DOI:10.20079/j.issn.1001-893x.220819005

深度学习辅助的 5G OFDM 系统的信道估计*

王义元,常 俊,卢中奎,余福慧,魏家齐

(云南大学 信息学院,昆明 650500)

摘 要:传统的信道估计算法难以满足 5G 系统中的高速率低时延的需求。针对该问题,将通信信 道的时频响应视为二维图像,提出了一种基于图像恢复技术的信道估计方法。首先,设定参数产生 基于 5G 新空口(New Radio, NR)标准的物理下行链路共享信道(Physical Downlink Shared Channel, PDSCH)的信道数据信息数据集,将所产生的信道矩阵看作二维图像;然后,构建基于卷积神经网络 的图像恢复网络,并融入残差连接来提高网络的性能;最后,利用训练好的网络模型进行信道估计。 仿真结果表明,与最小二乘算法(Least Square, LS)、实际信道估计(Practical Channel Estimation, PCE)和基于图像超分辨率 ChannelNet 网络相比,所提出的信道估计算法性能提升明显。

关键词:5G;正交频分复用(OFDM);信道估计;深度学习;卷积神经网络



中图分类号:TN911 文献标志码:A 文章编号:1001-893X(2024)01-0036-07

Deep Learning Assisted Channel Estimation for 5G OFDM Systems

WANG Yiyuan, CHANG Jun, LU Zhongkui, YU Fuhui, WEI Jiaqi

(School of Information, Yunnan University, Kunming 650500, China)

Abstract: The traditional channel estimation algorithm is difficult to meet the requirement of high speed and low delay in 5G system. For this problem, the authors propose a channel estimation method based on image restoration technology by considering the time-frequency response of communication channel as a two-dimensional image. First, parameters are set to generate a channel data information data set of physical downlink shared channel (PDSCH) based on 5G new radio (NR) standard, and the generated channel matrix is treated as a two-dimensional image. Then, an image restoration network based on convolutional neural network is constructed, and residual connection is incorporated to improve the performance of the network. Finally, the trained network model is used for channel estimation. The simulation results show that the performance of the proposed channel estimation algorithm is significantly improved compared with those of the Least Square (LS), Practical Channel Estimation (PCE) and Image-based Super-resolution ChannelNet network.

Key words:5G; channel estimation; orthogonal frequency division multiplexing (OFDM); deep learning; convolutional neural network

0 引 言

面对 5G 的多样化智能服务需求,无线通信的

信道状态信息(Channel State Information, CSI)的准确获取至关重要。在实际的无线通信环境中,信道

收稿日期:2022-08-19;修回日期:2022-09-23
 基金项目:国家自然科学基金资助项目(61562090)
 通信作者:常後 Email:changjun@ynu.edu.cn

容易受到多径传播、多普勒频移和传播环境的非平 稳特性的影响,并且在5G NR(New Radio)系统中使 用了大带宽,子载波的数据较大,信道频率响应矩阵 的维度较高,解调参考信号(Demodulation Reference Signals, DMRS) 仅在带宽内的部分子载波上传输,给 信道估计增加了很大的难度[1]。传统的信道估计 方法如最小二乘(Least Square, LS)算法和最小均方 误差估计(Minimum Mean Square Error, MMSE)算 法,都是在接收端利用导频位置处插入的已知导频 信息来进行信道的估计。其中,LS 算法利用导频处 的信道信息通过插值的方法来进行信道估计,但其 没有考虑信道中噪声的影响,信道估计的性能较差; MMSE 算法具有较高的信道估计性能,但其需要信 道的统计信息和矩阵的求逆运算来进行信道的恢 复,运算复杂度较大,难以实现,在实际的系统中没 有得到应用^[2]。

随着软硬件技术的飞速发展,深度学习技术在 计算机视觉,自然语言处理,无人驾驶等领域取得了 巨大的成功。将深度学习(Deep Learning, DL)引入 到无线通信中成为现代通信的研究热点,智能通信 成为现代通信系统的追求[3-4]。文献[5]提出了一 个五层全连接神经网络对一个正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 符号的信息直接进行端到端的信号检测与估计,仿 真结果表明,基于深度学习的信道估计方案在复杂 信道环境下较传统算法有明显优势且具有更强的鲁 棒性。文献「6-7]利用深度神经网络来代替传统信 道估计算法的插值过程来完成信道估计,仿真结果 表明深度学习信道估计算法较传统算法性能有显著 优势。鉴于深度学习技术在图像处理中取得的巨大 成功,以及信道矩阵具有与图片数据相似的特性,将 图像处理技术应用在信道估计方面受到了越来越多 的关注。文献[8]将快衰落通信信道的时频响应看 作二维图像,利用图像处理中的超分辨率(Super Resolution, SR)和图像恢复(Image Restoration, IR) 技术来进行信道估计,提出了 ChannelNet 网络模 型,实验结果表明该算法的性能与 MMSE 算法相 当。文献 [9-10] 提出将大规模多输入多输出 (Multiple-Input Multiple-Output, MIMO)系统中的信 道矩阵建模为 2D 图像,使用基于卷积神经网络 (Convolutional Neural Network, CNN)的去噪网络来 进行信道估计。文献[11]针对毫米波大规模 MIMO 系统提出了一种基于空间和频率的信道估计方案以 减少导频开销,仿真结果表明 CNN 网络可以有效利 用信道相关性来提高毫米波大规模 MIMO 系统的估计性能。文献[12]提出了一种基于 3GPP LTE 标准的 OFDM 信道估计方案,将残差学习的深度神经网络用于信道估计,仿真表明其性能与 MMSE 算法相当。

在上述的文献中,文献[5-7]虽验证了深度神 经网络在信道估计中的有效性,但所处理的数据都 只是一个 OFDM 符号的数据。在实际的通信系统 中,数据信息是一帧一帧地发送,导频只存在于部分 OFDM 符号中,因此其使用的数据与实际通信系统 中的数据不符,不能对实际的通信系统数据进行有 效验证。在文献[8]和[12]中,所考虑的系统是基 于 LTE 标准,并未考虑 5G 通信系统。基于以上分 析,为了解决 5G 移动通信系统在高速率需求的情 况下传统信道估计算法性能不足的问题,本文在 3GPP 5G NR 标准协议的基础上搭建通信系统进行 数据采集,将系统中的信道矩阵建模为一个具有2 个通道的图像,将信道估计问题视为一个图像处理 问题,提出了一种基于残差连接的深度卷积神经网 络 (Convolution Neural Network with Residual Connection, ReCNet) 信道估计算法, 以卷积神经网 络为基础构建优化单元,利用残差连接提升优化单 元的拟合能力来恢复出信道矩阵信息。仿真结果表 明,本文所提出的信道估计算法性能较传统信道估 计算法有较大提升。

1 系统模型

在本文中,以5G NR 标准协议来构建 OFDM 系 统,考虑单输入单输出(Single-Input Single-Output, SISO)的 OFDM 系统的 5G 物理下行链路共享信道 (Physical Downlink Shared Channel, PDSCH)。在系 统中数据信息是通过资源元素(Resource Element, RE)进行传输的,每一个 RE 对应的是一个 OFDM 符号上的一个载波。在 NR 标准中 N_{sym} 个 OFDM 符 号组成一个时隙(slot),在本文中取 N_{sym}=14。在一 个时隙中, N_{sc} 个子载波构成一个资源块(Resource Block, RB),在NR标准中规定N_{se}=12,一个 slot 中 可以有 N_{num} 个 RB,其中 N_{num} 的数量没有具体规定, 可根据需求设定。在本文中,如图1所示,一个 RB 中共有 $N_{sc} \times N_{sm}$ 个RE。在图1中,灰色的RE表示 的是解调参考信号(Demodulation Reference Signals, DMRS)即导频信号,空白方格表示 PDSCH RE,用 来传输发送信号信息。在 NR 系统中, DMRS 的位

置可以灵活配置,导频信息通过 DMRS RE 进行传输,数据信息通过 PDSCH RE 进行传输。在接收端 只有对 PDSCH RE 处进行信道估计之后,才能检测和 解码接收的数据。若想得到 PDSCH RE 处的信道估 计,一般首先要得到 DMRS RE 处的信道频率响应,然 后通过插值的方法 PDSCH RE 处的频率响应值。



图 1 资源网格 RB 与 RE 的概念图 Fig. 1 Concept diagram of resource grid RB and RE

在本文的系统模型中,信道信息被划分为时频 网格。第 t 个 OFDM 符号中的第 k 个子载波发送信 号可以表示为 $s_{k,t}$,则对应的接收端的信号 $y_{k,t}$ 可以 表示为

$$y_{k,t} = H_{k,t} s_{k,t} + w_{k,t} \tag{1}$$

式中: $H_{k,t}$ 表示的是 OFDM 系统中的第 t 个 OFDM 符号中的第 k 个子载波的信道频域响应; $w_{k,t}$ 表示 该载波上的加性高斯白噪声。对于信道的频率响应 H,本文考虑的是时变信道模型,定义为

$$H=f(\varphi,\phi,\omega) \tag{2}$$

式中:φ表示的随机延迟剖面;φ表示的是随机生成 的信道的延迟扩展;ω表示信道的多普勒频移。

在接收端,最小二乘算法^[12]可以利用发送的已 知 DMRS 导频参考信息和对应的接收到的信息,得 到 DMRS 位置处的信道响应。LS 信道估计算法可 以确定信道响应:

$$\hat{H}_{p}^{LS} = \operatorname{argmin} \| y_{p} - H_{p} s_{p} \|_{2}^{2}$$
(3)

式中: || · ||₂ 表示的是两者的距离; Ĥ^{IS}_p 表示的是 估计的信道响应; y_p 表示的是接收到的导频处的信 息值; s_p 表示的是导频值即 DMRS 值。因此, DMRS 位置处的信道响应可以表示为

$$\hat{h}_{\rm p}^{\rm LS} = {\rm diag}(\hat{H}_{\rm p}^{\rm LS}) = y_{\rm p}/s_{\rm p}$$
(4)

然后,利用插值算法可以得到整个信道响应 船^s。LS 信道估计算法比较简单,计算速度很快,容 易实现,但因其没有考虑信道的特性和噪声的信息, 故估计误差较大,难以满足信道估计的性能需求。

Matlab 的 5G Toolbox 工具箱提供了一种实用信 道估计算法(Practical Channel Estimation)^[13],本文 ・38・ 将此算法简称为 PCE 算法。在工具箱中利用 nrChannelEstimate 函数进行 PCE 算法信道估计。该 算法是在 LS 算法的基础上进行了改进:由于 LS 算 法没有考虑信道中噪声的影响,在 PCE 算法中对信 道冲激响应(Channel Impulse Response, CIR)进行去 噪。PCE 信道估计算法的具体步骤如下:

输入:接收端和发送端在 DMRS 位置处的信息。

步骤1 利用公式(4)计算出 \hat{H}_{n}^{LS} 。

步骤 2 在频域和时域执行码域多路复用解扩。

步骤3 将在步骤2中得到的 \hat{H}_{p}^{lS} 在频域上进行插值得到 $\hat{H}_{N_{x}xp}^{lS}$ 。

步骤 4 将 $\hat{H}_{N_{-}\times p}^{\text{LS}}$ 进行 IDFT 变换得到 CIR。

步骤5 将 CIR 进行去噪处理。

步骤 6 将去噪后的 CIR 进行 DFT 变换可得到 去噪后的信道响应 $\hat{H}_{N, \times_{D}}$ 。

步骤7 移除去噪后的信道响应中的多余子 载波。

步骤 8 通过分别在频率方向和时间方向上平均估计的噪声和插值获得信道频率响应 *h*。

输出:信道频率响应 f 的估计值。

2 基于深度学习的信道估计

深度学习在通信系统中的应用成为现在研究的 热点,信道估计问题可以用图像处理的相关算法进 行处理^[8-12]。在图像处理领域,将图像从低分辨率 恢复成高分辨率的图片是一个经典问题,可以将该 问题用数学公式表述为

$$\hat{I}_{x} = F(I_{x}; \theta) \tag{5}$$

式中: I_x 表示低分辨率的图像; \hat{I}_y 表示的是高分辨率的图像;F表示的是在参数为 θ 时的模型恢复问题。

文献[8]提出了 ChannelNet 信道估计网络,具体的网络流程如图 2 所示。该网络是由一个图像超分辨率 SRCNN 网络和一个图像恢复网络 DnCNN 串联而成,文中将导频值看成是低分辨率图片作为网络的输入,将完整的信道响应视为需要恢复的完美图像作为网络的输出。



图 2 ChannelNet 信道估计流程^[8] Fig. 2 ChannelNet channel estimation flowchart^[8]

在文献[8]中, ChannelNet 网络的信道估计性 能虽与 LMMSE 算法相当, 但该网络也存在很多不 足,如 SRCNN 网络和 DnCNN 网络不是端到端的训 练, 而是分别进行训练, 训练过程比较复杂而且 ChannelNet 网络共有 23 个卷积层, 网络的规模庞 大, 对硬件资源要求较高。针对上述不足,本文对深 度学习在信道估计中的应用做了进一步优化, 并将 其应用在 5G NR 系统的信道估计中。本文提出信 道估计流程如图 3 所示, 图中将信道信息进行了可 视化。



图 3 本文提出的信道估计架构 Fig. 3 The proposed channel estimation architecture

在接收端的一个时隙数据中,数据中只含有导频位置处的数据。利用 LS 算法得到导频位置处的 信道信息,通过二维线性插值得到分辨率较低的信 道矩阵信息,利用 LS 算法代替 ChannelNet 网络中 的 SRCNN 网络获得低精度的信道估计值,然后将 其输入到本文所提出的深度神经网络中来恢复出信 道的真实信道频率响应,整个过程可以表示为

$$\hat{H} = F_{\text{ReCNet}}(F_{\text{inp}}(\hat{H}_{\text{p}}^{\text{LS}};\theta_{\text{p}});\theta_{\text{R}})$$
(6)

式中: \hat{H}_{p}^{LS} 是表示经过 LS 算法得到的 DMRS 位置处的信道估计结果; \hat{H} 表示 ReCNet 神经网络模型在 θ_{B} 参数下的信道估计结果。

本文提出的 ReCNet 神经网络模型如图 4 所示。 由于信道频率响应数据是复数形式, 而现有的神经 网络架构无法对复数进行处理, 需要将信道响应的 数据改变数据的维度, 将复数的实部和虚部分开, 形 成两个通道的数据, 然后将其输入到网络模型中。 图 4 虚线框中的结构称为优化单元, 在每一个优化 单元中依次级联的是一个卷积层和激活层。本文的 模型中使用 N 个优化单元。对于第 n 个优化单元 来说, 1 ≤ n ≤ N, 前一层的输出首先通过一个卷积滤 波器数为 2^{N-n} 的卷积层, 此时使用的卷积核的大小 为 3×3。为了保证信道数据矩阵的长和宽在模型的 输入和输出时保持一致,模型使用的填充值为1。 在卷积层之后是激活层,使用 ReLU 激活函数(因为 ReLU 激活函数可以加快模型的收敛速度,同时也 能克服梯度消失的问题)。由于信道数据既有正数 也有复数,为保证数据不失真,在本模型中的最后一 个优化单元中不使用激活函数层。在优化单元的后 面,引入残差连接^[14],将模型的输入直接传递到优 化单元的最后一层,利用残差连接的方式可以有效 避免由于多个非线性操作导致的梯度消失的问题。 在通过加法器之后,将数据通过一个 Leak ReLU 层, 最后将得到的数据改变维度即可得到经过模型优化 后的信道的频率响应数据。



图 4 ReCNet 神经网络模型 Fig. 4 ReCNet neural network model

为了定义输入和输出之间的差异,此模型中使 用所有训练样本的均方误差(Mean Square Error, MSE),可以表示为

$$E_{\rm MS} = \frac{1}{B} \sum_{b=1}^{B} || H^b - \hat{H}^b ||_{\rm F}^2$$
(7)

式中:B是指训练集中每个训练批次的训练样本的 数量;H^b是指在这个批次中的第 b 个实际的信道样 本;Ĥ^b表示的是第 b 个估计到的信道频率响应。

3 系统仿真与结果分析

3.1 系统仿真

基于 3GPP 5G NR 标准生成波形和信道。系统 仿真图如图 5 所示,利用 Matlab2022a 来搭建基于 5G NR 标准的 SISO 下行信道链路的仿真模型。 PDSCH 编码过程是生成资源网格,为了在用户设备 (User Equipment,UE)和基站(Base Station,BS)之间 共享数据,在此过程中将编码数据映射到 PDSCH。 设置系统模型的载波为 3 GHz,在一个资源网格 RB 中的子载波的数量 N_{sc} = 12,子载波间隔设置为 30 kHz,则每一个 RB 占用 360 kHz 的带宽。系统 设置在一个子帧中有一个 slot,在每一个 slot 中包含 • 39• 的 OFDM 符号数为 N_{sym} = 14。在第 3 和第 12 个 OFDM 符号中设置参考信号 DMRS,具体分布如图 1 所示。与 LTE 标准不同,在 5G NR 的标准协议中,

在一个 slot 中 RB 数量可以灵活设置。本文将资源 RB 的数量设置为 $N_{\text{RB}} = 51$,由此可知在每一个 slot 中信道矩阵的大小为 612×14 的复数。



Fig. 5 System simulation block diagram

PDSCH 编码生成的网格经过预编码后利用快 速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)进行 OFDM 调制。在 OFDM 调制中,为避免 符号之间的多径干扰,插入保护间隔,即循环前缀 (Cyclic Prefix, CP)。经过调制之后生成的波形信 号通过信道模型。为不失一般性,本文考虑的是移 动状态下的动态信道模型,模型使用抽头延迟线 (Tapped Delay Line, TDL)信道,在TDL信道模型中 共包含 { 'TDL-A', 'TDL-B', 'TDL-C', 'TDL-D', 'TDL-E' },本系统的每一次运行时会随机使用其中 一种的信道参数,信道延迟设置为随机生成[1, 300] ns 的数值, 信道的多普勒频移设置为随机生成 [5,400]Hz。在经过信道模型后,向信号中添加高 斯白噪声 $w_{k,t}$ 。通过接收波形与 DMRS 相关来估计 定时频偏,以便执行 OFDM 解调。经过解调之后, 即可进行信道估计。

在模型的训练阶段,利用 Pytorch 深度学习架构 搭建神经网络模型,训练模型的参数设置如表1所 示。在本文的模型中,使用的优化单元个数 N=7, 即网络中有7个卷积层,在网络的训练测试过程中, 对于信道模型的训练,仅使用25 dB 的数据用于模 型的训练,待训练模型收敛后,将模型参数保存,用 于测试。

Tab. 1 Training parameter settings			
参数	设置	参数	设置
训练集	12 000	优化器	Adam
验证集	4 000	激活函数	ReLU LeakReLU
测试集	4 000	训练次数	200
学习率	0.001	批次大小	100

表1 训练参数设置

3.2 不同信道估计算法性能分析

为了更直观地展示用图像处理的方法对信道估 计的有效性,本文将信道估计结果进行可视化。在 相同的条件下,随机采集信噪比为 15 dB 时的信道 信息(包括接收的导频信息和真实的信道信息), 然后利用上述不同的信道估计方法进行信道估 计。图 6 展示的是经过可视化后的实际的信道信 息图像。



Fig. 6 Actual channel visualization (15 dB)

图 7 是经过信道估计后的可视化结果。与图 6 中的实际信道图像相比较,从直观的角度分析,LS 算法预测的信道矩阵的失真严重,性能最差;含有 去噪处理的 PCE 算法预测效果较 LS 算法有了较 大的提高,但与实际信道图像相比,很多细节仍较 为模糊;基于图像处理方法的 ChannelNet 算法和 ReCNet 算法的信道估计结果与实际的信道图像最 接近。









(b)PCE 算法







图 7 不同算法信道估计结果可视化 Fig. 7 Visualization of channel estimation results using different algorithms

图 8 显示了本文所提的信道估计算法与传统信 道估计 LS、实际信道(PCE)算法和 ChannelNet 信道 估计算法的性能对比,其中实线图表示的是按图 1 中的方式插入导频的情况。从图 8 中可知,LS 算法 的性能最差,本文所提出的 ReCNet 算法性能最好。 LS 算法由于本身没有考虑信道中噪声的影响,只是 进行线性插值,故性能最差。PCE 算法进行了去噪 处理,所以信道估计性能优于 LS 算法。而基于深度 学习的信道估计算法利用大量的信道先验信息进行 训练,可以有效地拟合信道信息,故性能最好。在低 信噪比时,本文所提算法性能优于 ChannelNet 算 法;在信噪比为 5 dB 时,本文所提出的算法性能较 ChannelNet 算法提高了 2 dB;在信噪比较大时,两 者性能接近一致。



channel estimation methods

3.3 导频数量对信道估计性能的影响

在信道估计的过程中导频至关重要。一般来 说,加入的导频数量越多,信道估计的性能就会越 好,但导频的加入会占用频谱资源,造成频谱资源的 浪费。在本小节中,将每个 RB 中的导频数量在图 1 的基础上增加1倍,在第1个和第14个 OFDM 符号 中增加导频,即在每个 RB 中有 4 个 OFDM 符号中 含有导频,仿真结果如图 8 中的虚线所示。从图 8 中可知,随着导频数量的增加时,所有的信道估计算 法的性能都有所提升,本文所提算法性能最优。其 中,LS 算法的信道估计性能的改变幅度最大, ChannelNet 算法和本文所提算法性能改变较小目保 持较好的信道估计性能;在信噪比为5dB时,本文 所提算法在增加导频时较正常导频改变了1dB,相 同情况下 LS 算法改变了 4 dB, 这表明传统信道估 计算法性能受导频数目的影响更大,本文所提信道 估计算法拥有更强的鲁棒性。

2023年

3.4 算法的时间复杂度

在相同条件下,以预测一个 RB 的信道信息为 基本单位,测试运行将本文所提算法、ChannelNet 算 法、LS 算法以及 PCE 算法所需时间,具体结果如表 2 所示。

答法的法征时间

夜~ 小門昇/	云的色门的问		
Tab. 2 The running time of different algorithms			
算法	运行时间/ms		
LS	0.1796		
PCE	0.209 5		
ChannelNet	2.002 3		
ReCNet	0.274 1		
本文 LS+ReCNet	0.4537		

从表 2 中可知,在所有的算法中,LS 算法所需 的时间最短,ChannelNet 算法用时最长,主要原因是 在 LS 算法主要的计算是线性插值,计算量较小,而 在 ChannelNet 算法中有 23 层卷积神经网络,模型的 参数较多,所需要计算量较多。本文提出的 LS+ ReCNet 信道估计算法较 ChannelNet 算法用时减少 了 77.34%。

4 结 论

近年来,深度学习技术在通信系统中的应用得 到了越来越受到了研究者的关注。受前人研究成 果^[5-12]的启发,本文将通信系统中的信道估计问题 看作深度学习中图像处理问题,提出了 ReCNet 网 络用于信道矩阵的恢复。通过仿真 5G NR 系统采 集信道数据信息来评估本文所提算法和文献[8]中 的 ChannelNet 算法以及传统信道估计算法的性能, 结果表明本文所提算法可以提高信道估计的精度并 拥有较强的鲁棒性,且较 ChannelNet 算法拥有更快 的运算速度。

参考文献:

- [1] NOH G, HUI B, KIM J, et al. DMRS design and evaluation for 3GPP 5G new radio in a high speed train scenario
 [C]//Proceedings of 2017 IEEE Global Communications Conference. Singapore: IEEE, 2017; 1–6.
- [2] 高尚蕾,张治中,段浴,等.5G系统中基于解调参考信号的信道估计方法[J].电讯技术,2021,61(2):191-196.
- [3] 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.
- [4] SHAFIN R, LIU L, CHANDRASEKHAR V, et al. 42 •

Artificial intelligence-enabled cellular networks: a critical path to beyond-5G and 6G [J]. IEEE Wireless Communications, 2020, 27(2):212-217.

- [5] 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, 2017,7(1):114-117.
- [6] 纪勤文,朱春华. 基于 BP 神经网络的 OFDM 系统信 道估计[J]. 电讯技术,2021,61(7):793-799.
- [7] 廖勇,花远肖,姚海梅. 基于深度学习的 OFDM 信道 估计[J]. 重庆邮电大学学报(自然科学版),2019,31 (3):348-353.
- [8] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4):652-655.
- [9] JIN Y, ZHANG J, AI B, et al. Channel estimation for mmWave massive MIMO with convolutional blind denoising network [J]. IEEE Communications Letters, 2019,24(1):95-98.
- [10] HE H, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems [J]. IEEE Wireless Communications Letters, 2018, 7(5):852-855.
- [11] DONG P, ZHANG H, LI G Y, et al. Deep CNN-based channel estimation for mmWave massive MIMO systems
 [J]. IEEE Journal of Selected Topics in Signal Processing, 2019, 13(5):989-1000.
- [12] LI L, CHEN H, CHANG H H, et al. Deep residual learning meets OFDM channel estimation [J]. IEEE Wireless Communications Letters, 2019,9(5):615–618.
- [13] MARUYAMA D, KANAI K, KATTO J. Performance evaluations of channel estimation using deep-learning based super-resolution [C]//Proceedings of 2021 IEEE 18th Annual Consumer Communications & Networking Conference. Chicago: IEEE, 2021:1-6.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016:770-778.

作者简介:

王义元 男,1993 年生于河南商丘,2017 年获学士学位,现硕士研究生,主要研究方向为深度学习、信道估计。

常 俊 男,1970 年生于云南玉溪,2001 年获硕士学位,现为副教授,主要研究领域为无线感知和无线通信。

卢中奎 男,1997 年生于山东菏泽,2019 年获学士学位,现硕士研究生,研究方向为深度学习、信道估计。

余福慧 女,1997 年生于贵州六枝,2021 年获学士学位,现为硕士研究生,主要研究方向为无线通信和信道估计。

魏家齐 女,2002 年生于四川内江,本科生,主要研究 方向为 OFDM、信道估计。