

基于深度学习的正交频分复用系统信道估计

张昀, 周婧, 黄经纬, 于舒娟, 黄丽亚

(南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 江苏 南京 210023)

摘要: 针对 5G 系统信号接收子载波间串扰和子符号间干扰问题, 提出了一种高效的基于深度学习的信道估计模型。在导频处进行初步估计获得估计信道, 并将其视为含噪声的低分辨率图像样本输入信道估计模型, 通过学习低分辨率图像与高分辨率图像之间的映射关系, 最终去除输入信道的噪声, 还原高分辨率信道图像, 获得整个信道状态信息。仿真结果表明, 该模型不仅延续了传统注意力机制抑制冗余信息的优势, 降低了计算开销, 还能获得良好的精度和鲁棒性, 对各种信道都有较好的估计效果。

关键词: 深度学习; 信道估计; 图像恢复; 注意力机制

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023240

Channel estimation for OFDM system based on deep learning

ZHANG Yun, ZHOU Jing, HUANG Jingwei, YU Shujuan, HUANG Liya

College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology),
Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract: An efficient channel estimation model based on deep learning was proposed for the problems of inter-carrier interference and inter-symbol interference in 5G system signal reception. The estimated channels were obtained through a preliminary estimation at the pilots. And they were treated as low resolution images containing noise, which were input into the channel estimation model. By learning the mapping relationship between the low resolution images and the high resolution images, the noise in input channels was removed, and the high-resolution channel images were restored to obtain the entire channel state information eventually. The simulation results show that the model not only continues the advantages of traditional attention mechanisms in suppressing redundant information, reduces computational overhead, but also achieves good accuracy and robustness, and has good estimation performance for various channels.

Keywords: deep learning, channel estimation, image restoration, attention mechanism

0 引言

正交频分复用 (OFDM, orthogonal frequency division multiplexing) 利用子载波频谱重叠的方式提高了带宽效率, 对频率选择性衰落和窄带干扰具有较高的鲁棒性。近年来, OFDM 凭借其实现复杂度低、应用广的特点成为当前 5G 无线网络及未来发展的重点^[1-2]。由于无线环境复杂多变, 信号在到

达接收机的过程中会受到多种干扰, 信道估计的目的就是对信道的时域或频域响应进行准确估计, 校正并恢复接收到的数据。在 OFDM 系统中, 获取准确的信道状态信息 (CSI, channel state information) 是相干检测、解调和均衡的关键。

传统的 OFDM 信道估计技术根据是否基于导频辅助可大致分为非盲信道估计和盲信道估计两类。非盲信道估计通常用于快速变化的无线环境

收稿日期: 2023-08-07; 修回日期: 2023-10-31

基金项目: 国家自然科学基金资助项目 (No.61977039)

Foundation Item: The National Natural Science Foundation of China (No.61977039)

中, 其中最常见的是最小二乘 (LS, least square) 算法和最小均方误差 (MMSE, minimum mean square error) 算法。LS 信道估计利用 LS 算法估计导频符号处的信道频率响应, 其结构简单且计算量小, 但没有考虑接收信号中的噪声和子载波间的干扰, 估计精度有限。MMSE 算法直接使用真实值与估计值的误差作为优化的目标, 但其需使用 LS 算法估计的结果, 而且计算量较大, 不适合直接应用。此外, 其他传统的线性估计方法依赖统计模型, 实现复杂度高, 在高动态环境中缺乏鲁棒性。相比之下, 深度学习网络能从大量训练数据中提取出信道的固有特征, 并利用高效并行计算方法更准确地估计信道。

近年来, 随着深度学习 (DL, deep learning) 概念的出现, 无线通信领域的研究者将深度学习与传统技术相结合并应用于物理层^[3], 包括信道解码^[4]、信号检测^[5]、信道均衡^[6]和信道估计^[7]。文献[8]提出了一种端到端的深度神经网络 (DNN, deep neural network) 实现了 OFDM 系统中的信道估计与信道检测, 首先利用模拟生成的数据进行离线训练, 然后将训练的模型直接用于恢复在线传输的数据。文献[9]利用基于学习去噪的近似消息传递 (LDAMP, learned denoising-based approximate message passing) 网络对毫米波信道进行迭代估计, 将去噪卷积神经网络 (DNCNN, denoising convolutional neural network) 与迭代稀疏信号恢复算法融合, 在每次迭代中使用 DNCNN 更新估计的信道。文献[10]将基于深度学习的超分辨率方法应用于大规模多输入多输出 (MIMO, multiple-input multiple-output) 系统中, 以解决到达方向估计和信道估计问题。文献[11]采用 DNN 将基于深度学习的信道估计扩展到双选择性信道, 并在数值上证明了该方法在许多场景中具有比传统估计方法更好的性能。文献[12]将残差网络结构运用于广义频分复用 (GFDM, generalized frequency division multiplexing) 时频双选择信道中, 证明了其在 GFDM 系统中也具有有良好的误码率性能和泛化能力。文献[13]利用信道的时频相关性, 引入了基于长短期记忆 (LSTM, long short-term memory) 的 DNN, 提出了一种更有效的信道压缩和恢复方法。文献[14]针对单输入单输出 (SISO) 信道将导频位置的信道时频响应视为一个低分辨率 (LR, low-resolution) 图像, 结合图像超分辨率 (SR, super-resolution) 算法和图像复原 (IR, image

restoration) 算法来提高输入图像的分辨率, 去除噪声的影响。但该网络针对特定的噪声水平进行训练, 仅当测试信道的噪声水平在训练范围内时, 才能达到良好的效果。文献[15]采用了一种卷积盲去噪网络先进行噪声级估计, 再针对输入信道进行非盲去噪, 以交互方式降低信道矩阵中的噪声, 在宽信噪比范围有较好的效果。但该方案由 2 个独立的子网络组成, 包含了多级损耗且网络复杂度高, 在训练效率和灵活性方面较差。由上述文献可知, 图像去噪技术对信道估计有显著的效果, 研究具有良好的复杂度与精度权衡的估计网络是提高信道估计性能的关键。

为了进一步发挥图像去噪在信道估计中的优势, 降低网络复杂度的同时提升信道估计的精度, 本文将图像去噪自编码网络^[16]引入信道估计领域, 提出用于 OFDM 系统的深度学习网络, 即基于动态注意力模块的信道估计去噪网络 (PDAAB, practical channel estimation denoising network with attention in attention block)。针对 OFDM 符号的块状符号结构, 在时频网格中插入二维分布的离散导频符号。利用导频符号位置处信道的初步估计值构成低分辨率信道时频增益图像, 作为 PDAAB 的输入, 通过 PDAAB 学习低分辨率信道图像与高分辨率信道图像之间的映射关系与参数, 最终达到去除输入图像噪声、还原高分辨率信道图像的效果。实验结果表明, 本文提出的 PDAAB 在低复杂度的情况下, 针对 SISO 系统和 MIMO 系统都具有良好的估计性能, 并且所训练的网络模型在不同的信道环境中都具有有良好的鲁棒性。

1 系统模型

本文主要涉及 2 个模型, 分别为 SISO 的 OFDM 信道模型和 MIMO 的 OFDM 信道模型。本节主要对 MIMO 信道模型结构进行介绍。

在移动通信领域, 由于 SISO 天线覆盖面积窄、传输可靠性低与传输数据量小的问题, MIMO 技术使用更加广泛^[17]。

本文使用均匀线性阵列 (ULA, uniform linear array) 的 MIMO 系统, 如图 1 所示。发射端具有 N_T 个发射天线和 N_T^{RF} 个发射射频链, 接收端具有 N_R 个接收天线和 N_R^{RF} 个接收射频链。为了降低功耗和成本, 实际的毫米波大规模 MIMO 系统中射频链的数量比天线的数量少得多^[18]。因此, 本文假设 $N_T^{\text{RF}} \ll N_T$, $N_R^{\text{RF}} \ll N_R$ 。

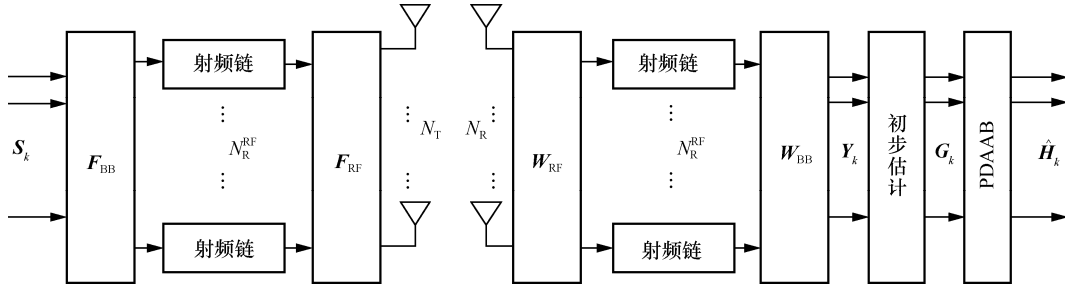


图 1 MIMO 系统

毫米波大规模 MIMO 信道对非视距 (NLOS) 信号具有较高的路径损耗, 并且具有明显的空间/角度稀疏性, 其中只有少量的优势多路径 (在现实环境中通常为 3~5 条多路径) 由毫米波 MIMO 多路径信道组成。点对点毫米波大质量 MIMO 信道可以建模为^[19]

$$\mathbf{H} = \sqrt{\frac{N_T N_R}{\rho}} \sum_{l=1}^L \alpha_l \mathbf{a}_R(\theta_l) \mathbf{a}_T^H(\varphi_l) = \sqrt{\frac{N_T N_R}{\rho}} \mathbf{A}_R \mathbf{D} \mathbf{A}_T^H \quad (1)$$

其中, \mathbf{H} 是大小为 $N_R \times N_T$ 的矩阵, 表示接收机与发射机之间的毫米波信道; ρ 表示平均路径损耗; L 表示主路径数, 假设路径振幅服从瑞利分布; $\alpha_l \sim \mathcal{N}(0, \sigma_\alpha^2)$ 表示第 l 条路径的传输增益, $l=1, 2, \dots, L$, σ_α^2 表示平均功率增益; $\theta_l \in [0, 2\pi]$ 和 $\varphi_l \in [0, 2\pi]$ 分别表示第 l 条路径的到达角 (AoD) 和出发角 (AoA); $\mathbf{a}_R(\theta_l)$ 和 $\mathbf{a}_T(\varphi_l)$ 分别表示天线阵列在接收端和发射端的响应向量, 计算式为

$$\mathbf{a}_R(\theta_l) = \frac{1}{\sqrt{N_R}} \left[1, e^{j\frac{2\pi}{\lambda}d \sin \theta_l}, \dots, e^{j(N_R-1)\frac{2\pi}{\lambda}d \sin \theta_l} \right]^T \quad (2)$$

$$\mathbf{a}_T(\varphi_l) = \frac{1}{\sqrt{N_T}} \left[1, e^{j\frac{2\pi}{\lambda}d \sin \varphi_l}, \dots, e^{j(N_T-1)\frac{2\pi}{\lambda}d \sin \varphi_l} \right]^T \quad (3)$$

其中, λ 表示载波波长, d 表示相邻天线之间的距离。

$$\mathbf{A}_R = [\mathbf{a}_R(\theta_1), \mathbf{a}_R(\theta_2), \dots, \mathbf{a}_R(\theta_L)] \quad (4)$$

$$\mathbf{A}_T = [\mathbf{a}_T(\varphi_1), \mathbf{a}_T(\varphi_2), \dots, \mathbf{a}_T(\varphi_L)] \quad (5)$$

$$\mathbf{D} = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_L) \quad (6)$$

假设发射端在一个波束方向上激活一条射频链发射导频, 接收端则使用不同波束方向的所有射

频链, 组合接收导频^[20]。发射的原始信号为 S_k , 则在接收端的基带内, 接收到的第 k 个子载波导频信号可表示为

$$\mathbf{Y}_k = \mathbf{W}_k^H \mathbf{H}_k \mathbf{F}_k S_k + \mathbf{W}_k^H \mathbf{Z}_k \quad (7)$$

其中, \mathbf{Z}_k 为加性白高斯噪声; $\mathbf{F}_k = \mathbf{F}_{RF} \mathbf{F}_{BB}$ 为发射机预编码器, \mathbf{F}_{RF} 和 \mathbf{F}_{BB} 分别为射频和基带与编码器。与发射端预编码器类似, \mathbf{W}_k 为接收端混合组合器, 由射频组合器 \mathbf{W}_{RF} 和基带组合器 \mathbf{W}_{BB} 组成。

根据文献 [21], 假设在最差的情况下 $\mathbf{W}_k = \mathbf{W}$, $\mathbf{F}_k = \mathbf{F}$, $\mathbf{X}_k = \sqrt{P} \mathbf{I}$, 其中, P 表示信号发射功率。式(7)可以转换为

$$\mathbf{Y}_k = \sqrt{P} \mathbf{W}^H \mathbf{H}_k \mathbf{F} + \mathbf{Q}_k \quad (8)$$

接收的导频信号经过初步估计模块, 通过 2 个矩阵进行处理, 得到一个初步估计矩阵 \mathbf{G}_k 为

$$\mathbf{G}_k = \mathbf{B}_1 \mathbf{Y}_k \mathbf{B}_2 \quad (9)$$

其中

$$\mathbf{B}_1 = (\mathbf{W}^H \mathbf{W})^{-1} \mathbf{W} \quad (10)$$

$$\mathbf{B}_2 = (\mathbf{F}^H \mathbf{F})^{-1} \mathbf{F} \quad (11)$$

最后, 将得到的初步估计矩阵 \mathbf{G}_k 作为深度神经网络的输入数据。通过映射关系输出估计的通道矩阵为

$$\hat{\mathbf{H}}_k = f_\theta(\mathbf{G}_k) \quad (12)$$

其中, θ 为 PDAAB 的参数集。

2 基于 PDAAB 的信道估计

尽管图像去噪技术已经发展了几十年, 但在有限的计算资源条件下从极嘈杂的图像中恢复高质量图像仍然具有挑战性。近年来, 基于深度神经网络的去噪方法在信道估计方面取得了巨大的成效。

本节提出了一种基于动态注意力模块的信道估计去噪网络 PDAAB，该网络能够降低计算开销，提高通信效率，并输出高质量的信道图像。

2.1 网络结构

本节将发射端与接收端之间的信道时频响应矩

阵 H 的实部与虚部分别视为一个二维图像。同时，为了更好地利用信道系数的相关性，将实部与虚部的 2 幅二维图像组合为低分辨率图像的 2 个通道。

PDAAB 使用了类似 U-Net 的结构，并在此基础上加入了动态注意力机制，其结构如图 2 所示。

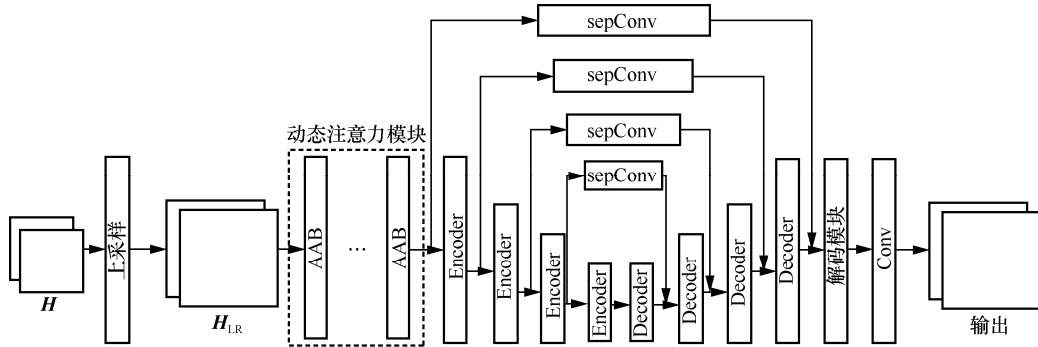


图 2 PDAAB 结构

该网络主要由 4 个编码器 (Encoder) 和 4 个具有跳跃连接的解码器 (Decoder) 组成。PDAAB 开始是一个 2 维卷积层，其滤波器个数为 16，核的大小为 3×3 ，步长为 1。每个编码器都由下采样模块和编码模块组成，编码模块使用了 5×5 的卷积核，降低模型深度并增加感受野的大小。下采样模块采用了步长为 2 的下采样特征图。编码器与解码器结构如图 3 所示。4 个编码器整体为一个收缩网络，通过 4 个下采样缩小图像尺寸，并特征提取浅层信息，将原始图像压缩为低维表示从而使网络学习最有用的特征信息。编码器的输入通过元素相加组合到相应的解码器，并采用 3×3 的可分离卷积 (sepConv) 来匹配通道形状，达到融合浅层信息与深层信息的目的。解码器仅使用 3×3 的可分离卷积

和 2×2 的反卷积进行上采样特征图。

最后，卷积层输出一个残差，添加到输入图像作为去噪结果。在输出位置，输入图和网络输出进行了一个元素相加操作，原图会加上网络的输出噪声，最后输出去除噪声图，网络只需要输出简单的去除噪声图而不是复杂的去除噪声原图，降低了网络学习的难度。但是由于导频数量的限制，需要将恢复通道放大，因此网络输入先通过上采样，将输入矩阵 H 放大到目标尺寸 H_{LR} 。

2.2 可分离卷积

为了降低计算成本，本文使用可分离卷积将一个完整的卷积运算分解为两步进行，即逐点卷积和逐深度卷积，大幅减少了卷积的参数^[22]。可分离卷积原理如图 4 所示。




图 3 编码器与解码器结构




图 4 可分离卷积原理

由图 4(a)可知, 逐深度卷积的每个卷积核只针对对应通道进行卷积计算, 并且卷积过程中滤波器的数量与输入的通道数保持一致。由图 4(b)可知, 逐点卷积与常规卷积过程相似, 采用 1×1 的卷积核进行卷积。深度可分离卷积在常规卷积的基础上进行了细小的改变, 不同于传统卷积同时对通道和区域进行操作, 深度可分离卷积实现了区域和通道的分离操作, 大幅减少卷积的参数, 使模型规模显著降低。

2.3 动态注意力机制

当前深度学习需要在复杂的数据集上进行学习, 这导致其架构越来越大, 产生的计算开销也随之增加。注意力机制能将有限的计算资源分配给信号中信息量分布更大的部分, 有效解决了信息超载问题。本文引入了一种低消耗动态注意力机制模块, 称为双注意力模块 (AAB, attention in attention block)^[23], 其结构如图 5 所示。

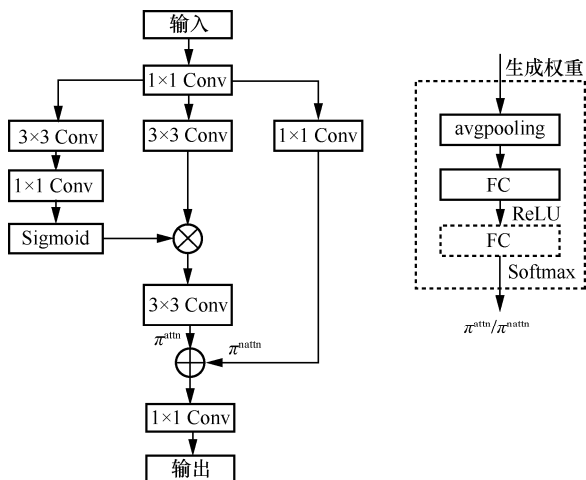


图 5 AAB 结构

AAB 分为注意力分支和非注意力分支, 注意力分支用于增强有用的信息, 非注意力分支用于学习被注意模块忽略的有益信息。该模块可以动态分配 2 个分支的权重, 充分利用 2 个分支的信息, 增强有效信息, 抑制冗余信息。

由图 5 可知, AAB 利用相同输入特征作为 2 个独立的分支来生成权重。输出结果可以表示为

$$x_n = f_{1 \times 1} \left(\pi_{n-1}^{\text{attn}} x_{n-1}^{\text{attn}} + \pi_{n-1}^{\text{nattn}} x_{n-1}^{\text{nattn}} \right) \quad (13)$$

其中, π_{n-1}^{attn} 和 π_{n-1}^{nattn} 分别为注意力分支和非注意力分支的权重; x_{n-1}^{attn} 和 x_{n-1}^{nattn} 分别为注意力分支和非注意力分支的输出; $f_{1 \times 1}$ 为卷积核大小为 1 的卷积操作。

根据图 5 可知, 分支权重为

$$\pi_{n-1} = f_{\text{da}}(x_{n-1}) \quad (14)$$

其中, $f_{\text{da}}(\cdot)$ 是动态权重模块。首先使用全局平均池化压缩输入 x_{n-1} 。连接层由 2 个全连接层 (FC) 和一个 ReLU 激活函数组成。这里使用全局平均池化来增加接受域, 这使动态注意模块可以从整个图像中捕获特征。因为约束动态权重可以促进动态注意模块的学习^[24], 所以设定 $\pi^{\text{attn}} + \pi^{\text{nattn}} = 1$ 。这种对动态权重的和约束可以压缩内核空间, 大大简化了权重的学习。因此, 使用 Softmax 函数生成注意力分支和非注意力分支的归一化权重。

加入 AAB 前后的模型验证损失如图 6 所示。从图 6 可以看出, 加入 AAB 后的模型训练收敛速度显著提高, 并且性能有所提升。

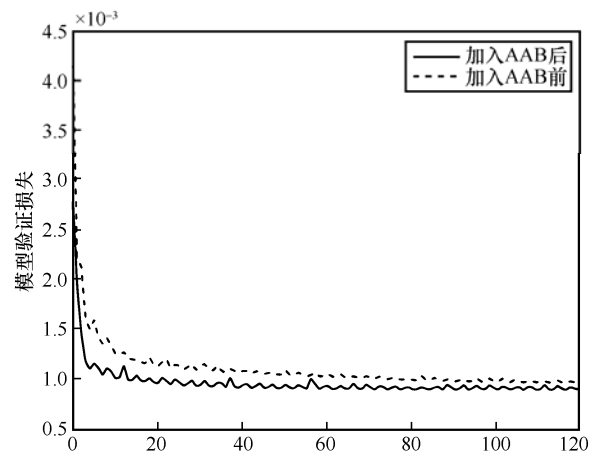


图 6 加入 AAB 前后的模型验证损失

2.4 训练

针对 PDAAB, 在仿真环境中按照一定的模型

参数随机生成 M 个训练样本, $(\mathbf{G}_i, \mathbf{H}_i)$ 为第 i 组训练样本。 \mathbf{G}_i 为初步估计得到的信道矩阵, 被视为含噪声的低分辨率信道图像, 将估计矩阵的虚实部分为一个信道图像的 2 个通道 $(\mathbf{G}_{i1}, \mathbf{G}_{i2})$, 则有 $\mathbf{G}_i \in \mathbb{C}^{A \times B \times 2}$, $A \times B$ 为信道矩阵的大小; \mathbf{H}_i 为相对应的真实信道矩阵。

该网络的训练采用了损失函数 ℓ_2 , 计算式为

$$\ell_2 = \frac{1}{\mathcal{T}} \sum_{\mathbf{G}_i \in \mathcal{T}} f_{\theta}(\mathbf{G}_i) - \mathbf{H}_i^2 \quad (15)$$

其中, \mathcal{T} 为训练集的大小; $f_{\theta}(\mathbf{G}_i)$ 为模型输出的信道矩阵。为了得到最佳网络参数集合, 使训练结果逐渐逼近最优值, Adam 优化器受到了广泛使用。同时引入了 L_2 正则化, 避免在训练的过程中出现过拟合, 即在原有的损失函数基础上加上权重参数的平方和, 计算式为

$$L = E_{\text{in}} + \lambda \sum_j w_j^2 \quad (16)$$

其中, E_{in} 为未包含正则化项的训练样本误差, λ 为正则化参数, w_j 为权重参数。文献[25]提出了 AdamW 优化器, 进一步提升了 Adam 优化器加入 L_2 正则化的效果。AdamW 通过将权重衰减与梯度更新解耦的方式, 有效提升 Adam 优化器的泛化性能。

设置初始学习速率 $\mu = 5 \times 10^{-4}$, 若 μ 过大会导致误差函数值出现不降反增的情况, μ 过小又会导致收敛速度过慢, 所以固定的学习率可能会导致模型在经过一定数目的迭代训练后仍无法收敛至最优值。采用余弦退火学习率, 即在每次迭代训练后减小学习率值, 当逐渐减小至最低值后保存局部最优解然后返回初始值, 不断循环往复, 计算式为

$$\mu_i = \mu_{\min} + \frac{1}{2} (\mu_{\max} + \mu_{\min}) \left(1 + \cos \left(\frac{T_i}{T_{\max}} \pi \right) \right) \quad (17)$$

其中, μ_i 为当前的学习率值; μ_{\min} 和 μ_{\max} 分别为学习率的最小值和最大值; T_{\max} 为学习率循环周期的一半; T_i 为当前所在的迭代循环轮次。该方法有利于避免陷入局部最优解, 继续寻找全局最优点。训练每一批的大小为 32, 每一次训练将数据随机打乱, 权重衰减设置为 0.01。

3 仿真结果分析

本节通过在不同的信道环境中的仿真实验,

验证了在 OFDM 系统中 PDAAB 的性能。同时, 考虑到 OFDM 中 SISO 系统和 MIMO 系统的信道环境, 利用 MATLAB 在不同的环境下分别生成了 40 000 个信道样本 $(\mathbf{G}_i, \mathbf{H}_i)$, 其中 32 000 个样本用于训练, 4 000 个样本用于验证, 剩余 4 000 个样本用于测试。

3.1 SISO 信道仿真实验

本节考虑发射机和接收机都是单天线的情况。本节模拟中, 每帧由 $N_s = 14$ 个 OFDM 子符号和 $N_f = 72$ 个子载波组成, 遵循 Vehicular-A (VehA) 无线信道标准。SISO 信道仿真参数如表 1 所示。

表 1 SISO 信道仿真参数

参数	参数值
系统带宽/MHz	1.6
载波频率/GHz	2.1
用户设备速度/(km·h ⁻¹)	50
子载波数	72
子符号数	14
导频数	48

本节将所提 PDAAB 与已有模型进行比较, 对比模型为 ChannelNet^[14]。ChannelNet 由超分辨率 SRCNN 与去噪模块 DNCNN 级联组成, ChannelNet 结构如表 2 所示。

表 2 ChannelNet 结构

模块	层数	滤波器数量	滤波器大小	激活函数
SRCNN	1	64	9×9	ReLU
	2	32	1×1	ReLU
	3	2	5×5	—
DNCNN	4	64	3×3	ReLU
	5~22	64	3×3	ReLU
	23	2	3×3	—

PDAAB 的训练集与验证集的收敛曲线如图 7 所示。结果显示, 随着迭代训练的增加, 网络的 L_2 损失值不断下降, 仅在 8 个 epoch 左右误差值就达到了 1×10^{-3} , 并在 80 个 epoch 之后趋于一个相对稳定的值。这表明了 PDAAB 具有良好的收敛速度, 可以在较少的训练轮次后获得不错的结果。




图 7 PDAAB 网络的训练集与验证集的收敛曲线

在信噪比 $SNR \in [0, 30]$ dB 的条件下，PDAAB、ChannelNet、非理想 MMSE 和 LS 在 OFDM 信道下的均方误差 (MSE) 如图 8 所示。实验结果表明，ChannelNet 在 $SNR=5\sim 30$ dB 范围内效果优于非理想的 MMSE 算法。而 PDAAB 效果优于 LS、非理想的 MMSE 与 ChannelNet，并且在大信噪比的情况下，MSE 仍能保持一个良好的下降趋势。

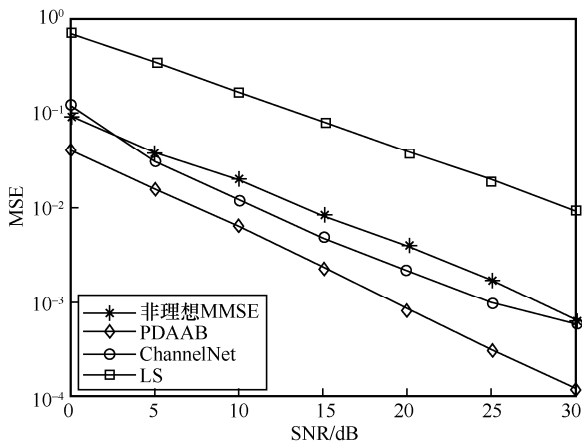


图 8 不同算法在 OFDM 信道下的均方误差

3.2 MIMO 信道仿真实验

本节通过仿真实验验证了 PDAAB 在 MIMO-OFDM 系统中的性能，并与传统信道估计算法和其他基于深度学习的信道估计算法进行了比较。

毫米波大规模多输入多输出已经成为 5G 的核心技术。第三代合作伙伴项目 (3GPP) 为 5G 系统定义了一个新的无线信道模型规范并受到

了广泛的应用，命名为 TR38.901^[26]。3GPP TR38.901 Release15 信道模型主要研究了频带范围在 0.5~100 GHz 的信道，基于此本文生成了仿真实验所需要的信道样本，MIMO 信道仿真参数如表 3 所示。

表 3 MIMO 信道仿真参数

参数名称	参数取值
载波频率/GHz	28
采样频率/MHz	100
接收天线数	16
发射天线数	32
子载波数	64
视距角	60°
基站天线高度/m	10
主路径数	1~4
最大多普勒频移/Hz	0,500,1 000

为了验证 PDAAB 的性能，本文将传统信道估计算法和几种已有的深度学习网络 (Deep CNN^[26]、DNCNN^[14]) 与其进行了对比。Deep CNN 由 10 个卷积层构成，每一层都结合批归一化层，避免梯度扩散和过拟合，输出层的激活函数设置为 Tanh。DNCNN、Deep CNN 的结构如表 2、表 4 所示。本节采用了归一化均方误差作为衡量信道估计性能的评价标准，表示为

$$NMSE = \mathbb{E} \left\{ \frac{\hat{H} - H_2^2}{H_2^2} \right\} \quad (18)$$

表 4 DeepCNN 结构

层数	滤波器数量	滤波器大小	激活函数
1~9	64	3×3	ReLU
10	2	3×3	Tanh

本节在城市微小区 (UMi) 街道 NLOS 场景下，使用了相同训练数据集，针对不同信噪比的信道数据进行训练，PDAAB、Deep CNN、DNCNN、非理想的 MMSE 在 MIMO-OFDM 信道下的归一化均方误差如图 9 所示。由图 9 可以看出，上述几种深度学习信道估计算法均优于非理想 MMSE 算法。其中，DNCNN 的性能优于 Deep CNN，而 PDAAB 的性能最优。

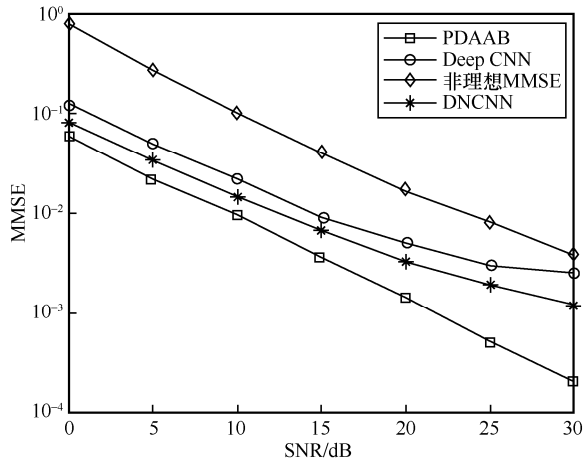


图 9 不同算法在 MIMO-OFDM 信道下的归一化均方误差

在实际场景中，主路径数可能会发生变化。本文根据不同的主路径数生成了信道样本，在主路径数 $L=3$ 的数据集上进行训练，然后分别测试训练模型在 $L=1,2,3,4$ 的数据集上的效果。测试阶段 $L=3$ 时使用的数据集与训练阶段一致，所以将其作为基线。在不同主路径数下 PDAAB 的归一化均方误差如图 10 所示。从图 10 可以看出，当 $L=1$ 时，效果优于基线，这表明 $L=1$ 时的信道结构较简单，更有利于去噪；当 $L=2$ 时，性能相较于基线略有下降，但是仍能保持一个不错的结果；当 $L=4$ 时，信道环境发生了显著变化，性能较基线有了明显的下降。根据结果可知，当 $L=1,2$ 时， $L=3$ 的数据集训练的模型具有较好的鲁棒性。




图 10 在不同主路径数下 PDAAB 的归一化均方误差

在高速移动环境中，随着最大多普勒频移的增大，信道会发生快速变化，将不利于信道估计的准确度。所以高精度的信道估计是保证通信可靠稳定的关键。为了验证针对 OFDM 系统的 PDAAB 在不

同最大多普勒频移下的性能和鲁棒性，本文在 $F_m = (0, 500, 1000)$ Hz 的条件下生成数据集。训练阶段使用了最大多普勒频移 $F_m = 0$ 作为基线，然后分别在 $F_m = (0, 500, 1000)$ Hz 进行了测试。在不同最大多普勒频移下不同算法的归一化均方误差如图 11 所示。结果表明，PDAAB 在 $F_m = (0, 500)$ Hz 的条件下有较好的效果，当 $F_m = 1000$ Hz 时，虽然相较于基线性能有所下降，但是在信噪比 $SNR \in [0, 30]$ dB 的范围性能效果仍优于 Deep CNN。这些结果也验证了该模型具有良好的泛化能力。




图 11 在不同最大多普勒频移下不同算法的归一化均方误差

根据文献[21]所述，将相邻的子载波同时作为网络的输入相较于单子载波能更好地利用信道之间的相关性，Deep CNN 具有更好的信道估计性能，但是随着输入通道数增加，复杂度也会略有提升。受此启发，将该方法应用于所提 PDAAB，即输入为 $(G_{11}, G_{11}, G_{21}, G_{21})$ ，并与 Deep CNN 进行比较。在 2 个相邻子载波上不同主路径数下的归一化均方误差如图 12 所示。在 $L=3$ 时进行训练，由图 12 可知，测试集在 $L=(1,2,3)$ 上表现出了较好的鲁棒性。结合图 12 和图 10 可知，当输入为相邻 2 个子载波时，PDAAB 的性能略优于单载波输入，并且 PDAAB 的性能要整体优于 Deep CNN。结果表明，当输入为相邻 2 个子载波时，PDAAB 的性能有了进一步提升并且仍具有鲁棒性。

本节研究了在 2 个子载波上的联合信道估计的情况。训练数据采用了 UMi 街道 NLOS 场景，测试阶段在 UMi 街道 NLOS 场景和城市宏小区 (UMa) 街道 NLOS 场景下进行。UMa NLOS 场景

在功率、天线高度和基站分布等方面与 UMi 街道 NLOS 场景有较大差异。在 2 个相邻子载波上不同场景下的归一化均方误差如图 13 所示。由图 13 可知, PDAAB 在不同的场景下仍具有较好的鲁棒性, 并且性能优于 Deep CNN。而非理想 MMSE 由于对信道信息的高度依赖, 性能损失较大。




图 12 在 2 个相邻子载波上不同主路径数下的归一化均方误差

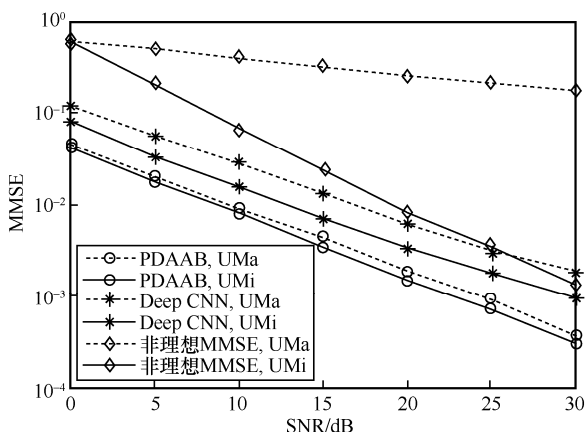


图 13 在 2 个相邻子载波上不同场景下的归一化均方误差

表 5 对上述几种深度学习信道估计算法进行了复杂度比较。这里主要比较了模型的时间复杂度和空间复杂度。时间复杂度采用浮点运算 (FLOP, floating point operation) 衡量模型所需计算量, 空间复杂度采用参数量衡量算法在运行过程中临时占用的存储空间大小。从表 5 可以看出, PDAAB 在计算复杂度上远低于其他 3 种算法, Deep CNN 次之。根据文献[26]可知, MMSE 的计算复杂度约为 1.4×10^8 , 高于 PDAAB 和 Deep CNN。经实验得出, PDAAB 每一轮迭代训练的时间约为 20 s, Deep CNN 和

DNCNN 计算时间分别为约 86 s 和约 180 s, 这表明 PDAAB 具有较高的训练效率, 计算成本显著降低。同时, 文献[23]证明了随着 AAB 的叠加, 模型的性能会有所提升。所以通过少量的复杂度的增加, 可以换取模型的性能, 使 PDAAB 网络可以根据不同的使用需求, 寻找一个复杂度和性能之间的平衡。

表 5 不同算法的复杂度

算法	参数量/个	浮点运算/FLOP
ChannelNet	0.8×10^6	3 7620 9408
DNCNN	0.7×10^6	3 4386 7392
Deep CNN	0.04×10^6	1 1442 5856
AAB	0.05×10^6	2541 6100
PDAAB	1.1×10^6	3352 3364

4 结束语

本文针对 OFDM 系统提出了一种基于深度学习的信道估计去噪网络 PDAAB。首先, 将导频位置的信道时频响应进行初步估计, 获得含噪声的低分辨率信道图像, 并将其作为 PDAAB 得到输入。然后, 通过 PDAAB 恢复相对应的高分辨率估计信道。最后, 通过不同场景下的信道估计问题对 PDAAB 的性能进行了测试。通过仿真实验表明, 本文提出的 PDAAB 在低复杂度的情况下, 针对 SISO-OFDM 系统和 MIMO-OFDM 系统都具有良好的估计性能, 并且在不同的信道环境具有良好的鲁棒性。同时, 该模型可以通过动态注意力机制模块 AAB 的数量调整, 获得一个所需的复杂度和性能之间的平衡。

参考文献:

- [1] 任斌, 张振宇, 方荣一, 等. 面向 5G-Advanced 无线系统的高精度定位技术[J]. 电信科学, 2022, 38(3): 65-73.
REN B, ZHANG Z Y, FANG R Y, et al. High-accuracy positioning for 5G-Advanced wireless systems[J]. Telecommunications Science, 2022, 38(3): 65-73.
- [2] 何彬, 李国兵, 陈源, 等. 基于图信号处理的 OFDM 系统导频设计和信道估计方法[J]. 物联网学报, 2022, 6(3): 91-102.
HE B, LI G B, CHEN Y, et al. Graph signal processing based pilot pattern design and channel estimation for OFDM system[J]. Chinese Journal on Internet of Things, 2022, 6(3): 91-102.
- [3] 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.
- [4] XU W H, WU Z Z, UENG Y L, et al. Improved polar decoder based on deep learning[C]//Proceedings of IEEE International Workshop on Signal Processing Systems (SiPS). Piscataway: IEEE Press, 2017: 1-6.
- [5] YAN L C, WANG Y, ZHENG N. 5G massive MIMO signal detection

- algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2022, 2022: 1-9.
- [6] CHENG X, LIU D J, WANG C, et al. Deep learning-based channel estimation and equalization scheme for FBMC/OQAM systems[J]. IEEE Wireless Communications Letters, 2019, 8(3): 881-884.
- [7] 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 channel estimation in FDD massive MIMO systems[J]. Journal on Communications, 2021, 42(8): 61-69.
- [8] 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.
- [9] 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.
- [10] HUANG H J, YANG J, HUANG H, et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system[J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8549-8560.
- [11] YANG Y W, GAO F F, MA X L, et al. Deep learning-based channel estimation for doubly selective fading channels[J]. IEEE Access, 2019, 7: 36579-36589.
- [12] 王莹, 任军, 史可, 等. 基于深度学习的广义频分复用系统时频双选择信道估计[J]. 通信学报, 2021, 42(10): 233-242.
- WANG Y, REN J, SHI K, et al. Doubly-selective channel estimation for generalized frequency division multiplexing systems based on deep learning[J]. Journal on Communications, 2021, 42(10): 233-242.
- [13] WANG T Q, WEN C K, JIN S, et al. Deep learning-based CSI feedback approach for time-varying massive MIMO channels[J]. IEEE Wireless Communications Letters, 2019, 8(2): 416-419.
- [14] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [15] 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.
- [16] WANG Y, HUANG H, XU Q, et al. Practical deep raw image denoising on mobile devices[C]//Proceedings of Computer Vision-ECCV 2020. Berlin: Springer, 2020: 1-16.
- [17] ZHAO J H, LIU J, YANG L H, et al. Future 5G-oriented system for urban rail transit: opportunities and challenges[J]. China Communications, 2021, 18(2): 1-12.
- [18] MUMTAZ S, RODRIGUEZ J, DAI L. mmWave massive MIMO: a paradigm for 5G[M]. Pittsburgh: Academic Press, 2016.
- [19] ALKHATEEB A, AYACH O E, LEUS G, et al. Channel estimation and hybrid precoding for millimeter wave cellular systems[J]. IEEE Journal of Selected Topics in Signal Processing, 2014, 8(5): 831-846.
- [20] WANG Y C, XU W, ZHANG H, et al. Wideband mmWave channel estimation for hybrid massive MIMO with low-precision ADCs[J]. IEEE Wireless Communications Letters, 2019, 8(1): 285-288.
- [21] 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.
- [22] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 1800-1807.

- [23] CHEN H, GU J, ZHANG Z. Attention in attention network for image super-resolution[J]. arXiv Preprint, arXiv: 2104.09497, 2021.
- [24] CHEN Y P, DAI X Y, LIU M C, et al. Dynamic convolution: attention over convolution kernels[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 11027-11036.
- [25] LOSHCILLOV I, HUTTER F. Decoupled weight decay regularization[J]. arXiv Preprint, arXiv: 1711.05101, 2017.
- [26] 3GPP. Study on channel model for frequencies from 0.5 to 100 GHz (Release 16): TR 38.901 V16.1.0 [S]. 2019.

[作者简介]



张昀 (1975-), 女, 江苏南京人, 博士, 南京邮电大学副教授, 主要研究方向为智能化算法与通信信号处理。



周婧 (1998-), 女, 江苏常州人, 南京邮电大学硕士生, 主要研究方向为深度学习与信号处理。



黄经纬 (2001-), 男, 江苏淮安人, 南京邮电大学硕士生, 主要研究方向为深度学习与信号处理。



于舒娟 (1967-), 女, 江苏南京人, 南京邮电大学教授, 主要研究方向为自适应信号处理、深度学习和智能大数据处理。



黄丽亚 (1972-), 女, 湖南绥宁人, 博士, 南京邮电大学教授, 主要研究方向为通信网络的 QoS 性能研究自适应信号处理、深度学习和智能大数据处理。