

# 面向 C-V2I 的基于边缘计算的智能信道估计

廖 勇, 田肖懿, 蔡志榕, 花远肖, 韩庆文

(重庆大学微电子与通信工程学院, 重庆 400044)

**摘 要:** 车联网对于超高可靠与低时延通信(Ultra-Reliable and Low Latency Communications, URLLC)具有严格的要求, 特别对于车到基础设施(Vehicle to Infrastructure, V2I)场景, URLLC 对传输管理交通状况至关重要. 3GPP Cellular-V2X(C-V2X)作为现在支撑车联网 URLLC 主流的无线技术, 仍存在技术挑战. 为进一步提升通信性能, 本文在 V2I 场景下, 基于车载终端、路侧单元(Road Side Unit, RSU)与边缘计算车联网服务器(Internet of Vehicles Server, IoV Server)的交互, 设计了一种基于 C-V2I 规范的智能信道估计框架. 在 IoV Server 中, 本文提出了一种基于深度学习的信道估计算法, 该算法利用一维卷积神经网络(One Dimensional Convolution Neural Network, 1D CNN)完成频域插值和条件循环单元(Conditional Recurrent Unit, CRU)进行时域状态预测, 通过引入额外的速度编码矢量和多径编码矢量跟踪环境的变化, 对不同移动环境下的信道数据进行精确训练. 最后通过系统仿真与分析表明, 所提算法能够通过信道参数编码追踪不同高速移动环境下的信道变化, 实现对信道数据的精确训练. 与车联网代表性信道估计算法相比, 所提算法提升了信道估计精度, 降低了误码率和增强了鲁棒性.

**关键词:** 车联网; 边缘计算; V2I; C-V2X; 信道估计; 深度学习

**中图分类号:** TN929.5      **文献标识码:** A      **文章编号:** 0372-2112 (2021)05-0833-10

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.12263/DZXB.20200953

## Intelligent Channel Estimation Based on Edge Computing for C-V2I

LIAO Yong, TIAN Xiao-yi, CAI Zhi-rong, HUA Yuan-xiao, HAN Qing-wen

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

**Abstract:** Internet of vehicles has strict requirements in Ultra-Reliable and Low Latency Communications (URLLC). Especially in vehicle to infrastructure (V2I) scenario, URLLC is crucial to correctly transport and manage traffic conditions. 3GPP Cellular-V2X (C-V2X), as the current mainstream wireless technology supporting the URLLC, still has technical challenges. In order to further improve the communication performance, this paper designs an intelligent channel estimation framework based on C-V2I specification based on the interaction between vehicle terminal, road side unit (RSU) and edge computing Internet of Vehicles server (IoV Server) in V2I communication scenario. In IoV Server, this paper proposes a channel estimation algorithm based on deep learning, which uses one-dimensional convolutional neural network (1D CNN) to complete frequency-domain interpolation and conditional recurrent unit (CRU) to predict the time-domain state. By introducing additional velocity coding vector and multipath coding vector, the channel data in different mobile environments are accurately trained. Finally, system simulation and analysis show that the proposed algorithm can track the channel changes in different high-speed mobile environments through channel parameter coding, and realize the accurate training of channel data. Compared with the representative channel estimation algorithms in the IoV, the proposed algorithm improves the channel estimation accuracy, reduces the bit error rate and enhances the robustness.

**Key words:** Internet of vehicles; edge computing; V2I; C-V2X; channel estimation; deep learning

## 1 引言

随着车联网<sup>[1,2]</sup>的快速发展, 车到万物(Vehicle to

Everything, V2X)的通信已成为车载服务的关键技术<sup>[3]</sup>. V2X 主要包括车到基础设施(Vehicle to Infrastructure, V2I)、车到车(Vehicle to Vehicle, V2V)和车到

行人 (Vehicle to Pedestrian, V2P). 目前支持 V2X 通信的标准主要有两类: IEEE 802. 11p 组织的专用短程通信 (Dedicated Short-Range Communication, DSRC)<sup>[4,5]</sup> 和 3GPP 组织的 Cellular-V2X (C-V2X)<sup>[6,7]</sup>. 文献[8]表明, 在公路交通场景中, C-V2X 的性能优于 DSRC.

V2I 作为智能交通系统 (Intelligent Transportation Systems, ITS) 中的重要部分, 对 ITS 的高效运转起着关键作用. 针对车联网 V2I 场景, 在实际应用中用户对超高可靠与低时延通信 (Ultra-Reliable and Low Latency Communications, URLLC) 有着极高的要求, 这也是保障道路交通安全的重要因素. 信道估计<sup>[9,10]</sup> 作为车联网 V2I 通信中的关键处理而受到了广泛关注. 当前全球的公路网络已经非常完善, V2I 的速度可以达到 200km/h 以上, 这也意味着在车联网通信的过程中将受到极其严重的多普勒频移的影响. C-V2I 物理层标准采用单载波频分多址 (Single Carrier Frequency Division Multiple Access, SC-FDMA) 系统, 即使在微小的频偏下也可能导致严重的子载波间干扰 (Inter-Carrier Interference, ICI), 给无线通信的同步、信道估计等带来了很大的困难, 因此信道估计的性能将很大程度上影响车联网 V2I 通信的质量<sup>[11,12]</sup>.

车联网无线信道具有快时变、非平稳的衰落特性<sup>[13,14]</sup>, 对信道估计有更高的实时性和准确性的要求, 因此车联网信道估计都是采用基于导频的信道估计方法. 其中, 最小二乘法 (Least Square, LS) 和最小均方误差 (Linear Minimum Mean Square Error, LMMSE)<sup>[15]</sup> 是最经典的信道估计方法, 再配合利用时域线性插值可以得到完整的信道矩阵信息, 但 LS 算法的估计性能较低, LMMSE 算法需要获取信道的先验信息, 在实际中往往很难实现. 文献[16]引入了增强的均衡方案谱时间平均 (Spectral Time Average, STA), 该方法利用来自数据子载波的判决, 并同时在时域和频域中进行平均来更新信道估计, 提高了车联网下信道的估计性能; 文献[17]提出了一种基于长训练导频序列的信道频域响应和构造数据导频 (Constructed Data Pilots, CDP) 的信道估计方案, 该方案利用数据符号构造导频, 并利用相邻两个符号内信道间的相关特性, 进一步优化信道更新的准确性, 但上述的两种算法都属于判决反馈式估计方法, 对速度的鲁棒性较差, 很难适应速度经常变化的车联网场景. 文献[18]给出了一种基于深度学习的信道估计方法, 该方法使用全连接深度神经网络 (Deep Neural Networks, DNN) 联合完成频域插值和估计频域插值系数, 以及利用长短期记忆 (Long Term Short Memory, LSTM) 循环神经网络联合完成时域状态预测和估计时域相关系数. 但是该方法所提网络中未考虑到适应移动速度以及多径数变化的问题, 当无线信道的多径条

件和移动速度条件都大幅变化时, 此时不同环境下的信道数据分布差异较大, 使得该算法估计性能下降, 鲁棒性较差.

针对上述问题, 为了进一步提升车联网 V2I 的通信质量, 本文设计了一种基于 C-V2I 标准的智能信道估计框架以及提出了一种深度学习的信道估计算法. 具体贡献如下:

(1) 设计了一种基于 C-V2I 的车联网智能信道估计框架. 面向时分双工 (Time division duplex, TDD) V2I 场景, 车载终端将上行信道信息传输至路侧单元 (Road Side Unit, RSU), RSU 将信道信息反馈至边缘计算车联网服务器 (Internet of Vehicles Server, IoV Server), IoV Server 通过收集到的信道数据, 利用深度学习完成信道估计模型的训练. 车载终端向 RSU 发送数据信息时, IoV Server 将通过训练得到的信道估计网络完成信道估计获取到信道信息, 进而完成上行链路的均衡和译码. 由于系统工作在 TDD 模式, 下行链路的信道信息将通过上下行信道的互易性获得.

(2) 为了应对高速移动环境下信道变化导致估计算法性能大幅下降的问题, 本文设计了多径编码矢量和速度编码矢量, 然后利用一维卷积神经网络 (One Dimensional Convolution Neural Network, 1D CNN) 完成频域插值和条件循环单元 (Conditional Recurrent Unit, CRU) 进行时域状态预测. 一方面, 我们将多径编码矢量通过加权的形式作用于 CNN 插值后的输出, 以此追踪信道多径的变化. 另一方面, CRU 将速度编码矢量作为网络的输入, 通过该矢量追踪不同移动环境下信道的变化. 通过离线训练, 该算法能够为不同的移动场景学习先验的多径编码和速度编码矢量, 能够通过这两个编码追踪不同移动环境下的信道变化, 实现对不同移动环境下信道数据进行精确训练, 最后通过仿真验证了所提算法的有效性.

## 2 系统模型

### 2.1 基于 C-V2I 的智能信道估计框架

C-V2X 标准下的通信场景如图 1 所示, 包括典型的 V2I, V2V 以及 V2P 三类. 本文主要考虑 V2I 场景, 即车载终端和 RSU 之间的通信. RSU 部署在道路旁, RSU 将接收到的数据传输到 IoV Server, IoV Server 存放历史车联网信道数据并对信道数据进行模型训练以及对信道进行估计.

C-V2X 支持 10MHz 和 20MHz 信道. 信道包括 1ms 子帧和每个 180kHz 的资源块 (Resource Blocks, RB) 两种. C-V2X 将子信道定义为同一子帧中的一组 RB, 并且子信道的 RB 数量不是固定的, 会根据数据包的大小以及使用的调制和编码方案 (Modulation and Coding

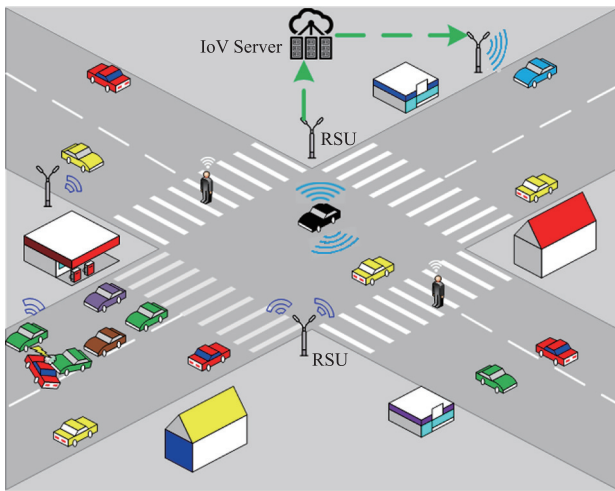


图1 C-V2X无线通信场景

Scheme, MCS)变化,子信道用于传输数据和控制信息.数据通过物理侧链共享信道(Physical Sidelink Control Channels, PSSCH)在传输块(Transport Blocks, TB)中传输.控制信息通过物理侧链控制信道(Physical Sidelink

Shared Channels, PSCCH)在侧链控制信息(Sidelink Control Information, SCI)消息中传输.假设系统工作模式为TDD,上下行信道具有互易性<sup>[19]</sup>.基于C-V2I的智能信道估计框架如图2所示,具体步骤如下:

- (1) 车载终端将 CSI 通过上行链路反馈至 RSU.
- (2) RSU 将 CSI 传输至 IoV Server.
- (3) IoV Server 存储 CSI,并结合历史的 CSI 进行深度学习训练,得到信道估计网络,具体处理过程详见第 3 节.
- (4) 车载终端将数据信号通过上行链路发送到 RSU.
- (5) RSU 将数据信号传输到 IoV Server.
- (6) IoV Server 通过已经训练好的信道估计网络,得到预测的 CSI,完成信道估计,并进行后续的信道均衡和译码,从而完成基带信号处理.
- (7) IoV Server 将处理得到的信号反馈至 RSU.
- (8) 对应的,下行链路车载终端的 CSI,将通过上下行信道互易性得到.

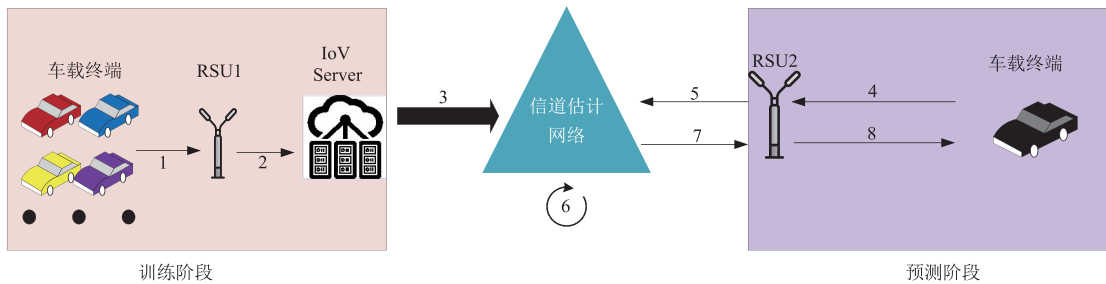


图2 基于C-V2I的智能信道估计框架

## 2.2 SC-FDMA 系统收发机信号处理

C-V2I 物理层传输系统是基于 SC-FDMA 的传输模式<sup>[20]</sup>,信号发射端信号处理的过程主要包括信道编码、调制、插入导频、离散傅里叶变换(Discrete Fourier Transform, DFT)、载波映射、快速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)、插入循环前缀(Cyclic Prefix, CP)、数模转换等,而接收端则是发射端信号处理的逆过程,最后恢复发送信号.

C-V2I 中基于 SC-FDMA 的一个传输帧包含  $I$  个传输符号,其中有  $I_d$  个数据符号和  $I_p$  个导频符号,并且 DFT 的点数为  $M$ ,传输子载波总数为  $N$ .记调制后的第  $i$  个数据符号为  $s_i = [s_i(0), \dots, s_i(M-1)]^T, i = 0, 1, \dots, I_d - 1$ ,经过  $M$  点 DFT 变换后得到发送数据频域符号  $X_i^d = [X_i^d(0), \dots, X_i^d(M-1)]^T, i = 1, 2, \dots, I_d$ ,并在子载波映射前插入 Zadoff-Chu 导频序列  $X_i^p = [X_i^p(0), \dots, X_i^p(M-1)]^T, i = 1, 2, \dots, I_p$ .为了完成接下来的  $N$  点 IFFT 变换,将频域符号调制到各个子载波上,需要对当前的频域符号进行补零操作,对不作为信息传输的 ( $N$

-  $M$ ) 个子载波位置进行补零得到完整的频域发送符号  $X_i(k)$ ,而后完成 IFFT 操作得到时域发送符号  $x_i = [x_i(0), \dots, x_i(N-1)]^T$ ,最后添加 CP 并进行数模转换后即可发送到无线传输信道中.

因此,SC-FDMA 频域发送符号可以表示为

$$X_i(k) = \begin{cases} X_i^d(k), & k \in k_{\text{signal}}, i = 0, 1, \dots, I_d - 1 \\ X_i^p(k), & k \in k_{\text{signal}}, i = 0, 1, \dots, I_p - 1 \\ 0, & k \in k_{\text{zero}}, i = 0, 1, \dots, I - 1 \end{cases} \quad (1)$$

其中,  $k_{\text{signal}}$  表示信息子载波,  $k_{\text{zero}}$  表示补零子载波.

经过车联网无线信道并成功在接收端接收后,需要进行模数转换以及去 CP 操作,并进行 FFT 变换后得到频域接收符号  $Y_i$ .

## 2.3 V2I 信道模型

本文以扩展车辆信道模型(Extended Vehicular A model, EVA)<sup>[21]</sup>作为 V2I 信道模型,考虑多普勒频移的多径信道传输模型下,V2I 信道冲激响应可以表示为

$$h(t, \tau) = \sum_{l=0}^{L-1} h_l(t) \cdot \delta(\tau - \tau_l) \cdot \exp(j2\pi f_{d,l}t) \quad (2)$$

其中,  $L$  为信道抽头总数,  $h_l(n)$  表示第  $l$  个抽头  $n$  时刻的信道冲激响应复增益,  $\tau_l$  表示各抽头的时延,  $f_{d,l}$  表示不同抽头下的最大多普勒频移.

记  $\mathbf{G}_i \in \mathbb{C}^{N \times N}$  为第  $i$  个 SC-FMDA 传输符号的信道冲激响应矩阵, 有

$$\mathbf{G}_i = \begin{bmatrix} h_i(0,0) & 0 & \cdots & h_i(0,L-1) & \cdots & h_i(0,1) \\ h_i(1,1) & h_i(1,0) & 0 & \cdots & \cdots & h_i(1,2) \\ \vdots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \cdots & 0 & h_i(N-1,L-1) & \cdots & h_i(N-1,0) \end{bmatrix} \quad (3)$$

其中  $h_i(n,l)$  表示第  $i$  个 SC-FMDA 传输符号时间上第  $l$  个抽头上时刻  $n$  的信道冲击响应.

由信号时域传输模型可以推导得, 信道冲激响应矩阵  $\mathbf{G}_i$  和信道响应矩阵  $\mathbf{H}_i \in \mathbb{C}^{N \times N}$  的关系可以表示为

$$\mathbf{H}_i = \mathbf{F} \mathbf{G}_i \mathbf{F}^H \quad (4)$$

其中,  $[\mathbf{F}]_{n,k} = \frac{1}{\sqrt{N}} \exp\left(-j \frac{2\pi}{N} kn\right) \in \mathbb{C}^{N \times N}$  表示傅里叶变换矩阵,  $(\cdot)^H$  表示共轭转置.

SC-FDM 系统频域传输模型可以描述为

$$\mathbf{Y}_i = \mathbf{H}_i \mathbf{X}_i + \mathbf{W}_i \quad (5)$$

其中,  $\mathbf{X}_i = [X(0), X(1), \dots, X(N-1)]^T \in \mathbb{C}^{N \times 1}$  为第  $i$  个频域发送信号,  $\mathbf{W}_i \in \mathbb{C}^{N \times 1}$  为信道噪声向量, 其协方差矩阵可以表示为  $\mathbf{Q}_w = \sigma_w^2 \mathbf{I}_N$ ,  $\sigma_w^2$  为噪声方差,  $\mathbf{I}_N$  为  $N$

维的单位方阵,  $\mathbf{H}_i \in \mathbb{C}^{N \times N}$  为待估计的信道频域响应矩阵.

### 3 CNN-CRU 信道估计

#### 3.1 CNN-CRU 信道估计结构

CNN-CRU 信道估计结构主要分为训练和预测两个部分, 其结构图如图 3 所示.




图3 CNN-CRU信道估计框架

首先, 我们需要对 CNN-CRU 进行训练, 训练的目的是调整 CNN-CRU 中的参数. 我们需要做的就是收集足够多的信道数据样本, 然后使用这些信道数据样本对 CNN-CRU 算法进行训练, 通过训练迭代求解该算法最小均方误差下的最优参数, 即使其学习到信道的变化特征. 对于预测, 此时 CNN-CRU 算法中的参数已经训练完成, 因此直接将训练好的 CNN-CRU 用于跟踪信道的变化, 完成在线信道估计. CNN-CRU 主要由 1D CNN 和双向 CRU (Bidirectional CRU, BiCRU) 组成, 其结构图如图 4 所示.

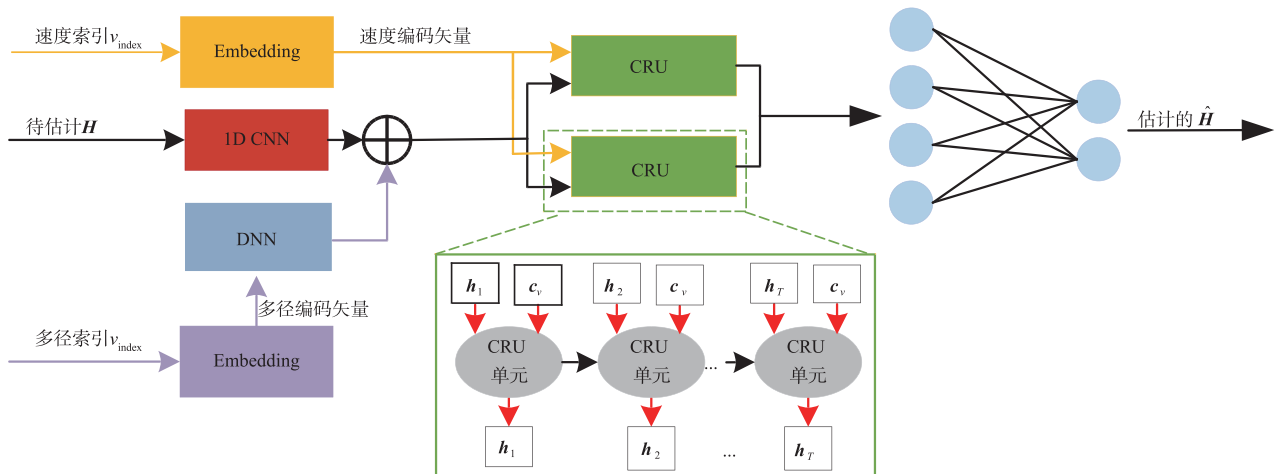


图4 CNN-CRU网络设计

#### 3.2 CNN-CRU 中的数据流

下面我们将详细介绍 CNN-CRU 中的输入数据预处理、条件编码矢量获取、频域插值、时域信道预测和数据降维.

##### (1) 输入数据预处理

信道估计的目的就是在接收端估计出信道频域响应矩阵  $\mathbf{H}$ , 而对于基于导频辅助的信道估计方法, 其目

的是通过导频符号处的信道响应预测出数据符号处的信道响应. 对于 CNN-CRU 信道估计算法, 该模型的输入为一个子帧大小的 CFR 矩阵, 该矩阵中导频符号位置处的信道响应通过 LS 方法初始化, 而数据符号位置处的信道响应数值被设为 0, 其输入数据表现形式为

$$\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_i, \dots, \mathbf{h}_r]^T \quad (6)$$

其中  $\mathbf{h}_i = [h_{i,1}, h_{i,2}, \dots, h_{i,N}]^T \in \mathbb{C}^N$ , 数据符号位置处  $h_{i,n}$

=0. 因为原始的信道响应数据为复数,因此在输入 CNN-CRU 之前需要对数据进行预处理,在本文中,我们将原始信道数据的实部和虚部提取出来然后拼接成一个维度,于是此时的信道数据变成  $\mathbf{H}' = \mathbb{R}^{T \times 2N}$ ,  $\mathbf{h}'_i \in \mathbb{R}^{2N}$ .

### (2) 条件编码矢量获取

为了使 CNN-CRU 算法适应特定的移动环境,我们在频域插值和时域状态预测时分别引入额外多径编码和速度编码矢量作为额外的输入,通过这两个编码矢量分别追踪车联网环境下多径条件的变化和移动速度的变化. 在本文中,这两种编码矢量都是通过深度学习中 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. 更具体的说,Embedding 嵌入层本质上是全连接网络,但是其侧重点与全连接不一样,Embedding 层的输出相当于全连接网络中的权重,即 Embedding 嵌入层获取的是网络中的权重. 在本文中,设我们需要仿真的不同的多径条件和不同的移动速度数分为  $N_d$  和  $N_v$ ,每个编码向量的维度均为  $2N$ ,于是 Embedding 嵌入矩阵可以表示为

$$\mathbf{E}_d = [\mathbf{e}_1^d, \mathbf{e}_2^d, \dots, \mathbf{e}_{N_d}^d]^T \quad (7)$$

$$\mathbf{E}_v = [\mathbf{e}_1^v, \mathbf{e}_2^v, \dots, \mathbf{e}_{N_v}^v]^T \quad (8)$$

其中,  $\mathbf{E}_d \in \mathbb{R}^{N_d \times 2N}$ ,  $\mathbf{E}_v \in \mathbb{R}^{N_v \times 2N}$ . 训练之前,嵌入矩阵中的数据随机初始化,训练时候,我们只需给嵌入层每个速度和多径对应的索引  $v_{\text{index}}$  和  $d_{\text{index}}$ ,嵌入层根据给定的索引获取嵌入矩阵中的指定的行向量作为编码矢量,其表达式为

$$\mathbf{c}_d = \text{select\_row}(\mathbf{E}_d, d_{\text{index}}) \quad (9)$$

$$\mathbf{c}_v = \text{select\_row}(\mathbf{E}_v, v_{\text{index}}) \quad (10)$$

其中  $\mathbf{c}_d$  和  $\mathbf{c}_v$  分别为给定多径和速度条件下的编码矢量.

### (3) 1D CNN 频域插值

在本文中,相较于文献[19]中使用 DNN 进行频域插值,而用 DNN 网络进行频域插值时,每个 SC-FDM 符号的插值是独立的,这样使得频域插值时没有利用到信道的时域变化特征. 因此本文利用 1D CNN 进行频域插值. 1D CNN 每个神经元的输出仅利用了每个通道上输入中卷积核大小的数据,该网络结构很巧妙的同时利用了信道时域和频域上的变化关系.

设  $\mathbf{L}_{k-1} = [\mathbf{I}_{k-1}^1, \mathbf{I}_{k-1}^2, \dots, \mathbf{I}_{k-1}^{C_{k-1}}] \in \mathbb{R}^{H_{k-1} \times C_{k-1}}$  为 1D CNN 第  $k-1$  层的输出,其中  $\mathbf{I}_{k-1}^c \in \mathbb{R}^{H_{k-1}}$  表示第  $c$  个通道上的数据矢量. 于是第  $k$  层卷积神经网络上第  $c$  个通道上第  $i$  个输出为

$$I_{k,i}^c = \sum_{m=1}^{C_{k-1}} \left\{ \sum_{m=1}^M (\mathbf{W}_k^{(c,t)}(m) \mathbf{I}_{k-1}^c(m + (i-1)S)) \right\} + \mathbf{b}_k^{(c)} \quad (11)$$

$c = 1, 2, \dots, C_k$

其中,  $\mathbf{W}_k \in \mathbb{R}^{C_{k-1} \times C_k \times M}$  和  $\mathbf{b}_k \in \mathbb{R}^{C_k}$  分别表示第  $k$  层的权重张量和偏置矢量,  $S$  为卷积滤波器在输入数据上滑动的

步长,  $M$  表示卷积滤波器的宽度.  $C_k$  表示第  $k$  层卷积神经网络输出的通道数. 因此我们可以得到第  $k$  层 1D CNN 上第  $c$  个通道上的输出矢量为

$$\mathbf{I}_k^c = [I_{k,1}^c, I_{k,2}^c, \dots, I_{k, \frac{H_{k-1}-M+1}{S}}^c]^T \quad (12)$$

第  $k$  层的输出数据为

$$\mathbf{L}_k = [\mathbf{I}_k^1, \mathbf{I}_k^2, \dots, \mathbf{I}_k^{C_k}] \in \mathbb{R}^{\frac{H_{k-1}-M+1}{S} \times C_k} \quad (13)$$

同样的,为了使得数据进行非线性变换,每层 1D CNN 网络后面需接激活函数,因此 1D CNN 每层的变换公式可以简写为如下

$$\mathbf{L}_k = f(\mathbf{W}_k * \mathbf{L}_{k-1} + \mathbf{b}_k) \quad (14)$$

在基于 1D CNN 频域插值的网络中,本文使用的卷积核宽度  $M=9$ ,步长  $S=1$ ,1D CNN 的输入和输出通道数为  $T$ . 于是第  $t$  个 SC-FDM 符号上第  $n$  个子载波上的信道响应为

$$h''_{t,n} = \sum_{i=1}^T \left( \sum_{j=1}^9 \mathbf{W}^{(t,i)}(j) \mathbf{H}'(j+n-1, t) \right) + (\mathbf{W}_d(n))^T \mathbf{c}_d \quad (15)$$

$t = 1, \dots, T; n = 1, \dots, N$

其中  $\mathbf{W} \in \mathbb{R}^{2N \times 2N}$  为多径编码矢量的权重矩阵. 因为卷积神经网络的变换过程会对原始的数据降维,因此我们会对输入填充多个零以保证输出和原始的输入维度一致. 由式(15)可知,一方面,估计第  $t$  个 SC-FDM 符号上第  $n$  个子载波上的信道频域响应时不仅利用该 SC-FDM 符号处第  $n$  个子载波附近导频符号处的信道频域响应,还利用了其他 SC-FDM 符号处第  $n$  个子载波附近导频符号处的信道频域响应,因此基于 1D CNN 的频域插值联合利用了信道的时/频域的变化关系,同时追踪信道频域响应的时/频域变化. 另一方面,每一个数据符号处的信道响应由导频符号处信道频域响应和多径编码矢量共同决定,通过多径矢量追踪信道由于多径条件变化所导致环境的变化. 对于每个 SC-FDM 符号插值后的输出可以表示为

$$\mathbf{h}''_t = f_r(\mathbf{W}^{(t)} * \mathbf{H}' + \mathbf{W}_d \mathbf{c}_d), t = 1, 2, \dots, T \quad (16)$$

其中  $t$  对应 1D CNN 中输出的第  $t$  个通道数.

### (4) CRU 时域状态预测

在时域状态预测时,为了适应特定的移动环境,我们设计了 CRU 网络,该网络将不同的移动速度编码成一个向量输入到时域状态网络中,因此此时的网络有两个输入:特定移动环境下的速度编码向量和频域插值后的信道数据. CRU 网络为我们设计的一个全新循环神经网络,该网络本质上是一个 RNN 网络,我们更改了每个循环单元的内部,并且借鉴了 LSTM 网络中门的形式,利用两种门控制网络中输入输出的流入形式,其示意图如图 5 所示.

同样的,CRU 网络主要由若干个 CRU 单元组成,每个单元有两个门控单元:输入门和更新门,输入门和




图5 CRU结构

更新门控制网络中各个部分数据的流入. 由此我们可以得到对第  $t$  个 SC-FDM 符号, 其时域状态预测数学变换式为

$$i_t = \sigma(U_i h_t'' + W_i h_{t-1}'') \quad (17)$$

$$u_t = \sigma(U_u h_t'' + W_u h_{t-1}'') \quad (18)$$

$$c_t = \tanh(U_c h_t'' + W_c h_{t-1}'' + i_t \odot V_c c_v) \quad (19)$$

$$h_t''' = u_t \odot c_t + (1 - u_t) \odot h_t'' \quad (20)$$

其中,  $i_t$  和  $u_t$  分别为 CRU 单元的输入门和更新门,  $c_t$  为记忆单元, 其中  $\sigma$  为 sigmoid 函数,  $h_t''$  为  $t$  时刻输入的信道数据,  $h_{t-1}''$  为  $t-1$  时刻前一 CRU 单元的状态,  $U_i, W_i, U_u, W_u, U_c, W_c, V_c$  为 CRU 网络的权重, 通过训练得到,  $\odot$  为元素乘法,  $c_v$  为特定速度下的编码矢量. 由式(19)可知, 输入门作用于速度编码矢量部分, 我们这样做是想通过门的形式控制速度编码中只有一部分信息流入到记忆单元中, 其好处是记忆单元的信息不会完全由速度编码控制, 而是各种信息的整合. 最后, 我们通过一个更新门直接控制记忆单元和输入得到最终的输出, 其变换式如式(20)所示, 即最终输出的一部分来自记忆单元, 另一部分直接来自输入, 其每个部分的流入程度通过更新门  $u_t$  决定. 例如在低速条件下, 信道响应的时域变化缓慢, 因此  $u_t$  数值较小, 最终输出主要由输入决定, 相反的, 对于高速移动条件, 此时信道响应的时域呈现快时变特性, 此时  $u_t$  数值较大, 因此最终的输出由包含多普勒频移参数影响的记忆单元决定. 本文使用 BiCRU 网络进行时域状态预测, BiCRU 网络为两个 CRU 网络的结合, 其中一个进行正向预测, 另一个进行反向预测. 一方面, 使用 BiCRU 网络能够充分利用当前时刻前后的所有信息用于当前时刻的预测, 另一方面通过双向预测, 能够抑制由于单向预测导致的误差传播. 对于时域状态预测, 每个 CRU 网络有  $T$  个 CRU 单元. BiCRU 网络  $t$  时刻的两个 CRU 的输出分别为

$$h_{FW,t} = \text{CRU}(h_{FW,t-1}, h_t'', c_t, \Theta_{FW}) \quad (21)$$

$$h_{BW,t} = \text{CRU}(h_{BW,t-1}, h_{t-1}'', c_t, \Theta_{BW}) \quad (22)$$

其中,  $\Theta_{FW}$  和  $\Theta_{BW}$  分别为前向 CRU 和后项 CRU 网络中的所有参数. 于是 BiCRU 网络  $t$  时刻的输出为

$$h_t''' = [h_{FW,t}; h_{BW,t}] \in \mathbb{R}^{4N \times 1} \quad (23)$$

#### (5) DNN 降维

通过 1D CNN 频域插值和 BiCRU 时域状态预测, 此时我们已经获得了所有资源网格的信道数据, 由于

使用了双向预测, 此时每个时刻的输出为两个 CRU 输出的拼接, 因此我们需要对此时的输出进行降维. 于是第  $t$  个 SC-FDM 符号最终信道估计的结果为

$$\hat{h}_t = f_T(W_{DR} h_t''') \quad (24)$$

最后, 我们将最终估计结果的实部和虚部分离出来作为估计的实部和虚部, 然后整合成复数的形式得到最终的估计结果.

### 3.3 模型训练

在本文中, 我们根据 EVA 信道模型生成训练数据. 对于离线训练, 训练样本的获取是通过系统仿真收集每帧内所有资源网格的信道数据监督数据, 然后按照一定的导频插入规则将数据处信道响应设置为 0 和每个样本对应速度和多径的索引值作为训练数据. 训练 CNN-CRU 的目的是最小化学习网络输出和标签数据之间的误差进而更新网络中的所有参数, 其中 CNN-CRU 网络中参数我们可以分为四大类: 频域插值系数、条件编码嵌入矩阵、时域相关系数和降维系数. 通过训练, CNN-CRU 网络能够学习到这些系数的最优解, 使得 CNN-CRU 网络中的参数能够更好的跟踪信道的变化. 对于在线估计, 此时 CNN-CRU 中的各种参数已经训练完成, 因此我们可以直接使用训练好的 CNN-CRU 网络进行信道估计.

为了训练 CNN-CRU 网络, 我们使用端到端的方式获取该网络中的所有权重. 设整个 CNN-CRU 网络的变换公式和所有参数分别为  $f_{\text{est}}(\cdot)$  和  $\Theta_{\text{est}}$ , 因此 CNN-CRU 网络估计得到的 CSI 可以表示为  $\hat{H} = f_{\text{est}}(H, d_{\text{index}}, v_{\text{index}}, \Theta_{\text{est}})$ . 我们使用自适应矩估计 (ADaptive Moment estimation, ADAM) 算法和随机梯度下降算法 (Stochastic Gradient Descent, SGD) 更新 DNN-LSTM 网络的参数集, ADAM 算法与传统采用固定学习率的梯度下降算法不同, 它能够通过训练自适应的更新学习率. 网络的损失函数为 MSE, 因此, 我们模型的预测损失为

$$L(\Theta_{\text{est}}) = \frac{1}{M_s} \sum_{i=1}^{M_s} (f_{\text{est}}(H_i, d_{\text{index}}^i, v_{\text{index}}^i, \Theta_{\text{est}}) - H_i^*)^2 \quad (25)$$

其中,  $H^*$  为监督数据,  $M_s$  为训练样本集中总的样本数. 在本文中, 我们所使用的训练集、校验集和测试集分别为 300000, 40000 和 20000, 其中各种数据集包含待估计的信道数据和每个数据样本对应速度的索引值  $v_{\text{index}}$  和多径索引值  $d_{\text{index}}$ , 其中各种数据集包含的信道数据的移动速度参数集合为 [60km/h, 110km/h, 160km/h, 210km/h, 260km/h, 310km/h], 即  $v_{\text{index}} = [0, 1, \dots, 5]$ , 多径数集合为 [3, 6, 9, 12, 15, 18], 即  $v_{\text{index}} = [0, 1, \dots, 5]$ , 数据收集通过 MATLAB 平台仿真得到.

### 4 复杂度分析

我们对比了 LS、LMMSE、STA、CDP 四种传统信道

估计方法, DNN-LSTM 算法和本文所提算法 CNN-CRU 算法的计算复杂度. 本文主要对比了算法估计两个 SC-FDM 符号所需的乘法次数和计算复杂度, 其中一个 SC-FDM 符号包含导频, 另一个 SC-FDM 符号与之相邻不包含导频, 其结果如表 1 所示.

表 1 算法的复杂度比较

算法	乘法次数	计算复杂度
CNN-CRU(在线)	$[(2MT + 2N_d)N] + [64N^2 + (2N_p + 12)N]$	$O(N^2)$
DNN-LSTM(在线)	$[4N^2] + [72N^2 + 12N]$	$O(N^2)$
LMMSE + 线性插值	$[3N^3 + N^2] + [N]$	$O(N^3)$
LS + 线性插值	$[N] + [N]$	$O(N)$
STA	$[N] + [2N]$	$O(N)$
CDP	$[N] + [4N]$	$O(N)$

从表 1 中的结果可以看出, LS、STA 和 CDP 的计算复杂度在同一个数量级, LMMSE 由于需要计算矩阵求逆而具有最高的计算复杂度, CNN-CRU 的在线估计复杂度与 DNN-LSTM 算法相当, 低于传统的 LMMSE 配合线性插值算法, 略高于 LS 配合线性插值算法. 对于 CNN-CRU 算法, 该算法仅仅是一些矩阵的乘法和加法运算, 因此其复杂度低于传统的 LMMSE 算法. 并且, 神经网络可以并行运行, 因此可以减少算法运算时间. 对于在线估计阶段, 此时直接将训练好的网络用于信道估计, 因此复杂度较低. 虽然 CNN-CRU 算法的计算复杂度与 DNN-LSTM 算法相当, 但通过所需的乘法次数可以看出 CNN-CRU 算法的复杂度是低于 DNN-LSTM 算法, 总的来说, CNN-CRU 的复杂度在可接受的范围内.

### 5 仿真分析

本节给出了车联网 V2I 点对点 SC-FDM 传输系统仿真及结果分析. 传输系统物理层数据帧结构按照 C-V2I 协议给定设置<sup>[22]</sup>, 一个子帧中包含有 14 个传输符号, 其中第 3、6、9 和 12 个符号为导频符号, 其余的系统参数设置如表格 2 所示. 另外, 本文的车联网信道模型为 EVA 信道模型其他信道参数的设置如表 3 所示.

表 2 系统参数设置

系统参数	设置
载波频率	5.9GHz
信道带宽	10MHz
子载波数	600
子载波间隔	15KHz
调制方式	QPSK

表 3 信道参数设置

信道参数	设置
信道模型	EVA
信道抽头数	[3, 6, 9, 12, 15, 18]
最大抽头时延	[0, 30, 150, 310, 370, 710, 1090, 1730, 2510] ns
最大相对速度	[60, 110, 160, 210, 260, 310] km/h
最大多普勒频移	[328, 601, 874, 1147, 1420, 1693] Hz

图 6 和图 7 展示了多径数为 9, 移动速度为 110km/h 时各种算法的 NMSE 性能和 BER 性能, 从图中我们可以看出.

(1) LS + 线性插值、CDP 和 STA 算法具有较差的 NMSE 性能, 这是由于这些算法导频处信道响应均通过 LS 算法估计得到, 而 LS 算法不能消除噪声的影响, 进而影响到数据符号处信道响应估计的准确性. LMMSE 具有较好的 NMSE 性能, 而 CNN-CRU 算法具有最好的 NMSE 性能, 表明 CNN-CRU 算法不仅能够有效去除导频处噪声的影响, 而且能够较好的跟踪信道的变化. 对于 DNN-LSTM 算法, 由于训练数据包含了各种环境的




图 6 多径数为 9, 移动速度为 110km/h 时各种算法的 NMSE 性能对比




图 7 多径数为 9, 移动速度为 110km/h 时各种算法的 BER 性能对比

信道数据,其不能拟合不同环境的信道数据,因此性能较差.

(2)在信噪比  $SNR < 20$  时,DNN-LSTM 算法的 BER 性能与 LMMSE 性能相当,这表明基于神经网络的方法具有较好的去噪性能,对噪声有较好的鲁棒性,此时 CNN-CRU 算法的已经达到估计性能的上限,此时该方法的 BER 性能主要受限于噪声的影响.

图 8 和图 9 展示了当  $SNR = 25\text{dB}$ ,多径数为 9 时,各种算法随移动速度变化的 NMSE 和 BER 性能对比.从图中我们可以看出,各种算法的 NMSE 性能和 BER 性能随着移动速度增加呈下降趋势.本文所提的 CNN-CRU 算法与 DNN-LSTM 算法 NMSE 性能随着速度的变化趋于平稳,表明基于深度学习的算法能够很好的跟踪信道速度的变化,而 CNN-CRU 算法通过引入速度编码矢量进一步提升算法对速度的鲁棒性,此时 CNN-CRU 算法的 NMSE 从 0.001 下降至 0.005 左右,其下降幅度仅仅为 0.004,其下降幅度大约为 CDP 算法的二十五分之一.




图8 多径数为9, SNR为25dB时不同速度环境下各种算法的NMSE性能对比

图 10 和图 11 展示了当  $SNR = 25\text{dB}$ ,移动速度为  $110\text{km/h}$  时,各种算法随多径变化的 NMSE 和 BER 性能对比,其仿真参数同表 2.从图中我们可以看出,各种算法的 NMSE 性能和 BER 性能随着移动速度增加呈下降趋势,当多径数从 9 增加到 18 时,传统的 STA、CDP、LS 和 LMMSE 算法的 NMSE 性能和 BER 性能急剧下降,表明传统的算法对多径的鲁棒性较差,此时 CNN-CRU 算法下降趋势较为平稳,表明所提算法具有较好的鲁棒性,此时 DNN-LSTM 算法的 NMSE 性能曲线随着多径数的变化存在跳变,即 DNN-LSTM 算法不能有效追踪信道多径条件的变化,而 CNN-CRU 算法通过引入多径编码矢量能够精确追踪到每个多径条件的变化,提升算法对多径的鲁棒性.

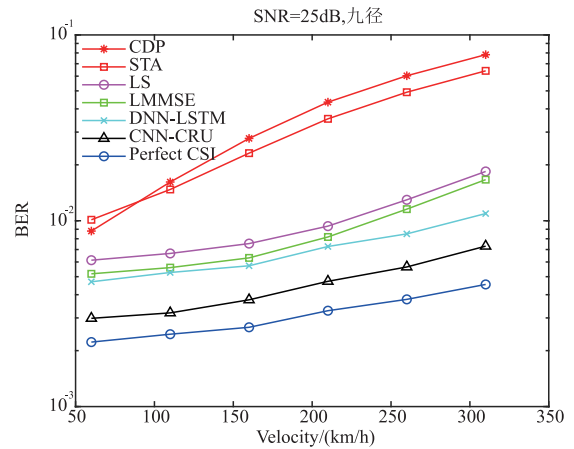


图9 多径数为9, SNR为25dB时不同速度环境下各种算法的BER性能对比

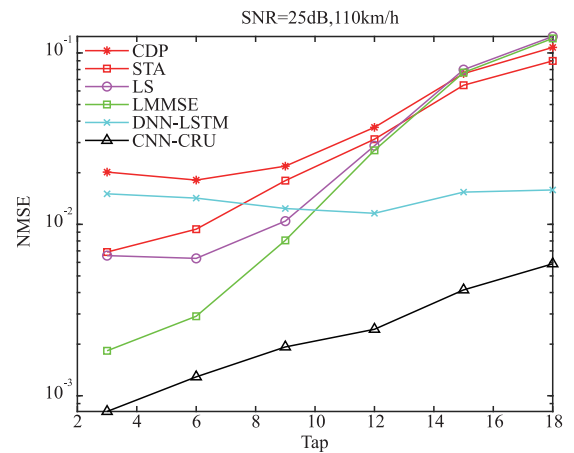


图10 移动速度为100km/h, SNR=25dB时不同多径环境下各种算法的NMSE性能对比

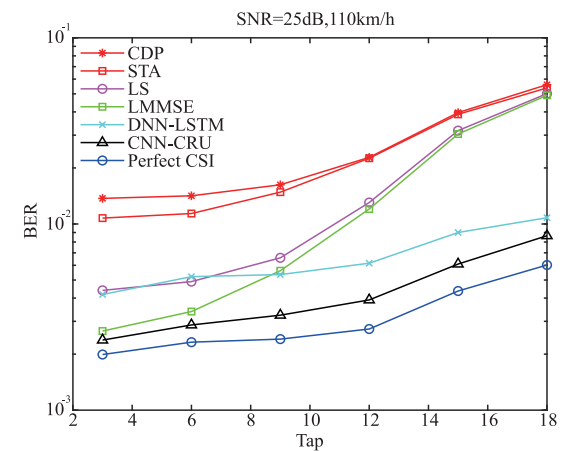


图11 移动速度为110km/h, SNR=25dB时不同多径环境下各种算法的BER性能对比

### 6 结语

为进一步提升车联网 V2I 通信质量,本文设计了一个面向 C-V2I 的基于边缘计算的智能信道估计框架,

充分利用了 IoV Server 的存储和计算能力。同时,针对车联网环境下传统信道估计性能的不足,在 IoV Server 中提出了一种基于 CNN-CRU 的信道估计网络,利用 CNN 完成频域插值和 CRU 进行时域状态预测,提升了信道估计的准确度。此外,我们引入速度编码矢量和多径编码矢量作为额外输入控制整个信道估计网络的输出达到精确训练的目的。通过分析及系统仿真表明,本文所提 CNN-CRU 网络能够有效地降低计算复杂度的同时还能保证信道估计精度和鲁棒性。

#### 参考文献

- [1] Bian M, Li K. Strategic analysis on establishing an automobile power in China based on intelligent & connected vehicles[J]. Strategic Study of Chinese Academy of Engineering, 2018, 20(1): 52 – 58.
- [2] Zhao X, Jing S, Hui F, et al. DSRC-based rear-end collision warning system—an error-component safety distance model and field test [J]. Transportation Research Part C: Emerging Technologies, 2019, 107: 92 – 104.
- [3] Abboud K, Omar H, Zhuang W. Interworking of DSRC and cellular network technologies for V2X communications; A survey[J]. IEEE Transactions on Vehicular Technology, 2016, 65(12): 9457 – 9470.
- [4] Kenney J B. Dedicated short-range communications (DSRC) standards in the United States[J]. Proceedings of the IEEE, 2011, 99(7): 1162 – 1182.
- [5] Yang Y, Fei D, Dang S. Inter-vehicle cooperation channel estimation for IEEE 802. 11p V2I communications [J]. Journal of Communications and Networks, 2017, 19(3): 227 – 238.
- [6] 3GPP. Evolved Universal Terrestrial Radio Access (E-UTRA) and Evolved Universal Terrestrial Radio Access Network (E-UTRAN); Overall Description[S]. 3GPP TS, 2010.
- [7] Chetlur V V, Dhillon H S. Coverage and rate analysis of downlink cellular vehicle-to-everything (C-V2X) communication[J]. IEEE Transactions on Wireless Communications, 2020, 19(3): 1738 – 1753.
- [8] Vukadinovic V, Bakowski K, Marsch P, et al. 3GPP C-V2X and IEEE 802. 11p for vehicle-to-vehicle communications in highway platooning scenarios [J]. Ad Hoc Networks, 2018, 74: 17 – 29.
- [9] 廖勇, 花远肖, 姚海梅, 等. 高速移动环境下基于深度学习的信道估计方法 [J]. 电子学报, 2019, 47(8): 1701 – 1707.  
Liao Y, Hua Y X, Yao H M, et al. Channel estimation method based on deep learning in high-speed mobile environments [J]. Acta Electronica Sinica, 2019, 47(8): 1701 – 1707. (in Chinese)
- [10] 廖勇, 张楠, 姚海梅, 等. 高速场景下基于叠加导频的现代 EKF 信道估计方法 [J]. 电子学报, 2019, 47(11): 2399 – 2406.  
Liao Y, Zhang N, Yao H M, et al. Iterative EKF channel estimation method based on superimposed pilot in high mobility scenarios [J]. Acta Electronica Sinica, 2019, 47(11): 2399 – 2406. (in Chinese)
- [11] Lai X, Chen Z, Zhao Y. Basis expansion model for fast time-varying channel estimation in high mobility scenarios [A]. International Conference on Communications and Networking in China [C]. Chongqing, China: EAI, 2016. 489 – 501.
- [12] Mao X, Hashemizadeh S, Chen R, et al. Soft decision directed dual-layer channel estimation for time-varying MIMO channels [A]. Wireless Communications & Networking Conference [C]. San Francisco, CA, USA: IEEE, 2017. 1558 – 2612.
- [13] 沈轩帆, 廖勇, 代学武, 等. 基于 BEM 的非平稳双选信道估计方法 [J]. 电子学报, 2019, 47(1): 204 – 210.  
Shen X F, Liao Y, Dai X W, et al. Non-stationary and doubly-selective channel estimation method based on basis expansion model [J]. Acta Electronica Sinica, 2019, 47(1): 204 – 210. (in Chinese)
- [14] 廖勇, 胡异, 杨馨怡, 等. 高速移动环境下基于动态 CSI 的 MIMO 系统改进模代数预编码 [J]. 电子学报, 2019, 47(6): 1209 – 1215.  
Liao Y, Hu Y, Yang X Y, et al. An improved tomlinson-harashima precoding based on dynamic CSI in high-speed mobile scenarios [J]. Acta Electronica Sinica, 2019, 47(6): 1209 – 1215. (in Chinese)
- [15] Aggarwal P, Gupta P, Bohara V A. A guard interval assisted OFDM symbol-based channel estimation for rapid time-varying scenarios in IEEE 802. 11p [A]. International Symposium on Personal [C]. Hong Kong, China: IEEE, 2015. 100 – 104.
- [16] Fernandez J A, Borries K, Cheng L, et al. Performance of the 802. 11p physical layer in vehicle-to-vehicle environments [J]. IEEE Transactions on Vehicular Technology, 2012, 61(1): 3 – 14.
- [17] Zhao Z, Cheng X, Wen M, et al. Channel estimation schemes for IEEE 802. 11p standard [J]. IEEE Intelligent Transportation Systems Magazine, 2013, 5(4): 38 – 49.
- [18] Liao Y, Hua Y, Dai X, et al. ChanEstNet: A deep learning based channel estimation for high-speed scenarios [A]. International Conference on Communications (ICC) [C]. Shanghai, China: IEEE, 2019. 1 – 6.
- [19] Mantri D S, Prasad N R, Prasad R. Mobility and heterogeneity aware cluster-based data aggregation for wireless sensor network [J]. Wireless Personal Communications,

2015, 86(2): 975 – 993.

- [20] Odabasioglu N, Leblebici M M, Karakaya B, et al. Cyclicprefix based time synchronization and comb type channel estimation for SC-FDMA systems over time-varying channels [A]. International Conference on Application of Information & Communication Technologies [C]. Rostov on Don, Russia: IEEE, 2015. 359 – 362.
- [21] Yang Y, Dang S, He Y, et al. Markov decision-based pilot

optimization for 5G V2X vehicular communications [J]. IEEE Internet of Things Journal, 2018, 6 ( 1 ): 1090 – 1103.

- [22] Chen S, Hu J, Shi Y, et al. Vehicle-to-everything (V2X) services supported by LTE-based systems and 5G [J]. IEEE Communications Standards Magazine, 2017, 1 ( 2 ): 70 – 76.

### 作者简介



**廖 勇 (通信作者)** 男, 1982 年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、区块链及其在无线通信中的应用等.  
E-mail: liaoy@cqu.edu.cn



**田肖懿** 男, 1998 年出生于贵州省铜仁市. 现为重庆大学微电子与通信工程学院研究生, 主要研究方向为人工智能算法及其在车联网通信下的应用.  
E-mail: tianxy@cqu.edu.cn



**蔡志镨** 男, 1996 年出生于福建省莆田市. 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: caizr@cqu.edu.cn



**花远肖** 男, 1994 年生于四川省阆中市. 2019 年毕业于重庆大学微电子与通信工程学院获硕士学位, 主要研究方向为人工智能算法及其在无线通信中的应用.  
E-mail: huayx@cqu.edu.cn



**韩庆文** 女, 1969 年出生于重庆市. 现为重庆大学微电子与通信工程学院高级工程师, 硕士生导师, 主要研究方向为 VANET、多载波通信系统、电光信号处理、时频分析和小波分析.  
E-mail: hqw@cqu.edu.cn