

差分编码与神经网络辅助的OFDM系统 信道估计方法

卿朝进¹, 凌国伟¹, 王 莉¹, 胡文权¹, 陈金良²

(1. 西华大学电气与电子信息学院, 四川成都 610039; 2. 西华大学航空航天学院, 四川成都 610039)

摘要: 正交频分复用系统中, 用于信道估计的导引占用宝贵的传输资源且消耗用户设备发射机能量。为应对这一困境, 提出差分检测与神经网络相结合的信道估计方法。在发射端, 将发送数据进行差分编码。在接收端, 将差分译码后的数据视为发射的导引, 借助面向判决信道估计思想, 捕获信道估计的初始特征; 在捕获到的初始特征的辅助下, 构建增强信道估计网络(Enhanced Channel Estimation Network, En-CENet), 融合差分与神经网络捕获的信道特征, 改进信道估计精度。仿真结果表明, 相对导引辅助信道估计和机器学习叠加信道估计方法, 本文方法在提高系统频谱效率、节省发射机能量消耗、降低接收机计算复杂度和运行时间的同时, 改善了信道估计精度。

关键词: 差分编码; 神经网络; 信道估计; 带宽资源; 能量消耗

基金项目: 四川省科技计划项目(No.2021JDRC0003); 四川省科技计划项目重大科技专项基金(No.19ZDZX0016); 四川省产业发展专项资金(No.ZYF-2018-056); 2020年成都市第二批重大科技应用示范项目(No.2020-YF09-00048-SN); 四川省科技厅科技攻关项目(No.2021YFG0064)

中图分类号: TN914

文献标识码: A

文章编号: 0372-2112(2024)06-1852-10

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

DOI: 10.12263/DZXB.20230030

Differential Coding and Neural Network-Aided Channel Estimation in OFDM Systems

QING Chao-jin¹, LING Guo-wei¹, WANG Li¹, HU Wen-quan¹, CHEN Jin-liang²

(1. School of Electrical Engineering & Electronic Information, Xihua University, Chengdu, Sichuan 610039, China;

2. School of Aeronautics & Astronautics, Xihua University, Chengdu, Sichuan 610039, China)

Abstract: In orthogonal frequency division multiplexing systems, the pilot used for channel estimation occupies valuable transmission resources and consumes user equipment energy. To tackle this issue, a channel estimation method combining differential detection and deep neural network is proposed. At the transmitter, the transmitted data are differentially encoded. At the receiver, according to the idea of decision-directed channel estimation, the recovered data with differential decoding are regarded as the transmitted pilot to capture the initial features of the channel estimation. With the help of the captured initial features, an enhanced channel estimation network (En-CENet) is built to improve the channel estimation accuracy by integrating the differential features and channel features captured by the neural network. The simulation results show that, compared with the pilot-based channel estimation method and machine learning superposition channel estimation method, the proposed method improves the channel estimation accuracy while improving the spectral efficiency, saving the energy consumption of user equipment and reducing the computational complexity and running time of receiver.

Key words: differential coding; neural network; channel estimation; bandwidth resources; energy consumption

Foundation Item(s): Sichuan Science and Technology Program (No.2021JDRC0003); Major Special Funds of Science and Technology of Sichuan Science and Technology Plan Project (No.19ZDZX0016); Special Funds of Industry Development of Sichuan Province (No.ZYF-2018-056); Demonstration Project of Chengdu Major Science and Technology Application (No.2020-YF09-00048-SN); Sichuan Science and Technology Program (No.2021YFG0064)

1 引言

正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)调制技术,因其抗多径干扰和频谱效率优势而被无线通信系统广泛采用,如第五代移动通信(5th Generation, 5G)系统^[1]、物联网系统^[1,2]等。然而,要获得 OFDM 调制的技术优势,精确的信道估计起着至关重要的作用^[3-14]。

在 OFDM 系统中,导引辅助信道估计是最为常见的方式之一^[4,5]。利用接收到的导引进行信道估计,涌现出了一系列的经典信道估计方法,如最小二乘(Least Squares, LS)和最小均方误差(Minimum Mean Square Error, MMSE)^[4,5]。近年来,随着神经网络技术的发展,深度神经网络已应用到了无线通信物理层的方方面面^[6]。在信道估计方面,神经网络展现出了优异的性能^[7-14],其文献综述可参考文献[7]。文献[8]提出了一种基于增强极限学习机(Extreme Learning Machine, ELM)的信道估计。基于深度图像先验网络,文献[9]利用一维卷积神经网络进行频域插值估计,并根据条件循环单元进行时域状态预测。针对 1-bit 量化系统,文献[10]设计了条件生成对抗网络(conditional Generative Adversarial Network, cGAN)以估计信道矩阵。文献[11]使用卷积神经网络(Convolutional Neural Networks, CNN)提取信道响应特征矢量并利用循环神经网络进行信道估计。文献[12]设计基于逐层计算的深度学习信道估计算法。文献[13]提出两个 CNN 分别执行降噪处理和逼近 MMSE 信道估计解。将信道矩阵视为图像,文献[14]利用深度神经网络,改善导引辅助 LS 信道估计。

虽然文献[5-14]能较好地估计出信道参数,但在提高频谱效率和降低能耗方面仍有待进一步改进。一方面,现有的导引信道估计需要分配额外的频谱资源以传输导引,降低了用于数据传输的频谱效率;另一方面,传输导引不可避免地耗费能量,有时还特别巨大,如多用户大规模 MIMO(Multiple-Input Multiple-Output, MIMO)系统^[15]。对于非插电式电池供电的用户设备(User Equipment, UE)而言,电池能量消耗是其主要挑战之一^[16]。特别地,物联网系统终端(如传感器节点)的电池寿命需要长达十年以上^[17]。对于这些终端而言,导引传输消耗的 UE 能量就显得特别浪费。为此,亟待研究提高数据传输频谱效率并减小能量消耗的有效信道估计方法。为提高频谱效率,减小 UE 能量消耗,文献[18]采用叠加导引方式,将用于估计的导引叠加在数据信息上进行传输。虽然,文献[18]提高了频谱效率并减小了 UE 的能量消耗,但叠加导引引入了叠加干扰,降低了信道估计的性能。因此,叠加导引信道估计方法,如文献[18],需要接收机采用高计算复杂度的迭

代干扰相消处理进行性能改善。为降低迭代处理引起的高计算复杂度,文献[19]研究了基于深度学习的叠加信道估计方法:利用深度学习抑制叠加干扰,从而获得了更好的 NMSE 性能。与之相比,差分编码与差分检测不需要信道估计即可完成信号检测^[20],且信号检测过程相对简单,是有效的选择方式之一。尽管如此,差分检测为非相干检测。相对于相干检测,差分检测是以牺牲检测性能为代价的^[20]。特别地,信道状态信息(Channel State Information, CSI)是通信系统需求所在,如用于基站(Base Station, BS)的波束成形,调制方式选择等^[21]。因此,即使是采用差分编码技术,用于捕获 CSI 的信道估计仍被通信系统所需。

受差分编码的启发,本文研究差分编码与神经网络辅助的 OFDM 系统信道估计方法。具体地,在 UE 端,不发射用于信道估计的导引,仅采用差分编码调制欲发射的数据信息;从而节省频谱资源占用,并减小 UE 发射机空口传输时的能量消耗。在 BS 端,接收机借鉴面向判决信道估计思想^[22],将差分检测的数据信息视为导引进行信道估计,从而获得 CSI 信息。在此基础上,我们构建信道估计增强网络(Enhanced Channel Estimation Network, En-CENet),利用神经网络求解非线性问题上的优势^[23],捕获信道特征并抑制非线性叠加干扰,从而改善信道估计性能。数值仿真实验表明,与传统方法相比,提出方法在提高了频谱利用率和降低能量消耗的基础上,改善了信道估计的归一化均方误差(Normalized Mean Square Error, NMSE)性能。

本文贡献总结如下:

(1)将差分辅助思想引入到基于神经网络辅助的信道估计中,提取新的 CSI 差分模态。具体地,在 UE 端,发射机采用差分方式传输数据信息,避免传输用于信道估计的导引信息,从而提高用于数据传输的频谱利用率,降低 UE 能量消耗。在 BS 接收端,将面向判决信道估计思想引入到 BS 接收机,提取差分辅助的 CSI 模态,将差分检测的数据信息视为导引进行信道估计,获得 CSI 信息的差分域模态。

(2)基于差分与神经网络辅助的信道估计增强方法。构建 En-CENet 网络,利用差分编码辅助的信道估计方法所获取的差分模态特征,结合神经网络抽取信道模态特征,联合训练优化网络参数以改进信道估计精度。不同于现有的神经网络辅助信道估计方法,本文方法从差分与神经网络协同视角出发,利用 CSI 多模态的融合学习思想,在降低 UE 能量消耗并提高频谱利用率的情况下改进信道估计精度。

(3)给出了较为详尽的实验验证与分析,结果表明:相对导引的信道估计方法,本文方法提高了频谱效

率、节省了UE的能量消耗。在提高频谱效率、节省UE的能量消耗的情况下,BS接收机信道估计的NMSE性能优于导引的LS与MMSE信道估计方法。相对于多径簇数和子载波数变化的影响,本文方法具有鲁棒性。

2 系统模型

系统模型如图1所示,考虑有 N 个子载波的OFDM系统。在UE发射端,对调制信号矢量 $\mathbf{a}=[a_1, a_2, \dots, a_N]^T \in \mathbb{C}^{N \times 1}$ 进行差分编码^[20],表示为

$$c_n = c_{n-1} \cdot a_n \quad (1)$$

其中, a_n 为调制信号矢量 \mathbf{a} 的第 n 个元素;为简单起见,根据文献[20],取 $c_0=1$,并将编码后的编码矢量表示为 $\mathbf{c}=[c_0, c_1, \dots, c_N]^T \in \mathbb{C}^{(N+1) \times 1}$ 。对编码矢量 \mathbf{c} 进行OFDM调制,首先对 \mathbf{c} 进行离散傅里叶反变换(Inverse Discrete Fourier Transform, IDFT),表示为

$$\tilde{\mathbf{c}} = \mathbf{F}_{(N+1)}^H \mathbf{c} \quad (2)$$

其中, $\mathbf{F}_{(N+1)} \in \mathbb{C}^{(N+1) \times (N+1)}$ 表示傅里叶变换矩阵^[8]。将 $\tilde{\mathbf{c}}$ 表示为 $\tilde{\mathbf{c}} = [\tilde{c}_0, \tilde{c}_1, \dots, \tilde{c}_N]^T$,根据文献[20]对 $\tilde{\mathbf{c}}$ 添加长度为 N_g 的循环前缀(Cyclic Prefix, CP),形成长度为 $N+N_g+1$ 的发射信号矢量 \mathbf{s} ,表示为

$$\mathbf{s} = [s_0, s_1, \dots, s_N]^T = \left[\underbrace{\tilde{c}_{N-N_g+1}, \dots, \tilde{c}_N}_{\text{CP}}, \tilde{c}_0, \tilde{c}_1, \dots, \tilde{c}_N \right]^T \quad (3)$$

UE端的发射信号矢量 \mathbf{s} 再经射频前端处理后,通过无线信道传输至BS接收机。

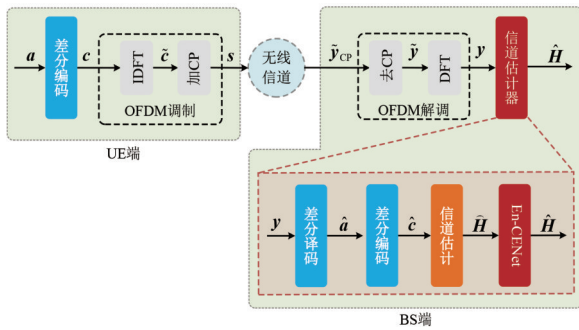


图1 收发信机模型

在BS端,接收机接收到长度为 $N+N_g+1$ 的时域信号采样矢量 $\tilde{\mathbf{y}}_{\text{CP}} \in \mathbb{C}^{(N+N_g+1) \times 1}$,表示为 $\tilde{\mathbf{y}}_{\text{CP}} = [\tilde{y}_{\text{CP},0}, \tilde{y}_{\text{CP},1}, \dots, \tilde{y}_{\text{CP},N+N_g}]^T$ 。然后,根据文献[20]对 $\tilde{\mathbf{y}}_{\text{CP}}$ 进行去CP处理,得到去CP后的信号矢量 $\tilde{\mathbf{y}} \in \mathbb{C}^{(N+1) \times 1}$,有

$$\tilde{\mathbf{y}} = [\tilde{y}_{\text{CP},N_g}, \tilde{y}_{\text{CP},N_g+1}, \dots, \tilde{y}_{\text{CP},N+N_g}]^T \quad (4)$$

将去CP后的信号矢量 $\tilde{\mathbf{y}}$ 进行离散傅里叶变换(Discrete Fourier Transform, DFT)形成频域接收信号矢量

$\mathbf{y} \in \mathbb{C}^{(N+1) \times 1}$,表示为

$$\mathbf{y} = \mathbf{F}_{(N+1)} \tilde{\mathbf{y}} \quad (5)$$

BS端接收机经过CP与DFT变换后,BS的频域等效接收信号可表示为^[21]

$$\mathbf{y} = \sqrt{P} \mathbf{c} \odot \mathbf{H} + \mathbf{v} \quad (6)$$

其中, $\mathbf{H} \in \mathbb{C}^{(N+1) \times 1}$ 表示频域等效信道矢量; P 为信号发射功率; \odot 表示Hadamard运算操作^[5]; $\mathbf{v} \in \mathbb{C}^{(N+1) \times 1}$ 是均值为零,方差为 σ_v^2 的复加性高斯白噪声。为后续表达方便起见,将频域接收信号矢量 \mathbf{y} 表示为 $\mathbf{y} = [y_0, y_2, \dots, y_N]^T \in \mathbb{C}^{(N+1) \times 1}$ 。

根据文献[20],对接收信号 \mathbf{y} 进行差分译码,得到译码后的矢量信号 $\hat{\mathbf{a}}$,从而还原出UE发射的数据信息。虽然差分检测完成了UE发射的数据信息的恢复,且不需要BS接收机进行信道估计和信道均衡等处理。但CSI仍然是通信系统需求所在,例如,物联网系统的BS应用CSI进行调制方式选择等^[5]。为此,在BS端估计出CSI信息非常必要。本文借鉴面向判决信道估计思想^[22],将差分检测的数据信息 $\hat{\mathbf{a}}$ 视为导引,从而进行信道估计。具体地,首先将差分检测得到的 $\hat{\mathbf{a}} = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_N]^T$ 进行差分编码,根据式(1)获得编码矢量 $\hat{\mathbf{c}} = [\hat{c}_0, \hat{c}_2, \dots, \hat{c}_N]^T$;然后,将差分检测获得的 $\hat{\mathbf{c}}$ 视为导引,结合接收信号 \mathbf{y} ,利用传统的信道估计方法,如LS信道估计^[5],得到初始信道估计 $\hat{\mathbf{H}}$ 。最后,将 $\hat{\mathbf{H}}$ 视为初始特征;并在此初始特征的辅助下,构建信道估计增强网络(En-CENet)估计出CSI(表示为 $\hat{\mathbf{H}} = [\hat{h}_0, \hat{h}_1, \dots, \hat{h}_N]^T$),从而改进信道估计的精度。

3 差分编码与神经网络辅助的信道估计方法

本节详细阐述本文方法。在3.1节中,给出基于差分检测的信道估计方法;在3.2节中,详细叙述差分检测与En-CENet相结合的信道估计增强方法。

3.1 差分编码辅助的初始信道估计

下面,首先阐述BS接收机的差分译码过程,以及根据译码信息进行的信道估计。

3.1.1 差分译码

本文采用的是逐字符检测^[20]。根据式(6)给出的第 n 和第 $n-1$ 个子载波上的接收信号 y_n 和 y_{n-1} ,差分检测的输出判决值为^[20]

$$\hat{a}_n = \max_{\tilde{a}_n} \text{Re} \left[\tilde{a}_n (y_n y_{n-1}^*) \right] \quad (7)$$

其中, \tilde{a}_n 表示对差分检测(或差分译码)的第 n 个取值进行判决时,星座集中可能的尝试取值^[20];上标*表示取共轭操作。以正交相移键控(Quadrature Phase Shift Keying, QPSK)相位调制为例, \tilde{a}_n 可以在星座映射集

$\{\sqrt{2}/2 + \sqrt{2}/2i, \sqrt{2}/2 - \sqrt{2}/2i, -\sqrt{2}/2 + \sqrt{2}/2i, -\sqrt{2}/2 - \sqrt{2}/2i\}$ 中进行取值.

从而,根据式(7),可获得第 n 个子载波上的信号检测估计值 \hat{a}_n .

3.1.2 基于差分译码的信道估计

根据式(7)获得的差分检测信号 \hat{a}_n ,我们借鉴面向判决信道估计方法^[22]进行信道估计.不同于经典的面向判决信道估计方法,这里的面向判决信道估计是在差分编码的基础上进行的.为此,首先将检测信号 \hat{a}_n 进行差分编码操作.根据式(1),有

$$\hat{c}_n = \hat{c}_{n-1} \cdot \hat{a}_n \quad (8)$$

同样地,根据文献[20],收发双方约定取 $\hat{c}_0 = 1$.于是,根据 $\hat{c}_0, \hat{c}_2, \dots, \hat{c}_N$ 和接收信号 $\mathbf{y} = [y_0, y_2, \dots, y_N]^T$,利用 LS 信道估计^[5,6],可得到信道矢量的估计值 $\hat{\mathbf{H}} \in \mathbb{C}^{(N+1) \times 1}$ 为

$$\hat{\mathbf{H}} = \begin{bmatrix} \frac{y_0}{\hat{c}_0}, \frac{y_2}{\hat{c}_2}, \dots, \frac{y_N}{\hat{c}_N} \end{bmatrix} \quad (9)$$

尽管式(9)可以恢复得到信道矢量的估计值 $\hat{\mathbf{H}}$,但采用的差分检测相对于相干检测牺牲了检测性能^[20].因此,差分检测恢复得到的且被视为导引的 $\hat{c}_0, \hat{c}_2, \dots, \hat{c}_N$ 并不精确,造成式(9)估计得到的 $\hat{\mathbf{H}}$ 精度不高.为解决这一问题,本文将 $\hat{\mathbf{H}}$ 视为初始特征,构建神经网络 En-CENet,从融合差分信道特征与神经网络捕获的信道特征的视角出发,改进信道估计精度.

3.2 基于神经网络的增强信道估计

3.2.1 En-CENet 网络架构

根据式(9),将 $\hat{\mathbf{H}}$ 视为信道估计的初始特征,构建 En-CENet网络增强信道估计(如改善信道估计的 NMSE 性能).基于 En-CENet的增强型信道估计处理流程如图2所示.

在图2中,首先对初始特征 $\hat{\mathbf{H}}$ 进行实值化处理,得到实值的初始特征 $\tilde{\mathbf{H}} \in \mathbb{R}^{2(N+1) \times 1}$,即

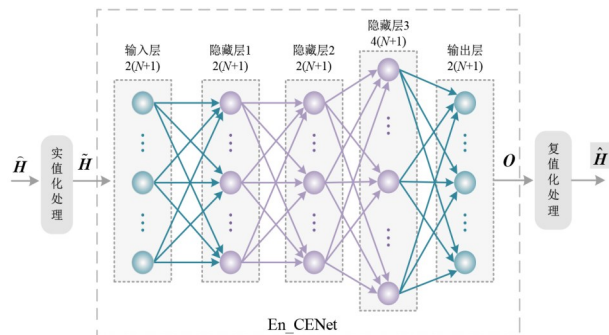


图2 基于En-CENet的增强信道估计

$$\tilde{\mathbf{H}} = \begin{bmatrix} \left[\text{Re}(\hat{\mathbf{H}}) \right]^T, \left[\text{Im}(\hat{\mathbf{H}}) \right]^T \end{bmatrix}^T \quad (10)$$

En-CENet提取 $\tilde{\mathbf{H}}$ 的差分模态进行CSI学习,获得增强信道估计矢量 $\hat{\mathbf{H}}$,从而改善信道估计精度.

En-CENet的网络架构如表1所示.该网络由一个输入层、 M 个隐藏层和一个输出层组成,各层之间通过全连接的方式提取特征^[23].利用多个隐藏层增强网络的学习能力和映射能力^[4],隐藏层1和隐藏层2均包含 $2(N+1)$ 个神经元,隐藏层3包含 $4(N+1)$ 个神经元.输入与输出层采用线性激活函数^[24];为避免纯线性组合,各隐藏层采用非线性的修正线性单元(Rectified Linear unit, ReLu)激活函数^[25].

表1 网络架构

层名	神经元大小	激活函数
输入层	$2(N+1)$	Linear
隐藏层1	$2(N+1)$	ReLU
隐藏层2	$2(N+1)$	ReLU
隐藏层3	$4(N+1)$	ReLU
输出层	$2(N+1)$	Linear

需要说明的是,目前最常用的激活函数是 ReLu 函数和 sigmoid 函数^[25].由于 ReLu 激活函数在缓解梯度消失的问题方面的优势^[26],本文的3个隐藏层均采用了 ReLu 激活函数.根据文献[26],ReLu 激活函数定义为 $f_a = \max(0, x)$.此外,每个隐藏层的神经元个数的选择,是在多次实验进行参数调谐后,从复杂度和性能上进行折中^[27].具体地,我们尝试了更大和更小的神经元个数:继续增大的神经元,会增加计算复杂度,但性能没有显著的增加;更小的神经元个数,则性能不能令人满意.输入层与输出层的神经元个数选择为 $2(N+1)$ 个,以确保与输入数据的维度保持一致;隐藏层1和隐藏层2选择了 $2(N+1)$ 个神经元,以达到降低计算复杂度的目的;而隐藏层3增大了神经元个数,以确保融合更多特征.

3.2.2 网络训练

将有 N_i 个样本的训练集合表示为 $\left\{ \left(\tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right), i = 1, 2, \dots, N_i \right\}$,其中, $\tilde{\mathbf{H}}_i$ 和 $\tilde{\mathbf{H}}_{\text{Label},i}$ 分别表示第 i 个训练样本对应的训练数据与训练标签.采用广泛使用的 COST2100^[28]信道模型生成 $\tilde{\mathbf{H}}_i$;利用生成的 $\tilde{\mathbf{H}}_i$,结合式(1)~(6),获得BS接收机接收信号 \mathbf{y}_i .基于 \mathbf{y}_i ,根据式(7)~(9),得到初步估计的CSI($\hat{\mathbf{H}}_i$).通常地,神经网络擅长处理实值数据^[27].为便于网络训练,将 $\hat{\mathbf{H}}_i$ 转换为实值形式 $\tilde{\mathbf{H}}_i$,即

$$\tilde{\mathbf{H}}_i = \left[\left[\text{Re}(\hat{\mathbf{H}}_i) \right]^T, \left[\text{Im}(\hat{\mathbf{H}}_i) \right]^T \right]^T \quad (11)$$

其中, $\tilde{\mathbf{H}}_i \in \mathbb{C}^{1 \times 2(N+1)}$; $\text{Re}(\cdot)$ 和 $\text{Im}(\cdot)$ 分别表示取实部和取虚部操作. 利用生成的 \mathbf{H}_i , 将其进行实值化处理, 形成标签 $\tilde{\mathbf{H}}_{\text{Label},i}$, 即

$$\tilde{\mathbf{H}}_{\text{Label},i} = \left[\left[\text{Re}(\mathbf{H}_i) \right]^T, \left[\text{Im}(\mathbf{H}_i) \right]^T \right]^T \quad (12)$$

使用 Adam 优化器^[29]进行网络参数优化, 其中, 优化参数设置为 $\beta_1 = 0.99$ 和 $\beta_2 = 0.999$, 初始学习速率设置为 0.001, 采用 L2 正则化防止模型过拟合^[23]. 训练过程中, 采用校验集对训练到的网络参数进行校验, 从而选择优化的网络参数^[27]. 这里校验集生成方法与训练集生成方法相同. 根据训练得到的网络参数, 我们可以获得估计精度增强的信道估计 $\hat{\mathbf{H}}$.

本文以长度为 $N+1 = 64+1 = 65$ 的情形为例进行网络训练, $\hat{\mathbf{H}}_i$ 的长度为 $2(N+1) = 130$. 将 $\hat{\mathbf{H}}_i$ 与式(12)生成的标签 $\tilde{\mathbf{H}}_{\text{Label},i}$ 形成 $N_i = 10^6$ 个样本的训练集合 $\left\{ \left(\tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right), i = 1, 2, \dots, N_i \right\}$. 网络训练的损失函数为最小均方误差 (MSE), 定义为

$$\text{Loss}_{\text{En-CENet}} = \frac{1}{N_i} \left\| \tilde{\mathbf{H}}_{\text{Label}} - \mathbf{O} \right\|_2^2 + \alpha \sum_{\ell} \left\| \mathbf{W}^{(\ell)} \right\|_2^2 \quad (13)$$

其中, \mathbf{O} 为增强的信道估计矢量 (实值形式); α 表示正则化系数; ℓ 为隐藏层层索引; $\mathbf{W}^{(\ell)}$ 为第 ℓ 层隐藏层的权重. 根据式(13)所示的损失函数, 利用训练集合 $\left\{ \left(\tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right), i = 1, 2, \dots, N_i \right\}$ 训练 En-CENet 网络, 得到优化的网络参数 θ . 其中, 训练 epoch 个数 G 的取值为 100, 每个 epoch 中从训练集合 $\left\{ \left(\tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right), i = 1, 2, \dots, N_i \right\}$ 随机选择 $v = 15$ 个训练样本, 形成 En-CENet 网络训练的批量.

3.2.3 在线运行

对接收信号 \mathbf{y} 进行差分检测, 根据式(7)得到差分检测矢量 $\hat{\mathbf{a}}$. 随后, 根据式(8)编码规则对 $\hat{\mathbf{a}}$ 再次进行差分编码, 得到编码矢量 $\hat{\mathbf{c}}$. 然后, 根据 \mathbf{y} 与 $\hat{\mathbf{c}}$, 利用式(9)所述的 LS 信道估计方法得到初始特征 $\hat{\mathbf{H}}$. 最后, 采用设计的 En-CENet 网络对初始特征 $\hat{\mathbf{H}}$ 进行增强, 表示为

$$\mathbf{O} = f_{\text{en}}(\hat{\mathbf{H}}, \theta) \quad (14)$$

其中, θ 为训练优化的网络参数. 根据式(14)的 En-CENet 增强网络, 得到增强的实值信道估计矢量值 \mathbf{O} . 将 \mathbf{O} 进行复值化处理, 即可得到复数值的信道估计矢量 $\hat{\mathbf{H}}$, 表示为

$$\hat{\mathbf{H}} = \mathbf{O}(1: (N+1), 1) + i \times \mathbf{O}(N+2: 2(N+1), 1) \quad (15)$$

根据 MATLAB 样式表示法^[30], 式(15)中 $\mathbf{O}(i:j, 1)$ 表示列矢量 \mathbf{O} 的第 i 行到第 j 行元素形成的子矢量.

3.3 算法总结

针对本文的差分编码与 En-CENet 辅助的 OFDM 系统信道估计算法, 算法总结如算法 1 所示.

算法 1 本文算法总结

输入: 接收信号 \mathbf{y} , 网络训练学习率 a , 批量大小 v , 最大训练次数 G

输出: 频域信道估计值 $\hat{\mathbf{H}}$

特征提取:

- 1 根据式(7)得到差分检测后的信号 $\hat{\mathbf{a}}$, 根据式(1)编码规则对 $\hat{\mathbf{a}}$ 进行编码, 得到编码矢量为 $\hat{\mathbf{c}}$
- 2 根据式(6)的接收信号 \mathbf{y} , 利用式(9)求解出初始信道估计值 $\hat{\mathbf{H}}$

网络训练:

- 3 根据式(11)产生训练集合 $\left\{ \tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right\}$
- 4 随机初始化 En-CENet 的网络参数 θ
- 5 FOR $t = 1, 2, \dots, G$ DO
 - 6 从训练集合 $\left\{ \tilde{\mathbf{H}}_i, \tilde{\mathbf{H}}_{\text{Label},i} \right\}$ 随机选择 v 个训练样本, 形成输入批量, 作为网络输入
 - 7 启动校验集合, 校验网络训练, 判断当前校验损失是否小于上一次校验损失. 若是, 继续下一次训练, 返回步骤 6. 否则, 提前终止训练计数器计数加 1
 - 8 使用学习率为 a 的 ADAM 算法更新 En-CENet 的网络参数 θ
 - 9 IF 提前终止训练计数器计数大于 P_{iter}
 - 10 网络终止训练
 - 11 ELSE
 - 12 继续下一次训练
 - 13 END IF
 - 14 END FOR

在线运行:

- 15 根据式(6)的接收信号 \mathbf{y} , 利用式(9)求解出初始信道估计值 $\hat{\mathbf{H}}$
- 16 根据式(11), 实值化 $\hat{\mathbf{H}}$ 形成 $\tilde{\mathbf{H}}$
- 17 将 $\tilde{\mathbf{H}}$ 输入 En-CENet 网络, 如式(14)所示, 获得网络输出 \mathbf{O}
- 18 根据式(15), 将网络输出 \mathbf{O} 拼接为复数值形式, 得到本文方法的信道估计 $\hat{\mathbf{H}}$

4 UE 端能量消耗与带宽占用分析

本文方法采用了差分编码技术, UE 端不用发送 BS 用于信道估计的导引. 相对于导引辅助信道估计方法^[5-14], 当 UE 以相同的数据速率和发射功率发射数据时, 本文方法的 UE 避免了发射导引信息, 从而减小了带宽资源的占用, 改善了频谱效率, 并因此降低了 UE 端的能量消耗. 文献[19]方法与本文方法均不发射导引, 因此具有相当的 UE 能量消耗和带宽资源占用.

下面就带宽资源占用与能量消耗方面的效益, 对本文方法与导引辅助信道估计方法^[5-14]、文献[19]方法

进行比较,同时,给出具体的参数实例.

UE 端考虑数据业务符号个数和导引符号个数分别为 N_{data} 和 N_{Pilot} , 每个符号持续时间为 T_0 , 发射功率为 P_0 . 于是, 导引辅助信道估计方法的能量消耗为

$$E_{\text{TDD}} = (N_{\text{data}} + N_{\text{Pilot}})T_0P_0 \quad (16)$$

与导引辅助信道估计方法相比, 本文采用差分模式, 文献[19]采用叠加导引, 本文方法和文献[19]方法的 UE 均不需要发射导引序列, 从而节省了能量开销. 将本文方法的能量消耗表示为 E_{Prop} , 有

$$E_{\text{Prop}} = (N_{\text{data}})T_0P_0 \quad (17)$$

由此可见, 本文方法相对于导引辅助信道估计方法的能量节省为

$$E_{\text{TDD}} - E_{\text{Prop}} = N_{\text{Pilot}}T_0P_0 \quad (18)$$

在带宽占用方面, 相对于导引辅助信道估计方法, 本文方法少传输了导引序列, 带宽占用时间减少为 $N_{\text{Pilot}}T_0$. 而导引辅助信道估计方法的带宽占用时间为 $(N_{\text{data}} + N_{\text{Pilot}})T_0$. 因此, 本文方法减少了导引辅助信道估计方法的带宽占用时间为 $(N_{\text{data}} + N_{\text{Pilot}})T_0 - N_{\text{data}}T_0 = N_{\text{Pilot}}T_0$.

表 2 给出了导引辅助信道估计方法、文献[19]方法与本文方法的带宽占用时间与能量消耗的对比, 并辅以实例. 其中, 具体实例的参数选择为 $N_{\text{data}} = 64$, $N_{\text{Pilot}} = 64$.

表 2 带宽资源占用和能量消耗

方法	带宽资源占用		总能量消耗	
	表达式	实例	表达式	实例
导引辅助	$(N_{\text{data}} + N_{\text{Pilot}})T_0$	$128T_0$	$(N_{\text{data}} + N_{\text{Pilot}})T_0P_0$	$128T_0P_0$
文献[19]	$(N_{\text{data}})T_0$	$64T_0$	$(N_{\text{data}})T_0P_0$	$64T_0P_0$
本文方法	$(N_{\text{data}})T_0$	$64T_0$	$(N_{\text{data}})T_0P_0$	$64T_0P_0$

从表 2 可以看出, 相比导引辅助信道估计方法, 本文方法和文献[19]方法均减小了带宽占用时间与能量消耗. 虽然本文方法与文献[19]方法有相同的带宽资源占用和能量消耗, 但本文方法的 BS 接收机还有计算复杂度、运行时间和信道估计精度改善上的优势, 我们将在第 5 节和第 6 节中进行验证.

5 计算复杂度与运行时间分析

根据文献[31], 本文采用权重数和浮点运算 (FLOP) 形式衡量神经网络的计算复杂度, 用复数乘法次数计算非网络部分的计算复杂度, 计算复杂度的比较如表 3 所示.

根据文献[31], 本文 En-CENet 神经网络的权重数为 $16N^2 + 34N + 24$, FLOP 的总数为 $32N^2 + 56N + 24$; 本文方法差分辅助的复数乘法次数为 $6N$. 从而, 本文方

表 3 计算复杂度与运行时间分析

方法	计算复杂度	计算复杂度实例 ($N=64$)	运行时间实例/s ($N=64$)
本文方法	$48N^2 + 96N + 48$	202 800	7.258 141
MMSE	$6N^3 + 4N^2 + 2N$	1 589 376	24.059 068
文献[19]	$96N^2 + 188N + 96$	405 344	14.090 224 6

法的总计算复杂度为三者的总和, 即: $48N^2 + 96N + 48$. MMSE 信道估计和文献[19]方法的计算复杂度分别为 $6N^3 + 4N^2 + 2N$ 和 $96N^2 + 188N + 96$.

根据表 3, 与 MMSE 信道估计和文献[19]方法相比, 本文方法具有更低的计算复杂度. 当子载波数 $N=64$ 时, MMSE 信道估计和文献[19]方法的计算复杂度分别为 1 589 376 和 405 344, 而本文方法的计算复杂度为 202 800; 本文方法降低了 MMSE 信道估计和文献[19]方法的计算复杂度. 在运行时间方面, 当子载波数 $N=64$ 时, 本文方法的运行时间为 7.258 141 s, 而 MMSE 信道估计和文献[19]方法的运行时间分别为 24.059 068 s 和 14.090 224 6 s. 可以看出, 本文方法的运行时间小于 MMSE 信道估计和文献[19]方法. 因此, 本文方法计算复杂度和运行时间均低于 MMSE 信道估计和文献[19]方法, 从而达到了节省传输资源的目的.

6 数值仿真结果

在第 4 节中, 我们分析了本文方法能有效改善 UE 端能量消耗和带宽占用; 在第 5 节中, 我们进一步分析了本文方法在计算复杂度和运行时间上的优势. 在此情况下, 本节进一步验证提出方法在 BS 端信道估计的有效性和健壮性. 首先, 在 6.1 节, 我们给出仿真所需的参数设置; 随后, 在 6.2 节验证提出方法的有效性; 最后, 在 6.3 节对提出方法的健壮性进行验证.

6.1 参数设置

仿真过程中, 子载波个数设置为 $N=64$; UE 到 BS 端的信道矢量 \mathbf{H} 根据信道模型 COST2100^[28] 生成. 根据文献[28]的描述, COST2100 信道模型是目前非常接近真实场景的信道模型之一; 本文考虑室外半城市环境, 其载波频率为 300 MHz, UE 的移动速度设置为 1 m/s, 多径簇数设置为 6. 导引信道估计采用 Zadoff-Chu 序列^[21] 作为导引序列, 其导引序列长度 N_{Pilot} 取值为 $N_{\text{Pilot}} = N=64$. 发送数据长度取值为 $N_{\text{data}} = N=64$; 其调制方式采用 QPSK 调制. NMSE 和 SNR 的定义如下.

NMSE 定义为

$$\text{NMSE} = \frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \quad (19)$$

以分贝 (dB) 形式表达的信噪比 (Signal-to-Noise Ra-

tio, SNR)的定义为

$$\text{SNR} = 10 \log_{10} \left(\frac{\sigma_s^2}{\sigma_v^2} \right) \quad (20)$$

其中, σ_s^2 为数据或导引的发射功率; σ_v^2 为噪声功率.

仿真中考虑两种导引辅助信道估计方法:经典的LS信道估计方法和MMSE信道估计方法^[5,6]. 为方便起见,将导引的LS和MMSE信道估计方法分别简称为“导引LS”和“导引MMSE”. 同时,为验证提出方法中构建的En-CENet的有效性,仿真了仅采用差分检测辅助的信道估计(不采用En-CENet的基于面向判决的信道估计方法),表示为“差分方法”;为进一步验证差分为网络带来了额外特征学习,还仿真了只采用网络学习输出的信道估计,表示为“无差分网络”. 对于文献[19]的方法,表示为“文献[19]方法”.

6.2 有效性分析

为了验证本文方法的有效性,图3给出了信道估计的NMSE性能. 其中,所有方法均采用相同的发射功率和发射数据速率;本文方法因基于差分模式,UE端发射了更少的数据,从而消耗了更少的能量. 在此情况下,我们对比NMSE性能的有效性.




图3 NMSE性能比较

从图3可以看出:

(1)本文方法在给定的SNR范围内,均获得了最小的NMSE. 其原因在于,本文方法使用差分方法获得初始特征,并利用En-CENet融合初始特征(差分辅助)与信道特征(非差分辅助),增强了基于神经网络信道估计的特征,继而改善了信道估计的NMSE性能.

(2)相对于“导引LS”和“导引MMSE”,本文方法在不发射导引信息(本次仿真中,节省一半的能量开销)的情况下,仍然减小了LS和MMSE经典信道估计方法的NMSE. 本文方法在节省能量开销和带宽资源占用的情况下,获得了更小的NMSE. 此外,经典的MMSE信道

估计方法还需要知道信道与噪声的二阶统计信息^[5,6]. 因此,相对于经典的LS和MMSE信道估计方法,本文方法有效地改善了能量开销、带宽资源占用和NMSE性能.

(3)相比同样能提高频谱利用率的“文献[19]方法”,本文方法能获得更小的NMSE. 尽管“文献[19]方法”也提高了频谱利用率,降低能量开销;但本文方法的NMSE性能明显优于“文献[19]方法”.

(4)构建的En-CENet是有效的. 没有神经网络En-CENet的辅助,“差分方法”在相对较低的SNR情况下(如SNR小于15 dB),NMSE性能差于LS和MMSE信道估计方法.“差分方法”获得了更大的NMSE,其原因在于:在低SNR下,差分检测并不能得到较好的信号检测性能,错误检测信号(被视为导引)带来了信道估计的错误延播. 本文方法在“差分方法”基础上增加的En-CENet,提取到了信道的显著特征,并融合了“差分方法”形成的初始特征. 相对于“导引LS”和“导引MMSE”,即使在信噪比较低的情况下,也能获得更小的NMSE;En-CENet有效地改善了“差分方法”的NMSE性能.

(5)差分辅助的初始特征是有效的. 在没有差分辅助,只有En-CENet网络的情况下,“无差分网络”所得NMSE性能不及“导引MMSE”信道估计方法.“无差分网络”的NMSE远大于“导引MMSE”的NMSE. 由此可见,差分辅助为神经网络提供了重要的特征信息,从而使得本文方法在各给定的SNR下获得了最小的NMSE.

综上所述,在所给定的SNR范围内,相对于“导引LS”和“导引MMSE”,“差分方法”虽然提高了频谱效率,降低了能量消耗,但牺牲了NMSE性能. 本文方法融合“差分方法”与神经网络,在提高频谱效率、降低能量消耗的同时,有效地改善了NMSE性能.


6.3 健壮性分析

在本节中,我们分析仿真参数对提出方法的性能影响. 首先,我们验证多径簇数 L 对信道估计的影响. 随后,在不同子载波数 N 的取值下,验证本文信道估计方法的健壮性.

6.3.1 多径簇数 L 的影响分析

为验证多径簇数对NMSE性能的影响,仿真了在多径簇数 $L=4$ 、 $L=6$ 和 $L=8$ 时的NMSE性能,如图4所示. 除多径簇数参数 L 变化外,其他仿真参数与6.1节中的参数设置保持一致.


从图4可以看出,由于采用了充分的CP长度(CP长度大于最大多径延迟),多径衰落在频域上体现为频率平坦的信道特征,随着多径簇数改变,“导引LS”“导引MMSE”“差分方法”“文献[19]方法”和本文方法的NMSE性能并未受到明显影响. 尽管如此,在各给定

图4 不同 L 下NMSE性能分析

SNR 和多径簇数的情况下,相比基于块状导引的“导引LS”“导引MMSE”“差分方法”和“文献[19]方法”,本文方法始终获得最小的NMSE.由此可见,在多径簇数变化的情况下,本文方法的NMSE性能仍优于“导引LS”“导引MMSE”“差分方法”“文献[19]方法”的NMSE性能.

6.3.2 子载波个数 N 的影响分析

为验证子载波数对NMSE性能的影响,仿真了子载波数 $N=16$ 、 $N=64$ 、 $N=128$ 下的NMSE性能,如图5所示.除子载波数 N 变化外,其他仿真参数与6.1节中的参数设置保持一致.

图5 不同 N 下NMSE性能分析

从图5可以看出,随着子载波数 N 的增加,在给定的SNR内,相比导引方法、“差分方法”和“文献[19]方法”,本文方法始终获得了最小的NMSE.由此可见,本文方法在子载波数变化的情况下,仍能改善信道估计的NMSE性能.此外,在相对较高的SNR区域,如 $\text{SNR} \geq 16$ dB,“差分方法”和本文方法的NMSE随 N 增加而减小.这是因为在相对较高的SNR区域,差分检测的误码率相对较低,其形成的更长的导引更易于对抗多径干扰与噪声影响.综上所述,在各给定的SNR和子载波数的情况下,相比“导引LS”“导引MMSE”“文献[19]方法”和“差分方法”,本文方法仍获得了更好的NMSE性能.

7 结论

针对OFDM系统中的信道估计问题,本文研究了基于差分编码与神经网络辅助的信道估计方法.利用差分编码,避免了系统因导引发射而占用带宽资源,从而减小了UE端能量消耗;在此情况下,BS接收机提取到差分视角下的CSI模态,服务于信道估计的增强网络

En-CENet,改善接收端信道估计的NMSE性能.相比基于块状导引的“导引LS”和“导引MMSE”,本文方法不但减少了带宽资源的占用、降低了UE端能量消耗,还获得了更好的NMSE性能.相对于同样能降低带宽资源占用的“文献[19]方法”,本文方法在计算复杂度更低的情况下,同样取得了更好的NMSE性能.本文方法借助差分辅助与神经网络(非差分)辅助下的CSI特征,融合出了时新的显著CSI特征;且差分辅助与神经网络辅助二者缺一不可.仿真验证了本文方法的有效性和健壮性.对于5G-IoT大规模机器类型通信,本文研究为其提供了新思路,研究可延长IoT终端的电池寿命并改善短分组下的频谱效率.此外,差分辅助CSI特征开发的思想,可应用于下一代移动通信系统的智能信道估计中,以改善信道估计的精确性.


参考文献

- [1] ZAIDI A L, BALDEMAIR R, MOLES-CASES V, et al. OFDM numerology design for 5G new radio to support IoT, eMBB, and MBSFN[J]. IEEE Communications Stan-

- dards Magazine, 2018, 2(2): 78-83.
- [2] SOLTANI N, CHENG H, BELGIOVINE M, et al. Neural network-based OFDM receiver for resource constrained IoT devices[J]. IEEE Internet of Things Magazine, 2022, 5(3): 158-164.
- [3] 姜斌, 唐禹, 包建荣, 等. 水声信道频域Turbo均衡的期望传播改进算法[J]. 电子学报, 2022, 50(3): 652-662.
- JIANG B, TANG Y, BAO J R, et al. Improved expectation propagation algorithm of frequency domain turbo equalization for underwater acoustic channels[J]. Acta Electronica Sinica, 2022, 50(3): 652-662. (in Chinese)
- [4] WANG T Q, WEN C K, WANG H Q, et al. Deep learning for wireless physical layer: Opportunities and challenges[J]. China Communications, 2017, 14(11): 92-111.
- [5] ALI M S, LI Y, JEWEL M K H, et al. Channel estimation and peak-to-average power ratio analysis of narrowband Internet of Things uplink systems[J]. Wireless Communications and Mobile Computing, 2018, 2018: 2570165.
- [6] HOSSAIN JEWEL M K, SALE ZAKARIYYA R, FAMORIJI O J, et al. A low complexity channel estimation technique for NB-IoT downlink system[C]//2019 IEEE MTT-S International Wireless Symposium (IWS). Piscataway: IEEE, 2019: 1-3.
- [7] VILAS BOAS E C, E SILVA J D S, DE FIGUEIREDO F A P, et al. Artificial intelligence for channel estimation in multicarrier systems for B5G/6G communications: A survey[J]. EURASIP Journal on Wireless Communications and Networking, 2022, 2022(1): 116.
- [8] QING C J, WANG L, DONG L, et al. Enhanced ELM based channel estimation for RIS-assisted OFDM systems with insufficient CP and imperfect hardware[J]. IEEE Communications Letters, 2022, 26(1): 153-157.
- [9] 张聿远, 张立民, 闫文君. 基于深度多级残差网络的低信噪比下空频分组码识别方法[J]. 电子学报, 2022, 50(1): 79-88.
- ZHANG Y Y, ZHANG L M, YAN W J. A space-frequency block code recognition based on deep multilevel residual network with low SNR[J]. Acta Electronica Sinica, 2022, 50(1): 79-88. (in Chinese)
- [10] DONG Y D, WANG H X, YAO Y D. Channel estimation for one-bit multiuser massive MIMO using conditional GAN[J]. IEEE Communications Letters, 2021, 25(3): 854-858.
- [11] 廖勇, 李玉杰. 一种轻量化低复杂度的FDD大规模MIMO系统CSI反馈方法[J]. 电子学报, 2022, 50(5): 1211-1217.
- LIAO Y, LI Y J. Lightweight and low complexity CSI feedback method for FDD massive MIMO systems[J]. Acta Electronica Sinica, 2022, 50(5): 1211-1217. (in Chinese)
- [12] ZHOU Z, LIU L J, JERE S, et al. RCNet: Incorporating structural information into deep RNN for online MIMO-OFDM symbol detection with limited training[J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 3524-3537.
- [13] KUNDU N K, MCKAY M R. Channel estimation for reconfigurable intelligent surface aided MISO communications: From LMMSE to deep learning solutions[J]. IEEE Open Journal of the Communications Society, 2021, 2: 471-487.
- [14] GINIGE N, SHASHIKA MANOSHA K B, RAJATHEVA N, et al. Untrained DNN for channel estimation of RIS-assisted multi-user OFDM system with hardware impairments[C]//2021 IEEE 32nd Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). Piscataway: IEEE, 2021: 561-566.
- [15] HUSSEIN H S, HUSSEIN S, MOHAMED E M. Efficient channel estimation techniques for MIMO systems with 1-bit ADC[J]. China Communications, 2020, 17(5): 50-64.
- [16] 3GPP. Cellular System Support for Ultra-Low Complexity and Low Throughput Internet of Things (CIoT), V13.1.0[R]. Sophia Antipolis Cedex: 3GPP, 2016.
- [17] YOU Y H, JUNG Y A, CHOI S C, et al. Complexity-effective sequential detection of synchronization signal for cellular narrowband IoT communication systems[J]. IEEE Internet of Things Journal, 2021, 8(4): 2900-2909.
- [18] JIAO J, ZHOU J L, WU S H, et al. Superimposed pilot code-domain NOMA scheme for satellite-based Internet of Things[J]. IEEE Systems Journal, 2021, 15(2): 2732-2743.
- [19] QING C J, HU W Q, WANG L, et al. Superimposed pilot-based channel estimation for RIS-assisted IoT systems using lightweight network[EB/OL]. (2022-12-07)[2023-01-06]. <https://arxiv.org/abs/2212.03525>.
- [20] 宋立军. 多载波无线通信系统中的差分检测关键技术研究[D]. 成都: 电子科技大学, 2005.
- SONG L J. Researches on Key Techniques of Differential Detection in Multi-Carrier Wireless Communication Systems[D]. Chengdu: University of Electronic Science and Technology of China, 2005. (in Chinese)
- [21] ZHENG B X, ZHANG R. Intelligent reflecting surface-

enhanced OFDM: Channel estimation and reflection optimization[J]. IEEE Wireless Communications Letters, 2020, 9(4): 518-522.

- [22] ZHANG J, MU X, CHEN E, et al. Decision-directed channel estimation based on iterative linear minimum mean square error for orthogonal frequency division multiplexing systems[J]. IET Communications, 2009, 3(7): 1136-1143.
- [23] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.
- [24] QING C J, CAI B, YANG Q Y, et al. Deep learning for CSI feedback based on superimposed coding[J]. IEEE Access, 2019, 7: 93723-93733.
- [25] SZE V, CHEN Y H, YANG T J, et al. Efficient processing of deep neural networks: A tutorial and survey[J]. Proceedings of the IEEE, 2017, 105(12): 2295-2329.
- [26] HUANG H, XIA W C, XIONG J, et al. Unsupervised learning-based fast beamforming design for downlink MIMO[J]. IEEE Access, 2018, 7: 7599-7605.
- [27] QING C J, DONG L, WANG L, et al. Joint model and data-driven receiver design for data-dependent superimposed training scheme with imperfect hardware[J]. IEEE Transactions on Wireless Communications, 2022, 21(6): 3779-3791.
- [28] LIU L F, OESTGES C, POUTANEN J, et al. The COST 2100 MIMO channel model[J]. IEEE Wireless Communications, 2012, 19(6): 92-99.
- [29] KINGMA D, BA J. Adam: A method for stochastic optimization[EB/OL]. (2017-01-30)[2023-01-06]. <https://arxiv.org/abs/1412.6980>.
- [30] LIN L, YANG C, MEZA J C, et al. SelInv: An algorithm for selected inversion of a sparse symmetric matrix[J]. ACM Transactions on Mathematical Software, 2011, 37(4): 1-19.
- [31] GUO J J, WEN C K, JIN S. CAnet: Uplink-aided downlink channel acquisition in FDD massive MIMO using deep learning[J]. IEEE Transactions on Communications, 2022, 70(1): 199-214.



凌国伟 男,1998年出生,四川遂宁人. 硕士研究生. 主要研究方向为信道估计.
E-mail: lgwbest1234@163.com

作者简介



卿朝进 男,1978年出生,四川安岳人. 教授、硕导、博士. 主要研究方向为无线网络与通信.
中国电子学会会员编号:E190158574M.
E-mail: qingchj@mail.xhu.edu.cn