图化后的数据送入 GraphSAGE 信道插值器 (GraphSAGE Channel Interpolator, GCI) 中, 通过边更新、聚合操作、节点更新三大模块进行网络训练, 同时采用多普勒频移矢量作为节点特征控制网络拟合不同多普勒条件的信道, 使得网络具备可解释性. 最后, 系统仿真验证了在不同速度环境下算法的有效性和鲁棒性, 较线性插值、样条插值以及全连接网络, 本文所提 GCI 在低、中和高速移动环境下具有最优的误码率 (Bit Error Rate, BER) 和归一化均方误差 (Normalized Mean Square Error, NMSE) 性能, 特别地, 在 200 km/h 高速移动条件下 GCI 的优势更为明显.

关键词: 车联网; V2I; 双选衰落信道; 高速移动; 多普勒频移; GNN; 信道估计; 信道频率响应

基金项目: 国家自然科学基金 (No.61501066); 重庆市自然科学基金 (No.cstc2019jcyj-msxmX0017)

中图分类号: TN929.5

文献标识码: A

文章编号: 0372-2112(2024)03-0772-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220545

Intelligent Channel Estimation of SC-FDMA Based on GNN for V2I Scenarios in Internet of Vehicles

LIAO Yong, YIN Zi-song, TIAN Xiao-yi

(School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

Abstract: With the rapid development of the Internet of vehicles, vehicle to infrastructure (V2I) communication puts forward higher requirements for the reliability and delay of vehicle networking. Channel estimation is an important guarantee for high reliable and low-latency communication of receiver. To solve the problems that the traditional channel interpolation algorithm cannot effectively fit the fast time-varying characteristics of V2I channel, the ability of adaptive Doppler frequency shift is weak, and the interpretability of traditional neural network is not strong, this paper presents a single carrier-frequency division multiple access (SC-FDMA) intelligent channel estimation algorithm based on graph neural network (GNN). The proposed algorithm takes the data points in the channel frequency response as the nodes of the graph and the inter-symbol time domain correlation as the edges. The graphical data is fed into the GraphSAGE channel interpolator (GCI). The network training is carried out through the three modules of edge update, aggregation operation and node update. At the same time, the Doppler shift vector is used as the node feature control network to fit the channels with different Doppler conditions, making the network interpretable. Finally, the system simulation verifies the effectiveness and robustness of the algorithm in different speed environments. Compared with linear interpolation, spline interpolation and fully connected network, the proposed GCI has the best performance of bit error rate (BER) and normalized mean square error (NMSE) in low, medium and high-speed mobile environments, especially, the advantage of GCI is more obvious under the condition of 200 km/h high-speed movement.

Key words: Internet of vehicles; V2I; doubly selective fading channel; high mobility; Doppler shift; GNN; channel

estimation; channel frequency response

Foundation Item(s): National Natural Science Foundation of China (No.61501066); Natural Science Foundation of Chongqing, China (No.cstc2019jcyj-msxmX0017)

1 引言

随着交通运输和信息通信技术的快速发展,目前交通行业已经进入智能交通系统(Intelligent Transportation Systems, ITS)^[1]时代. 支撑 ITS 无线通信的标准主要有基于 IEEE 802.11p 的专用短程通信(Dedicated Short Range Communication, DSRC)和 3GPP 的蜂窝车联网(Cellular-Vehicle to Everything, C-V2X). C-V2X 包括长期演进车联网(Long Term Evolution-V2X, LTE-V2X)和新空口车联网(New Radio-V2X, NR-V2X), LTE-V2X 采用峰均比较低的单载波频分多址(Single Carrier-Frequency Division Multiple Access, SC-FDMA)波形进行传输^[2], NR-V2X 传输使用具有循环前缀的正交频分复用(Cyclic Prefix-Orthogonal Frequency Division Multiplexing, CP-OFDM)波形^[3]. V2X 可以实现车对路基础设施(Vehicle to Infrastructure, V2I)、车对车(Vehicle to Vehicle, V2V)等情况下车载终端的直连传输,华为、大唐等中国企业致力于推进 C-V2X 标准, NR-V2X 计划在 2022 年宣布冻结^[4].

在 V2X 场景中, V2I 是其中应用较为频繁的场景,可以用于传递车载终端与路侧单元(Road Side Unit, RSU)之间的交互消息,实现 ITS 与移动边缘计算(Mobile Edge Computing, MEC)服务器之间双向数据传输,以此保障道路交通安全,并能为驾驶者提供相关娱乐服务^[5]. V2I 通信最大延迟为 100 ms,为保证 V2I 的可靠低时延通信,信道估计技术倍受国内外研究学者的关注. 最小二乘法(Least Square, LS)^[6]和线性最小均方误差(Linear Minimum Mean Squared Error, LMMSE)^[7]是经典的基于导频的信道估计方法. V2X 信道具有快时变特性,使用 LS 和 LMMSE 算法无法很好地追踪信道的变化,导致信道估计性能较差. 文献[8]总结了在双选衰落信道下各种信道插值算法的性能,并且采用基扩展模型(Basis Expansion Model, BEM)来降低双选信道估计的复杂度,同时提出了一种改进的拉格朗日插值方法. 针对 V2X 信道的双选衰落特性,文献[9]在数据插值部分使用扩展卡尔曼滤波(Extended Kalman Filter, EKF)算法进行信道追踪,在快时变信道下,能确保 V2X 通信的低延迟性,同时减少信道估计开销. 为进一步提高 V2X 的通信性能,文献[10]提出了一种基于 BEM 的改进正则化正交匹配追踪(improved Regularized Orthogonal Matching Pursuit, iROMP)迭代稀疏信道估计算法(BEM-iROMP),能有效提高归一化均方误差(Normalized Mean Square Error, NMSE)和误码率(Bit Error Rate, BER)性能. 但是,高速移动信道的非线性特性使

得信道估计仍存在不少挑战.

近年来,由于深度学习(Deep Learning, DL)可以解决非线性信号处理问题,因而在无线通信领域得到广泛应用,特别在信道估计领域已取得一些显著效果. 文献[11]针对 NR-V2I 设计了一种基于 DL 的信道估计算法,该算法使用一维卷积神经网络完成频域插值,再使用条件递归单元(Conditional Recurrent Unit, CRU)进行时域状态预测,在不同的移动环境中能够提高信道估计精度,增强鲁棒性. 为了解决高速移动环境中快时变和非平稳特性下的信道估计性能较差的问题,文献[12]提出了一种使用卷积神经网络和递归神经网络进行信道估计的网络 ChanEstNet,该网络能够降低计算复杂度,显著改善性能. 文献[13]使用双向长短期记忆(Bidirectional-Long Short-Term Memory, BiLSTM)网络对高速移动下多输入多输出(Multiple-Input Multiple-Output, MIMO)-OFDM 系统的信道响应矩阵进行估计,仿真表明该算法在精度和系统性能方面均优于传统信道估计算法. 以上工作都是通过“黑箱”操作实现了端到端的学习,无法清楚地解释隐藏在数据集中的空间相关性. 由于图神经网络(Graph Neural Network, GNN)能够有效地提取数据中的空间关系,开始广泛应用于无线信道数据处理中^[14]. GNN 将传统的基于模型的操作与端到端的学习相结合,因此能够准确地捕获数据特征,在 DL 框架下,空间相关性的精确提取将有助于神经网络跟踪时变的大规模 MIMO 信道^[15]. 文献[16]研究了高海拔平台站(High-Altitude Platform Station, HAPS)通信,首次将图注意力网络(Graph Attention Network, GAT)用于信道估计中,通过一个节点处的 GAT 即可单独估计级联信道系数,该算法性能上优于 LS,且应对小尺度衰落具有一定的鲁棒性. 文献[17]提出一种基于 GNN 的信道跟踪方法,能够获得一定的性能提升. GNN 及其可解释性正在迅速发展,已有较多研究工作给出了多种 GNN 的可解释方法^[18,19].

虽然 DL 已经用于信道估计中,但是目前大部分信道估计算法所采用的网络仍然是一个“黑匣子”,可以得到较传统算法更好的通信性能,但是缺乏过程和结果的可解释性,一旦网络出现异常,将无法对网络故障进行精准的诊断,从而影响了其从理论到实际中的应用. 另外,随着新型的可解释性神经网络的出现,将这些新型网络模型应用到车联网特定场景进行实验验证仍是一个亟待研究的领域.

为了解决车联网 V2I 场景快时变信道下数据符号插值算法拟合效果不佳、自适应多普勒频移能力弱、传

神经网络可解释性不强的问题,本文提出一种基于 GNN 的数据符号智能信道估计算法. 该算法基于离线训练—在线插值的模式,首先对从 SC-FDMA 系统中获取到的不同信道环境的信道频率响应数据进行图化处理,将图的节点作为信道频率响应中的数据点,图的边作为符号间时域相关性,增强了信道估计过程的可解释性,同时为了保证算法能追踪到不同环境移动速度的变化,在图化处理时根据不同环境条件增加额外的节点特征以控制网络拟合不同多普勒条件的信道. 将图化后的数据送入 GraphSAGE 信道插值器(GraphSAGE Channel Interpolator, GCI)中,然后通过边更新、聚合操作、节点更新三大模块进行网络训练. 最后,系统仿真验证了在不同速度环境下的算法的有效性和鲁棒性,在低中高速移动条件下,相比线性插值、样条插值、全连接网络(Fully-Connected Network, FCN)三种插值方法,所提算法具有最优的 NMSE 和 BER 性能,特别地在高速移动环境下, GCI 的优势更明显.

2 问题建模

2.1 场景及处理流程

车联网 V2X 主要包括 V2I、V2V、车对行人(Vehicle to Pedestrian, V2P)和车与网络(Vehicle to Network, V2N)的交互,以 V2I 场景为例,如图 1 所示,车载终端、RSU、MEC Server 组成 V2I 通信链路.

面向车联网 V2I 场景下的 SC-FDMA 传输流程主要包含需要发送的比特流在进入 SC-FDMA 传输系统后,进行符号调制、串并转换等操作. 信号经过高速移动信道后在接收端做逆过程操作,为了消除信道和噪声造成的衰落和干扰,需要进行信道估计和均衡,最后还原数据比特流. 具体收发端信号处理过程可参照文献[20],此处不再赘述.




图 1 V2I 无线通信场景

本文面向车联网 V2I 场景基于 GNN 的智能信道估计的部署流程以及系统处理主要分为训练阶段和预测阶段.

训练阶段:

(1)RSU 收集车载终端反馈的信道状态信息(Channel State Information, CSI),同时 RSU 将 CSI 传输至 MEC Server;

(2)MEC Server 存储反馈的 CSI,并结合以往的 CSI 进行 GNN 信道估计网络训练,得到 GNN 信道估计网络,具体处理流程可参见本文第 3 节.

预测阶段:

(1)其它车载终端根据需要将信道数据信号通过上行链路传输至 RSU,同时 RSU 将信道数据信号传输至 MEC Server;

(2)MEC Server 通过已经训练好的 GNN 信道估计网络,得到预测的 CSI,完成信道估计后进行接下来的信道均衡等操作,从而完成整个信号处理;

(3)MEC Server 将处理得到的结果反馈至 RSU,对于下行链路车载终端的 CSI,可以通过上下行信道互易性得到.

2.2 V2I 信道模型

车联网环境下的无线信道是一个典型的多径快时变双选衰落信道,一方面由于多径效应,无线信道表现出频选特性,另一方面因为车载终端的相对快速移动,无线信道还有多普勒频移造成的时变特性. 本文以扩展车辆信道模型(Extended Vehicular A model, EVA)^[21]作为 V2I 信道模型.

假设信道有 K 条可分辨多径,由于存在多普勒频移,即在一个 SC-FDMA 传输符号周期中的信道冲激响应(Channel Impulse Response, CIR)是时变的,该多径时变双选信道的 CIR 为

$$h_{t,k} = \sum_{k=0}^{K-1} \alpha_{t,k} \cdot \delta(\tau - \tau_k) \quad (1)$$

其中, $h_{t,k}$ 为 t 时刻第 k 条径的时变 CIR, $\alpha_{t,k} = \alpha_k \cdot \exp(j2\pi f_d t)$, α_k 为第 k 条径的路径增益, τ 表示多径信道的时延, τ_k 为第 k 条径的路径时延, f_d 为多普勒频移, $\delta(\cdot)$ 为冲激函数.

根据 SC-FDMA 系统信号处理的过程,添加循环前缀(Cyclic Prefix, CP)后的发送信号经过多径时变双选信道后到达接收端,接收端对接收信号进行时域采样后得到的一个符号为

$$y_n = \sum_{k=0}^{K-1} h_{n,k} x_n + w_n, n = -N_{cp}, \dots, 0, 1, \dots, N-1 \quad (2)$$

其中, y_n 为在 n 时刻采样的接收符号, w_n 为 n 时刻采样且方差为 σ_w^2 的零均值加性高斯白噪声, N_{cp} 为 CP 长度, N 为快速傅里叶变换(Fast Fourier Transform, FFT)点数. 不考虑 CP 符号,则时域上第 i 个 SC-FDMA 传输符号 $\mathbf{x}_i = [x_0, x_1, \dots, x_{N-1}]^T$ 的接收符号表示为 $\mathbf{y}_i =$

$[y_0, y_1, \dots, y_{N-1}]^T$, 将该时域传输过程表示为矩阵形式

$$\mathbf{y}_i = \mathbf{G}_i \mathbf{x}_i + \mathbf{w}_i \quad (3)$$

其中, $\mathbf{w}_i = [w_0, w_1, \dots, w_{N-1}]^T$ 为噪声向量, $\mathbf{G}_i \in \mathbb{C}^{N \times N}$ 为 CIR 矩阵, 且表示为

$$\mathbf{G}_i = \begin{bmatrix} h_{0,0} & 0 & \dots & 0 & h_{K-1,0} & \dots & h_{0,1} \\ h_{1,1} & h_{1,0} & 0 & \dots & 0 & \dots & h_{1,2} \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ h_{L-1,K-1} & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & \ddots & h_{N-2,0} & 0 \\ 0 & \dots & \dots & h_{N-1,K-1} & \dots & h_{N-1,1} & h_{N-1,0} \end{bmatrix} \quad (4)$$

频域接收符号 $\mathbf{y}_i^f \in \mathbb{C}^N$ 可以通过对 \mathbf{y}_i 做 N 点 FFT 变换获得, 即

$$\mathbf{y}_i^f = \mathbf{F} \mathbf{y}_i = \mathbf{F} \mathbf{G}_i \mathbf{x}_i + \mathbf{F} \mathbf{w}_i = \mathbf{F} \mathbf{G}_i \mathbf{F}^H \mathbf{x}_i^f + \mathbf{w}_i^f \quad (5)$$

其中, \mathbf{w}_i^f 为频域的高斯白噪声向量, \mathbf{x}_i^f 为频域传输符号向量. 则可以得到第 i 个 SC-FDMA 传输符号对应的频域响应矩阵

$$\mathbf{H}_i = \mathbf{F} \mathbf{G}_i \mathbf{F}^H \quad (6)$$

则由式(5)可以得到频域传输过程为

$$\mathbf{y}_i^f = \mathbf{H}_i \mathbf{x}_i^f + \mathbf{w}_i^f \quad (7)$$

在块衰落^[22]假设下, 存在 $h_{0,l} = h_{1,l} = \dots = h_{N-1,l}$, 因此上述的 \mathbf{H}_i 为一个对角阵, 那么式(7)还可以表示为

$$\mathbf{y}_i^f = \mathbf{X}_i \mathbf{h}_i + \mathbf{w}_i^f \quad (8)$$

其中, \mathbf{X}_i 代表对角线上元素取 \mathbf{x}_i^f 的对角阵, \mathbf{h}_i 为 \mathbf{H}_i 取对角线元素组成的向量.

3 GNN 信道估计

为了解决 V2I 场景快时变信道下插值算法效果差、拟合效果不好, 并且自适应多普勒频移能力弱、传统神经网络可解释性不强的问题, 本文提出了一种基于 GNN 的数据插值信道估计算法. 该算法采用离线训练—在线插值的模式, 对 SC-FDMA 系统中获取到不同环境条件的信道频率响应数据进行图化处理, 在图化处理时根据不同环境条件的节点增加额外的节点特征, 以保证该算法能追踪到不同环境、移动速度的变化, 再将图数据输入 GraphSAGE^[23,24] 的 GCI 训练, 后续可以直接使用 GCI 进行信道插值完成信道估计.

3.1 数据中的图形式

图的本质是描述一个实体集合中实体间关系的数据结构, 因此对 GNN 的输入数据需要先图化成对应的数据结构, 该结构主要由节点和边构成, 节点代表的是具体的个体, 边代表的是节点间存在的关系, 一个图的结构表达式可表示为

$$\mathcal{G} = \{\mathcal{V}, \mathcal{E}\} \quad (9)$$

其中, \mathcal{G} 代表图, \mathcal{V} 代表图中的节点集合, \mathcal{E} 代表图中的

边集合.

节点集合的表达式如式(10)所示, 其中 \mathcal{V}_i 代表实体节点, $i = 1, \dots, N_{\text{node}}$, N_{node} 代表包含的节点总数, 可以确定图的大小. 任意一个节点 \mathcal{V}_n 都存在一个节点特征向量 $\mathbf{f}_n \in \mathbb{R}^{\text{nd}}$, \mathbf{f}_n 包含了这个实体节点的特征信息, nd 为节点的特征维度大小, 整个图也可以看作 $N_{\text{node}} \times \text{nd}$ 维度的节点特征.

$$\mathcal{V} = \{\mathcal{V}_1, \mathcal{V}_2, \dots, \mathcal{V}_{N_{\text{node}}}\} \quad (10)$$

边集合的表达式如式(11)所示, 其中 \mathcal{E}_i 代表图中的边, 其中 $i = 1, \dots, N_{\text{edge}}$, N_{edge} 代表图中各节点依赖关系的数量, 其中任意一条边都代表了连接的两个节点的关系, 因此也可以表示为 $\mathcal{E}_n = \mathcal{E}_{i,j} = [\mathcal{V}_i^e, \mathcal{V}_j^e]$, 若该图为有向图, 那么边的方向由 \mathcal{V}_i^e 指向 \mathcal{V}_j^e ; 若该图为无向图, 则存在关系 $\mathcal{E}_n = [\mathcal{V}_i^e, \mathcal{V}_j^e] = [\mathcal{V}_j^e, \mathcal{V}_i^e]$. 另外, 任意一条边 \mathcal{E}_n 都存在一个边特征向量 $\mathbf{f}_e \in \mathbb{R}^{\text{ed}}$, 该特征向量包含了这条边的特征信息, ed 为边的特征维度大小.

$$\mathcal{E} = \{\mathcal{E}_1, \mathcal{E}_2, \dots, \mathcal{E}_{N_{\text{edge}}}\} \quad (11)$$

3.2 基于 GNN 的信道估计体系结构

基于 GNN 的信道估计过程包含了离线训练和在线插值两个步骤, 其结构如图 2 所示. 从图中可以看到, 不同多普勒条件的信道在图化后节点都拥有不同的额外速度特征.

GCI 是一种采用聚合函数的特殊图卷积插值器, 包含了 5 层 GraphSAGE 网络, 其输入为 SC-FDMA 通信系统中信道频率响应矩阵图化后的数据, 其中 GraphSAGE 的更新迭代过程示意图如图 3 所示. GraphSAGE 包含了三个功能模块, 包括边更新、聚合操作以及节点更新. 首先使用图中某层中的各领域的节点更新其邻边, 再针对某个节点的邻边进行聚合操作, 最后使用聚合后得到的聚合边更新相应的节点.

3.3 车联网无线信道数据图化

首先, 通过 LMMSE 算法获取导频处的信道频率响应, 为了处理方便, 如图 4 所示对其余数据处的信道频率响应进行初始化, 数据处的信道频率响应等于其后邻近导频处的信道频率响应, 在最后两个符号之后没有导频符号, 则取前一导频处的信道频率响应. 设在 x 时刻估计到的导频处信道频率响应为 $h(x)$, 则有 $h(x-1) = h(x-2) = h(x)$, 对一个子帧中的最后一个导频处, 有 $h(x-1) = h(x-2) = h(x+1) = h(x+2) = h(x)$.

设 n_{subc} 代表一个子帧中的子载波数, n_{frame} 为一个子帧中总数据点, 且 $n_{\text{frame}} = n_{\text{subc}} \times 14$, 则一个子帧中信道频率响应可以表示为

$$\begin{aligned} \mathbf{h}_{\text{frame}} &= (h^1(1), h^1(2), \dots, h^1(14), h^2(1), \dots, h^{n_{\text{subc}}}(14)) \\ &= (h(1), h(2), \dots, h(n_{\text{frame}})) \end{aligned} \quad (12)$$

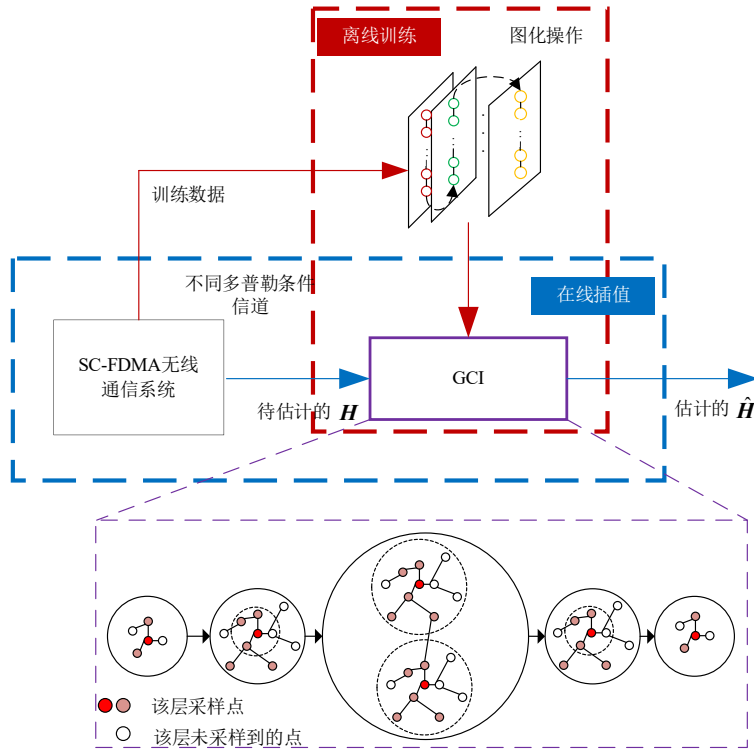


图2 基于GNN的信道估计结构




图3 GraphSAGE更新图数据示意图

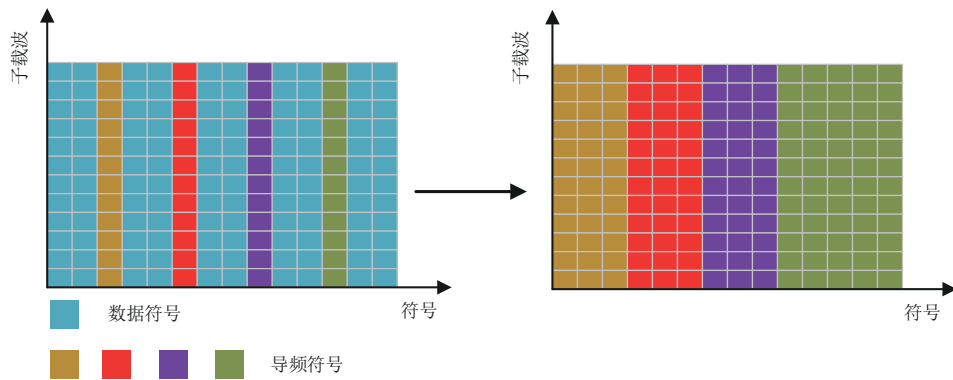


图4 数据处信道频率响应初始化

由于GCI的输入是图数据集,在一个子帧中,需要把 $\mathbf{h}_{\text{frame}}$ 图化成式(9)的形式,将本文研究的插值问题看作类似图节点分类的任务,需要得到每个数据点的值,则将 $\mathbf{h}_{\text{frame}}$ 中的每个元素都作为一个节点,由于 $h(n_{\text{frame}})$ 为复变量,将每个节点 $h(n_{\text{frame}})$ 的实部和虚部都作为节

点特征.另外,加入多普勒矢量作为额外的节点特征,通过速度索引值输入到Embedding网络^[20]获得多普勒编码矢量 $\mathbf{c}(v_{\text{index}})$,以追踪车联网下移动速度的变化.多普勒编码矢量则是通过深度学习中Embedding网络获取,Embedding嵌入层可以将输入的索引值转换为一

定维度大小的向量, Embedding 嵌入层本质上是 FCN, 但 Embedding 嵌入层获取的是网络中的权重. 在本文中, 设需要仿真的不同的移动速度的个数为 N_v , 每个编码向量的维度为 $2N$, 于是 Embedding 嵌入矩阵可以表示为

$$\mathbf{E}_v = [\mathbf{e}_1^v, \mathbf{e}_2^v, \dots, \mathbf{e}_{N_v}^v]^T \quad (13)$$

其中, $\mathbf{E}_v \in \mathbb{R}^{N_v \times 2N}$. 训练之前嵌入矩阵中的数据随机初始化, 训练时嵌入层根据给定的速度索引 v_{index} 获取嵌入矩阵中指定的行向量作为编码矢量, 其表达式为

$$\mathbf{c}(v_{\text{index}}) = \text{select_row}(\mathbf{E}_v, v_{\text{index}}) \quad (14)$$

其中, $\mathbf{c}(v_{\text{index}})$ 代表速度索引为 v_{index} 时的多普勒编码矢量. 因此, 节点集 \mathcal{V} 中的每个元素表示为

$$\mathcal{V}(n) = [\text{Re}(h(n)), \text{Im}(h(n)), \mathbf{c}(v_{\text{index}})]^T \quad (15)$$

其中, $\text{Re}(h(n))$ 代表 $h(n)$ 的实部, $\text{Im}(h(n))$ 为代表 $h(n)$ 的虚部, $\mathbf{c}(v_{\text{index}})$ 代表速度索引为 v_{index} 时的多普勒矢量. 那么, 节点集可以表示为 $\mathcal{V} = [\mathcal{V}(1), \mathcal{V}(2), \dots, \mathcal{V}(n)]$.

为了确立节点之间的关系, 而且需要保证节点特征的维度和边特征的维度一致, 本文对多普勒矢量采用由 1 组成的矢量作为其边特征, 并且采用信道模型时域相关性作为 $\text{Re}(h(n)), \text{Im}(h(n))$ 节点特征的边, 该相关性参考了 Jakes 模型下的时域相关性, 表示如下

$$\Psi(\Delta t) = J_0(2\pi f_d \Delta t) \quad (16)$$

其中, $\Psi(\Delta t)$ 代表符号时间 Δt 的符号间时域相关性, $J_0(\cdot)$ 代表第一类零阶贝塞尔函数, f_d 代表多普勒频移.

为了简化 GCI 网络, 减少复杂度, 对于任意节点只取其相邻的节点建边, 而且由于在建立节点时相邻节点的相关性间隔为 1, 则 $\Delta t = n_{\text{subc}} T_s$, 那么定义节点间初始边特征为

$$\mathcal{E}_{i,j} = [J_0(2\pi f_d n_{\text{subc}} T_s), J_0(2\pi f_d n_{\text{subc}} T_s), 1] \quad (17)$$

3.4 图网络的计算步骤

对于 GCI 中, 每层 GraphSAGE 中包括了三个子功能单元模块, 节点更新模块 f^v , 边更新模块 f^e 以及聚合模块 $f^{\varepsilon \rightarrow \nu}$. 每层 GNN 会通过更新节点来缩小与相似特征类别节点的差异并加大与不同类别节点的差异, 而更新边是计算邻域节点的相关性, 聚合操作则是对某一节点的所有邻边进行聚合获得聚合边, 最后聚合边用于更新节点.

设一个子帧内的符号数据图化后的数据表示为

$$\mathcal{G}_{\text{frame}} = \{\mathcal{V}(n), \mathcal{E}_{i,j}\} \quad (18)$$

其中, n 代表该子帧中数据点总数, $i, j = 1, \dots, n$.

对于边更新模块 f^e 的输入包括了上层节点特征, 上层边特征表示为

$$\begin{aligned} \mathcal{E}_{i,j}^m &= f^e(\mathcal{V}^{m-1}(i), \mathcal{V}^{m-1}(j), \mathcal{E}_{i,j}^{m-1}) \\ &= P^e(\mathcal{V}^{m-1}(i), \mathcal{V}^{m-1}(j), \mathcal{E}_{i,j}^{m-1}) \end{aligned} \quad (19)$$

其中, $\mathcal{E}_{i,j}^m$ 代表经过第 m 层边更新后的 i 节点和 j 节点的新边特征, $\mathcal{V}^{m-1}(i)$ 和 $\mathcal{V}^{m-1}(j)$ 分别为第 $m-1$ 层的 i, j 节点, P^e 代表用于独立提取图中边特征的多层感知机.

然后, 在更新完所有的边之后, 使用这些新的边特征以及聚合模块 $f^{\varepsilon \rightarrow \nu}$ 进行聚合操作, 对于节点 i 处的聚合操作为

$$\begin{aligned} \tilde{\mathcal{E}}_i^m &= f^{\varepsilon \rightarrow \nu}(\mathcal{E}_{i,j}^m), \mathcal{V}(j) \in \mathcal{N}(\mathcal{V}(i)) \\ &= \text{Ag}(\mathcal{E}_{i,j}^m) \end{aligned} \quad (20)$$

其中, $\tilde{\mathcal{E}}_i^m$ 为第 m 层的 i 节点处的聚合边, $\mathcal{N}(\mathcal{V}(i))$ 代表节点 $\mathcal{V}(i)$ 的邻域, $\text{Ag}(\cdot)$ 代表 GCI 中使用的聚合函数, 本算法中使用的是 Mean 函数. 最后, 使用上式得到的聚合边以及节点更新模块 f^v 进行节点更新

$$\begin{aligned} \mathcal{V}^m(i) &= f^v(\tilde{\mathcal{E}}_i^m, \mathcal{V}^{m-1}(i)) \\ &= P^v(\tilde{\mathcal{E}}_i^m, \mathcal{V}^{m-1}(i)) \end{aligned} \quad (21)$$

其中, $\mathcal{V}^m(i)$ 代表经过第 m 层更新后的 i 节点特征, P^v 代表用于提取图中节点特征的多层感知机. 另外值得讨论的是, 通过式 (21) 可以看出, 基于 GCI 的插值算法还重新对导频处的节点特征进行了去噪更新, 因此可以说此次更新还对导频处的信道数据进行了再次校正.

在训练时, 最终的训练目的是能够让网络学习到节点之间隐藏的关系并最小化网络插值输出与实际信道响应数据的均方误差. 最后, 通过多层的更新模块后可以得到最后的图输出 $\widehat{\mathcal{G}}_{\text{frame}} = \{\widehat{\mathcal{V}}(n), \widehat{\mathcal{E}}_{i,j}\}$, 再由 $\widehat{\mathcal{G}}_{\text{frame}}$ 通过逆图化操作恢复出最后的信道频率响应

$$\begin{aligned} \widehat{\mathbf{h}}_{\text{frame}} &= \left(\widehat{\mathcal{V}}(1)[1] + j \widehat{\mathcal{V}}(1)[2], \widehat{\mathcal{V}}(2)[1] + j \widehat{\mathcal{V}}(2)[2], \dots, \right. \\ &\quad \left. \widehat{\mathcal{V}}(n_{\text{frame}})[1] + j \widehat{\mathcal{V}}(n_{\text{frame}})[2] \right) \end{aligned} \quad (22)$$

其中, $\widehat{\mathcal{V}}(1)[1]$ 代表经过 GCI 插值后的 $\widehat{\mathcal{V}}(1)$ 节点特征中的第一维度元素, 后续再将上式转换成信道频率响应的矩阵形式, 完成基于 GCI 的数据处理信道估计算法.

3.5 模型训练

由于本算法采用了离线训练-在线插值的联合模式进行估计, 因此在第一阶段需要先以离线的方式训练好 GCI 模型. 通过 SC-FDMA 仿真系统收集每一帧中资源网络的信道频率响应矩阵作为标签数据, 同时通过 LMMSE 导频信道估计算法得到的信道频率响应和每个样本对应的速度索引作为训练样本的初始数据. 训练 GCI 是以最小化插值器输出样本数据与标签数据的均方误差为目的来更新插值器中的所有参数, 其中 GCI 中

的参数可以分为两类:节点更新系数、边更新系数.通过训练可以得到这些系数的最优解,使得GCI能较为准确的追踪到信道的变化,并且找寻到相邻节点间的隐藏关联信息.对训练完成的GCI模型,由于已经训练好中间的所有参数,后续可以直接用于信道在线插值.

本文采用了端到端的方式来训练GCI模型.设整个GCI模型中的更新模块函数和所有参数分别为 $f_{\text{GCI}}(\cdot)$ 和 Θ_{GCI} ,图化操作和逆图化操作分别为 $f^{h \rightarrow g}(\cdot)$ 和 $f^{g \rightarrow h}(\cdot)$,那么GCI模型插值后得到的信道频率响应可以表示为

$$\widehat{\mathbf{H}} = f^{g \rightarrow h} \left(f_{\text{GCI}} \left(f^{h \rightarrow g}(\mathbf{H}, \mathbf{v}_{\text{index}}), \Theta_{\text{GCI}} \right) \right) \quad (23)$$

另外,本算法使用自适应矩估计(ADaptive Moment estimation, ADAM)算法来更新GCI模型的参数集,ADAM算法的学习率不是固定的,而是在训练时找到合适样本数据的学习率,损失函数采用了MSE,因此GCI模型的训练损失表示为

$$\begin{aligned} L(\Theta_{\text{GCI}}) &= \frac{1}{M_t} \sum_{i=1}^{M_t} \left(\widehat{\mathbf{H}}_i - \mathbf{H}_i^{\text{La}} \right)^2 \\ &= \frac{1}{M_t} \sum_{i=1}^{M_t} \left(f^{g \rightarrow h} \left(f_{\text{GCI}} \left(f^{h \rightarrow g}(\mathbf{H}_i, \mathbf{v}_{\text{index}}), \Theta_{\text{GCI}} \right) \right) - \mathbf{H}_i^{\text{La}} \right)^2 \end{aligned} \quad (24)$$

其中, \mathbf{H}^{La} 代表标签数据, M_t 代表训练集中的总样本数.

在本算法中,采用的5层GraphSAGE节点维度分别为[32, 64, 128, 64, 32],上述提到的多层感知机结构由FCN和线性整流函数(Rectified Linear Unit, ReLU)激活函数组成,并在最后的输出后面加入批标准化(Batch-Normalization, BN)操作.另外,使用的训练集、验证集以及测试集的数量分别为30 000、8 000、1 000,在Python平台上仿真收集数据.训练的服务器配置为Intel(R) Xeon(R) CPU E5-2678 v3 @2.50 GHz 2.50 GHz(2处理器)、64 GB内存、NVIDIA GeForce RTX 2080 Ti显卡、64位操作系统,训练的总迭代次数epoch为100,训练时间约150 min.

4 复杂度分析

表1给出了GCI与FCN、传统的线性插值、样条插值的复杂度对比, N 为子载波数, d 为一个子帧间的数据数,设FCN的输入层维度为 N_d ,FCN隐藏层神经元设置为 $[2N_d, 4N_d, 8N_d, 4N_d, 2N_d]$,则乘法次数一共为 $82NN_d d$,时间复杂度为 $O(NN_d)$;设GCI输入层节点数和边数分别为 $N_d, N_d - 1$,其中GCI中五层节点维度为 $[N_d, 2N_d, 4N_d, 2N_d, N_d]$,并且更新节点和边采用的多层感知机由一层输出维度为输入维度两倍的全连接层构成,聚合操作使用均值函数,由于邻节点只设定前后相

邻元素,则第一层GraphSAGE更新节点和边的乘法运算次数和为 $2N_d^2 + (N_d - 1)(2N_d - 1)$,聚合操作需要利用输入层的邻节点求均值得到第一层的所有节点特征,因此乘法次数为 $2N_d$,第一层GraphSAGE更新的乘法运算次数共为 $4N_d^2 - N_d + 1$,以此类推,可以获得GCI算法的乘法运算次数为 $(40N_d^2 - 6N_d + 4)dN/N_d$,时间复杂度为 $O(NN_d)$,虽然相比传统算法复杂度有所增加,但是 N_d 远小于 N ,GCI算法所花费的代价并不大,与提升的估计性能相比,这部分的代价完全在接受范围之内,另外与经典的FCN模型相比,时间复杂度在同一量级,但是估计精度相较FCN来说有很大提升.由于本文所提算法采用离线训练-在线预测的方式,此处分析的是离线训练的计算复杂度,模型训练完成用于在线预测时,预测时间将会非常短暂,能够满足几乎实时的要求^[20].

表1 算法复杂度对比

算法	乘法运算次数	时间复杂度
线性插值	dN	$O(N)$
样条插值	$N(2p+6d+4)$	$O(N)$
FCN	$82NN_d d$	$O(NN_d)$
GCI	$(40N_d^2 - 6N_d + 4)dN/N_d$	$O(NN_d)$

5 仿真分析

在本文中,为了评估基于GNN的数据信道估计算法的插值性能,对不同环境下数据符号处几种不同的信道插值算法的性能进行对比,其中包括线性插值^[25]和样条插值^[25]两种传统的插值算法,另外还对比了基于FCN的信道插值算法^[26],其中FCN一共设置了五层隐藏层,每层的数目表示为(64, 128, 256, 128, 64),激活函数为ReLU.在进行仿真对比之前,GCI模型以及FCN模型已经完成了离线训练,其中的训练集的信道参数与仿真时的信道参数相同,并且训练集中包含了各种速度下的信道频率响应矩阵,仿真时的信道速度集合为[50 km/h, 100 km/h, 200 km/h],即速度索引可表示为 $\mathbf{v}_{\text{index}} = [0, 1, 2]$.仿真搭建系统时使用Python3.7,仿真系统中主要的相关参数如表2,为更加清晰展示信道估计算法的处理,未加入信道编码以及信道解码过程,仿真中对各类算法的BER、NMSE性能进行比较分析.

图5~图7展示了低速(50 km/h)、中速(100 km/h)和高速(200 km/h)下不同信噪比(Signal-to-Noise Ratio, SNR)条件时不同插值算法的NMSE和BER性能对比.其中,Linear为线性插值,Cubic为样条插值,FCN代表全连接网络估计模型,GCI为本文提出的基于GNN的数据插值算法.另外,本文的各个插值算法的仿真分析对比都是在LMMSE导频处信道估计的前提完成的,根据以下图的现象可以分析得到:


表 2 仿真系统参数

参数名称	参数值
载波频率	5.9 GHz
信道带宽	10 MHz
调制方式	QPSK
FFT 点数	1 024
子载波间隔	15 kHz
子帧中符号数	14
多径时延/ns	[0, 60, 190, 320, 390, 710, 1 100, 1 750, 2 540]
相对功率/dB	[0,-1.5,-1.4,-3.6,-0.6,-9.1,-7.0,-12.0,-16.9]
图节点相关间隔	1


(1)在低速下,从各个插值算法的 NMSE 来看,GCI 模型拥有最优的插值效果,传统的 Linear 插值算法性能最差,Cubic 插值性能稍好于 Linear,FCN 模型也有着较

好的效果,不过略逊于 GCI. 从 BER 的性能来看,在低 SNR 下各插值算法性能基本重合,高 SNR 下的性能差别也不是非常明显,GCI 模型和 FCN 模型的性能稍好于两种传统的插值算法. 分析认为,低速情况下,多普勒频移较低,信道的时变较慢,信道受多径的影响的较多,传统的信道插值算法由于导频处的估计可能还有部分噪声,导致性能较差,而 GCI 模型和 FCN 模型由于不仅能捕捉到信道之间的时域关联信息,而且还对导频处也有消除噪声的作用,因此有较好的估计性能.

(2)在中速下,由于移动速度的提高,多普勒频移也有所上升,各类算法的 NMSE 以及 BER 的性能也随之有一定降低. 对于 NMSE 性能,传统算法的性能降低了很多,Linear 插值算法依然性能最差,而 GCI 模型性能还是最优,对比次优的 FCN 模型,SNR 增益峰值也达




(a) NMSE




(b) BER

图 5 $v=50$ km/h 时 SNR 变化下各信道估计算法在数据处的性能对比



(a) NMSE



(b) BER

图 6 $v=100$ km/h 时 SNR 变化下各信道估计算法在数据处的性能对比

到了约 4 dB. 对于 BER 性能, 在高 SNR 下 GCI 明显有着更好的性能, 传统的两种插值算法性能依然是最差的.

分析认为, 随着速度逐渐增加, 由于更快的时变性, 传统插值算法开始不再能很好的拟合信道的变化, GCI 插值模型与传统插值算法的性能差距也开始拉开;

另外, 由于 GCI 采用相邻节点间关系更新相对于 FCN 能更好的捕捉相邻时域符号间的变化相关信息, 并且 GCI 添加的速度索引的编码矢量, 可以通过这些矢量来控制模型应对不同信道的变化, 因此相较 FCN 拥有更好的性能.




图7 $v=200$ km/h时SNR变化下各信道估计算法在数据处的性能对比

(3)在高速下,能比较清晰地对比各算法的NMSE性能以及BER性能,各类算法的性能都有明显的降低.在NMSE和BER性能上,GCI插值模型有着最优的性能,与其他算法都拉开了较大的差距.针对NMSE性能,GCI插值模型在低SNR下的性能远优于其他插值算法,随着SNR的增大,传统插值算法与FCN模型的性能也没有明显的提升趋势,而GCI插值模型性能有较大的提升.对于BER性能,在高SNR下GCI插值模型有着明显的优势.

分析认为,在高多普勒频移的影响下由于信道时变剧烈,传统插值算法的性能严重下降,GCI模型的估计性能下降相对来说更为缓慢,而GCI模型相对FCN模型也有着较大的性能增益,表明FCN模型在应对高多普勒时也难以很好地估计到信道的变化,而GCI模型不仅对于信道变化的敏感程度更高,而且通过加入速度索引的编码矢量更好的控制网络拟合信道的时变性,以提升算法在数据处的信道估计性能.

6 结语

针对目前车联网V2I场景下数据符号信道插值效果不佳、自适应多普勒频移能力弱以及传统神经网络可解释性不强的问题,提出了基于GNN的SC-FDMA智能信道估计算法.该算法在信道频率响应数据进行图化操作时加入多普勒编码矢量作为节点特征,应对不同多普勒频移条件下信道的快速变化,最后再输入GCI

中寻找节点间时域符号上的关联信息,使得信道估计的网络过程具有可解释性.系统仿真结果表明,相较于传统插值算法以及FCN模型,本文所提算法具有更好的估计性能及鲁棒性,适用于车联网V2I场景下的高可靠低时延通信.

参考文献

- [1] MOHARM K I, ZIDANE E F, EL-MAHDY M M, et al. Big data in ITS: Concept, case studies, opportunities, and challenges[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(8): 3189-3194.
- [2] ANWAR W, FRANCHI N, FETTWEIS G. Physical layer evaluation of V2X communications technologies: 5G NR-V2X, LTE-V2X, IEEE 802.11bd, and IEEE 802.11p[C]// 2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall). Piscataway: IEEE, 2019: 1-7.
- [3] GARCIA M H C, MOLINA-GALAN A, BOBAN M T, et al. A tutorial on 5G NR V2X communications[J]. IEEE Communications Surveys & Tutorials, 2021, 23(3): 1972-2026.
- [4] CHEN S Z, HU J L, SHI Y, et al. A vision of C-V2X: Technologies, field testing, and challenges with Chinese development[J]. IEEE Internet of Things Journal, 2020, 7(5): 3872-3881.
- [5] 3GPP. Overall description of radio access network (RAN)

- aspects for vehicle-to-everything (V2X) based on LTE and NR: ETSI TR 137 985[S/OL]. (2020-07-01). https://www.etsi.org/deliver/etsi_tr/137900_137999/137985/16.00.00_60/tr_137985v160000p.pdf.
- [6] VAN DE BEEK J J, EDFORS O, SANDELL M, et al. On channel estimation in OFDM systems[C]//1995 IEEE 45th Vehicular Technology Conference. Countdown to the Wireless Twenty-First Century. Piscataway: IEEE, 1995: 815-819.
- [7] NOH M, LEE Y, PARK H. Low complexity LMMSE channel estimation for OFDM[J]. IEE Proceedings - Communications, 2006, 153(5): 645-650.
- [8] LIAO Y, SUN G D, SHEN X F, et al. BEM-based channel estimation and interpolation methods for doubly-selective OFDM channel[C]//2018 IEEE International Conference on Smart Internet of Things (SmartIoT). Piscataway: IEEE, 2018: 70-75.
- [9] PEDROSA P, CASTANHEIRA D, SILVA A, et al. Efficient joint channel equalization and tracking for V2X communications using SC-FDE schemes[J]. IEEE Access, 2020, 8: 55158-55169.
- [10] 廖勇, 蔡志镛. 基于基扩展模型的改进正则化正交匹配追踪 V2X 快时变 SC-FDMA 信道估计[J]. 通信学报, 2021, 42(4):177-184.
LIAO Y, CAI Z R. Basis expansion model-based improved regularized orthogonal matching pursuit channel estimation for V2X fast time-varying SC-FDMA[J]. Journal on Communications, 2021, 42(4): 177-184. (in Chinese)
- [11] LIAO Y, CAI Z R, SUN G D, et al. Deep learning channel estimation based on edge intelligence for NR-V2I[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 13306-13315.
- [12] LIAO Y, HUA Y X, DAI X W, et al. ChanEstNet: A deep learning based channel estimation for high-speed scenarios[C]//ICC 2019 - 2019 IEEE International Conference on Communications (ICC). Piscataway: IEEE, 2019: 1-6.
- [13] LIAO Y, HUA Y X, CAI Y L. Deep learning based channel estimation algorithm for fast time-varying MIMO-OFDM systems[J]. IEEE Communications Letters, 2020, 24(3): 572-576.
- [14] CHOWDHURY A, VERMA G, RAO C, et al. Unfolding WMMSE using graph neural networks for efficient power allocation[J]. IEEE Transactions on Wireless Communications, 2021, 20(9): 6004-6017.
- [15] RANASINGHE V, RAJATHEVA N, LATVA-AHO M. Graph neural network based access point selection for cell-free massive MIMO systems[C]//2021 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE, 2021: 1-6.
- [16] TEKBIYIK K, KURT G K, HUANG C W, et al. Channel estimation for full-duplex RIS-assisted HAPS backhauling with graph attention networks[C]//ICC 2021 - IEEE International Conference on Communications. Piscataway: IEEE, 2021: 1-6.
- [17] YANG Y D, ZHANG S, GAO F F, et al. Graph neural network-based channel tracking for massive MIMO networks[J]. IEEE Communications Letters, 2020, 24(8): 1747-1751.
- [18] LANCIANO T, BONCHI F, GIONIS A. Explainable classification of brain networks via contrast subgraphs [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 3308-3318.
- [19] YING R, BOURGEOIS D, YOU J X, et al. GNNExplainer: Generating explanations for graph neural networks[J]. Advances in Neural Information Processing Systems, 2019, 32: 9240-9251.
- [20] 廖勇, 田肖懿, 蔡志镛, 等. 面向 C-V2I 的基于边缘计算的智能信道估计[J]. 电子学报, 2021, 49(5):833-842.
LIAO Y, TIAN X Y, CAI Z R, et al. Intelligent channel estimation based on edge computing for C-V2I[J]. Acta Electronica Sinica, 2021, 49(5): 833-842. (in Chinese)
- [21] YANG Y, DANG S P, HE Y J, et al. Markov decision-based pilot optimization for 5G V2X vehicular communications[J]. IEEE Internet of Things Journal, 2019, 6(1): 1090-1103.
- [22] ADIREDDY S, TONG L, VISWANATHAN H. Optimal placement of training for frequency-selective block-fading channels[J]. IEEE Transactions on Information Theory, 2002, 48(8): 2338-2353.
- [23] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs[C]//31st Conference on Neural Information Processing System. Long Beach: Curran Associates Inc, 2017: 1025-1035.
- [24] LIU J L, ONG G P, CHEN X Q. GraphSAGE-based traffic speed forecasting for segment network with sparse data[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(3): 1755-1766.
- [25] COLERI S, ERGEN M, PURI A, et al. Channel estimation techniques based on pilot arrangement in OFDM sys-


tems[J]. IEEE Transactions on Broadcasting, 2002, 48(3): 223-229.

- [26] YE H, LI G Y, JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems [J]. IEEE Wireless Communications Letters, 2018, 7(1): 114-117.


作者简介



廖 勇 男, 1982年1月出生于四川省自贡市. 现为重庆大学副研究员、博士生导师. 主要研究方向为下一代无线通信、人工智能、量子计算及其在无线通信中的应用. 中国电子学会会员编号: E190005972S.
E-mail: liaoy@cqu.edu.cn



尹子松 男, 1996年8月出生于江西省吉安市. 现为重庆大学微电子与通信工程学院研究生. 主要研究方向为车联网通信下的信道估计算法.
E-mail: yinzs@cqu.edu.cn



田肖懿 男, 1998年1月出生于贵州省铜仁市. 重庆大学硕士. 主要研究方向为人工智能算法及其在车联网通信下的应用.
E-mail: tianxy@cqu.edu