

许喆, 郝传辉, 赵一, 等. 基于多尺度卷积神经网络的大规模 MIMO 系统混合波束成形方法[J]. 智能计算机与应用, 2025, 15(12): 144-150. DOI:10.20169/j.issn.2095-2163.25050601

基于多尺度卷积神经网络的大规模 MIMO 系统 混合波束成形方法

许喆^{1,2}, 郝传辉², 赵一², 陶振钊², 王洪丰²

(1 吉林化工大学 信息与控制工程学院, 吉林 吉林 132022; 2 德州学院 计算机与信息学院, 山东 德州 253023)

摘要: 针对毫米波大规模多输入多输出 (Multiple-Input Multiple-Output, MIMO) 系统中混合波束成形 (Hybrid Beamforming, HBF) 因不完美信道状态信息 (Channel State Information, CSI) 导致的频谱效率退化问题, 本文提出了一种基于深度学习的端到端神经网络优化方法。首先, 多尺度卷积神经网络模型优化模拟预编码器, 通过以负的优化目标为损失函数实现端到端优化; 其次, 再通过传统零强迫 (Zero Forcing, ZF) 方法优化数字预编码器, 以最小化多用户间干扰并提升系统在有限频谱资源下的传输效率。仿真结果表明, 与传统波束成形方法及其他深度学习方法相比, 本文所提出的两阶段优化方法在频谱效率方面具有显著优势。

关键词: 毫米波大规模多输入多输出; 混合波束成形; 深度学习; 频谱效率

中图分类号: TN911.23

文献标志码: A

文章编号: 2095-2163(2025)12-0144-07

Hybrid beamforming design for large-scale MIMO systems based on multi-scale convolutional neural networks

XU Zhe^{1,2}, HAO Chuanhui², ZHAO Yi², TAO Zhenzhao², WANG Hongfeng²

(1 School of Information and Control Engineering, Jilin University of Chemical Technology, Jilin 132022, Jilin, China;

2 School of Computer and Information, Dezhou University, Dezhou 253023, Shandong, China)

Abstract: To address spectral efficiency degradation in millimeter-wave (mmWave) massive Multiple-Input Multiple-Output (MIMO) systems caused by imperfect channel state information (CSI), this paper proposes an end-to-end deep learning-based neural network optimization method for hybrid beamforming (HBF). The proposed approach employs a two-stage strategy. Firstly, a deep learning model utilizing multi-scale convolutional neural networks is developed to optimize the analog precoder through end-to-end training, with the negative spectral efficiency as the loss function. Secondly, a conventional zero-forcing (ZF) method is employed to design the digital precoder, minimizing multi-user interference and further enhancing transmission efficiency under limited spectral resources. Simulation results demonstrate that the proposed two-stage optimization approach significantly improves spectral efficiency compared to traditional beamforming algorithms and existing deep learning-based methods.

Key words: millimeter-wave MIMO; hybrid beamforming; deep learning; spectral efficiency

0 引言

随着 5G 移动通信技术的快速发展, 无线通信系统对频谱利用率、传输速率及能量效率提出了更高要求。毫米波 (mmWave) 频段因其丰富的频谱资源和高带宽特性, 成为支撑 5G 高数据率、大容量传输的关键技术^[1-3]。然而, 毫米波信号在传播过程

中存在路径损耗大、穿透能力弱等问题。大规模多输入多输出 (Massive MIMO) 技术凭借其增强的空间复用能力, 有效克服了毫米波信号的传播瓶颈。传统 MIMO 系统多采用全数字波束成形 (Digital Beamforming), 尽管具备高度的信号处理灵活性, 但其对射频链路的高需求使得系统复杂度与功耗随天线规模增加而急剧上升, 限制了其在大规模系统中的

基金项目: 德州学院学科(平台)建设(023XKZX017); 德州市市级研发计划项目(2022dzkj097)。

作者简介: 许喆(2001—), 男, 硕士研究生, 主要研究方向: 自适应波束成形。

通信作者: 王洪丰(1981—), 男, 博士, 教授, 主要研究方向: 大数据挖掘, 机器学习。Email: dzuhwf@163.com。

收稿日期: 2025-05-06

应用^[4]。为此,混合波束成形(Hybrid Beamforming, HBF)架构应运而生,通过融合模拟与数字波束成形技术,在显著降低硬件成本与能耗的前提下,实现接近全数字方案的通信性能^[5]。

尽管混合波束成形架构能够较好地适应毫米波信道的稀疏性与多径特性,其优化过程仍面临诸多挑战,尤其是在模拟预编码器中,信号通过相位移器调控,受到非凸恒模约束的限制,使得问题求解复杂度显著增加。文献[6]提出了基于正交匹配追踪(OMP)算法,但其依赖于预设的模拟波束成形器码本,难以实现全局最优;文献[7]提出了基于流形优化交替最小化(MO-AltMin)方法,将混合预编码建模为矩阵分解问题,并在特定条件下提升了收敛性;文献[8]采用启发式搜索策略,设计模拟预编码矩阵,在一定程度上改善了搜索效率。然而,上述方法普遍假设完美的信道状态信息(Channel State Information, CSI),但在实际通信中,当 CSI 存在误差时,其系统性能显著退化,难以保障预编码设计的鲁棒性与泛化能力^[9]。

近年来,深度学习(Deep Learning, DL)因其强大的特征提取与非线性建模能力,逐渐被引入无线通信中的波束成形优化研究。文献[9]利用深度神经网络(Deep Neural Network, DNN)学习毫米波信道的结构特征,构建混合波束成形方案,有效降低了计算复杂度并提升频谱效率;文献[10]提出结合奇异值分解(Singular Value Decomposition, SVD)和深度学习的混合波束成形策略,借助神经网络近似求解 SVD 矩阵,提升了预编码器设计的效率与精度。然而,上述方法均依赖监督学习框架,需大量标注数据,难以适应真实通信环境下的动态变化^[11]。文献[11]提出了波束成形神经网络(Beamforming Neural Network, BFNN),采用多层全连接网络,在不完美 CSI 条件下实现无监督学习以提升频谱效率,但其迭代开销较大;文献[12]引入卷积神经网络(Convolutional Neural Network, CNN),构建低复杂度波束优化模型,但受限于单尺度卷积结构,其特征提取能力存在不足。

本文提出一种基于多尺度卷积(Multi-Scale Convolution Neural Network, MSCNN)的端到端混合波束成形优化方法,采用两阶段结构以兼顾性能与计算效率。第一阶段多尺度卷积神经网络模型对模拟预编码器进行端到端优化,模型融合多尺度卷积结构,兼顾毫米波信道的全局与局部特征表达,显著增强了对不完美信道状态信息条件下信道特性的建

模能力,弥补了单一尺度卷积特征提取能力不足的问题;第二阶段在优化完成的模拟预编码器基础上,引入零强迫(Zero Forcing, ZF)方法,设计数字预编码器,以降低联合优化问题的求解复杂度与运算负担,提升系统在不完美 CSI 环境下的频谱效率与鲁棒性。

1 系统模型和问题公式

本文选用一个多用户毫米波下行链路混合波束成形系统,由一个基站和多个单天线用户组成,基站采用全连接式架构。毫米波 MIMO 系统模型图如图 1 所示,假设基站配备 N_T 个均匀线性阵列天线(Uniform Linear Array, ULA)和 N_{RF} 条射频链(RF Chains),用于同时服务 k 个单天线用户。为了保证系统的服务能力与资源分配匹配,用户数与射频链数量之间需要满足约束条件: $K \leq N_{RF} \leq N_T$,即用户数不得超过射频链数,射频链数也不得超过天线数。

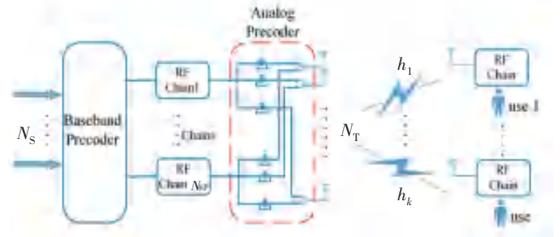


图 1 毫米波 MIMO 系统模型图

Fig. 1 System model of the millimeter-wave MIMO communication system

在混合波束成形架构中,基站信号首先通过基带数字预编码器处理,随后经由数模转换器和模拟相移器实现模拟波束成形,最终生成发射信号。发射信号可表示为:

$$\mathbf{X} = \mathbf{V}_{RF} \mathbf{V}_{BB} \mathbf{s} \quad (1)$$

其中, $\mathbf{V}_{RF} \in C^{N_T \times N_{RF}}$ 为模拟预编码器, $\mathbf{V}_{BB} = [v_1, \dots, v_k] \in C^{N_{RF} \times K}$ 表示数字预编码器, $\mathbf{s} = [s_1, \dots, s_k]^T$ 为用户数据符号向量。

假设各用户信号之间相互独立且功率归一,对于用户信号的约束条件: $\mathbf{E}[|s_i|^2] = 1, \mathbf{E}[s_i s_j] = 0, \forall i \neq j$ 。模拟预编码器由可调相移器实现,为满足硬件约束,其每个元素需满足恒模约束条件 $|V_{RF}(i, j)| = \frac{1}{\sqrt{N_T}}, i = 1, \dots, N_T; j = 1, \dots, N_{RF}$,同时,为满足系统功率限制,整体混合预编码矩阵需满足总发射功率约束: $\|\mathbf{V}_{RF} \mathbf{V}_{BB}\|_F^2 \leq P_{\max}$ 。

信号通过混合预编码后,基站发射信号 \mathbf{X} 经由毫米波信道传输,第 k 个用户接收到的信号可表示为:

$$\mathbf{y}_k = \mathbf{h}_k^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},k} \mathbf{s}_k + \sum_{i \neq k} \mathbf{h}_k^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},i} \cdot \mathbf{s}_i + \mathbf{n}_k \quad (2)$$

其中, \mathbf{s}_k 表示第 k 个用户的数据符号, $\mathbf{h}^H \in \mathbb{C}^{1 \times N_T}$ 为第 k 个用户对应的下行信道, \mathbf{n}_k 为加性高斯白噪声,服从高斯分布 $\mathbf{n}_k \sim CN(0, \sigma^2)$, 第二项 $\sum_{i \neq k} \mathbf{h}_k^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},i} \cdot \mathbf{s}_i$ 表示来自其他用户信号的串扰干扰项。

本文采用广泛应用于毫米波通信系统中的 Saleh-Valenzuela (SV) 信道模型对下行链路建模,有效刻画毫米波信道中的稀疏多径特性。假设第 k 个用户的信道包含 L_k 条传播路径,其中包括 1 条视距 (Line-of-Sight, LOS) 路径和 $l_k - 1$ 条非视距 (Non-Line-of-Sight, NLOS) 路径。基站至第 k 个用户的信道向量可表示为

$$\mathbf{h}_k = \sqrt{\frac{N_T}{L_k}} \sum_{l=1}^{L_k} \alpha_{k,l} \partial_l^H(\phi_{k,l}) \quad (3)$$

其中, $\alpha_{k,l}$ 为第 k 个用户第 l 条路径的复增益系数,综合考虑路径损耗和小尺度衰落; $\phi_{k,l}$ 为该路径的离开角 (Azimuth Angle of Departure, AOD); $\partial_l(\phi_{k,l}) \in \mathbb{C}^{N_T \times 1}$ 为发射端的阵列方向矢量,其表达式为:

$$\partial_l(\phi) = \frac{1}{\sqrt{N_T}} [1, e^{j\frac{2\pi d}{\lambda} \sin(\phi)}, \dots, e^{j\frac{2\pi d}{\lambda} (N_T-1) \sin(\phi)}]^T \quad (4)$$

其中, λ 为信号的波长, d 为天线间距。

本文整体下行信道矩阵为 $\mathbf{H} = [\mathbf{h}_1^H, \mathbf{h}_2^H, \dots, \mathbf{h}_K^H]^H \in \mathbb{C}^{K \times N_T}$ 。为进一步刻画信道统计特性,假设路径增益满足 $\alpha_{k,l} \sim CN(0, \sigma_\alpha^2)$, 出射角服从均匀分布,即 $\phi_{k,l} \sim u[0, 2\pi]$, 以反映毫米波信道中路径稀疏和方向分布广泛的特点。

本系统的优化目标是最大化频谱效率 (Spectral Efficiency, SE), 而接收端的信干噪比 (Signal-to-Interference-plus-Noise Ratio, SINR) 直接影响每个用户的通信性能。对于第 k 个用户, 其 SINR 定义为:

$$\text{SINR}_K = \frac{|\mathbf{h}_K^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},k}|^2}{\sum_{i \neq k} |\mathbf{h}_K^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},i}|^2 + \sigma^2} \quad (5)$$

其中, $\mathbf{V}_{\text{BB},k}$ 表示第 k 个用户的数字预编码向量, σ^2 为高斯噪声功率。系统的总频谱效率定义为所有用户的传输速率之和:

$$\mathbf{R} = \sum_{k=1}^K \log_2(1 + \text{SINR}_K) \quad (6)$$

因此,系统的优化目标可形式化表述为下式所示的约束优化问题:

$$\begin{aligned} \text{maximize}_{\mathbf{V}_{\text{RF}}, \mathbf{V}_{\text{BB}}} \quad & \mathbf{R} = \sum_{k=1}^K \log_2(1 + \text{SINR}) \\ \text{s. t.} \quad & |\mathbf{V}_{\text{RF}}(i, j)| = \frac{1}{\sqrt{N_T}}, \forall i, j \\ & \|\mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB}}\|_F^2 \leq \mathbf{P}_{\text{max}} \end{aligned} \quad (7)$$

2 混合波束成形设计

本文提出了一种基于多尺度卷积神经网络的端到端优化方法,用于毫米波混合波束成形系统中模拟预编码器的优化。与传统单尺度卷积网络不同,该方法采用并行的多尺度卷积核,同时提取毫米波信道的局部与全局特征,并结合残差网络 (Residual Network, ResNet), 有效缓解深层网络训练中的梯度消失问题。此外,为避免依赖大量的标注数据,该方法采用了无监督学习策略,通过以频谱效率的负值作为损失函数,实现端到端的模型优化。在模拟预编码器优化完成后,进一步采用 ZF 方法设计数字预编码器,提高系统在不完美 CSI 条件下的频谱效率和鲁棒性。多尺度卷积网络模型图如图 2 所示。

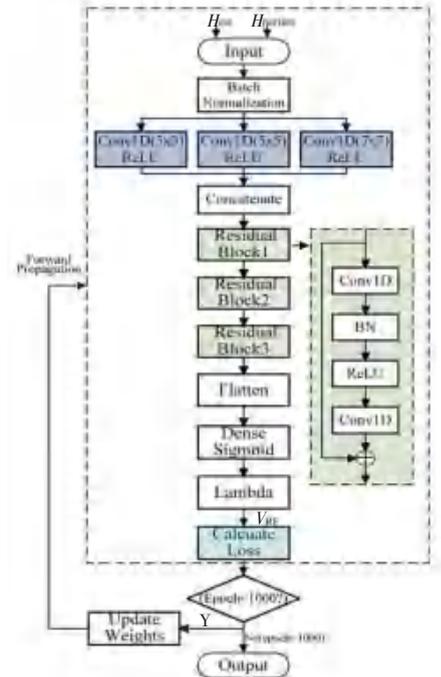


图2 多尺度卷积网络模型图

Fig. 2 Architecture of the proposed network model

2.1 多尺度卷积神经网络模型

根据系统模型构建混合波束成形系统,通过系统仿真生成 SV 信道数据,并使用一种毫米波信道估计器获得不完美 CSI 矩阵 $\mathbf{H}_{\text{est}} \in \mathbb{C}^{K \times N_T}$, 该估计器利用分层码本中的波束成形器发送导频信号,并依据用户反馈信号完成信道估计。通过设置信道估计过程中的 SINR, 可以获取不同误差水平的不完美 CSI 数据,以增强模型训练时的数据多样性。

考虑到输入信道矩阵 \mathbf{H}_{est} 为复数张量,为便于卷积网络计算,首先将复数信道矩阵 \mathbf{H}_{est} 分解为实部 $\mathbf{H}_{\text{real}} \in \mathbb{R}^{K \times N_T}$ 和虚部 $\mathbf{H}_{\text{imag}} \in \mathbb{R}^{K \times N_T}$, 再沿特征维度拼接,构成三维实数张量作为网络输入,即: $\mathbf{X} \in \mathbb{R}^{K \times N_T \times 2}$ 。

本文提出的方法将输入张量 \mathbf{X} 并行送入多个不同尺度的一维卷积层,卷积核尺寸为 3×3 、 5×5 、 7×7 , 分别捕获毫米波信道的局部和全局空间特征。随后,将三路特征在通道维度拼接,如下式:

$$\mathbf{F}_{\text{concat}} = [\mathbf{F}_{3 \times 3} \oplus \mathbf{F}_{5 \times 5} \oplus \mathbf{F}_{7 \times 7}] \quad (8)$$

为进一步缓解因不完美 CSI 带来的梯度消失及训练不稳定性问题,特征拼接后引入多层残差网络模块,从更深层次挖掘信道数据的高维抽象特征,显著提升了模型的表达能力与训练效率,增强了优化过程的稳定性。

残差网络的输出特征记为 $\mathbf{X}_{\text{out}} \in \mathbb{R}^{B \times N_T \times C}$, 需映射为模拟预编码器所需的相位参数。为此,首先针对 \mathbf{X}_{out} 进行展平操作,将其转换为一维向量形式,如下式:

$$\tilde{\mathbf{X}} = \text{Flatten}(\mathbf{X}_{\text{out}}) \in \mathbb{R}^{B \times N_T \times C} \quad (9)$$

随后通过批量归一化 (Batch Normalization, BN) 层降低特征尺度差异,并经隐藏层映射生成相位向量 $\boldsymbol{\theta}$, 具体可以表示如下式:

$$\tilde{\mathbf{X}}_{\text{bn}} = \text{BN}(\tilde{\mathbf{X}}) \quad (10)$$

输出向量 $\mathbf{X}_{\text{phase}}$ 表示模拟预编码器的相位归一化参数:

$$\mathbf{X}_{\text{phase}} = \sigma(\mathbf{W}_o \tilde{\mathbf{X}}_{\text{bn}} + \mathbf{b}_o) \quad (11)$$

其中, $\sigma(\cdot)$ 为 Sigmoid 激活函数,用于将输出值映射到区间 $(0, 1)$, 为后续在 Lambda 层中映射到 $[0, 2\pi)$ 做好准备, \mathbf{W}_o 、 \mathbf{b}_o 分别为权重矩阵与偏置向量。

在网络输出与天线数 N_T 相对应的相位参数向量 $\mathbf{X}_{\text{phase}} = \boldsymbol{\theta}$ 后,需要将该向量转换为复数值向量 \mathbf{V}_{RF} , 实现模拟预编码器的相位控制。为此,本文在

模型末端添加了自定义的 Lambda 层。具体来说,为满足模拟预编码器的恒模约束,通过 Lambda 层将相位参数向量 $\boldsymbol{\theta}$ 转换为复数域预编码矩阵 \mathbf{V}_{R} :

$$\mathbf{V}_{\text{RF}} = \frac{1}{\sqrt{N_T}} \mathbf{e}^{j \cdot 2\pi \boldsymbol{\theta}} = \frac{1}{\sqrt{N_T}} (\cos(2\pi \boldsymbol{\theta}) + j \cdot \sin(2\pi \boldsymbol{\theta})) \quad (12)$$

2.2 无监督学习策略

为实现 \mathbf{V}_{RF} 的端到端优化,将负的频谱效率作为损失函数。相比依赖标注数据的监督方法,无监督思路在实际通信场景中更具可行性。具体而言,以理想 CSI 下系统频谱效率的负值作为损失函数,引导网络参数更新,从而使 \mathbf{V}_{RF} 逐渐逼近理想性能。损失函数定义如下式,该损失函数能够直接体现 \mathbf{V}_{RF} 对平均系统传输速率的影响。

$$\text{loss} = -\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K \log_2 \left(1 + \frac{|\mathbf{h}_{k,n}^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},k}|^2}{\sum_{i \neq k} |\mathbf{h}_{k,n}^H \mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB},i}|^2 + \sigma^2} \right) \quad (13)$$

其中, N 表示训练批次内的样本数量, $\mathbf{h}_{k,n}^H$ 表示第 n 个样本中第 k 用户的理想信道向量。

为有效启动网络训练,首先对 \mathbf{V}_{RF} 进行随机初始化,初始值定义如下式:

$$\mathbf{V}_{\text{RF}}^{(0)}(i, j) = \frac{1}{\sqrt{N_T}} \mathbf{e}^{j \cdot \boldsymbol{\theta}_{i,j}}, \boldsymbol{\theta}_{i,j} \sim \mathbf{u}(0, 2\pi) \quad (14)$$

其中, $\boldsymbol{\theta}_{i,j}$ 随机相位角均匀分布于区间 $[0, 2\pi]$, 以确保模拟预编码矩阵满足恒模约束。

随后,利用 ZF 方法为给定的初始模拟预编码矩阵计算初始数字预编码矩阵 $\mathbf{V}_{\text{BB}}^{(0)}$: $\mathbf{V}_{\text{BB}}^{(0)} = (\mathbf{H} \mathbf{V}_{\text{RF}}^{(0)})^+$, 其中 $(\mathbf{H} \mathbf{V}_{\text{RF}}^{(0)})^+$ 表示 $\mathbf{H} \mathbf{V}_{\text{RF}}^{(0)}$ 的伪逆。

在训练过程中,每个训练周期首先固定当前的 \mathbf{V}_{BB} , 通过反向传播更新网络参数以优化 \mathbf{V}_{RF} 。随后,基于更新后的 \mathbf{V}_{RF} , 在下一个周期重新计算 \mathbf{V}_{BB} 。该循环持续迭代,直至模型收敛,从而确保模拟和数字预编码器之间实现协同适配,最大化系统频谱效率。

在训练阶段结束, \mathbf{V}_{RF} 已完成优化,为进一步提高系统频谱效率,利用正则化零强迫方法重新计算 \mathbf{V}_{BB} :

$$\mathbf{V}_{\text{BB}} = (\hat{\mathbf{H}} \mathbf{V}_{\text{RF}})^H (\hat{\mathbf{H}} \mathbf{V}_{\text{RF}} (\hat{\mathbf{H}} \mathbf{V}_{\text{RF}})^H + \varepsilon \mathbf{I})^{-1} \quad (15)$$

其中, $\varepsilon = 10^{-6}$ 抑制病态矩阵影响。

此外,为满足系统发射功率约束 $\|\mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB}}\|_F^2 \leq \mathbf{P}_{\text{max}}$, 需对 \mathbf{V}_{BB} 进行如下归一化操作:

$$\mathbf{V}_{\text{BB}} \leftarrow \frac{\sqrt{\mathbf{P}_{\text{max}}}}{\|\mathbf{V}_{\text{RF}} \mathbf{V}_{\text{BB}}\|_F} \mathbf{V}_{\text{BB}} \quad (16)$$

其中, $\|\cdot\|_{Fro}$ 表示 Frobenius 范数。

上述归一化步骤确保了系统发射功率不超过预设的最大功率限制,从而在提高频谱效率的同时兼顾了能效和稳定性。需要强调的是,ZF 方法适用于用户数 K 不超过射频链路数 N_{RF} 且有效信道矩阵 $\hat{H}V_{RF}$ 满秩的条件下。此时,ZF 算法能够有效地消除用户间的干扰,提升系统的整体传输性能。

3 仿真参数设置与仿真结果分析

3.1 仿真参数设置

本文仿真考虑多用户毫米波下行链路系统,基站配置 $N_T = 64$ 个 ULA 发射天线,天线间距 $d = \frac{\lambda}{2}$ 。

基站端射频链数量设定为 $N_{RF} = 3$, 根据系统的约束条件,即 $K \leq N_{RF} \leq N_T$, 用户数量设置为 $K = 2$, 每个用户配备单天线,形成典型的多用户通信场景。系统采用的毫米波信道模型为 SV 模型,每个用户的传播路径数为 $L_k = 3(1LOS + 2NLOS)$ 本文所提出模型参数见表 1。

表 1 MSCNN 模型参数

Table 1 Parameter settings of the MSCNN model

层	输出维度	激活函数	参数量
输入层	$N_T \times K \times 2$		0
多尺度卷积	$N_T \times K \times 48$		1 751
残差连接层	$N_T \times K \times 16$	ReLU	1 440
展平层	$N_T \times K \times 64$		0
隐藏层	$N_T \times K \times 1$	Sigmoid	134 484
Lambda 层	$N_T \times K \times 1$		0

在仿真中,共生成 10^4 组信道样本,按 4 : 1 的比例随机划分训练集与验证集,分别用于模型训练与泛化能力监控。此外,生成相同数量 SNR = 20 dB 时的信息样本作为验证集。网络训练采用批次大小 (Batch size) 为 128, 训练周期 (epoch) 数量设定为 1 000。优化器采用 Adam 优化器,初始学习率为 10^{-3} 。为进一步提升训练稳定性和防止过拟合,训练过程采用 Keras 框架中的 ReduceLROnPlateau 和 ModelCheckpoint 回调函数。当连续 20 个 epoch 验证损失未降低时,自动将学习率减小为当前值的 20%,并设定最小学习率为 10^{-4} 。同时,ModelCheckpoint 回调函数监测验证损失,保留验证集表现最优的模型权重。

实验使用的硬件平台为运行 Windows 11 操作系统的计算机,配备 AMD Ryzen 5 5600 CPU 和

NVIDIA GeForce RTX 2060S GPU,提供文档运算支持、加速矩阵运算并加快训练。软件环境为 Python 3.6,配合 TensorFlow 2.3.0 深度学习框架,确保模型的搭建、训练和优化的稳定性和高效性。

3.2 仿真结果分析

为了有效评估所提出的 MSCNN 模型性能,本文首先验证了多尺度卷积模块在信道特征提取方面的有效性;其次,分析了在不同信噪比水平的信道估计误差条件下所提方法的鲁棒性;最后,将所提出方法 (MSCNN) 与两种传统方法即 MO-AltMin 方法与 Heuristic 方法以及两种深度学习方法即 CNN 方法和 FCNN 方法进行性能比较。

首先验证了多尺度卷积核在 SINR = 20 dB 且信道估计路径数准确,即 $L_{est} = 3$ 条件下的有效性。不同卷积核下的性能比较如图 3 所示,可见多尺度卷积核配置相比单尺度卷积核显著提升了频谱效率,且优势在高信噪比区间更加明显。其中,3×3、5×5、7×7 组合的多尺度配置表现最佳,在 SNR 为 20 dB 时,频谱效率达到 14 bit/s/Hz,较其他多尺度配置和单尺度配置分别提升约 5% 和 13%。相比之下,单尺度卷积核 3×3 与 5×5 配置的性能明显较差,在 SNR = 20 dB 时的频谱效率仅为 12.37 bit/s/Hz (3×3) 和 12.19 bit/s/Hz (5×5)。

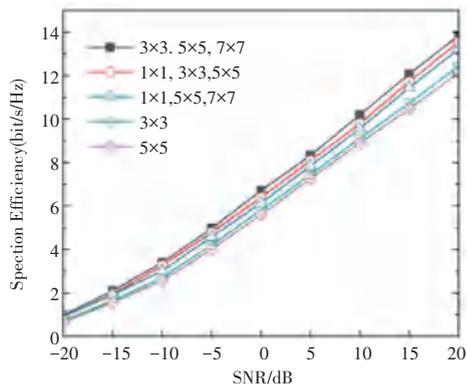


图 3 不同卷积核下的性能比较

Fig. 3 Performance comparison under different convolution kernel sizes

不同数量 (1~4 个) 残差块对频谱效率 (SE) 的影响如图 4 所示,可见当残差块数量为 3 时,模型性能达到最佳;从 1 个增至 2 个时,性能明显提高,说明浅层网络特征提取不足;进一步增加至 4 个时,SE 提升趋于饱和,可能因网络过深引发过拟合问题。因此,后续实验中残差块数量选为 3,以平衡性能与计算复杂性。

不同信道估计 SNR 条件下模型 SE 的鲁棒性结

果如图 5 所示。整体来看, SE 随通信 SNR 的增加而提高, 但不同估计 SNR 数据集之间的性能差异较小, 特别是在低通信 SNR 区域 ($-20 \sim 0$ dB), 差距几乎可忽略。例如, 当通信 SNR 为 0 dB 时, 不同估计 SNR 的 SE 差异不足 0.4 bit/s/Hz, 体现了模型优异的泛化能力。在高通信 SNR 条件, 如 20 dB 下, 即使信道估计 SNR 为 -20 dB 与 30 dB 的情况相比, SE 差距也不超过 1 bit/s/Hz, 表明本文所提出的模型在不同程度的信道估计误差下均保持了稳定的性能, 具有良好的鲁棒性。

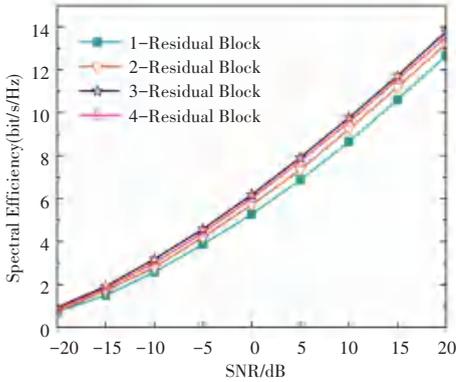


图 4 不同残差块数量的性能比较

Fig. 4 Performance comparison with varying numbers of residual blocks

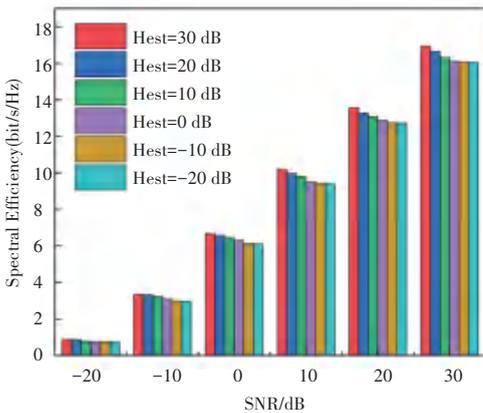
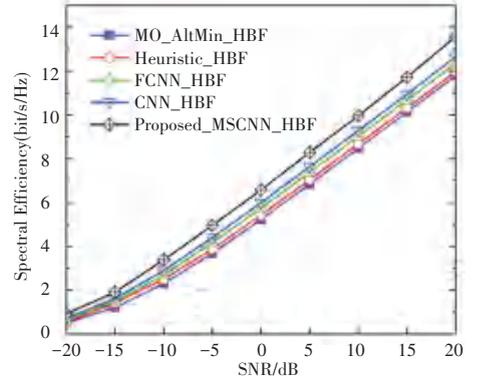


图 5 不同信道估计 SNR 下模型鲁棒性分析

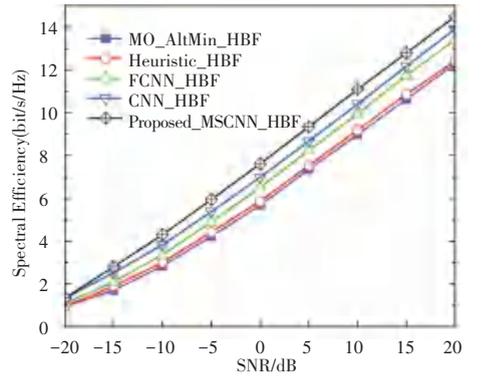
Fig. 5 Robustness analysis of the model under different channel estimation SNR levels

在天线数为 $N_T = 64$ 和 $N_T = 128$ 时, 不同 HBF 方案的 SE 性能如图 6 所示, 可明显看出基于深度学习的波束成形算法 CNN-HBF 和 FCNN-HBF 在中高 SNR 区域的表现显著优于传统算法 MO-AltMin-HBF 和 Heuristic-HBF。本文提出的 MSCNN-HBF 方案在整个 SNR 范围内均取得了最优性能, 当 $N_T = 64$ 时, MSCNN-HBF 在高 SNR 下的性能优势尤为突

出; 随着天线数量增加至 128, 各方案的 SE 均有所提高, 但 MSCNN-HBF 方案仍然保持了明显的性能优势, 表明本文提出的多尺度卷积优化方法在毫米波大规模天线系统中具有优异的适应性和鲁棒性。



(a) $N_T = 64$



(b) $N_T = 128$

图 6 不同混合波束成形算法的 SE 对比

Fig. 6 Spectral efficiency comparison of different hybrid beamforming algorithms

4 结束语

本文构建了两阶段混合波束成形方法, 先以多尺度卷积残差网络无监督优化模拟预编码器, 再用零强迫方法设计数字预编码器。仿真表明, 对比传统方法及深度学习算法, 所提方法在不同信道估计误差、天线规模和信噪比条件下均表现出最优的频谱效率。此外, 所提方法在低估计信噪比条件下仍能保持较高的性能水平, 展示出优异的泛化能力与鲁棒性, 为毫米波大规模 MIMO 系统提供了稳定且高效的波束成形解决方案。

参考文献

- [1] ALKHATEEB A, EI AYACH O, 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.
- [2] NIU Y, LI Y, JIN D, et al. A survey of millimeter wave

- communications (mmWave) for 5G: Opportunities and challenges [J]. *Wireless Networks*, 2015, 21: 2657–2676.
- [3] MIRZAEI J, SHAHBZPANAHI S, SOHRABI F, et al. Hybrid analog and digital beamforming design for channel estimation in correlated massive MIMO systems [J]. *IEEE Transactions on Signal Processing*, 2021, 69: 5784–5800.
- [4] 黄天赐, 杜江, 马腾, 等. 毫米波 MIMO 系统中基于 CNN 的混合波束成形设计[J]. *传感器与微系统*, 2023, 42(7): 78–82.
- [5] KEBEDE T, WONDIE Y, STEINBRUNN J, et al. Precoding and beamforming techniques in mmwave – massive MIMO: Performance assessment [J]. *IEEE Access*, 2022, 10: 16365 – 16387.
- [6] El AYACH O, RAJAGOPAL S, ABU–SURRA S, et al. Spatially sparse precoding in millimeter wave MIMO systems [J]. *IEEE Transactions on Wireless Communications*, 2014, 13(3): 1499–1513.
- [7] YU X, SHEN J C, ZHANG J, et al. Alternating minimization algorithms for hybrid precoding in millimeter wave MIMO systems [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2016, 10(3): 485–500.
- [8] SOHRABI F, YU W. Hybrid digital and analog beamforming design for large-scale antenna arrays [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2016, 10(3): 501–513.
- [9] HUANG H, SONG Y, YANG J, et al. Deep-learning-based millimeter-wave massive MIMO for hybrid precoding [J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(3): 3027 – 3032.
- [10] PEKEN T, ADIGA S, TANDON R, et al. Deep learning for SVD and hybrid beamforming [J]. *IEEE Transactions on Wireless Communications*, 2020, 19(11): 7345–7359.
- [11] LIN T, ZHU Y. Beamforming design for large-scale antenna arrays using deep learning [J]. *IEEE Wireless Communications Letters*, 2020, 9(1): 103–107.
- [12] ZHANG T, DONG A, ZHANG C, et al. Hybrid beamforming for MISO system via convolutional neural network [J]. *Electronics*, 2022, 11(14): 2213.