

面向5G OFDM系统的轻量化信道估计神经网络模型^{*}

江桦 邓艳翔 赵振禹 孙鹏 王玮

(郑州大学电气与信息工程学院 郑州 450001)

摘要: 现有的基于深度学习的信道估计算法精度显著优于传统算法,但因运行缓慢、参数庞大而难以满足实时通信需求,且无法在移动终端上有效部署。针对上述问题,提出了一种轻量化信道估计神经网络模型 ESPCN-net,将信道估计问题建模为从低分辨率图像(即稀疏导频处的信道响应)重建为高分辨率图像(即完整信道响应)的超分辨率任务。该模型摒弃现有神经网络模型的插值环节,在无需插值预处理的情况下,直接从导频信号中学习信道特征的空间相关性,恢复高精度信道状态信息。实验结果表明,所提模型在典型5G OFDM多径信道场景下,从计算效率来看,较SRCNN、ChannelNet分别提升25.7%和77.2倍。在计算复杂度方面,乘加累积操作数仅为SRCNN的36.4%、ChannelNet的0.76%,展现出优异的计算效率。参数规模上,虽然ESPCN-net的 47.25×10^3 参数比SRCNN多,但远低于ChannelNet(682.34×10^3)和ReCNet(100.45×10^3)。

关键词: 5G OFDM;神经网络;信道估计;超分辨率重建;轻量化

中图分类号: TN911.3;TP183 **文献标识码:** A **国家标准学科分类代码:** 510.40

Lightweight channel estimation neural network model for 5G OFDM systems

Jiang Hua Deng Yanxiang Zhao Zhenyu Sun Peng Wang Wei

(School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: The existing deep learning-based channel estimation algorithms have significantly higher accuracy than traditional algorithms, but they are difficult to meet the real-time communication requirements due to their slow operation and large parameters, and cannot be effectively deployed on mobile terminals. To address these issues, a lightweight channel estimation neural network model ESPCN-net is proposed, which models the channel estimation problem as a super-resolution task of reconstructing a high-resolution image (i. e., the complete channel response) from a low-resolution image (i. e., the channel response at sparse subcarriers). This model abandons the interpolation step in existing neural network models and directly learns the spatial correlation of channel features from pilot signals without interpolation preprocessing to restore high-precision channel state information. Experimental results show that in typical 5G OFDM multipath channel scenarios, compared with SRCNN and ChannelNet, the proposed model improves the computational efficiency by 25.7% and 77.2 times, respectively. In terms of computational complexity, the number of multiply-accumulate operations is only 36.4% of SRCNN and 0.76% of ChannelNet, demonstrating excellent computational efficiency. In terms of parameter scale, although the 47.25×10^3 parameters of ESPCN-net are more than those of SRCNN, they are far less than those of ChannelNet (682.34×10^3) and ReCNet (100.45×10^3).

Keywords: 5G OFDM;neural network;channel estimation;super-resolution reconstruction;lightweight

0 引言

5G通信技术以其高速率、低延迟和大容量的显著优势,成为推动社会发展和技术进步的关键力量。其中,正交频分复用(orthogonal frequency division multiplexing, OFDM)作为5G通信的核心技术之一,通过将高速数据流

分割成多个低速子数据流,并在多个正交子载波上同时传输,有效提高了频谱效率和抗多径衰落能力。在复杂的通信环境中,准确的信道估计至关重要,它是实现可靠数据传输和高效通信的基础^[1]。文献[2]提出了一种基于正交叠加的稀疏码分多址接入系统信道估计方法,有效降低了导频资源时隙开销。文献[3]对双时间尺度策略的基站-RIS

间信道估计方法进行改进,提出了一种基于主特征值分解的全局优化求解方法,显著降低了信道估计的复杂度。文献[4]提出一种基于稳定快速变换递归最小二乘算法的数字域自干扰抑制方法。有效抑制了水下收发一体机系统来自同侧的自干扰信号。文献[5]提出了一种多层贝叶斯模型下基于马尔科夫链蒙特卡罗采样器的 OFDM 水声通信信道估计方法,该方法能够在无任何信道先验信息下实现准确的 OFDM 水声信道估计和跟踪译码。传统的信道估计方法^[6]在相对简单的信道条件下能够取得一定的效果。但随着通信环境日益复杂,多径衰落、噪声干扰等因素对信道估计精度的影响愈发显著,这些传统方法的局限性逐渐凸显,难以满足 5G 通信对高精度信道估计的严格要求。

随着深度学习技术的快速发展,其在无线通信物理层^[7]的应用日益凸显,包括信道解码^[8]、信号检测^[9]、信道均衡^[10]和信道估计^[11]。特别是在信道估计领域取得了显著进展。现有研究主要可分为以下 3 类方法:1)端到端深度学习方法。文献[12]创新性地提出了一种基于 5 层全连接网络的端到端模型,通过联合训练策略自动学习无线信道与调制信号的联合概率分布。然而,全连接结构导致计算复杂度较高,限制了其在实时系统中的应用;2)压缩感知与深度学习融合方法。He 等^[13]将压缩感知理论与深度学习相结合,提出的波束空间稀疏化方法有效解决了毫米波大规模多输入多输出(multiple-input multiple-output, MIMO)系统的信道估计难题,为高维信道处理提供了新思路;3)基于图像超分辨率的深度学习方法。这类方法将信道矩阵视为二维图像进行处理,文献[14]提出的 ChannelNet 采用超分辨率卷积神经网络(super-resolution convolutional neural network, SRCNN)和去噪卷积神经网络(denoising convolutional neural network, DNCNN)级联结构,将信道估计建模为图像超分辨率重建问题。文献[15]基于卷积神经网络(convolutional neural network, CNN)构建图像恢复网络,通过引入残差连接提升了网络性能。文献[16]设计的复数生成对抗网络模型,充分利用了信号的复数特征,实现了更准确的信道估计。文献[17]提出的 PDAAB 网络创新性地引入动态注意力模块,在单输入单输出(single-input single-output, SISO)和 MIMO 系统中均表现出色。文献[18]采用卷积盲去噪网络,通过噪声级估计和非盲去噪的交互处理,在宽信噪比(signal-to-noise ratio, SNR)范围内取得了良好效果。通过对现有文献的分析可以发现,基于图像超分辨率思想的深度学习方法在信道估计领域展现出独特优势。这类方法将信道矩阵的估计问题转化为图像恢复问题,通过深度学习网络提取信道特征再恢复出完整的信道响应,能够有效提高信道估计精度。然而,现有信道估计神经网络模型普遍存在推理时间长、参数量庞大的问题。这不仅导致在实时通信场景中,无法快速准确地完成信道估计,影响通信的实时性和流畅性;而且在资源受限的移动终端上,由于硬件资源有限,严重阻碍了 5G 通信技术在移动终端设备上的广泛应用和普及。

针对上述难题,本文提出一种轻量化的神经网络模型

ESPCN-net。一方面,该模型借鉴谷歌提出的 ConvNeXt 网络模型^[19]对网络结构进行优化,ConvNeXt 使用纯卷积搭建类似于 Transformer 的网络结构,通过一步步探究卷积网络结构以及激活函数、归一化层、卷积核大小、数目等超参数设置,以达到卷积结构的效果最优值。另一方面,摒弃现有网络对数据进行插值的预处理环节,将未经插值处理的信道响应数据直接传入网络。无插值预处理可减小输入神经网络的训练数据的大小,降低计算量。此外,插值方法只是一种固定数学变换,并不能引入额外的信道特征信息。本文引入一种高效的子像素卷积层^[16],该层通过学习一组上采样滤波器阵列,避免插值带来的计算开销。因此,无插值预处理与借鉴 ConvNeXt 结构设计两者结合,在保证估计精度的同时兼顾了计算复杂度和结构的轻量化。实验结果表明,所提模型在典型 5G OFDM 多径信道场景下,相较于现有神经网络模型,在保持相同信道估计精度的同时,参数量减少,推理速度提升,显著降低了计算复杂度,进一步满足通信的实时性需求且更易于部署在资源受限的移动终端。

1 系统模型

本文严格遵循第 3 代合作伙伴计划(3rd generation partnership project, 3GPP)制定的 5G 新空口(new radio, NR)标准协议搭建 OFDM 系统。该系统采用 SISO 架构,将研究重点置于 5G 物理下行链路共享信道(physical downlink shared channel, PDSCH)。在 5G NR 体系下, PDSCH 作为承载下行用户数据和控制信息的关键信道,通过灵活的子载波间隔、资源块(resource block, RB)配置、循环前缀(cyclic prefix, CP)配置等参数,能够高效支持大规模的频谱利用和多用户的并行传输。

在该系统中,数据信息通过资源单元(resource element, RE)进行传输,RE 是时频资源的最小单位。它在时域上对应一个 OFDM 符号,在频域上对应一个子载波。在 5G NR 中,时隙(Slot)是信号的时域资源单位,每个 Slot 包含 N_s 个 OFDM 符号,通常在 NR 系统中, N_s 设置为 14 或 12,取决于所使用的子载波间隔。资源块是频域资源的最小分配单位,每个资源块中包含 N_{sc} 个子载波,5G NR 标准中规定 $N_{sc} = 12$ 。一个时隙中可以有 N_{RB} 个 RB,其中 N_{RB} 的数量没有具体规定,可根据实际需求灵活设定。本文设定的参数值为 $N_s = 14, N_{RB} = 12$,即一个时隙包含 12 个符号,612 个子载波。资源网格如图 1 所示。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 的位置和数量可以灵活配置。

在 OFDM 系统模型中,发送端经过 OFDM 调制后的时域信号为:

$$x[n] = \frac{1}{N_{sc}} \sum_{k=0}^{N_{sc}-1} x[k] e^{j2\pi kn/N_{sc}}, n = 0, 1, \dots, N_{sc} - 1 \quad (1)$$




图 1 资源网格

Fig. 1 Resource grid

其中, $x[n]$ 为第 $x[k]$ 个子载波上的调制符号, N_{sc} 为系统总的子载波数(含保护带), 循环前缀长度 N_{cp} 根据 3GPP TDL-A 信道延迟扩展动态调整。

经过多径信道后, 接收信号 $y[n]$ 可表示为:

$$y[n] = \sum_{l=0}^{L-1} h_l x[n-1] + w[n] \quad (2)$$

其中, h_l 为第 l 条路径的复信道增益, $w[n]$ 是加性高斯白噪声 (additive white Gaussian noise, AWGN), l 为多径数。

对接收信号去除 CP 并做 FFT 后, 频域接收信号为:

$$Y[k] = H[k]X[k] + W[k], k = 0, 1, \dots, N_{sc} - 1 \quad (3)$$

其中, $H[k] = \sum_{l=0}^{L-1} h_l e^{-j2\pi k l / N_{sc}}$ 为第 k 个子载波的信道频率响应, $W[k]$ 为频域噪声。

最后, 将导频处 LS 估计值 $\hat{H}_p^{LS}$ 映射为低分辨率信道矩阵 $\mathbf{H}_{LR}$, 通过神经网络恢复出全子载波信道矩阵 $\mathbf{H}_{HR}$ 。

2 基于深度学习的信道估计

本文提出的信道估计模型核心设计包含特征提取层、复合残差模块(compound residual block, CRB)和上采样模块。网络结构如图 2 所示。




图 2 网络结构

Fig. 2 Network structure

网络采用端到端的学习框架, 通过非对称空间-通道特征融合实现高效的信道估计。网络主要由以下组件构成: 特征提取层、复合残差模块、上采样模块。

2.1 特征提取层

通信系统中的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。因此, 将未经插值处理的信道频率响应数据的实部和虚部转换为双通道数据形式, 再将其输入到网络模型中。输入导频处的信道响应值经初始卷积层(Conv1)进行浅层特征提取, 采用 3×3 卷积核实现空间上下文感知。具体形式化表示为:

$$F_0 = N_1(\text{Conv}_{3 \times 3}(X_{\text{DMRS}})) \quad (4)$$

其中, N_1 表示层归一化(LayerNorm), 其计算过程为: 沿着归一化维度(通常是通道维度 C), 计算每个样本的均值 μ 和方差 σ^2 , 即:

$$\mu = \frac{1}{C} \sum_{i=1}^C x_i \quad (5)$$

$$\sigma^2 = \sum_{i=1}^C (x_i - \mu)^2 \quad (6)$$

其中, C 是通道数, 均值和方差的计算独立于批次(batch)和空间维度(H, W), 即每个样本单独计算。

使用均值和方差对输入进行归一化:

$$\hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (7)$$

其中, ϵ 是一个极小值, 防止分母为 0。归一化后的均值为 0, 方差为 1。

引入可学习的缩放参数 γ (weight) 和偏置参数 β (bias), 恢复模型的表达能力:

$$y_i = r_i \cdot \hat{x}_i + \beta_i \quad (8)$$

其中, γ 和 β 的形状与 C 相同。这一步允许模型决定是否保留或调整归一化后的分布。

2.2 复合残差模块

经过特征提取层处理的信道响应作为初步特征输入到 CRB。CRB 采用残差连接 (residual connection, RC), 通过恒等映射缓解了深层网络的梯度消失问题, 显著提升了模型的训练稳定性和表征能力。残差结构允许梯度通过跨层短路路径直接回传, 避免了传统堆叠层中因连续乘法导致的梯度衰减。为了降低计算成本, 深度残差模块中的卷积操作采用深度可分离卷积, 深度可分离卷积可以将参数量降为标准卷积的 $1/C$ (C 为通道数)。具体而言, 首先通过分组数为通道数的 5×5 深度卷积进行空间特征编码, 接着使用通道维度层归一化稳定训练; 随后通过 1×1 卷积将通道数扩展 4 倍并施加 GELU 激活函数, 引入全局响应归一化增强通道间交互; 最后通过 1×1 卷积将通道数压缩回原始维度。这种“深度卷积-通道扩展-压缩”的设计借鉴了谷歌提出的 ConvNeXt 的网络结构设计, 在保持输入输出空间分辨率的同时, 通过层归一化和双重 1×1 卷积的级联结构, 兼顾了局部特征提取能力与跨通道信息融合效率。

2.3 上采样模块

本文使用的 PixelShuffleHW 上采样模块是对经典 PixelShuffle^[20] 模块的扩展改进, 针对非对称空间分辨率上采样需求进行了适配。经典 PixelShuffle 在图像超分辨率任务中应用, 对高度 H 和宽度 W 的缩放倍数相同 ($r_H = r_w$), 未考虑到 OFDM 信道矩阵导频数目在频域和时域方向的放大倍数不一致, 这对于 5G NR 中灵活的导频配置至关重要。为解决这一问题, PixelShuffleHW 通过解耦高度与宽度的缩放因子 (r_H 和 r_w), 将输入张量的通道维度分解为 $r_H \times r_w$ 的子块, 并通过通道-空间维度的动态重组实现非对称上采样。具体地, 输入形状为 $[N, C \times r_H \times r_w, H, W]$ 的特征图, 经通道拆分、维度置换和空间合并操作后, 输出分辨率提升至 $[N, C, H \times r_H, W \times r_w]$ 。

本文所提出的网络设计突破了传统深度学习信道估计方法依赖插值预处理的计算范式。相较于现有方案 (如基于插值后重建的 CNN 或 Transformer 模型), 本方法直接利用导频信号的稀疏性特征, 通过 PixelShuffleHW 模块的通道-空间动态映射机制, 将导频信号的低维特征直接上采样至目标信道响应维度, 省去显式插值步骤, 通过端到端联合优化抑制了插值导致的频域相位失真同时显著降低计算复杂度, 节约模型推理时间。

3 系统仿真与结果分析

本节对提出的基于深度学习的 OFDM 通信系统下信道估计方案进行了仿真和性能对比, 基于 3GPP 5G NR 标准生成波形和信道, 仿真系统参数配置如表 1 所示。

表 1 仿真系统参数配置

Table 1 Simulation system parameter configuration

参数	参数值
子载波数	612
符号数	12
子载波间隔/kHz	60
信道模型	TDL-A
延迟扩展/ns	1~300
最大多普勒频移/Hz	5~400
发射天线数	1
接收天线数	1
噪声类型	AWGN

3.1 数据集

本文采用基于 3GPP 5G NR 标准的仿真数据生成方案, 通过 MATLAB 5G Toolbox 构建符合实际通信系统规范的信道估计数据集。数据生成过程严格遵循物理层信号处理链, 确保仿真环境与真实 5G 系统的高度一致性。数据生成基于端到端的仿真流程, 如图 3 所示。每个训练样本包含输入-标签对, 其中输入为经过实际信道畸变和噪声污染后的导频处信道估计值, 标签为理想的信道频率响应矩阵。这种方法确保了模型能够学习从受损观测值到真实信道的准确映射。数据生成的关键参数配置如表 1 所示。这些参数通过 MATLAB 内置参数配置函数进行统一管理, 确保参数设置的一致性和可重复性。




图 3 5G NR 仿真数据

Fig. 3 5G NR simulation data

数据集具有严格的层次化结构和划分方案, 以确保模型评估的客观性和可靠性。总样本量为 10 000 个完整的信道响应矩阵, SNR 覆盖范围为 1~30 dB, 采用科学的数据划分策略以防止过拟合并保证泛化能力, 训练集为 9 000 个样本 (占总样本 90%), 验证集为 1 000 个样本 (占总样本 10%)。测试集在 1~30 dB 范围内以 1 dB 为间隔, 每个 SNR 等级独立生成 1 000 个样本, 用于测试模型在不同 SNR 条件下的表现。为提高数据集的多样性和模型的泛化能力, 每次迭代随机选择信道参数, 如延迟扩展和最大多普勒频移。

3.2 训练策略

采用均方误差(mean squared error, MSE)损失函数衡量预测信道矩阵 $\hat{\mathbf{H}}$ 与理想信道矩阵 $\mathbf{H}$ 的差异:

$$L = \frac{1}{N} \sum_{i=1}^N \| \hat{\mathbf{H}}_i - \mathbf{H}_i \|_2^2 \tag{9}$$

采用 Adam 优化器(学习率 0.001, $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 1 \times 10^{-8}$)训练网络,设置批量大小为 128,训练 100 个 epoch。训练过程中每 10 个 epoch 在验证集上评估模型性能,并记录训练损失曲线以监控收敛情况。所有计算均在 GPU 上完成,训练完成后保存模型权重。此外,计算模型的计算量和参数量,并利用 CUDA 事件计时器测量模型推理时间,以全面评估模型性能。

3.3 实验结果与分析

在 SNR $\in [1 \text{ dB}, 30 \text{ dB}]$ 时,ESPCN-net、ChannelNet、ReCNet 和 SRCNN 4 种网络的估计性能表现如图 4 所示。




图 4 4 种网络 的 MSE 性能表现
Fig. 4 MSE performance of four networks

实验数据表明,所有网络 的 MSE 均随 SNR 增加呈现单调递减趋势,这完全符合理论预期。ESPCN-net 和 ChannelNet 在整个 SNR 区间内均展现出优于 ReCNet 和 SRCNN 的性能表现。具体而言,ESPCN-net 凭借其创新的亚像素卷积网络结构设计,在中低 SNR 区间(1~20 dB)保持轻微优势;而 ChannelNet 则通过双子网络堆叠结构,在高 SNR 区域(>25 dB)展现出更优的性能。而当 SNR 超过 25 dB 时,ESPCN-net 出现明显性能饱和现象,原因是轻量化设计虽然显著降低了计算复杂度,但其 47.25×10^3 的参数规模在高 SNR 下进行信道估计时特征提取能力有限,难以充分捕捉高 SNR 条件下信道矩阵中的细微结构与时频域的相关性。尽管 CRB 模块引入 ConvNeXt 设计思想,但其 5×5 深度卷积的感受野仍不足以建模高 SNR 信道的复杂空间依赖关系。相比之下,ChannelNet 凭借 682.34×10^3 的参数量和级联结构,在高 SNR 环境下表现出更强性能,支持更复杂的特征变换。ESPCN-net 虽然在计算效率与估计精度之间取得平衡,但其轻量化架构也决定了其在高 SNR 区域的性能上限。

表 2 展示了 4 种信道估计网络的关键性能指标对比。

从计算效率来看,ESPCN-net 以 12.44 ms 的推理时间显著优于其他模型,较 SRCNN 快 25.7%,比 ChannelNet 快 77.2 倍。在计算复杂度方面,ESPCN-net 的乘加累积操作数(multiply accumulate, Mac)仅为 SRCNN 的 36.4%,为 ChannelNet 的 0.76%,大幅降低了计算复杂度。参数规模上,虽然 ESPCN-net 的 47.25×10^3 参数虽比 SRCNN 的 14.11×10^3 多,但远低于 ChannelNet 的 682.34×10^3 和 ReCNet 的 100.45×10^3 。因此,ESPCN-net 网络的关键性能指标对比其他 3 种网络,在保持最低计算复杂度的同时,其信道估计精度也最优,完美实现了计算效率与估计精度的最佳平衡。

表 2 4 种网络的关键性能指标对比
Table 2 Comparison of key performance indicators of four networks

模型	推理时间/ ms	Mac/ $\times 10^6$	参数总数/ $\times 10^3$
SRCNN	16.83	105.06	14.11
ChannelNet	960.13	5 034.36	682.34
ReCNet	34.90	741.44	100.45
ESPCN-net	12.44	38.24	47.25

导频设计对信道估计性能具有关键影响。理论上,估计精度会随导频数量增加而提升,但过多导频会挤占频谱资源,降低数据传输效率。为权衡估计精度与传输效率之间的关系,本研究在不同 SNR 条件下进行实验评估,结果如图 5 所示。在增加一个导频的情况下,ESPCN-net 在低 SNR 区域 的 MSE 性能最大提升约 37.2%,在中 SNR 区域 的 MSE 性能最大提升约 34.7%,而在高 SNR 区域最大提升仅为 23.9%。这表明导频配置应随信道条件动态调整,在低 SNR 恶劣环境下可增加导频以提升估计精度,在高 SNR 良好环境下则可适当减少导频以优化频谱利用率。




图 5 不同导频数目对信道估计精度的影响
Fig. 5 The impact of different numbers of pilots on channel estimation accuracy

为更加直观评估不同信道估计网络的性能表现,本研究在 SNR 为 15 dB 的测试环境下开展了对比实验,并对各网络的估计结果进行了可视化分析。图 6 展示了 5 种信




图 6 不同网络信道估计结果可视化

Fig. 6 Visualization of channel estimation results using different algorithms

道响应图像,以图 6(a)真实信道响应作为基准参考,包括图 6(b)ESPCN-net、图 6(c)ChannelNet、图 6(d)SRCNN 和图 6(e)ReCNet 这 4 种网络的估计结果。

从可视化结果中可以看出, SRCNN 网络所估计的信道矩阵存在显著的结构失真与噪声放大现象,其可视化图像中可见明显的伪影和局部畸变,说明该模型在高噪声环境下难以有效捕捉信道结构特征。ReCNet 网络与 ChannelNet 网络的估计结果在整体轮廓上较为接近真实信道,反映出一定的重建能力,但仍存在可见的细节丢失与边缘模糊问题,尤其是在信道响应变化剧烈的区域,估计结果平滑过度,未能充分保留高频成分。相比之下, ESPCN-net 网络估计的信道矩阵在视觉上最接近真实响应,其可视化图像在边缘保持和细节还原方面表现优异,结构连续性良好,噪声抑制效果明显。

综上所述, ESPCN-net 在 SNR 为 15 dB 的条件下信道估计精度最佳,不仅视觉重建质量更高,其数值指标也一致地反映出其在信道估计任务中的有效性与先进性。

4 结 论

本研究针对 5G OFDM 系统中现有深度学习模型计算复杂度高的问题,提出了一种轻量化信道估计神经网络模型 ESPCN-net。通过无插值预处理的端到端学习框架,模型在保证估计精度的同时,显著降低了参数量和计算开销。实验结果表明,在 3GPP TDL-A 多径信道下,所提模型在 1~30 dB 内均表现出优越性能:估计精度与现有深度

学习模型(如 ChannelNet)相比,在相近精度下参数量减少 93%;推理时间仅 12.44 ms,较 SRCNN 提速 25.7%,模型的 Mac 计算量仅 38.24×10^6 ,易于部署在资源受限的移动终端。本研究的轻量化设计为深度学习在 5G/6G 物理层的高效部署提供了可行方案,尤其适用于资源受限的移动终端与物联网设备。

参考文献

- [1] ZHAO L L, ZHANG P, DONG Q C, et al. Research of the channel estimation in wireless communication systems[J]. ITM Web of Conferences, 2019, 25:01002.
- [2] 李啸天,季雪京,马金龙. 基于正交叠加的 SCMA 系统信道估计方法[J]. 电子测量技术, 2024, 47(19):9-16.
LI X T, JI X J, MA J L. Channel estimation method for SCMA system based on orthogonal superposition[J]. Electronic Measurement Technology, 2024, 47(19):9-16.
- [3] 余开. 智能反射表面辅助无线系统信道估计方法研究[J]. 电子测量与仪器学报, 2025, 39(5):262-269.
SHE K. Research on channel estimation method for intelligent reflective surface-assisted wireless system[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5):262-269.
- [4] 蒋佳佳,杨绪宝,郭同同,等. 基于 SFTRLs 算法的水下自干扰抑制方法研究[J]. 仪器仪表学报, 2025, 46(7):225-234.
JIANG J J, YANG X B, GUO T T, et al. Research on underwater self-interference suppression method

- based on SFTRLS algorithm[J]. Chinese Journal of Scientific Instrument, 2025, 46(7): 225-234.
- [5] 张舒然, 武岩波, 朱敏. 基于 MCMC 采样器的簇稀疏水声信道估计方法[J]. 仪器仪表学报, 2019, 40(8): 201-212.
ZHANG S R, WU Y B, ZHU M. A method for estimating clustered sparse underwater acoustic channels based on MCMC sampler[J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 201-212.
- [6] 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.
GAO S L, ZHANG Z Z, DUAN Y, et al. An channel estimation method based on demodulation reference signal in 5G system [J]. Telecommunication Engineering, 2021, 61(2): 191-196.
- [7] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. 通信学报, 2019, 40(2): 19-23.
GUI G, WANG Y, HUANG H. Deep learning based physical layer wireless communication techniques: Opportunities and challenges [J]. Journal on Communications, 2019, 40(2): 19-23.
- [8] XU W H, WU Z Z, UENG Y L, et al. Improved polar decoder based on deep learning[C]//2017 IEEE International Workshop on Signal Processing Systems, 2017: 1-6.
- [9] 高媛, 王慧, 孔菲菲, 等. 基于深度学习的 OFDM 系统信号检测设计[J]. 计算机测量与控制, 2025, 33(4): 24-31.
GAO Y, WANG H, KONG F F, et al. Design of OFDM system signal detection based on deep learning[J]. Computer Measurement & Control, 2025, 33(4): 24-31.
- [10] 杨旻, 李扬, 周明拓. 基于数据驱动深度学习方法的无线信道均衡[J]. 中兴通讯技术, 2018, 24(2): 25-29.
YANG Y, LI Y, ZHOU M T. The wireless channel equalization based on data-driven deep method [J]. ZTE Technology Journal, 2018, 24(2): 25-29.
- [11] 黄源, 何怡刚, 吴裕庭, 等. 基于深度学习的压缩感知 FDD 大规模 MIMO 系统稀疏信道估计算法[J]. 通信学报, 2021, 42(8): 61-69.
HUANG Y, HE Y G, WU Y T, et al. Deep learning for compressed sensing based sparse channelestimation in FDD massive MIMO systems [J]. Journal on Communications, 2021, 42(8): 61-69.
- [12] 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.
- [13] HE H T, 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.
- [14] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [15] 王义元, 常俊, 卢中奎, 等. 深度学习辅助的 5G OFDM 系统的信道估计[J]. 电讯技术, 2024, 64(1): 36-42.
WANG Y Y, CHANG J, LU Z K, et al. Deep learning assisted channel estimation for 5G OFDM systems[J]. Telecommunication Engineering, 2024, 64(1): 36-42.
- [16] 陆元智, 魏祥麟, 于龙, 等. 基于复数生成对抗网络的 5G OFDM 信道估计方法[J]. 电信科学, 2024, 40(3): 39-52.
LU Y Z, WEI X L, YU L, et al. 5G OFDM channel estimation method based on complex-valued generative adversarial network [J]. Telecommunications Science, 2024, 40(3): 39-52.
- [17] 张昀, 周婧, 黄经纬, 等. 基于深度学习的正交频分复用系统信道估计[J]. 通信学报, 2023, 44(12): 124-133.
ZHANG Y, ZHOU J, HUANG J W, et al. Channel estimation for OFDM system based on deep learning[J]. Journal on Communications, 2023, 44(12): 124-133.
- [18] JIN Y, ZHANG J Y, AI B, et al. Channel estimation for mmWave massive MIMO with convolutional blind denoising network [J]. IEEE Communications Letters, 2020, 24(1): 95-98.
- [19] LIU Z, MAO H Z, WU C Y, et al. A convnet for the 2020s [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11966-11976.
- [20] SHI W Z, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.

作者简介

江桦(通信作者), 博士, 教授, 博士生导师, 主要研究方向为通信信号处理、信号检测和电子对抗。

E-mail: jh653@sina.com

邓艳翔, 硕士研究生, 主要研究方向为信道估计。

E-mail: dengyanxiang2022@163.com

赵振禹, 博士研究生, 主要研究方向为语义通信、图像处理、人工智能大模型。

E-mail: zhenyuzhao@gs.zzu.edu.cn

孙鹏, 博士, 副教授, 主要研究方向为无线通信和信号处理、消息传递与因子图理论、5G/6G、大规模 MIMO、毫米波通信、卫星通信与电子对抗。

E-mail: iewwwang@zzu.edu.cn

王玮, 博士, 副教授, 主要研究方向为无线通信、信号处理等。

E-mail: iepengsun@foxmail.com