

面向空间非平稳太赫兹 UM-MIMO 信道估计的门控多尺度模型 驱动迭代网络

于舒娟, 卢宏宇, 孙洋, 蔡良隆, 管腾飞, 张昀, 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: 针对太赫兹 (terahertz, THz) 超大规模多输入多输出 (ultra-massive multiple-input multiple-output, UM-MIMO) 系统中混合场路径幅度随阵元位置连续变化带来的空间非平稳 (spatial non-stationarity, SnS) 信道估计难题, 本文首先将基于秩匹配的幅度衰减因子 (amplitude attenuation factor, AAF) 统计生成方法扩展至平面子阵列 (array-of-subarrays, AoSA) 混合场信道, 构建 AAF 型空间非平稳混合场信道估计场景; 然后, 创新性构建了门控通道交互模块 (GCIU)、多尺度特征融合模块 (MRFU) 和空间能量引导注意力模块 (SEGA), 构成门控多尺度注意力 (GMSA) 网络, 替代 PR-DEN 的非线性映射部分, 由此提出 PR-DEN-GMSA 算法用于估计 AAF 型空间非平稳混合场信道。仿真结果表明, 所提算法在所构建的 AAF 型空间非平稳混合场信道场景下, 三次独立训练的五点平均 NMSE 为 -17.076 ± 0.030 dB, 较 PR-DEN 改善 0.696 dB; 在参数量与运算量匹配条件下, NMSE 分别改善 1.023 dB 和 0.816 dB; 模型参数量与单次网络调用的理论 FLOPs 分别降低约 41.6% 和 22.1%。所提算法对测试范围内的 AAF 相关长度、子阵列间距和吸收系数变化表现稳定, 并在严重欠采样场景下具有更小的最大精度损失。

关键词: 太赫兹通信; 超大规模多输入多输出; 空间非平稳; 模型驱动迭代

中图分类号: TP309

文献标志码: A

A Gated Multi-Scale Model-Driven Iterative Network for Spatially Non-Stationary THz UM-MIMO Channel Estimation

YU Shujuan, LU Hongyu, Sun Yang, CAI Lianglong, GUAN Tengfei, ZHANG Yun, HUANG Liya

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

Abstract: To address spatially non-stationary (SnS) channel estimation in terahertz (THz) ultra-massive MIMO systems, where hybrid-field path amplitudes vary continuously across antenna elements, a rank-matching-based amplitude attenuation factor (AAF) generation method was extended to array-of-subarrays (AoSA) hybrid-field channels, and an AAF-based SnS hybrid-field estimation scenario was constructed. A gated multi-scale attention (GMSA) network comprising GCIU, MRFU, and SEGA was then developed to replace the nonlinear mapping in PR-DEN, yielding PR-DEN-GMSA. Simulations showed that its five-point average NMSE over three independent runs was -17.076 ± 0.030 dB, improving PR-DEN by 0.696 dB. Under parameter- and computation-matched settings, NMSE was improved by 1.023 dB and 0.816 dB, while the parameter count and per-call theoretical FLOPs were reduced by 41.6% and 22.1%. The proposed algorithm remains stable under the tested variations in AAF correlation length, inter-subarray spacing, and absorption coefficient, and achieves a smaller maximum NMSE degradation under severe undersampling.

Key words: terahertz communication, ultra-massive MIMO, spatial non-stationarity, model-driven iteration

收稿日期: 2026-XX-XX; 修回日期: 2026-XX-XX

通信作者: 黄丽亚, huangly@njupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61977039)

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

0 引言

太赫兹 (THz) 超大规模多输入多输出 (UM-MIMO) 系统通过大规模天线阵列提高频谱效率, 是第六代移动通信的重要研究方向^[1]。为兼顾阵列增益与硬件复杂度, 系统通常采用部分连接的平面子阵列 (AoSA) 架构^[2-3]。较大的阵列孔径使近场球面波与远场平面波可能同时存在, 形成混合场信道^[4]; 局部遮挡和非均匀散射又使信道响应随阵元位置变化, 呈现空间非平稳性^[5-6]。两类特性分别反映近远场路径响应的差异和路径幅度在阵列上的空间差异, 并共同影响信道估计。现有空间非平稳信道估计方法多面向近场传播场景, 对近远混合场特性与路径幅度空间非平稳特性共存条件下的信道估计研究仍相对有限。

文献[6]基于 100 GHz 和 132 GHz 室内均匀线阵测量, 采用 Beta 边缘分布与秩匹配方法生成具有空间依赖的幅度衰减因子 (AAF), 描述路径沿阵列的连续幅度变化。文献[7-8]利用近场球面波响应和远场平面波响应构建近远混合场信道, 但每条路径使用全阵列共享的幅度系数, 不能描述同一路径幅度随阵元位置的变化, 因此在路径幅度维度上采用的是空间平稳假设。基于此, 本文将文献[6]的 AAF 生成方法引入文献[7-8]所采用的混合场框架, 并依据二维 AoSA 阵元的物理位置构造空间依赖关系, 从而构建了同时包含近远混合场特性与路径幅度空间变化的 AAF 型空间非平稳混合场信道, 为后续信道估计研究提供对象。

目前, 针对非 AAF 型混合场信道的估计研究主要包括数据驱动方法^[9]和模型驱动方法^[2-4, 7-8, 10-12]。其中, 文献[7]提出的 FPN-OAMP 将线性估计与可学习的非线性估计相结合; 文献[8]提出的 PR-DEN 基于 PR 算子分裂构建迭代估计框架, 并采用残差卷积网络实现非线性映射。然而, 在混合场信道中引入 AAF 后, 信道既具有近远混合场特性, 又呈现路径幅度随阵元位置变化的空间非平稳特性。其中, 各路径的空间幅度变化包括相邻阵元之间的较小局部变化和跨越多个阵元的较大范围变化; 不同阵元位置的路径响应强弱也存在差异; 在利用卷积网络提取这类信道特征时, 不同特征通道中还可能包含重复信息。PR-DEN 原有非线性映射采用常规残差网络, 难以同时处理上述特征。基于上述考虑, 本文提出门控通道交互模块、

多尺度特征融合模块和空间能量引导注意力机制模块, 创新性地构建 GMSA 网络, 代替 PR-DEN 原有的非线性映射部分, 进而提出 PR-DEN-GMSA 算法, 实现对 AAF 型空间非平稳混合场信道的估计。本文的主要贡献如下:

1) 针对文献[7-8]存在的局限, 本文引入文献[6]提出的 AAF 统计生成方法, 并结合二维 AoSA 阵列阵元间的物理距离, 构建幅度权重的空间依赖关系, 由此建立 AAF 型空间非平稳混合场信道模型。

2) 针对 AAF 型信道特征提取过程中不同特征通道承载的信息存在差异和冗余的问题, 提出门控通道交互模块 GCIU, 通过数据自适应门控机制调节特征通道间的信息交互, 增强有效特征并抑制冗余响应; 针对 AAF 路径幅度在不同空间范围内呈现不同变化特征的特点, 构建多尺度特征融合模块 MRFU, 通过并行多尺度特征提取与融合, 提取不同空间尺度下的路径幅度变化特征; 针对 AAF 使不同阵元位置的路径响应强弱不同这一特点, 构建空间能量引导注意力模块 SEGA, 根据中间特征的空间能量分布自适应调整不同位置的特征响应权重。三个模块分别从特征交互、多尺度融合和空间加权三个方面处理信道特征, 协同提高 AAF 型空间非平稳信道的估计精度。

3) 提出 PR-DEN-GMSA 模型驱动信道估计算法。该算法以 PR 算子分裂与 Halpern 更新构成的有限迭代模型驱动框架为基础, 以 GMSA 网络替换 PR-DEN 原有的非线性映射, 并利用 LS 估计结果初始化信道及对偶状态。通过线性估计、GMSA 非线性映射与对偶状态更新的交替迭代, 实现空间非平稳混合场信道的恢复。

1 系统模型

图 1 所示的上行链路采用 AoSA 架构。基站由 S 个均匀平面子阵组成, 共含 N 根天线, 服务 K 个单天线用户。每个子阵连接一条射频链, 射频链数 $N_{\text{RF}} = S$, 且 $K \leq S$ 。子阵按 $S_x \times S_y$ 排列, 每个子阵含 $N_x \times N_y$ 个阵元。

子阵索引 (s_x, s_y) 及子阵内索引 (u, v) 均从 0 开始, 取值范围分别由 S_x 、 S_y 、 N_x 和 N_y 确定。子阵及子阵内阵元分别按列优先编号, 全阵信道按子阵顺序排列, 第 n 个阵元的物理坐标 $\mathbf{p}_n$ 为:




图1 基于PR-DEN-GMSA的THz UM-MIMO信道估计系统

$$\mathbf{p}_n = (s_x \Delta_x + u d_x, s_y \Delta_y + v d_y, 0) \quad (1)$$

其中, Δ_x 、 Δ_y 为相邻子阵起始阵元间距, d_x 、 d_y 为子阵内阵元间距, 单位均为 m。 D_{ij} 为阵元 $\mathbf{p}_i$ 与 $\mathbf{p}_j$ 之间的欧氏距离, 孔径 D 为其最大值。载波波长 λ_c 为光速与载波频率 f_c 之比, 瑞利距离为:

$$D_{\text{Rayleigh}} = \frac{2D^2}{\lambda_c} \quad (2)$$

基站与用户之间的信道由 L 条路径构成, 第 1 条为视距 (LoS) 路径, 其余为非视距 (NLoS) 路径。第 l 条路径的阵列响应 $\mathbf{a}(\phi_l, \theta_l, r_l)$ 采用文献[7]的混合场模型: 当基站与用户之间的路径距离大于瑞利距离时 r_l 采用远场平面波响应, 否则采用近场球面波响应。 ϕ_l 和 θ_l 分别为方位角和相对 z 轴的仰角。

为描述沿阵列连续变化的路径幅度, 引入 AAF 向量 $\mathbf{b}_l$, 其分量 $b_{l,n}$ 取值为 $[0, 1]$, 越小表示衰减越强。 LoS 路径的 AAF 为全 1 向量, NLoS 路径的 AAF 按文献[6]的 Beta 边缘分布与秩匹配方法生成, 模型如图 2 所示。

Beta 分布的形状参数为 p 、 q , 相应统计参数

列于表 1。为在二维 AoSA 架构中生成具有空间相关性的 AAF, 本文根据阵元间的实际欧氏距离构造秩匹配前相关高斯向量的协方差矩阵。令 d_{corr} 为无量纲相关衰减参数, δ_{ref} 为参考阵元间距, 空间衰减率 $\kappa = d_{\text{corr}}/\delta_{\text{ref}}$, 单位为 m^{-1} 。相关高斯向量的协方差矩阵 Σ 满足:

$$[\Sigma]_{ij} = \exp(-\kappa D_{ij}) \quad (3)$$

由式(3)可知, 阵元 $\mathbf{p}_i$ 与 $\mathbf{p}_j$ 对应相关高斯变量的理论相关系数为 $\rho_{\text{th}}(D_{ij}) = \exp[-(d_{\text{corr}}/\delta_{\text{ref}})D_{ij}]$, 由于 $d_{\text{corr}} > 0$ 且 $\delta_{\text{ref}} > 0$, 理论相关系数随阵元距离增加而逐渐减小并趋近于 0。随后, 对协方差矩阵进行 Cholesky 分解, 生成具有上述空间相关结构的高斯向量, 再通过秩匹配得到 AAF^[6]。

将 AAF 与混合场阵列响应相结合, 天线域复信道 $\mathbf{h}_a$ 表示为:

$$\mathbf{h}_a = \sum_{l=1}^L \beta_l (\mathbf{b}_l \odot \mathbf{a}(\phi_l, \theta_l, r_l)) e^{-j2\pi f_c \tau_l} \quad (4)$$

其中, β_l 与 τ_l 分别为第 l 条路径的增益与时延, $\odot$ 表示逐元素乘法, j 为虚数单位。

各用户发送正交导频, 基站通过导频相关分离




图2 AAF型空间非平稳混合场信道模型

用户。以下考虑任一用户，记 $\mathbf{h}$ 为分子阵角域信道， $\mathbf{U}$ 为 $N \times N$ 的分子阵酉 DFT 矩阵，则有：

$$\mathbf{h}_a = \mathbf{U}\mathbf{h} \quad (5)$$

第 t 个导频时隙的模拟合并矩阵 $\mathbf{W}_{\text{RF},t}$ 为 $N \times S$ 维块对角矩阵，各子阵独立生成等概率 ± 1 权重，不同时隙独立重采样。全部时隙矩阵拼接后整体归一化，使 Frobenius 范数平方为 N 。数字合并为单位阵，总合并矩阵 $\mathbf{W}_t = \mathbf{W}_{\text{RF},t}$ 。

导频符号 s_t 取 1， $\mathbf{n}_t$ 为 N 维天线域复高斯噪声，上标 H 表示共轭转置。单时隙观测为：

$$\mathbf{y}_t = \mathbf{W}_t^{\text{H}} \mathbf{U} \mathbf{h} s_t + \mathbf{W}_t^{\text{H}} \mathbf{n}_t \quad (6)$$

在信道相干时间内，各时隙的不同合并权重提供多组线性投影。将 P 个时隙的 S 路输出堆叠，令 $\mathbf{M} = \mathbf{P}\mathbf{S}$ ， $\mathbf{B}$ 为 $s_t \mathbf{W}_t^{\text{H}}$ 按时隙堆叠形成的 $M \times N$ 矩阵，按照 $\mathbf{A} = \mathbf{B}\mathbf{U}$ ，则有：

$$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{n} \quad (7)$$

其中， $\mathbf{y}$ 为 M 维复观测， $\mathbf{A}$ 为 $M \times N$ 维观测矩阵， $\mathbf{n}$ 为合并后的噪声。本文利用多时隙观测、角域结构及学习先验估计 $\mathbf{h}$ ，再由式(5)恢复阵元响应。

噪声在天线域按时隙独立生成，经模拟合并形成观测噪声，估计时未显式白化。网络将向量实部、虚部上下拼接，并使用相应的实数块矩阵，维度见表 1。8 个输入通道依次对应 4 个子阵的实部与虚部，每个通道的二维位置对应子阵角域网格。

2 基于 PR-DEN-GMSA 的信道估计

本文沿用 PR-DEN^[8] 的正则化估计框架，以 LS 结果初始化，并通过 GMSA 实现信道先验对应的非线性修正。LS 初值统一写为伪逆形式：

$$\mathbf{h}^{(0)} = \mathbf{A}^\dagger \mathbf{y} \quad (8)$$

其中， $\mathbf{A}^\dagger$ 为 Moore - Penrose 伪逆，由奇异值分解计算，截断容差见表 2。该表达适用于一般观测矩阵；本文实验中 $M < N$ ，取其中的最小范数 LS 解。

2.1 GMSA 整体网络结构

GMSA 的整体结构如图 3 所示。首先，将输入信道向量 $\mathbf{x}_{\text{in}}$ 重排为二维特征图，经 3×3 卷积扩展至 64 通道，得到初始特征 $\mathbf{x}_0$ 。随后，4 层 GCIU 依次提取特征 $\mathbf{x}_1$ 、 $\mathbf{x}_2$ 、 $\mathbf{x}_3$ 和 $\mathbf{x}_4$ ；SEGA 调节最深层特征的响应，得到 $\mathbf{x}_{\text{att}}$ 。MRFU 汇聚初始特征、前三层 GCIU 特征与 SEGA 输出，最后经 1×1 卷积得到输出 $\mathbf{x}_{\text{out}}$ 。下面分别介绍本文提出的 GCIU、

MRFU、SEGA 模块。




图3 GMSA 整体网络结构

2.2 GCIU 门控通道交互模块

传统残差块的卷积参数在训练完成后保持固定，虽然输出特征会随输入变化，但缺少根据当前输入自适应调节信息传递的机制。对于 AAF 型空间非平稳混合场信道，近远混合场特性与路径幅度空间非平稳特性共同反映在网络特征中，不同特征通道承载的信息存在差异，并可能包含冗余响应。为此，本文提出 GCIU，利用乘性门控自适应调节不同位置和特征通道的信息传递，并通过深度卷积提取局部空间特征、逐点卷积实现通道交互，其结构如图 4 所示。

设输入、输出特征分别为 $\mathbf{X}$ 、 $\mathbf{Y}$ ，通道数为 C 。LN($\cdot$) 表示层归一化，Linear($\cdot$) 表示线性映射。输入经层归一化和线性映射分为三个分支：

$$[\mathbf{G}, \mathbf{I}, \mathbf{C}] = \text{Linear}(\text{LN}(\mathbf{X})) \quad (9)$$

其中， $\mathbf{G}$ 为门控分支， $\mathbf{I}$ 为信息分支， $\mathbf{C}$ 为卷积分支。卷积分支经深度卷积与逐点卷积处理后，与信息分支拼接，再与激活后的门控分支逐元素相乘：

$$\mathbf{Z} = \text{GELU}(\mathbf{G}) \odot [\mathbf{I}; \text{PWConv}(\text{DWConv}(\mathbf{C}))] \quad (10)$$

其中，GELU($\cdot$) 为高斯误差线性单元，DWConv($\cdot$) 和 PWConv($\cdot$) 分别为深度卷积和逐点卷积， $[\cdot; \cdot]$ 表示通道拼接。为稳定深层特征传递，输出映射后加入层归一化、可学习层缩放与随机深度正则化，形成残差输出：

$$\mathbf{Y} = \mathbf{X} + \text{DropPath}(\gamma \odot \text{LN}(\text{Linear}(\mathbf{Z}))) \quad (11)$$

其中， γ 为可学习残差缩放向量，DropPath($\cdot$) 表示随机深度正则化。

4 层 GCIU 的 DropPath 概率依次为 0、0.0333、0.0667 和 0.1。训练时，每次调用重新采样掩码，MRFU 及能量编码器中的批归一化统计同步更新；推理时关闭 DropPath 并采用保存的统计量。训练前向迭代关闭梯度记录，但保持训练模式。

2.3 MRFU 多尺度特征融合模块

AAF 空间相关性会使信道中各路径的幅度变




图4 GCIU网络结构

化既包含相邻阵元之间的局部变化,也包含跨越多个阵元的较大范围变化,单一尺度的卷积结构难以同时提取不同空间范围内的特征。为此,本文设计MRFU,汇聚初始特征、不同深度GCIU的输出以及经SEGA增强的深层特征,并采用不同空洞率的并行卷积分支扩大感受野,实现局部特征与较大范围特征的融合,其结构如图5所示。

MRFU汇聚不同深度的特征,并利用不同空洞率覆盖局部与较大邻域,以适应AAF引起的非均匀结构,结构如图5所示。

MRFU将初始特征 x_0 、前三层GCIU特征 x_1 、 x_2 、 x_3 与SEGA输出 x_{att} 在通道维拼接,经 1×1 卷积压缩:

$$X_f = \delta \left(\text{BN} \left(f_{1 \times 1} \left([x_0; x_1; x_2; x_3; x_{att}] \right) \right) \right) \quad (12)$$

式(12)~式(14)中,卷积映射 f 的下标为卷积核

尺寸,上标 d 为空洞率;BN($\cdot$)和 $\delta(\cdot)$ 分别表示批归一化与ReLU激活。该步骤将5C通道压缩为C通道,再通过三条不同空洞率的 3×3 卷积分支提取空间特征:

$$\begin{aligned} S_1 &= \delta \left(f_{3 \times 3}^{d=1} (X_f) \right), S_2 = \delta \left(f_{3 \times 3}^{d=2} (X_f) \right), \\ S_3 &= \delta \left(f_{3 \times 3}^{d=4} (X_f) \right) \end{aligned} \quad (13)$$

三条分支的空洞率分别为1、2和4,对应不同感受野。

三路特征在通道维拼接后,经 1×1 卷积再次聚合:

$$F = \text{BN} \left(f_{1 \times 1} \left([S_1; S_2; S_3] \right) \right) \quad (14)$$

最后,MRFU采用可学习门控残差连接输出融合特征:

$$Y = X_f + \beta \cdot \delta(F) \quad (15)$$

其中, β 为可学习门控参数,用于调节融合分支对主干特征的贡献。

2.4 SEGA空间能量引导注意力模块

引入AAF后,同一路径的响应幅度随阵元位置变化,并在网络中间特征中表现为不同空间位置的响应强度变化。为此,本文设计SEGA,在多尺度空间注意力的基础上引入特征能量分支,并结合通道注意力调节不同空间位置和特征通道的响应,其结构如图6所示。

空间注意力 M_s 沿用文献[13]:沿高度和宽度聚合特征,将通道分为四组,经核大小为3、5、7、9的一维深度卷积、组归一化与Sigmoid生成权重。

对于输入特征 X ,沿C个通道计算各空间位置的平方均值:




图5 MRFU网络结构

$$\mathbf{E} = \frac{1}{C} \sum_{c=1}^C \mathbf{X}_c^2 \quad (16)$$

其中, $\mathbf{X}_c$ 为第 c 个通道, $\mathbf{E}$ 表示特征响应的相对强弱。由 $\mathbf{E}$ 生成能量权重 $\mathbf{M}_e$, 调制空间注意力输出:

$$\mathbf{X}_{out} = \mathbf{X} \odot \mathbf{M}_s \odot (1 + \lambda(2\mathbf{M}_e - 1)) \quad (17)$$

其中, λ 为可学习标量经 Sigmoid 映射至 (0,1) 得到的调制系数。归一化能量 $\bar{\mathbf{E}}$ 与权重 $\mathbf{M}_e$ 计算如下:

$$\bar{\mathbf{E}} = \frac{\mathbf{E}}{\max(\max(\mathbf{E}), \varepsilon_E)} \quad (18)$$

$$\mathbf{M}_e = \text{Sigmoid}(\text{Conv}(\bar{\mathbf{E}})) \quad (19)$$

其中, ε_E 为分母保护常数, 取值见表 2; 最大值逐样本在空间维度计算, 全零特征的归一化能量为零。Conv($\cdot$) 依次包括无偏置 3×3 卷积、批归一化、ReLU 和无偏置 1×1 卷积。




图 6 SEGA 网络结构

2.5 PR-DEN-GMSA 信道估计算法

PR-DEN-GMSA 保留 PR-DEN 的线性子问题与 Halpern 更新结构^[8,14], 以所提 GMSA 替换非线性映射, 并在迭代间共享网络参数。

记 θ 为网络参数, k 为从 0 开始的迭代索引, ρ 为分裂参数。信道与对偶状态均以最小范数 LS 解初始化, 相关配置见表 2。

先以对偶状态 $\boldsymbol{\eta}^{(k)}$ 为输入, 结合观测矩阵 $\mathbf{A}$ 与导频观测 $\mathbf{y}$ 求解线性子问题^[8]:

$$\mathbf{q}^{(k+1)} = (\mathbf{A}^T \mathbf{A} + \rho \mathbf{I}_{2N})^{-1} (\mathbf{A}^T \mathbf{y} + \boldsymbol{\eta}^{(k)}) \quad (20)$$

其中, $\mathbf{q}^{(k+1)}$ 为本次线性估计, $\mathbf{I}_{2N}$ 为与实数信道维度一致的单位矩阵。

随后, 将 PR 反射项输入 GMSA, 实现可学习的非线性修正^[8]:

$$\mathbf{h}^{(k+1)} = \mathbf{R}_\theta(2\mathbf{q}^{(k+1)} - \frac{1}{\rho} \boldsymbol{\eta}^{(k)}) \quad (21)$$

其中, $\mathbf{h}^{(k+1)}$ 为当前信道估计, $\mathbf{R}_\theta(\cdot)$ 为 GMSA 映射; 式(21)括号内为 PR 反射项。

令 $\mathbf{Q}(\boldsymbol{\eta})$ 、 $\mathbf{H}_\theta(\boldsymbol{\eta})$ 分别表示式(20)、式(21)在状态 $\boldsymbol{\eta}$ 处的结果, 基础映射为:

$$\mathbf{F}_\theta(\boldsymbol{\eta}; \mathbf{A}\mathbf{y}) = \boldsymbol{\eta} + 2\rho[\mathbf{H}_\theta(\boldsymbol{\eta}) - \mathbf{Q}(\boldsymbol{\eta})] \quad (22)$$

固定观测、网络参数及归一化统计量, 关闭 DropPath 后, 基础映射不随迭代次数变化。Halpern 策略采用以下更新^[14]:

$$\boldsymbol{\eta}^{(k+1)} = \frac{1}{k+2} \boldsymbol{\eta}^{(0)} + \frac{k+1}{k+2} [\boldsymbol{\eta}^{(k)} + 2\rho(\mathbf{h}^{(k+1)} - \mathbf{q}^{(k+1)})] \quad (23)$$

PR 分裂与 Halpern 迭代的理论分析要求相应算子的单调性、基础映射的非扩张性及不动点存在^[8,14]。本文未对 GMSA 施加相应算子约束, 因此通过 NMSE、基础映射残差及终止统计评价所测场景中的经验迭代效果。本文采用 PR/Halpern 更新结构进行有限次前向估计。

为评价连续两次迭代之间信道估计的变化程度, 本文采用相邻两次信道估计的最大相对差异作为迭代变化评价指标:

$$\mathcal{J}^{(k+1)} = \max_{1 \leq b \leq B} \|\hat{\mathbf{h}}_b^{(k+1)} - \hat{\mathbf{h}}_b^{(k)}\|_2 \quad (24)$$

其中, B 当前测试批次的样本数, b 为批内样本索引。当 $\mathcal{J}^{(k+1)}$ 不大于表 2 所列阈值或达到最大迭代次数时, 返回当前估计; 测试阶段每完成一次式(22)所示基础映射的计算记为一次迭代, LS 初始化不计入迭代次数。

训练采用线性域 NMSE 损失。记 $\hat{\mathbf{h}}_b$ 、 $\mathbf{h}_b$ 为第 b 个样本的估计与真实信道, 则逐样本损失为:

$$\ell_b = \frac{\|\hat{\mathbf{h}}_b - \mathbf{h}_b\|_2^2}{\max(\|\mathbf{h}_b\|_2^2, \varepsilon_h)} \quad (25)$$

其中, $\varepsilon_h > 0$ 为分母保护常数, 批损失取逐样本损失的均值。

反向传播采用单步截断梯度^[15]: 先关闭梯度记录完成前向迭代, 再将停止状态视为常量, 执行一次 PR 更新并计算损失, 仅通过该次更新反向传播。

为评价当前状态与基础映射不动点的接近程度, 采用当前状态经过基础映射前后的相对偏差, 定义状态 $\boldsymbol{\eta}^{(k)}$ 处的逐样本相对残差:

$$r_k = \frac{\|F_\theta(\eta^{(k)}) - \eta^{(k)}\|_2}{\max(\|\eta^{(k)}\|_2, \varepsilon_r)} \quad (26)$$

其中, $\varepsilon_r > 0$ 为数值保护常数。最终残差中位数用于迭代分析。推理与训练步骤分别见算法 1 和算法 2。

算法 1 PR-DEN-GMSA 推理流程

输入: 观测 y 、矩阵 A 、网络参数 θ 及表 2 配置。

1) 将观测实数化, 按式(8)初始化信道与对偶状态。

2) 切换至评估模式, 预计算线性子问题的固定矩阵。

3) 按式(20)、式(21)计算线性解与当前信道估计, 并计算式(24)的停止量。

4) 若达到停止阈值或迭代上限, 返回当前估计; 否则按式(23)更新状态, 返回步骤 3)。

5) 还原复数角域信道, 由式(5)恢复天线域信道。

算法 2 PR-DEN-GMSA 训练流程

输入: 训练集、验证集及表 2 中的优化配置。

1) 初始化共享网络参数, 每个周期打乱样本并分批。

2) 保持训练模式并关闭梯度记录, 完成 LS 初始化与前向迭代; DropPath 和批归一化按第 2.2 节处理。

3) 固定停止状态, 再执行一次 PR 更新, 由式(25)的批均值计算损失并反向传播。

4) 用 Adam 更新参数, 按表 2 调整学习率, 以验证集 NMSE 选择模型。

5) 冻结参数并切换至评估模式, 统计测试精度、终止状态及运行成本。

3 仿真实验与结果分析

3.1 仿真场景与参数设置

本文依据文献[7-8]的混合场信道模型, 结合文献[6]的 AAF 生成方法构建仿真数据集。AAF 的边缘分布及相关参数取自文献[6]在 100 GHz 和 132 GHz 室内均匀线阵场景下的测量结果。本文将该生成方法应用于 300 GHz 二维 AoSA 混合场, 以实际阵元位置作为 AAF 的空间采样点, 并依据阵元间的欧氏距离构造秩匹配前相关高斯变量的协方差矩阵。其中, 子阵内采样间隔为相邻阵元间距 0.2 mm; NLoS 散射体距离在 10~25 m 内均匀采样, 具体仿真参数见表 1。

表 1 信道仿真参数

参数名称	参数取值	参数名称	参数取值
载波频率/GHz; 波长/m	300; 0.001	LoS 路径时延/ns	100
基站总天线数	1024	NLoS 路径时延/ns	$\tau_l \sim \mathcal{U}(100, 110)$
子阵列数及排列	4 (2×2)	分子吸收系数/m ⁻¹	0.0033
单个子阵阵元数及排列	256 (16×16)	折射率	2.24-j0.025
子阵内相邻阵元间距/m	0.0002	粗糙度系数/m	8.8×10^{-5}
子阵列间距/起始阵元间距/m	0.056 / 0.059	形状参数 p 的对数均值	$\mu_p = 0.37$
阵列 x/y 跨度; 孔径/m	0.062 / 0.062; 约 0.08768	形状参数 p 的对数标准差	$\sigma_p = 0.58$
导频长度	128	形状参数 q 的对数线性拟合系数	$\zeta = 0.48$
欠采样率	0.5	形状参数 q 的对数线性拟合常数	$\zeta = 1.03$
路径方位角	$\phi_l \sim \mathcal{U}(-\pi/2, \pi/2)$	AAF 截断指数分布率参数	40.61
路径仰角	$\theta_l \sim \mathcal{U}(-\pi, \pi)$	无量纲 AAF 相关衰减参数	[0.018, 0.12]
入射角	$\varphi_{i,l} \sim \mathcal{U}(0, \pi/2)$	AAF 参考间距/m	132 GHz 半波长 (约 0.001136)
总路径数	5	p 截断范围; q 下限	[0.2, 5.0]; 0.001
瑞利距离/m	15.376	复观测/信道维度	512 / 1024
LoS 路径长度/m	30	实数观测矩阵维度	1024×2048
NLoS 散射体距离/m	$r_l \sim \mathcal{U}(10, 25)$	网络输入维度	批量大小×8×16×16

为表征生成数据的 AAF 统计特性,按照表 1 的参数分布独立生成 100 组 AAF。对于每一固定阵元对,利用其在不同 AAF 实现中的幅度值计算 Pearson 相关系数,再按照阵元对的物理距离分组并取组内平均。生成 AAF 的均值和标准差分别为 0.5455 和 0.2746;当子阵内阵元平均距离由 0.320 mm 增至 3.271 mm 时,平均相关系数由 0.9463 降至 0.6492,体现了子阵内相关性随距离增加而减弱的特征。此外,本文独立生成 1000 组秩匹配前相关高斯向量,并将不同阵元距离下的经验相关系数与式 (3) 的理论相关系数进行对照,二者的变化趋势及数值基本一致,说明二维 AoSA 空间相关性的生成过程符合预设模型。

实验采用 NVIDIA GeForce RTX 3080、PyTorch 2.2.2+cu121 及 FP32 精度,分别训练低、高信噪比 (signal-to-noise ratio, SNR) 模型,训练与验证样本的 SNR 在对应区间内随机抽取,配置见表 2。

训练、验证和测试集独立生成;固定数据划分,以三次独立随机初始化训练评价性能波动。0、5、10 dB 测试使用低 SNR 模型,15、20 dB 测试使用高 SNR 模型。

FPN-OAMP、PR-DEN 与 PR-DEN-GMSA 在相同 AAF 分布下重新训练,共用数据划分、观测矩阵、SNR 分组及训练预算,并在相同 5000 个测试信道与噪声样本上比较;迭代上限均为 15,前向停止阈值均为 0.01,其中,PR-DEN-GMSA 在各测试 SNR 下的平均实际迭代次数均为 15 次。正交匹配追踪 (OMP) 使用角域观测矩阵作为稀疏字典,

在原子匹配过程中,对字典各列进行二范数归一化并加入 10^{-12} 的数值保护,LS 投影使用原始字典列,原子数上限与残差阈值见表 2。正交近似消息传递 (OAMP) 采用线性最小均方误差估计和软阈值去噪,迭代次数为 15 次;在每个测试 SNR 下,线性估计矩阵中的噪声方差取相应测试样本噪声方差的均值。各算法共用信道、噪声及观测矩阵。

3.2 评估标准

为了客观评估本文提出的 PR-DEN-GMSA 与其他算法的性能,采用归一化均方误差 (NMSE, normalized mean square error) 作为评价指标进行分析。NMSE 表达式为:

$$\text{NMSE} = 10 \cdot \lg \left\{ \mathbb{E} \left[\frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \right] \right\} \quad (27)$$

其中, $\hat{\mathbf{H}}$ 和 $\mathbf{H}$ 分别表示预测信道和真实信道。

针对空间非平稳性场景下的鲁棒性测试,本文设计 NMSE 退化量作为评价指标。该指标以表 1 所构建的信道条件为基准,分别计算基准信道下的 NMSE 与信道条件改变后的 NMSE,并将后者相对前者的增量定义为 NMSE 退化量:

$$\Delta \text{NMSE} = \text{NMSE}_{\text{changed}} - \text{NMSE}_{\text{Table1}} \quad (28)$$

3.3 仿真结果与性能分析

3.3.1 GCIU 门控结构及层数分析

在无融合及注意力模块时,比较 3、4、5 层 GCIU 与 4 层残差结构,结果见图 7。4 层 GCIU 的五点平均 NMSE 比 4 层残差结构低 0.25 dB;增加至 5 层后收益较小,参数量则继续增加,因此采用 4

表 2

模型训练参数

参数名称	参数取值	参数名称	参数取值
训练集样本	80000	训练批量大小	128
测试集样本	5000	测试批量大小	64
验证集样本	5000	Adam 权重衰减	0
低 SNR/dB	0-10	最大迭代次数; 前向停止阈值	15; 0.01
高 SNR/dB	10-20	相对残差评价阈值	0.01
周期数	150	PR 分裂参数 ρ	1
学习率	0.001	LS 伪逆相对截断容差	10^{-15}
学习率衰退周期	30	能量归一化保护常数 ϵ_E	10^{-8}
学习率衰减的乘法因子	0.5	能量调制原始参数初值	0.5
优化器	Adam	OMP 原子数上限; 残差阈值	40; 10^{-6}

层 GCIU。




图7 不同GCIU结构的NMSE性能

由表3可知，4层GCIU相对4层残差网络的参数量减少约72.5%，AAF场景下的五点平均NMSE改善0.246 dB，表明GCIU能够以较小的参数规模取得更低的信道估计误差。

3.3.2 基于不同融合方式的性能对比

在4层GCIU基础上，比较无融合、普通融合、ASPP^[16]和MRFU，结果见图8。MRFU相对三组对照的五点平均NMSE改善分别为0.18 dB、0.21 dB和0.24 dB；0 dB时相对无融合的改善为0.39 dB。

表3的训练结果显示，加入MRFU后AAF场景平均NMSE由-16.626 dB降至-16.828 dB。相对ASPP，MRFU将参数量由288776降至272649，减少约5.6%，同时取得更低NMSE，验证了该融合结构的有效性。




图8 不同融合方式的NMSE性能

3.3.3 基于不同注意力模块的性能对比

在相同GCIU与MRFU主干下，设置无注意力、SE^[17]、ECA^[18]、CBAM^[19]、SCSA^[13]、EMA^[20]及SEGA对照，结果见图9。SEGA相对上述六组对照的五点平均NMSE改善依次为0.27 dB、0.26 dB、0.24 dB、0.16 dB、0.20 dB和0.17 dB。

为验证特征能量分支的作用，实验比较采用SCSA与SEGA的网络。由表3可知，与GCIU+MRFU+SCSA相比，GCIU+MRFU+SEGA的参数量减少127，平稳场景和AAF场景下的五点平均NMSE分别改善0.027 dB和0.170 dB，且AAF场景下的改善幅度更大，表明所引入的特征能量分支能够在本文AAF信道条件下进一步降低估计误差。

3.3.4 不同算法性能对比

图10比较LS、OMP、OAMP、FPN-OAMP^[7]、PR-DEN与PR-DEN-GMSA。所提算法相对五组基线的五点平均NMSE改善依次为15.01 dB、10.87 dB、9.59 dB、0.74 dB和0.696 dB。其中，在相同

表3 结构复杂度与独立训练对比结果

网络结构	参数量	单次网络调用/GFLOPs	平稳NMSE/dB	AAF非平稳 NMSE/dB
4层残差网络	468616	0.1557	-17.042±0.021	-16.380±0.019
4层GCIU	128776	0.0478	-17.220±0.015	-16.626±0.035
GCIU+MRFU	272649	0.1212	-17.430±0.047	-16.828±0.026
GCIU+MRFU+SCSA	273673	0.1213	-17.563±0.034	-16.906±0.024
GCIU+MRFU+SEGA	273546	0.1213	-17.590±0.028	-17.076±0.030
匹配参数残差网络	276376	约0.0810	仅AAF对照	-16.053±0.027
匹配FLOPs残差网络	377336	约0.1195	仅AAF对照	-16.260±0.025

NMSE为三次独立训练的五个SNR点平均值的均值±样本标准差；规模匹配网络仅设置AAF对照。运算量为单次网络调用。




图9 不同注意力模块的NMSE性能

AAF信道数据和训练预算下，三次独立训练中PR-DEN与PR-DEN-GMSA的五点平均NMSE分别为 -16.380 ± 0.019 dB和 -17.076 ± 0.030 dB，平均改善为0.696 dB。

平稳场景将各路径的AAF设为全1向量，其余远近混合场参数、阵列结构、导频、归一化方式及训练预算均保持一致；各网络分别在平稳信道和AAF非平稳信道上进行训练与测试。由表3可知，与PR-DEN相比，PR-DEN-GMSA在平稳场景和AAF非平稳场景下的五点平均NMSE分别改善0.548 dB和0.696 dB，AAF场景下的改善幅度更大。结合逐模块消融结果可知，GCIU、MRFU和SEGA的组合能够进一步降低本文AAF非平稳信道条件下的估计误差。

为排除模型规模差异的影响，实验选取宽度分别为46和56的残差网络作为对照，使其参数量与运算量分别与所提方法相匹配，对应偏差分别为1.03%和1.48%。与两组对照相比，所提GMSA分别取得1.023 dB和0.816 dB的性能改善，表明在规模接近时其结构优势依然成立。

3.3.5 迭代过程与基础映射残差分析

图11和图12给出了5 dB和15 dB下的NMSE变化。5 dB时，所提算法前两次迭代的NMSE高于PR-DEN，随后取得更低误差；两种SNR下的后续迭代均逐渐趋稳。

为考察迭代次数对基础映射残差的影响，在保持已训练模型参数不变的条件下，将测试阶段的状态迭代延长至30、50和100次，并在5 dB和15 dB条件下分别对5000个测试样本统计基础映射相对




图10 不同信噪比水平下各算法的NMSE性能




图11 NMSE随迭代次数的变化(SNR=5 dB)




图12 NMSE随迭代次数的变化(SNR=15 dB)

残差及不同阈值的达标比例，结果见表4。

由表4可知，在15次迭代状态下，PR-DEN-GMSA在5 dB和15 dB条件下的基础映射相对残差中位数分别为0.065568和0.047189。延长迭代后，15 dB条件下的残差中位数持续下降，在100次时

表4 不同迭代次数下的基础映射相对残差及样本达标比例

SNR/ dB	迭代 次数	残差中位数	残差< 0.1/%	残差< 0.05/%	残差< 0.01/%
5	15	0.065568	100.00	0.00	0.00
5	30	0.033824	100.00	99.94	0.00
5	50	0.021637	99.96	99.58	0.00
5	100	0.022793	96.44	89.42	0.00
15	15	0.047189	100.00	100.00	0.00
15	30	0.024105	100.00	100.00	0.00
15	50	0.014577	100.00	100.00	0.00
15	100	0.007395	100.00	99.90	98.56

降至 0.007395，且 98.56% 的测试样本残差低于 0.01；5 dB 条件下的残差中位数在 50 次时降至 0.021637，100 次时仍保持在 0.022793。上述结果表明，增加迭代次数能够进一步减小基础映射相对残差，其中高信噪比条件下的改善更加明显。

3.3.6 鲁棒性测试

本节从空间非平稳程度、主路径数、视距路径阻塞、近远场分布、子阵列间距、子阵内相邻阵元间距、分子吸收系数、视距路径长度以及欠采样率等多个维度，分别设计实验对算法的鲁棒性进行测试。表 5-表 6 和表 12 分别比较三种算法相对于表 1 的信道改变场景的 NMSE 退化量，正值表示退化，负值表示改善。

AAF 相关衰减参数 d_{corr} 的弱组、标准组和强组区间为 [0.005, 0.04]、[0.018, 0.12] 和 [0.05, 0.25]，其余分布参数及路径可见性不变。弱组相关长度较长，强组较短。各测试信道在角域变换前归一化到单位阵元平均功率；噪声按设定 SNR 在天线域生成，再经模拟合并。路径损耗变化与 LoS 移除后仍采用相同归一化与噪声规则。由表 5 可知，弱组下 GMSA 的五点 NMSE 均有改善；强组 NMSE 最大退化量为 0.320 dB，与 PR-DEN 的 0.278 dB 和 FPN-OAMP 的 0.290 dB 相近。这表明所提算法在两组相关长度失配下的误差变化均较小，保持了稳定的估计精度。

模型以 5 条路径训练，用 3~7 条路径测试，结果见图 13。3、4 条路径时平均 NMSE 改善 1.66 dB、0.62 dB，6、7 条路径时的 NMSE 平均退化量分别为 0.75 dB、1.20 dB。这表明所提算法无需重新训练即可适应路径数变化，在路径增加至 7 条时

表5 AAF 相关衰减失配下的 NMSE 退化量

AAF 相关性组别	0 dB	5 dB	10 dB	15 dB	20 dB
弱组/FPN-OAMP	-0.081	-0.120	-0.170	-0.219	-0.316
弱组/PR-DEN	-0.075	-0.117	-0.184	-0.226	-0.317
弱组/PR-DEN-GMSA	-0.075	-0.116	-0.175	-0.204	-0.298
强组/FPN-OAMP	-0.004	0.020	0.076	0.182	0.290
强组/PR-DEN	-0.008	0.016	0.071	0.179	0.278
强组/PR-DEN-GMSA	0.014	0.070	0.146	0.222	0.320

以各算法在同一测试批次的标准组结果为基线，正值表示退化，负值表示 NMSE 改善。

仍将 NMSE 平均退化量控制在 1.20 dB。




图13 不同主路径数下的PR-DEN-GMSA性能

模型在 1 条 LoS 与 4 条 NLoS 路径下训练，测试时移除 LoS 并重新归一化。表 6 中 GMSA 的 NMSE 最大退化量为 2.976 dB，与 PR-DEN 的 2.929 dB 和 FPN-OAMP 的 2.965 dB 相近。这表明视距路径缺失后，所提算法仍可利用剩余 4 条 NLoS 路径的观测恢复信道，误差增幅与两种对照相当。

表6 LoS 移除下的 NMSE 退化量

路径状态	0 dB	5 dB	10 dB	15 dB	20 dB
LoS 移除/FPN-OAMP	0.963	1.357	1.911	2.101	2.965
LoS 移除/PR-DEN	0.924	1.278	1.803	2.115	2.929
LoS 移除/PR-DEN-GMSA	1.079	1.383	1.931	2.255	2.976

以各算法在同一测试批次的 LoS 非阻塞结果为基线。

表 7 中，混合场训练模型在纯近场、纯远场下的 NMSE 平均退化量为 1.794 dB、1.754 dB，NMSE 最大退化量为 2.21 dB、2.17 dB。20 dB 时 NMSE 仍达到 -21.01 dB、-21.06 dB，说明近远场路径组成发生变化后，模型仍能保持有效的信道估

计能力。

表7 PR-DEN-GMSA在不同场景下的NMSE

区域	0 dB	5 dB	10 dB	15 dB	20 dB
近场区域	-8.99	-12.51	-15.53	-18.38	-21.01
远场区域	-9.03	-12.52	-15.61	-18.40	-21.06
混合场区域	-11.20	-14.38	-17.30	-20.12	-22.39

表8中, 相对于训练间距为 $\lambda_c/5$, $\lambda_c/6$ 和 $\lambda_c/8$ 时平均NMSE改善0.138 dB和0.628 dB; $\lambda_c/4$ 时NMSE平均退化量为1.542 dB。这表明所提算法在较紧凑的测试阵列中提升了估计精度。

表8 PR-DEN-GMSA在不同阵元间距下的NMSE

阵元间距	0 dB	5 dB	10 dB	15 dB	20 dB
$\lambda_c/4$	-10.14	-12.77	-14.66	-19.15	-20.96
$\lambda_c/5$	-11.20	-14.38	-17.30	-20.12	-22.39
$\lambda_c/6$	-11.24	-14.49	-17.28	-20.40	-22.67
$\lambda_c/8$	-11.56	-14.93	-17.73	-21.03	-23.28

表9中, 相对于 $56\lambda_c$ 的子阵列间距, $36\lambda_c$ 和 $76\lambda_c$ NMSE平均退化量分别为0.294 dB、0.084 dB, 这表明所提算法对这两种子阵布局变化具有较好的适应性。

表9 PR-DEN-GMSA在不同子阵列间距下的NMSE

子阵列间距	0 dB	5 dB	10 dB	15 dB	20 dB
$36\lambda_c$	-11.17	-14.25	-16.69	-19.85	-21.96
$56\lambda_c$	-11.20	-14.38	-17.30	-20.12	-22.39
$76\lambda_c$	-11.19	-14.36	-17.11	-20.08	-22.23

表10中, 吸收系数在 $0.0023 \sim 0.0053 \text{ m}^{-1}$ 变化时, 相对 0.0033 m^{-1} 基线的最大绝对NMSE差值仅为0.29 dB, 这表明所提算法在固定SNR的归一化信道中对该参数变化保持稳定。

表10 PR-DEN-GMSA在不同分子吸收系数下的NMSE

吸收系数/ m^{-1}	0 dB	5 dB	10 dB	15 dB	20 dB
0.0023	-11.10	-14.33	-17.04	-19.99	-22.16
0.0033	-11.20	-14.38	-17.30	-20.12	-22.39
0.0043	-11.19	-14.46	-17.20	-20.15	-22.31
0.0053	-11.11	-14.32	-17.01	-20.03	-22.22

表11中, LoS距离由30 m变为10 m、50 m时, NMSE平均退化量为0.318 dB、0.098 dB。这表明所提算法在这两种距离失配下基本保持估计精度。

表11 PR-DEN-GMSA在不同LoS路径长度下的NMSE

LoS路径长度/m	0 dB	5 dB	10 dB	15 dB	20 dB
10	-10.93	-14.14	-16.78	-19.91	-22.04
30	-11.20	-14.38	-17.30	-20.12	-22.39
50	-11.13	-14.39	-17.07	-20.07	-22.24

由表12可知, 当欠采样率降至0.375时, 所提算法在0~15 dB的四个信噪比条件下均取得三种算法中最低的绝对NMSE; 在20 dB时, 其NMSE为-20.21 dB, 与FPN-OAMP的-20.24 dB接近。当欠采样率进一步降至0.250时, 所提算法在五个信噪比条件下均取得最低的绝对NMSE, 其相对欠采样率0.500基线的最大NMSE退化量为3.99 dB, 低于PR-DEN的7.32 dB和FPN-OAMP的16.05 dB。上述结果表明, 在本实验设置的严重欠采样条件下, 所提算法能够保持较好的估计精度。

3.3.7 复杂度分析

本文从参数规模、理论算术运算量和实际运行效率三个方面比较各算法的复杂度。参数规模以参数量表示; 理论算术运算量采用FLOPs表示, 其中一次乘加计为2 FLOPs, 分别统计单次网络调用和完成15次迭代所需的运算量; 实际运行效率通过首次估计时延和固定观测矩阵下的后续估计时延衡量, 训练与推理过程中的峰值显存用于反映存储开销。观测矩阵的伪逆和线性子问题矩阵在计时前完成预计算。首次估计时延包括预计算完成后的LS初始化和迭代估计过程; 固定观测矩阵下的后续估计直接复用上述矩阵。当观测矩阵改变时, 需要重新进行矩阵预计算。

由表13可知, 与PR-DEN相比, 所提算法的参数量减少约41.6%, 单次网络调用与完整15次迭代的理论FLOPs分别减少约22.1%和20.5%, 同时取得了更高的信道估计精度。然而, 多分支结构需要分别执行卷积并融合特征, 增加GPU算子调用和中间结果读写; 空洞卷积的间隔采样可能降低访存连续性, 注意力模块的权重计算与特征加权也会

表 12 不同欠采样率下各算法的 NMSE 及退化量

欠采样率/算法	0 dB	5 dB	10 dB	15 dB	20 dB
0.375/ FPN-OAMP	-7.95 (2.21)	-11.18 (2.16)	-14.15 (1.88)	-17.45 (2.30)	-20.24 (2.04)
0.375/ PR-DEN	-8.05 (2.22)	-11.22 (2.24)	-14.02 (2.10)	-17.42 (2.35)	-20.00 (2.20)
0.375/ PR-DEN-GMSA	-8.88 (2.26)	-12.11 (2.24)	-15.04 (2.01)	-17.81 (2.21)	-20.21 (1.96)
0.250/ FPN-OAMP	-7.15 (3.01)	-10.31 (3.03)	-12.92 (3.10)	-7.43 (12.32)	-6.23 (16.05)
0.250 /PR-DEN	-6.50 (3.76)	-9.39 (4.08)	-12.33 (3.79)	-12.86 (6.91)	-14.87 (7.32)
0.250/ PR-DEN-GMSA	-7.44 (3.69)	-10.74 (3.60)	-13.77 (3.29)	-16.26 (3.75)	-18.18 (3.99)

以各算法在同一测试批次的欠采样率 0.500 结果为基线。括号外为绝对 NMSE, 括号内为相对各算法欠采样率 0.500 结果的 NMSE 退化量。

产生额外的中间数据。这些因素是理论 FLOPs 降低而实际运行开销增加的原因。总体来看, 所提算法在估计精度、参数规模和理论算术运算量方面仍具有竞争力, 后续将进一步优化多分支及注意力模块的实现, 以降低实际运行时延和显存开销。

4 结束语

本文面向 AoSA 架构 THz UM-MIMO 系统中混合场传播与 AAF 型空间非平稳特性共存的信道估计问题, 将空间相关 AAF 生成机制引入近远场 NLoS 路径, 构建 AAF 型空间非平稳混合场信道及其观测模型。在此基础上, 构建由 GCIU、MRFU 和 SEGA 组成的 GMSA 网络, 并将其作为非线性映射嵌入基于 PR 算子分裂与 Halpern 更新的模型驱动迭代框架, 提出 PR-DEN-GMSA 信道估计算法。仿真结果表明, 三个模块均能提高信道估计性能, 组合使用可进一步降低恢复误差。与 LS、OMP、OAMP、FPN-OAMP 和 PR-DEN 相比, 所提算法的

五点平均 NMSE 分别改善 15.01 dB、10.87 dB、9.59 dB、0.74 dB 和 0.70 dB, 并在所测试的 AAF 相关程度、路径组成、阵列参数及欠采样条件下保持较好的估计性能。此外, 所提算法相对 PR-DEN 的参数数量减少约 41.6%, 单次网络调用和 15 次迭代累计的理论 FLOPs 分别减少约 22.1% 和 20.5%, 但在当前测试环境下的前向时延与峰值显存更高, 实际运行效率仍有优化空间。未来将进一步优化网络结构与实现方式, 并研究太赫兹宽带信道的频率选择性、波束斜视效应及用户移动条件下空间非平稳信道的时变特征。

于舒娟 (1967-), 女, 江苏南京人, 博士, 南京邮电



表 13 不同算法的复杂度

统计项	FPN-OAMP	PR-DEN	PR-DEN-GMSA
参数量/个	468616	468616	273546
单次网络调用/GFLOPs	0.1557	0.1557	0.1213
单次迭代/GFLOPs	0.1641	0.1683	0.1339
15 次迭代累计/GFLOPs	2.4615	2.5244	2.0080
首次估计时延均值/ms	125.70	149.28	240.29
复用时延中位数/ms	7.08	19.90	50.30
峰值显存/GB (训练/推理)	1.331 / 0.0421	1.348 / 0.0924	1.784 / 0.1868

大学教授，主要研究方向自适应信号处理、深度学习和智能大数据处理。

卢宏宇（2002-），男，山西忻州人，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。

孙洋（2001-），女，内蒙古呼和浩特人，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。

蔡良隆（2001-），男，浙江温州人，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。

管腾飞（2002-），男，安徽省阜阳人，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。

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。

黄丽亚（1972-），女，江苏南京人，博士，南京邮电



大学教授，主要研究方向脑机接口（BCI）、复杂网络、机器学习、认知神经科学。

参考文献：

- [1] Premanand R, Vishwakarma N, Jose J, et al. RIS for 6G THz networks: advances in modeling, hardware, signal processing, and standardization [J]. IEEE Communications Surveys & Tutorials, 2026, 28: 6018-6056.
- [2] Li Y, Madhukumar A S. Hybrid near- and far-field THz UM-MIMO channel estimation: A sparsifying matrix learning-aided Bayesian approach[J]. IEEE Transactions on Wireless Communications, 2025, 24 (3): 1881-1897. DOI: 10.1109/TWC.2024.3514141.
- [3] Li Y, Madhukumar A S, Chu Z, et al. Wideband hybrid-field THz UM-MIMO channel estimation: A dual-attention-aided deep-unfolded Bayesian learning approach[J]. IEEE Transactions on Communications, 2026, 74: 6523-6540. DOI: 10.1109/TCOMM.2026.3675428.
- [4] Li Y, Madhukumar A S, Chu Z, et al. Model-driven deep learning-aided wideband hybrid-field THz UM-MIMO channel estimation[C]//Proceedings of the 2025 IEEE Global Communications Conference. Piscataway: IEEE Press, 2025: 2669-2674.
- [5] Zhang J, Lin J, Tang P, et al. Channel measurement, modeling, and simulation for 6G: a survey and tutorial[EB/OL]. (2023-05-26)[2026-09-14]. <https://arxiv.org/abs/2305.16616>.
- [6] Xu H, Zhang J, Tang P, et al. Empirical study on near-field and spatial non-stationarity modeling for THz XL-MIMO channel in indoor scenario[J]. IEEE Transactions on Wireless Communications, 2026, 25: 4435-4451.
- [7] Yu W, Shen Y, He H, et al. An adaptive and robust deep learning framework for THz ultra-massive MIMO channel estimation[J]. IEEE Journal of Selected Topics in Signal Processing, 2023, 17(4): 761-776. DOI: 10.1109/JSTSP.2023.3282832.
- [8] Yuan D, Wu S, Tang H, et al. A Peaceman-Rachford splitting approach with deep equilibrium network for channel estimation[C]//Proceedings of the 2024 IEEE 24th International Conference on Communication Technology. Piscataway: IEEE Press, 2024: 1525-1533.
- [9] Ranjith S, Jesu Jayarin P, Chandra Sekar A. A multi-fusion integrated end-to-end deep kernel CNN based channel estimation for hybrid range UM-MIMO 6G communication systems[J]. Applied Acoustics, 2023, 210: 109427. DOI: 10.1016/j.apacoust.2023.109427.
- [10] Lu J, Zhang J, Lei H, et al. Adaptive hybrid-field channel estimation in THz XL-MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2025, 74(7): 11557-11562. DOI: 10.1109/TVT.2025.3549507.
- [11] 于舒娟, 赵阳, 魏玉尧, 等. 超大规模太赫兹系统深度学习信道估计算法[J]. 通信学报, 2025, 46(1): 144-156. DOI: 10.11959/j.issn.1000-436x.2025018. Yu S J, Zhao Y, Wei Y Y, et al. Deep learning channel estimation algorithm for

- ultra-massive terahertz systems[J]. Journal on Communications, 2025, 46(1): 144-156.
- [12] 于舒娟, 魏玉尧, 蔡良隆, 等. 基于深度残差定点网络的太赫兹UM-MIMO系统信道估计算法[J]. 通信学报, 2025, 46(5): 77-90.
Yu S J, Wei Y Y, Cai L L, et al. Channel estimation algorithm for THz UM-MIMO systems based on a deep residual fixed-point network[J]. Journal on Communications, 2025, 46(5): 77-90.
- [13] Si Y, Xu H, Zhu X, et al. SCSA: Exploring the synergistic effects between spatial and channel attention[J]. Neurocomputing, 2025, 634: 129866.
- [14] Lieder F. On the convergence rate of the Halpern iteration[J]. Optimization Letters, 2021, 15(2): 405-418.
- [15] Zhao Y, Zheng S, Yuan X. Deep equilibrium models for snapshot compressive imaging[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2023, 37(3): 3642-3650. DOI: 10.1609/aaai.v37i3.25475.
- [16] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European Conference on Computer Vision. Cham: Springer, 2018: 801-818.
- [17] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.
- [18] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 11534-11542.
- [19] Woo S, Park J, Lee J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [20] Ouyang D, He S, Zhang G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//Proceedings of the 2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2023: 1-5.